

Klassifizierung von Vegetation in einer Laserscan-Punktwolke

CORINNE STUCKER¹

Zusammenfassung: Mit der zunehmenden Verwendung der Laserscanning-Technologie wird eine automatisierte Punktwolkenanalyse stets wichtiger, um 3D-Modelle unserer Umwelt zeitnah und zu vertretbaren Kosten zu erstellen. Im Rahmen dieser Arbeit wurde ein Klassifikationsalgorithmus für die automatische Klassifizierung relevanter Objektkategorien in 3D-Punktwolken statischer, terrestrischer Laserscans entwickelt. Die Eignung der ausgewählten Merkmale für die Klassifizierung von terrestrischen Punktwolken sowie der Einfluss der Nachbarschaftsdefinition auf das Klassifizierungsergebnis wurden mit den bestehenden Klassifizierungsmethoden Naive Bayes und Random Forests untersucht. Der Schwerpunkt wurde auf die Detektion von Vegetation sowie auf die Differenzierung zwischen Baumkrone, Baumstamm und Boden gelegt.

1 Einleitung

Die Datenerhebung für die Erstellung von präzisen, dreidimensionalen Landschafts- und Stadtmodellen erfolgt zunehmend mit luftgestütztem oder terrestrischem Laserscanning. Die Technologie des Laserscannings erlaubt, Messgebiete zeitnah, flächendeckend und berührungslos aufzunehmen. Sie ist deshalb prädestiniert, die komplexen Geometrien einer Szene detailgetreu und hochauflösend zu erfassen. Im Bereich der Holz- und Forstwirtschaft bietet sich das terrestrische Laserscanning als zeitsparende und effiziente Erfassungsmethode an, um Baumbestände zu kartieren und forstinventur-relevante Geometrieparameter wie Anzahl und Position von Bäumen, Baumarten, Baumhöhen oder Brusthöhendurchmesser von Baumstämmen zu bestimmen (BENNERT 2013). Aus diesen Parametern können die eigentlichen Zielgrößen von Waldinventuren wie Holzvorrat oder Biomasse abgeleitet werden.

Unabhängig vom Anwendungsbereich müssen Punktwolken in einem ersten Verarbeitungsschritt klassifiziert werden. Ziel der Klassifikation ist es, jeden LiDAR Punkt einer relevanten Objektklasse zuzuweisen. Diese Problemstellung erweist sich als äußerst komplex, nicht zuletzt aufgrund der Vielfalt an Erscheinungsformen, Geometrien und Ausprägungen der verschiedenen Objektklassen. Ferner kommt die Schwierigkeit hinzu, dass einzig auf der Grundlage der Koordinaten eines LiDAR Punktes P dessen Klassenzugehörigkeit nicht bestimmt werden kann. Die Klassifizierung eines Punktes P erfolgt deshalb unter Verwendung sogenannter Merkmale.

2 Verwandte Arbeiten

Die vorliegende Arbeit beruht vorwiegend auf den von CHEHATA et al. (2009) vorgeschlagenen Merkmalen für die Klassifizierung von Punktwolken aus Airborne Daten. CHEHATA et al. (2009) definierten 15 Merkmale basierend auf geometrischen und strukturellen Eigenschaften von

¹ Studentin BSc. Geomatik und Planung, ETH Zürich, Schweiz;
E-Mail: stuckerc@student.ethz.ch

Punktwolken, zwei Merkmale zur Charakterisierung der Anzahl registrierten Echos sowie vier weitere Merkmale in Bezug auf das Echoprofil des Signals. Von den insgesamt 21 Merkmalen wurden 13 Merkmale ausgewählt und für terrestrische Punktwolken adaptiert. Zusätzlich wurde ein von GROSS et al. (2002) eingeführtes Merkmal übernommen, mit welchem die lokalen Oberflächeneigenschaften von Objekten approximiert werden können.

3 Methodik

3.1 Nachbarschaftsdefinition

Jeder LiDAR Punkt P der Punktwolke wird durch die Punkte in seiner lokalen Nachbarschaft N_P charakterisiert. Die Merkmale des Punktes P beschreiben die räumliche Verteilung und Ausrichtung der Punkte innerhalb von N_P sowie die räumliche Beziehung zwischen dem Punkt P und seinen benachbarten Punkten. Da die Merkmalsberechnung den kritischen Schritt im gesamten Klassifikationsprozess darstellt und die Qualität der Klassifizierung direkt von den verwendeten Merkmalen abhängig ist, erweist sich die Definition der Nachbarschaft als fundamentale Grundlage. Bedingt durch die unregelmäßige 3D-Verteilung der Scanpunkte ist es zudem erforderlich, eine flexible und auf die lokale Punktdichte angepasste Nachbarschaftsdefinition einzuführen.

In Anlehnung an GROSS et al. (2007) wurden zwei Nachbarschaftstypen definiert. Die kugelförmige Nachbarschaft eines Punktes P ist durch all diejenigen Punkte gegeben, deren euklidische Raumdistanz zum Punkt P einen festgelegten Grenzwert r unterschreitet. Die zylindrische Nachbarschaft eines Punktes P umfasst sämtliche Punkte, die in der XY-Ebene höchstens im Abstand r vom Punkt P entfernt liegen und eine maximale vertikale Distanz h zum Punkt P aufweisen. Des Weiteren wurde gemäß GUO et al. (2011) die Bedingung eingeführt, dass die 3D-Nachbarschaft eines LiDAR Punktes P aus mindestens fünf Punkten bestehen muss. Befanden sich innerhalb der festgelegten Nachbarschaft N_P für einen Punkt P mit fixem Radius r weniger als fünf Punkte, wurde mithilfe des k-Nearest-Neighbor-Algorithmus der Radius r solange vergrößert, bis dem Punkt P mindestens fünf Nachbarspunkte zugeordnet werden konnten.

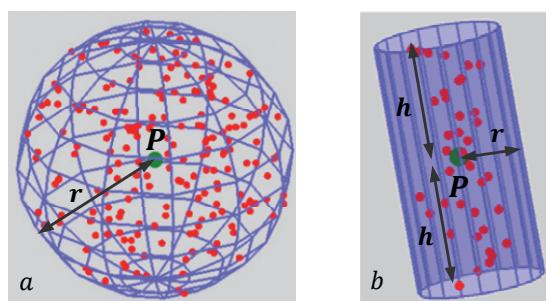


Abb. 1: kugelförmige (a) bzw. zylindrische (b) Nachbarschaftsdefinition für den in grün dargestellten LiDAR Punkt P . Modifizierte Darstellung nach GROSS et al. (2007).

Die Merkmale wurden sowohl für die kugelförmige (siehe Abb. 1a) als auch für die zylindrische (siehe Abb. 1b) Nachbarschaftsdefinition auf mehreren Massstabsstufen berechnet. Insgesamt wurden drei kugelförmige (Radien r von 30 cm, 50 cm und 1 m) und zwei zylindrische Nachbarschaften (Radius r von 30 cm und Höhe h von 50 cm bzw. Radius r von 50 cm und Höhe h von

1 m) definiert, sodass für jeden LiDAR Punkt ein Merkmalsvektor bestehend aus 66 Elementen resultierte. Der Grundgedanke des multiskalen-Ansatzes stammt von BRODU & LAGUE (2012).

3.2 Merkmalsgewinnung

3.2.1 Merkmale basierend auf der Höhe von LiDAR Punkten

Die relative Höhe Δz entspricht der Höhendifferenz zwischen dem Punkt P und der mittleren Bodenhöhe der Punktwolke. Als mittlere Bodenhöhe wurde der Mittelwert der 1%-tiefst gelegenen Punkte der gesamten Punktwolke angenommen. Die relative Höhe Δz eignet sich für die Unterscheidung zwischen Bodenpunkten und Nicht-Bodenpunkten.

Die Höhenvarianz σ_z^2 des Punktes P charakterisiert die Streuung der Punkt-Höhen innerhalb der lokalen Nachbarschaft N_P . Sie kann genutzt werden, um glatte, horizontale Oberflächen von Objekten zu unterscheiden, die vorwiegend vertikal ausgerichtet sind. Für eine kugelförmige Nachbarschaft mit einem eher geringen Radius r kann das Merkmal σ_z^2 zudem verwendet werden, um raue Oberflächenstrukturen zu detektieren (RUTZINGER et al. 2008).

3.2.2 Merkmale basierend auf Eigenwerten

Aus der Kovarianzmatrix einer lokalen Nachbarschaft N_P können durch Eigenwertzerlegung die Eigenvektoren \vec{e}_1 , \vec{e}_2 und \vec{e}_3 sowie die dazugehörigen Eigenwerte $\lambda_1 \geq \lambda_2 \geq \lambda_3 \geq 0$ der lokalen Punktwolke gewonnen werden. Die Eigenvektoren geben die Hauptrichtungen der lokalen Punktwolke an, die Eigenwerte $\lambda_{1,2,3} \in \mathbb{R}$ kennzeichnen deren Größenordnung. Die Größenverhältnisse der drei Eigenwerte erlauben es, die lokale räumliche Verteilung der Punkte innerhalb der gegebenen Nachbarschaft N_P zu erfassen (siehe Abb. 2 sowie die Merkmalsdefinitionen (1) bis (5)). Die Richtungsabhängigkeit A_λ gibt an, ob die Verteilung der Punkte innerhalb der Nachbarschaft N_P mit der Raumrichtung variiert. A_λ ist umso grösser, je markanter sich die räumliche Verteilung der Punkte in der ersten und dritten Hauptrichtung unterscheidet (gilt z. B. für raue Oberflächen wie Waldboden). Eine niedrige Richtungsabhängigkeit A_λ bzw. eine hohe Sphärizität S_λ ist für Punkte gegeben, deren Nachbarspunkte isotrop verteilt sind (z. B. Punkte von Baumkronen). Die Ebenheit P_λ charakterisiert planare Nachbarschaftsstrukturen und weist insbesondere für ebene Objektklassen wie Boden hohe Werte auf. Die Linearität L_λ kennzeichnet lineare Objektstrukturen und ist deshalb ein gutes Mass für die Charakterisierung von Baumstämmen. Die Oberflächenvariation σ_λ beschreibt, wie stark die Punkte innerhalb der Nachbarschaft N_P von der Objektoberfläche abweichen.

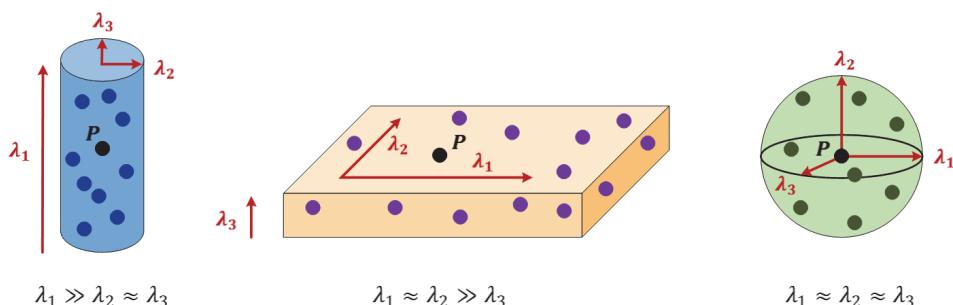


Abb. 2: Größenverhältnisse der Eigenwerte $\lambda_{1,2,3}$ als Indikatoren für die lokale räumliche Verteilung der Punkte innerhalb der Nachbarschaft des Punktes P . Modifizierte Darstellung nach LALONDE et al. (2006).

$$\text{Richtungsabhängigkeit: } A_\lambda = \frac{\lambda_1 - \lambda_3}{\lambda_1} \quad (1) \quad \text{Sphärizität: } S_\lambda = 1 - A_\lambda = \frac{\lambda_3}{\lambda_1} \quad (2)$$

$$\text{Ebenheit: } P_\lambda = \frac{\lambda_2 - \lambda_3}{\lambda_1} \quad (3) \quad \text{Linearität: } L_\lambda = \frac{\lambda_1 - \lambda_2}{\lambda_1} \quad (4)$$

$$\text{Oberflächenvariation: } \sigma_\lambda = \frac{\lambda_3}{\lambda_1 + \lambda_2 + \lambda_3} \quad (5)$$

3.2.3 Merkmale basierend auf der lokalen Ebene

Merkmale basierend auf der lokalen Ebene Π_P der Nachbarschaft N_P beschreiben die Orientierung der lokalen Punktverteilung sowie die räumliche Beziehung zwischen dem Punkt P und den Punkten in dessen Nachbarschaft. Sie können genutzt werden, um Vegetation von ebenen Objektklassen wie Fassaden oder Boden zu trennen und ermöglichen die Differenzierung zwischen Baumstämmen und Baumkronen. Die Ebenenschätzung wurde unter Anwendung des MSAC-Algorithmus (*M-Estimator SAmple Consensus*) vorgenommen, eine von TORR & ZISSEMAN (2000) entwickelte Erweiterung des RANSAC-Algorithmus. Folgende Merkmale wurden von der lokalen Ebene Π_P der Nachbarschaft N_P für den Punkt P abgeleitet:

- α_Π : Winkel zwischen dem Normalenvektor der lokalen Ebene Π_P und der Vertikalen
- $\sigma_{\alpha_\Pi}^2$: Varianz des Abweichungswinkels α_Π innerhalb der Nachbarschaft N_P
- d_P : lotrechter Abstand des Punktes P von der lokalen Ebene Π_P
- R_Π : Residuen der lokalen Ebene, d.h. skaliert-gewichtete Summe der lotrechten Abstände d_i zwischen jedem Punkt i innerhalb der Nachbarschaft N_P und der lokalen Ebene Π_P mit Gewichtungsfaktor $l = 1.2$ gemäss CHEHATA et al. (2009):

$$R_\Pi = \sum_{i \in N_P} \frac{d_i^l}{l} \quad (6)$$

3.3 Klassifizierung

Die Klassifizierung wurde als überwachter Lernprozess durchgeführt. Als Klassifizierungsmethode wurde zum einen *Naive Bayes* als klassisches generatives Verfahren und zum anderen *Random Forests* als modernes diskriminatives Verfahren verwendet.

4 Ergebnisse und Diskussion

Für beide Klassifizierungsmethoden wurde untersucht, ob sich die ausgewählten Merkmale sowie der multiskalen-Ansatz mit den fünf definierten Nachbarschaften für die Klassifizierung von terrestrischen Punktwolken bewähren. Die Evaluierung erfolgte mit dem Verfahren der einfachen Kreuzvalidierung unter Verwendung zweier Datensätze, die beide rund 160'000 3D-Punkte umfassen. Mit dem Testgebiet *Reussegg* wurde eine umfangreiche Parameterstudie durchgeführt, um den Zusammenhang zwischen Art und Grösse der berücksichtigten Nachbarschaften und dem Klassifizierungsergebnis zu analysieren. Die Erkenntnisse wurden genutzt, um abschliessend die Performanz des erarbeiteten Klassifikationsalgorithmus mit dem Testgebiet *ETH_HXE* zu ermitteln. Für detailliertere Ausführungen zur Parameterstudie, für die Auswertung des Testgebietes *ETH_HXE* und für weitere Visualisierungen sei auf STUCKER (2014) verwiesen.

Die Klassifizierung des Testgebietes *Reussegg* mit Naive Bayes als Klassifizierungsmethode resultiert in einer Gesamtklassifikationsgenauigkeit von 92.66%. Die mittlere Genauigkeit beträgt 86.81%, die mittlere Zuverlässigkeit 88.07%. Wird für die Klassifizierung Random Forests verwendet, kann die Gesamtklassifikationsgenauigkeit auf 95.54% gesteigert werden. Die mittlere Genauigkeit beläuft sich auf 87.72%, die mittlere Zuverlässigkeit auf 94.59%. Der Kappa-Koeffizient ist mit einem Wert von 92.13% um rund 5 Prozentpunkte höher als bei der Klassifizierung mit Naive Bayes. Fehlklassifikationen treten sowohl bei Naive Bayes als auch bei Random Forests vorwiegend im Übergangsbereich zwischen Boden und Baumstämmen, für Baumstämme im Innern von Baumkronen sowie an den oberen Enden von Baumstümpfen auf (siehe Abb. 3). In STUCKER (2014) wurde gezeigt, dass diese Fehlklassifikationen auf die berechneten Merkmalswerte zurückzuführen sind. Die falsch klassifizierten Punkte – insbesondere Baumstammpunkte in Bodennähe – weisen für etliche Merkmale ähnliche Werte auf wie Punkte von Baumkronen. Diese Gegebenheit hat zur Folge, dass die einzelnen Klassen nicht mehr voneinander unterschieden werden können. Die Übereinstimmung zwischen den Merkmalswerten ist umso höher, je grösser die Nachbarschaft für die Merkmalsberechnung gewählt wird. Art und Dimension der Nachbarschaft haben somit einen wesentlichen Einfluss auf die Qualität der Klassifizierung. BLOMLEY et al. (2014) haben nachgewiesen, dass die Eigenwert-basierten Merkmale stark von der gewählten Nachbarschaftsgrösse abhängig sind. Durch die Verwendung sogenannter *shape distribution* Merkmale kann die Klassifizierungsgenauigkeit und -zuverlässigkeit jedoch markant verbessert werden. Diese Merkmale sind von der Grösse der berücksichtigten Nachbarschaft unabhängig und erfassen signifikante Muster in der Verteilung der LiDAR Punkte besser als die in dieser Arbeit verwendeten Eigenwert-basierten Merkmale.

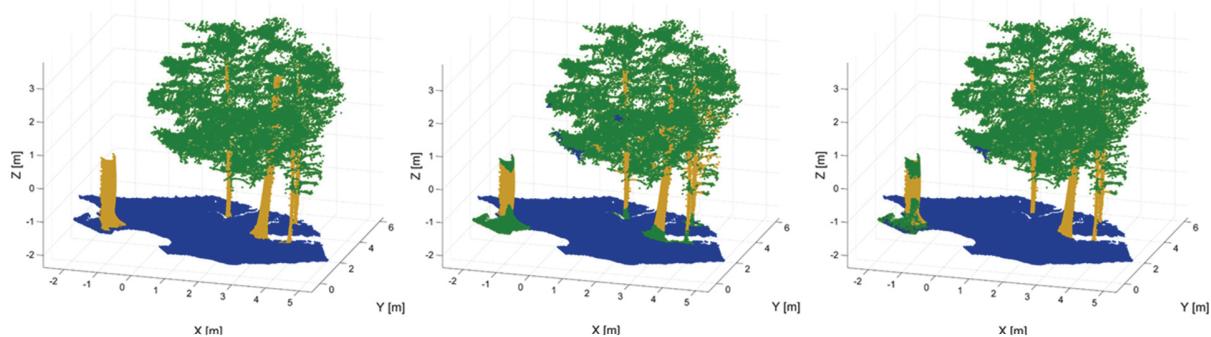


Abb. 3: Klassificationsergebnis für das Testgebiet *Reussegg* (blau: Boden, braun: Baumstamm, grün: Baumkrone) unter Verwendung aller fünf Nachbarschaftsdefinitionen.
(links): Ground Truth, (Mitte): Naive Bayes Klassifizierung, (rechts): Random Forests Klassifizierung

Die Wahl des multiskalen-Ansatzes scheint für die Merkmalsberechnung geeignet zu sein. Wird die Klassifizierung auf Basis einer einzigen Nachbarschaftsdefinition durchgeführt, fällt die Gesamtklassifikationsgenauigkeit um 6 (Naive Bayes) bzw. um 3 Prozentpunkte (Random Forests) schlechter aus als bei der Klassifizierung unter Verwendung aller Nachbarschaften. Auch mit Beschränkung des multiskalen-Ansatzes auf einen Nachbarschaftstypus kann die Klassifizierung nicht signifikant verbessert werden. Random Forests liefert jeweils höhere Genauigkeiten und Zuverlässigerkeiten für die einzelnen Klassen als Naive Bayes. Einzig die Genauigkeit der Klasse «Baumstamm» fällt niedriger aus (Overfitting aufgrund des beschränkten Trainingsdatensatzes).

5 Fazit und Ausblick

Die implementierten Merkmale sind für die Klassifizierung von terrestrischen Punktwolken zweckmäßig und eignen sich im Speziellen, um Vegetation in Punktwolken zu detektieren. Der erarbeitete Klassifikationsalgorithmus nutzt sämtliche Merkmale für alle Nachbarschaftstypen und -größen. Für weiterführende Arbeiten ist daher die Ermittlung der relevanten und diskriminativen Merkmale angezeigt. Die berücksichtigten Nachbarschaften können zudem optimiert werden, indem diese für jeden einzelnen Punkt individuell bestimmt werden. Ein Ansatz für die Merkmalsselektion und für die automatische Bestimmung von optimalen Nachbarschaftsgrößen wurde von WEINMANN et al. (2014) präsentiert. Weiteres Verbesserungspotential liegt in der Einführung von nachbarschaftsgrößen-unabhängigen Merkmalen (BLOMLEY et al. 2014).

6 Literaturverzeichnis

- BIENERT, A., 2013: Automatische Extraktion von 3D-Baumparametern aus terrestrischen Laser-scannerdaten. Dissertation, Technische Universität Dresden, Deutschland.
- BLOMLEY, R., WEINMANN, M., LEITLOFF, J. & JUTZI, B., 2014: Shape distribution features for point cloud analysis - a geometric histogram approach on multiple scales. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, II-3, S. 9-16.
- BRODU, N. & LAGUE, D., 2012: 3D terrestrial lidar data classification of complex natural scenes using a multi-scale dimensionality criterion: Applications in geomorphology, *ISPRS Journal of Photogrammetry and Remote Sensing* **68**, S. 121-134.
- CHEHATA, N., GUO, L. & MALLET, C., 2009: Airborne lidar feature selection for urban classification using random forests. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* **39** (3/W8), S. 207-212.
- GROSS, H., JUTZI, B. & THOENNESSEN, U., 2007: Segmentation of tree regions using data of a full-waveform laser. *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences* **36** (3), W49A.
- GROSS, M., PAULY, M. & KOBELT, L. P., 2002: Efficient simplification of point-sampled surfaces. *Proceedings of the IEEE Visualization Conference*, S. 163-170.
- GUO, L., CHEHATA, N., MALLET, C. & BOUKIR, S., 2011: Relevance of airborne lidar and multispectral image data for urban scene classification using Random Forests. *ISPRS Journal of Photogrammetry and Remote Sensing*, **66** (1), S. 56-66.
- LALONDE, J.-F., VANDAPEL, N., HUBER, D. F. & HEBERT, M., 2006: Natural terrain classification using three-dimensional lidar data for ground robot mobility. *Journal of field robotics* **23** (10), S. 839-861.
- RUTZINGER, M., HÖFLE, B., HOLLAUS, M. & PFEIFER, N., 2008: Object-based point cloud analysis of full-waveform airborne laser scanning data for urban vegetation classification. *Sensors* **8** (8), S. 4505-4528.
- STUCKER, C., 2014: Klassifizierung von Vegetation in einer Laserscan-Punktwolke. Bachelorarbeit, ETH Zürich, Schweiz.
- TORR, P. H. S. & ZISSERMAN, A., 2000: MLESAC: A new robust estimator with application to estimating image geometry. *Computer Vision & Image Understanding*, **78** (1), S. 138-156.
- WEINMANN, M., JUTZI, B. & MALLET, C., 2014: Semantic 3D scene interpretation: A framework combining optimal neighborhood size selection with relevant features. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, II-3, S. 181-188.