

# Klassifizierung von Gebäudefassaden in einer Laserscan-Punktwolke

NICO LANG<sup>1</sup>

*Zusammenfassung: Mit der rasanten Entwicklung der Laserscanning Technologie wird die effiziente Prozessierung der 3D-Punktwolken zu einer aktuellen Aufgabe. In dieser Arbeit wird eine Methode zur automatisierten Klassifizierung von Punktwolken, aufgenommen mit terrestrischem Laserscanning, präsentiert. Dabei liegt der Fokus auf der Interpretation von Gebäudefassaden. Da beim Laserscanning sehr große Datenmengen entstehen, ist eine manuelle Analyse und Interpretation der Daten kaum möglich. Die Semantik der Punkte ist nebst der Geometrie eine wichtige Information für die 3D-Rekonstruktion unserer Umwelt. 3D-Stadtmodelle sind immer gefragter und finden ihre Anwendung beispielsweise in der Stadtplanung, im virtuellen Tourismus sowie in der Augmented Reality. In dieser Arbeit wird ein Lösungsansatz mittels überwachter Klassifizierung präsentiert, wobei dem Klassifizierer klassenspezifische Merkmalswertverteilungen im Trainingsschritt erlernt werden. Für die Charakterisierung der Punkte werden nebst den Airborne Lidar Merkmalen (CHEHATA et al. 2009) selbst entworfene 3D-spezifische Merkmale verwendet. Die Qualität der Merkmale wird mit zwei Klassifizierungsmethoden experimentell evaluiert. Die Resultate zeigen, dass die Airborne Lidar Merkmale erfolgreich auf terrestrische Laserscan-Punktwolken angewendet werden können und die Klassifizierung mit der Ergänzung der neuen Merkmale verbessert wurde.*

## 1 Einleitung

Bereits heute leben 54% der Weltbevölkerung in urbanen Gebieten (UNITED NATIONS 2014). Mit der steigenden Urbanisierung entstehen bei der Errichtung der nötigen Infrastrukturen anspruchsvolle Planungsaufgaben, wobei 3D-Stadtmodelle als optimale Planungsinstrumente dienen. Das Verständnis urbaner Gebiete ist somit wichtig für deren zukünftige Entwicklung, weshalb der Fokus bei der automatisierten Klassifizierung auf Gebäudefassaden gelegt wird.

Punktwolken, aufgenommen mit terrestrischem Laserscanning, bieten eine geeignete Grundlage für eine detaillierte 3D-Rekonstruktion von Gebäuden. Der Vorteil gegenüber Punktwolken aus Image Matching besteht in der hohen Genauigkeit der Messungen, wobei auch bei mangelnder Objekttextur die Objektgeometrien genau erfasst werden. Airborne Lidar Scans haben den Nachteil, dass auf Grund der ungünstigen Aufnahmegeometrie aus dem Zenit auf den Gebäudefassaden kaum Punkte vorhanden sind. Zudem ergibt sich durch die geringere Messdistanz terrestrischer Aufnahmen eine höhere Punktdichte und damit eine detailliertere Erfassung der Gebäudestrukturen. Die Auswertung von Geometrie und Semantik ist bei sehr grossen Datenmengen manuell kaum möglich, weshalb die automatische Klassifizierung ein wichtiger Teil der Modellierung darstellt. Die Klassifizierung der Punktwolke kann als erster Schritt dazu dienen, um Semantik und Geometrie gemeinsam zu rekonstruieren. Mit den ersten Smartphone-Prototypen (ATAP PROJECT TANGO 2014), welche bereits Punktwolken erfassen können, wäre mittels der automatischen Klassifizierung zukünftig eine Erweiterung der Augmented Reality in 3D denkbar. Ebenso könnte mit der gewonnenen Semantik die Indoor-Navigation unterstützt werden. Die

---

<sup>1</sup> Student BSc. Geomatik und Planung, ETH Zürich, Schweiz; E-Mail: nlang@student.ethz.ch

Schwierigkeit solcher Echtzeitanwendungen besteht in der zeitaufwändigen Prozessierung der großen Datenmengen.

## 2 Methoden

Zur Klassifizierung terrestrischer Laserscan-Punkte wird ein merkmalsbasierter, überwachter Klassifizierungsansatz verwendet. Die einzelnen Messpunkte werden durch Merkmale charakterisiert und in Klassen eingeteilt. Die von CHEHATA et al. (2009) präsentierten Airborne Lidar Merkmale werden mit neu entworfenen Merkmalen für terrestrische Laserscan-Punkte ergänzt. Diese neu entworfenen Merkmale zielen auf die 3D-Information terrestrischer Laserscans ab. Während Airborne Lidar Scans typischerweise zu 2.5D-Modellen verarbeitet werden und damit pro XY-Koordinate maximal ein Punkt existiert, wird bei terrestrischen Laserscans die vollständige 3D-Information berücksichtigt. Da sich Gebäudefassaden entlang der vertikalen Richtung erstrecken, ist die Verwendung von 3D-Modellen für dessen Erfassung zwingend notwendig. Durch die Analyse der Punktverteilung entlang der vertikalen Richtung lassen sich Fassadenpunkte differenziert charakterisieren. Zur experimentellen Evaluierung der Merkmale werden zwei Standardverfahren der überwachten Klassifizierung genutzt.

### 2.1 Merkmale

Die Punkte werden durch Merkmale charakterisiert, die aus der Geometrie der lokalen Punkt-nachbarschaft berechnet und in einem Merkmalsvektor an den Klassifizierer übergeben werden. Total werden die fünf folgenden Merkmalsgruppen zur Charakterisierung der Punkte verwendet: Eigenwertmerkmale, Höhenmerkmale, Merkmale basierend auf der lokalen Ebene, Merkmale des Histogramms der Höhendifferenzen und die Merkmale der lokalen räumlichen Verteilung.

#### 2.1.1 Merkmale für Airborne-Laserscanpunkte von CHEHATA et al. (2009)

Die Eigenwertmerkmale, Höhenmerkmale sowie die Merkmale der lokalen Ebene, stützen sich auf die Ideen, welche von CHEHATA et al. (2009) präsentiert und auf 2.5D-Modellen getestet werden. Die Hauptrichtungen der Punktverteilung innerhalb der Punktnachbarschaft werden mit der Eigenwertzerlegung der Kovarianzmatrix innerhalb einer Kugelnachbarschaft bestimmt. Woraus sich Eigenwertmerkmale wie beispielsweise die Linearität berechnen lassen. Um die Merkmale der lokalen Ebene zu berechnen, wird aus den Punkten der lokalen Punktnachbarschaft mit einer Ausgleichung nach den kleinsten Quadraten die lokale Ebene geschätzt. Die Ausgleichung wird mit der Verwendung der Ransac- (FISCHLER und BOLLES 1981) respektive der modifizierten Msac-Methode (TORR und ZISSERMAN 2000) robuster gemacht, indem die Ausreißer der Punktnachbarschaft vor der Ausgleichung aus der Punktmenge entfernt werden.

#### 2.1.2 Merkmale für terrestrische Laserscan-Punktwolken

Um die vollständige 3D-Information aus terrestrischen Laserscans zu nutzen, werden zwei Merkmalsgruppen als Ergänzung neu entworfen: Die Merkmale des Histogramms der Höhendifferenzen und die Merkmale der lokalen räumlichen Verteilung (LANG 2014). Aufgrund der limitierten Seitenzahl wird hier nur auf die erstgenannte Merkmalsgruppe weiter eingegangen.

Im Unterschied zu 2.5D-Modellen können 3D-Modelle mehrere Punkte mit der gleichen XY-Koordinate enthalten, wodurch Gebäudefassaden in vertikaler Richtung detailliert dargestellt werden können. Mit den Merkmalen des Histogramms der Höhendifferenzen wird die Verteilung

der Punkte entlang der Z-Achse beschrieben. Damit ermöglichen diese Histogramme eine differenzierte Charakterisierung der Punkte innerhalb der Fassade. Die Abbildung 2.1 zeigt ein generiertes Punktbeispiel und wie sich die Histogramme z.B. für die Klassen Wand und Dach unterscheiden.

Die Höhendifferenzen  $dh_i$  werden aus der Differenz der Höhe des aktuellen Punktes  $h_{P_A}$  und den Höhen aller Nachbarschaftspunkte  $h_{P_i}$  innerhalb einer vertikalen Zylindernachbarschaft mit unbeschränkter Höhe berechnet ( 2.1 ).

$$dh_i = h_{P_A} - h_{P_i} \quad (2.1)$$

Die Höhendifferenzen werden auf den Wertebereich [-1, 1] normiert und in einem Histogramm mit  $n_{bins}$  Intervallen gespeichert. Insgesamt werden acht Histogramm-basierte Merkmale extrahiert ( LANG 2014 ). Aus Platzgründen werden in diesem Shortpaper jedoch nur die Merkmale bezüglich der lokalen Maxima angesprochen.

Die lokalen Maxima des Histogramms werden detektiert, indem jeder Häufigkeitswert mit den Häufigkeitswerten der Nachbarintervalle verglichen wird. Ist ein Häufigkeitswert grösser als die beiden Nachbarwerte, so wird das Intervall als lokales Maximum erkannt. Zum einen wird die Anzahl der lokalen Maxima als Merkmal verwendet, zum anderen wird aus den Positionen der Maxima auf der X-Achse des Histogramms der durchschnittliche Abstand  $\text{avg}_{\text{dist Peaks}}$  als Merkmal berechnet ( 2.2 ).

$$\text{avg}_{\text{dist Peaks}} = \text{mean}(\text{difference}(\text{locations})) \quad (2.2)$$

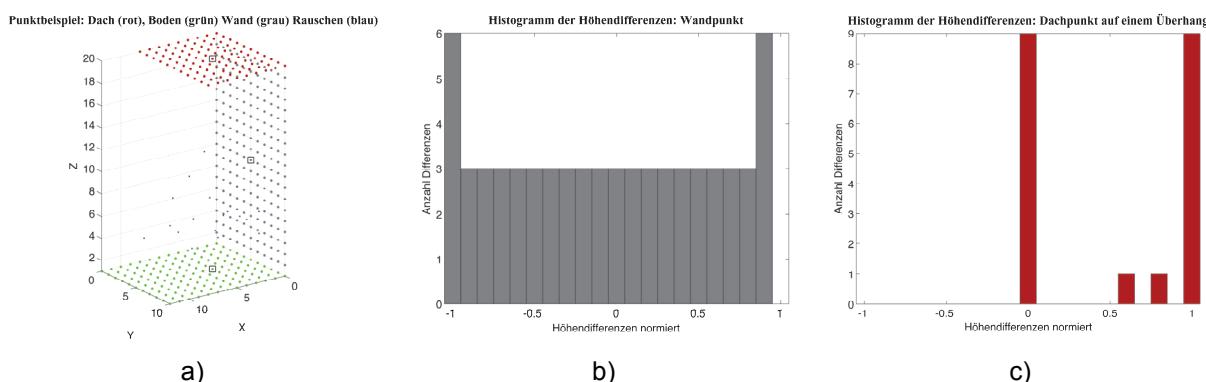


Abbildung 2.1 a) Generiertes Punktbeispiel für eine Hausfassade: Boden (grün), Wand (grau), Dach (rot), Rauschen (blau); Histogramme der Höhendifferenzen für b) die Klasse Wand und c) die Klasse Dach

## 2.2 Klassifizierer

Die Qualität der Merkmale wird mit den zwei überwachten Klassifizierungsmethoden Naive Bayes und Random Forest experimentell evaluiert.

Der Naive Bayes Klassifizierer ist ein generatives Modell ( DUDA et al. 2012 ), das für die Klassifizierung die Verteilung der Merkmalswerte in den Klassen aus den Trainingsdaten schätzt. Dabei wird in der Regel eine Normalverteilung der Merkmale angenommen. Der Random Forest Klassifizierer ist dahingegen eine diskriminative Methode, welche keine bekannte Verteilung der Merkmalswerte in den Klassen voraussetzt. Stattdessen werden mit einem Ensemble von zufällig generierten Entscheidungsbäumen die optimalen Entscheidungsflächen im Merkmalsraum geschätzt ( BOSCH et al. 2007 ).

### 3 Ergebnisse und Diskussion

Zur Evaluierung der implementierten Merkmale wird die Klassifizierungsmethode auf eine homogene Punktwolke mit einem durchschnittlichen Punktabstand von 0.06 m angewendet. Der Datensatz wird in drei Szenen mit je ca. 70'000 Punkten unterteilt. Um die Merkmale unabhängig von Overfitting Effekten evaluieren zu können, werden gleiche Merkmalswertverteilungen in den Klassen des Trainings- und Testdatensatzes benötigt. Diese ähnlichen Verteilungen werden mit verschiedenen Varianten der Kreuzvalidierung erreicht. Für die M-fold cross-validation (DUDA et al. 2012) wird der gesamte Datensatz zufällig in 3 disjunkte Teilmengen der gleichen Szene unterteilt. Die drei Teilmengen werden im Kreuzverfahren jeweils als Test- und Trainingsdatensatz verwendet und die Ergebnisse aus allen Kombinationen gemittelt.

Da der Fokus dieser Arbeit auf der Klassifizierung von Gebäudefassaden liegt, sind die folgenden sechs Klassen für die verwendeten Daten von Bedeutung: Boden, Wand, Dach, Clutter (entspricht der Restklasse), Vegetation und Fenster.

#### 3.1 Einfluss der Nachbarschaftsgrösse auf die Klassifikation

Die Anzahl Punkte in der Nachbarschaft ist von der Punktdichte und vom Nachbarschaftsradius abhängig und hat einen Einfluss auf die Berechnung der Merkmalswerte. Mit der Variation des Radius (vgl. Abbildung 3.1) wird das Optimum für den verwendeten Datensatz ermittelt. Dazu wird eine Klassifizierung durchgeführt, bei der sich die Szenen in Training und im Test unterscheiden.

Für den Random Forest Klassifizierer erzielt der multiskalare Ansatz die höchste overall accuracy von 71.4%. Die Naive Bayes Methode erzielt mit dem Radius 0.5 m die höchste overall accuracy von 75.3%. Die Verschlechterung mit dem multiskalaren Ansatz, kann an der zu geringen Datenmenge für die große Anzahl Merkmale liegen. Die Abbildung 3.2 zeigt die besten Resultate aus der Abbildung 3.1 für beide Klassifizierungsmethoden.

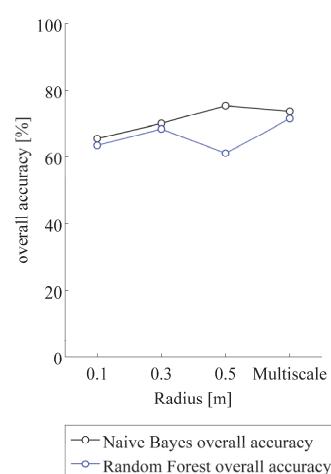


Abbildung 3.1 Einfluss des Nachbarschaftsradius;  
Multiscale = [0.1, 0.3, 0.5]

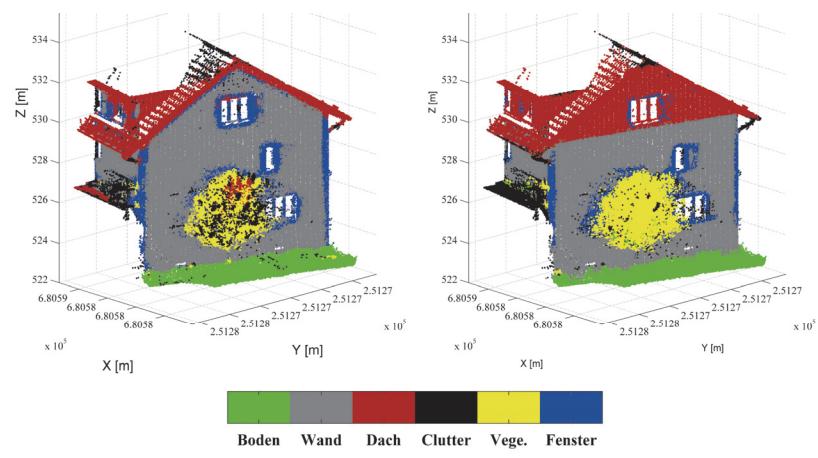


Abbildung 3.2 Klassifikation visualisiert:  
Naive Bayes mit Radius 0.5 m (links); Random Forest multiskalarer Ansatz mit den Radien 0.1 m, 0.3 m und 0.5 m (rechts)

### 3.2 Vergleich Random Forest und Naive Bayes

In der Abbildung 3.2 ist besonders auffällig, dass der Random Forest Klassifizierer alle Wandpunkte ab einer Höhe von 7 m der Klasse Dach zuordnet. Die Ursache dafür liegt in einem Overfitting an die Trainingsdaten. Da in der Trainingsszene keine Wandpunkte oberhalb von 7 m enthalten sind, schätzt der Random Forest Klassifizierer dort eine Entscheidungsfläche im Merkmalsraum zur Trennung der Klassen Dach und Wand. Der Naive Bayes lässt das Resultat auf Grund seiner Unschärfe an den Klassengrenzen besser aussehen. Der Random Forest wäre eigentlich der genauere Klassifizierer, vorausgesetzt die Verteilungen der Merkmalswerte in den Klassen sind im Training und im Test ähnlich. Dies wird mit den Ergebnissen der M-fold cross-validation in Abbildung 3.3 gezeigt. Der Random Forest liefert eine höhere Genauigkeit und Zuverlässigkeit als der Naive Bayes Klassifizierer. Für zukünftige Arbeiten müssen umfassendere Datensätze zur Evaluierung herangezogen werden.

Für die Detektion von Fensterrahmenpunkte wird mit dem Naive Bayes Klassifizierer bei einem Radius von 0.3 m mit 78 % die höchste Producer's accuracy erreicht. In der Visualisierung der Klassifikation (vgl. Abbildung 3.2) ist zu erkennen, dass lineare Strukturen, wie Gebäudekanten ebenfalls als Fensterpunkte klassifiziert werden. Daraus lässt sich schliessen, dass das Eigenwertmerkmal Linearität für die Charakterisierung der Fensterpunkte eine wichtige Rolle spielt.

### 3.3 Evaluierung der Merkmale für terrestrische Laserscan-Punktwolken

Die M-fold cross-validation wird zum einen nur mit den Airborne Lidar Merkmalen und zum anderen mit allen Merkmalen durchgeführt. Die Abbildung 3.3 zeigt, wie sich die Genauigkeit und die Zuverlässigkeit bei beiden Klassifizierungsmethoden durch die Ergänzung der neu entworfenen Merkmale verbessern. Hervorzuheben ist die Verbesserung der Genauigkeit der Klasse Fenster für den Random Forest Klassifizierer von 35.1% auf 65.2%.

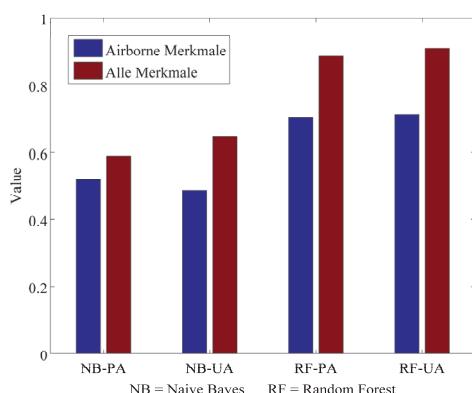


Abbildung 3.3 M-fold cross-validation;  
PA: Producer's accuracy/ Genauigkeit;  
UA: User's accuracy/ Zuverlässigkeit

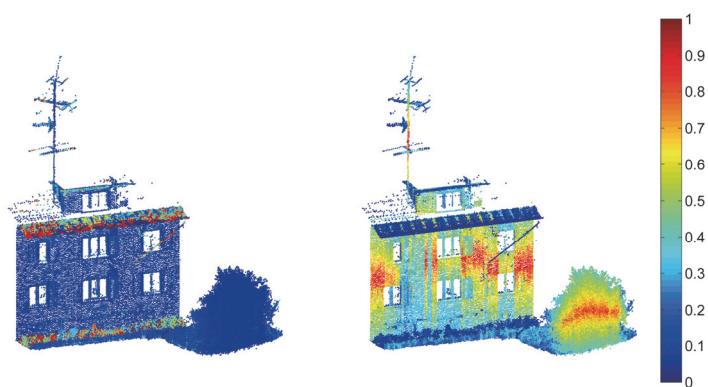


Abbildung 3.4 Merkmalswerte visualisiert: Durchschnittliche Abstand der Peakpositionen im Histogramm der Höhendifferenzen  $\text{avg}_{\text{dist Peaks}}$  (links); Anzahl Peaks im Histogramm der Höhendifferenzen (rechts)

Die Abbildung 3.4 zeigt, dass die Merkmale des Histogramms der Höhendifferenzen sich besonders eignen um Vorsprünge wie zum Beispiel das Vordach von der Wand zu trennen (links). Die Einführung einer weiteren Klasse „Vorsprung“ wäre somit möglich. Die Merkmalswerte der Klassen Wand, Dach und Boden unterscheiden sich besonders an den Klassengrenzen (rechts), womit eine differenzierte Charakterisierung der Fassadenpunkte ermöglicht wird.

## 4 Schlussfolgerung und Ausblick

Die präsentierte Klassifizierungsmethode wird mit den Airborne Lidar Merkmalen (CHEHATA et al. 2009) erfolgreich auf terrestrische Laserscann-Punkte angewendet. Mit der Ergänzung durch die neu entworfenen Merkmale konnte eine deutliche Verbesserung für die gewählten Klassen gezeigt werden. Aus der Analyse der Nachbarschaftsgrösse geht hervor, dass z.B. die Qualität der Eigenwertmerkmale stark von der Wahl des Radius abhängig ist. BLOMLEY et al. (2014) präsentieren aktuell die Shape distribution features, deren Qualität weniger von der Wahl des Nachbarschaftsradius beeinflusst wird. Ausblickend bietet die „Variable Importance“ nach CHEHATA et al. (2009) eine Möglichkeit die Wichtigkeit der Merkmale zu messen. AIJAZI et al. (2014) präsentieren einen Ansatz zur Fensterdetektion, der die fehlenden Punkte auf der Fensterscheibe durch eine Invertierung der Punkte reproduziert. Auch NGUATEM et al. (2014) zeigen weitere Möglichkeiten zur Fensterdetektion auf, die zukünftig beachtet werden.

## 5 Literaturverzeichnis

- AIJAZI, A.K, CHECCHIN, P. & TRASSOUDAINE, L., 2014: Automatic Detection and Feature Estimation of Windows for Refining Building Facades in 3D Urban Point Clouds, ISPRS Ann. Photogramm. Remote Sens. Spatial Inf. Sci., II-3, 1-8, doi:10.5194/isprsannals-II-3-1-2014.
- ATAP PROJECT TANGO (2014, June 05). Retrieved October 20, 2014, from <https://www.google.com/atap/projecttango/#project>.
- BLOMLEY, R., WEINMANN, M., LEITLOFF, J. & JUTZI, B., 2014: Shape distribution features for point cloud analysis – a geometric histogram approach on multiple scales, ISPRS Ann. Photogramm. Remote Sens. Spatial Inf. Sci., II-3, 9-16, doi:10.5194/isprsannals-II-3-9-2014.
- BOSCH, A., ZISSERMAN, A. & MUÑOZ, X., 2007: Image classification using random forests and ferns. IEEE 11<sup>th</sup> International Conference on Computer Vision, S. 1-8
- 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** (Part 3/W8), S. 207-212.
- DUDA, R. O., HART, P. E. & STORK, D. G., 2012: Pattern classification. John Wiley & Sons.
- 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), S. 381-395.
- NGUATEM, W., DRAUSCHKE, M. & MAYER, H., 2014: Localization of Windows and Doors in 3d Point Clouds of Facades. ISPRS Ann. Photogramm. Remote Sens. Spatial Inf. Sci., II-3, 87-94, doi:10.5194/isprsannals-II-3-87-2014.
- LANG, N., 2014: Klassifizierung von Gebäudefassaden in einer Laserscan-Punktfolge. Bachelorarbeit, ETH Zürich.
- TORR, P. H. & ZISSERMAN, A., 2000: MLESAC: A new robust estimator with application to estimating image geometry. Computer Vision and Image Understanding **78** (1), S. 138-156.
- UNITED NATIONS, 2014: Department of Economic and Social Affairs, Population Division. World Urbanization Prospects: The 2014 Revision, Highlights (ST/ESA/SER.A/352), S. 7-12.