

Landesamt für Geoinformation
und Landesvermessung Niedersachsen


HERZLICH WILLKOMMEN!

Deep-Learning-Verfahren zur semantischen Segmentierung von photogrammetrischen Punktwolken aus Luftbildern

Markus Hülsen (M.Sc.)
Oldenburger 3D-Tage, 31.01.2024




Niedersachsen




Motivation

- LGLN = Geobasisdaten für Niedersachsen
- ↻
 - Luftbildbefliegung: 3 Jahres Turnus
 - ALS: max. 10 Jahres Turnus
- Luftbildbefliegungen → **aktuellere** Daten
- **DIM-Punktwolken** bisher ungenutzt
- Gründe zur semantischen Segmentierung:
 - Ableitung aktueller Geländemodelle
 - Change Detection
 - 3D-Rekonstruktionen




© LGLN, digitales Orthophoto

Weg zum Deep-Learning-Modell



Generierung einer
Ground-Truth




Auswahl einer
Deep-Learning-Architektur




Bestimmung einer
Trainingskonfiguration

Generierung der Ground Truth

- DIM-Punktwolke 2022
- 66,8 Mio. Punkte
- Erste Annotation in Dissertation
- Klassen:
 - Gelände
 - Nicht-Gelände
 - Gebäude
 - Brücken



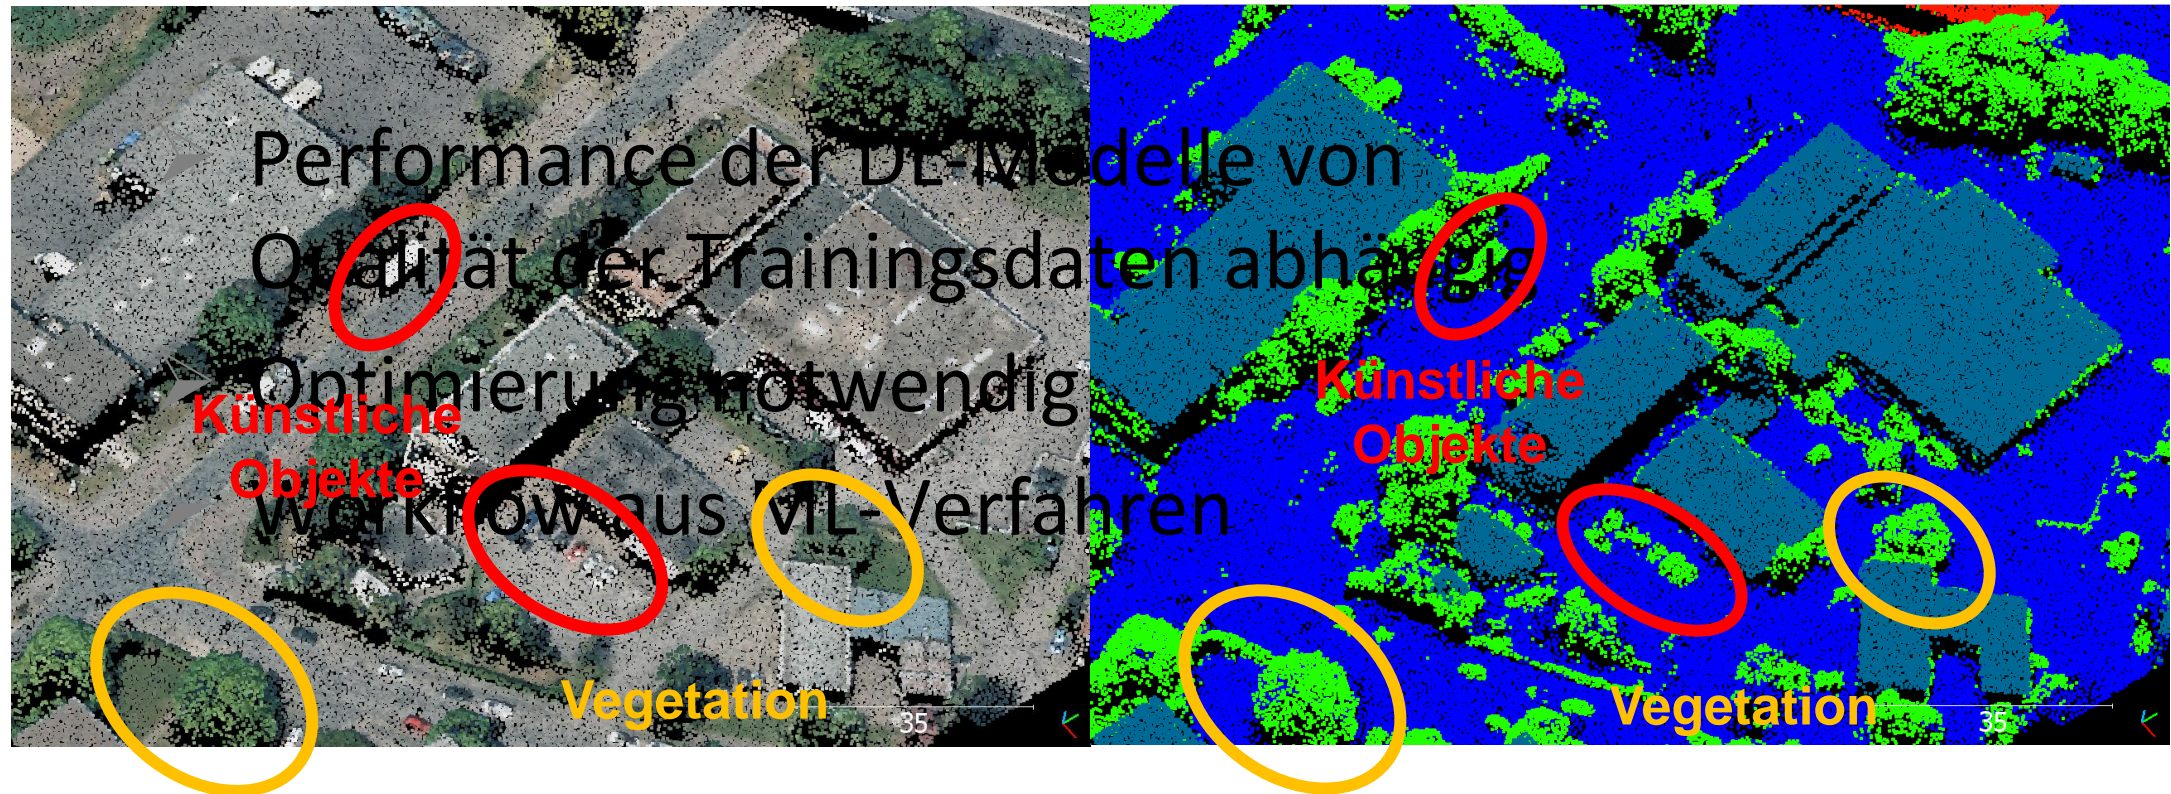
Generierung der Ground Truth



- Gelände
- Nicht-Gelände
- Gebäude
- Brücken

Generierung der Ground Truth

- Klasse „Nicht-Gelände“ sehr heterogen
 - Beinhaltet Vegetation & künstliche Objekte



Optimierung der Annotation

CSF

Optimierung der Klasse *Boden* durch ***Cloth-Simulation-Filter***
(Zhang et al. 2016)

Bereinigung
Gebäudeklasse

Trennung von Vegetation und Gebäude anhand von **Schwellwerten**

K-Means

Gruppierung mit **K-Means** in Bereiche mit ähnlichen Eigenschaften
Manuelle Annotation der Cluster

K-Means,
DBSCAN &
Random
Forest

Gruppierung aufgrund Radiometrie mit **K-Means**,
räumliches Cluster der radiometrischen Klassen mit **DBSCAN** und
Klassifikation der Cluster mit **Random Forest**


→ Nach jedem Schritt: manuelle Inspektion der Ergebnisse



Optimierung der Annotation

Geometrische
Klassifikation


- Gelände
- Nicht-Gelände
- Gebäude



Optimierung der Annotation

Cloth-Simulation-
Filter (CSF)


- Gelände
- Nicht-Gelände
- Gebäude



Optimierung der Annotation

K-Means 1


- Gelände
- Nicht-Gelände
- Gebäude
- Vegetation
- Künstliche Objekte



Optimierung der Annotation

K-Means 2


- Gelände
- Nicht-Gelände
- Gebäude
- Vegetation
- Künstliche Objekte




Optimierung der Annotation

K-Means +
DBSCAN +
RF


- Gelände
- Gebäude
- Vegetation
- Künstliche Objekte





Generierung der Ground-Truth

	Boden	Gebäude	Vegetation	Künstliche Objekte	Brücken
Punktanzahl	31.463.945	12.384.375	22.498.089	330.857	101.342
Rel. Anteil	47.12%	18.55%	33.69%	0.50%	0.15%




Batching: Aufteilung der Punktwolke

- Gesamte Punktwolke zu groß für Netz
- Kreisförmige, überlappende „Batches“
 - Nach Winiwarter et al. (2019)
 - Gitterpunkte mit festem Abstand
 - Feste Anzahl an Nachbarn K
- Hier $K = 100.000$
 - Training: 4.287 Batches
 - Validierung: 400 Batches



Deep Learning Architektur: PointNet++

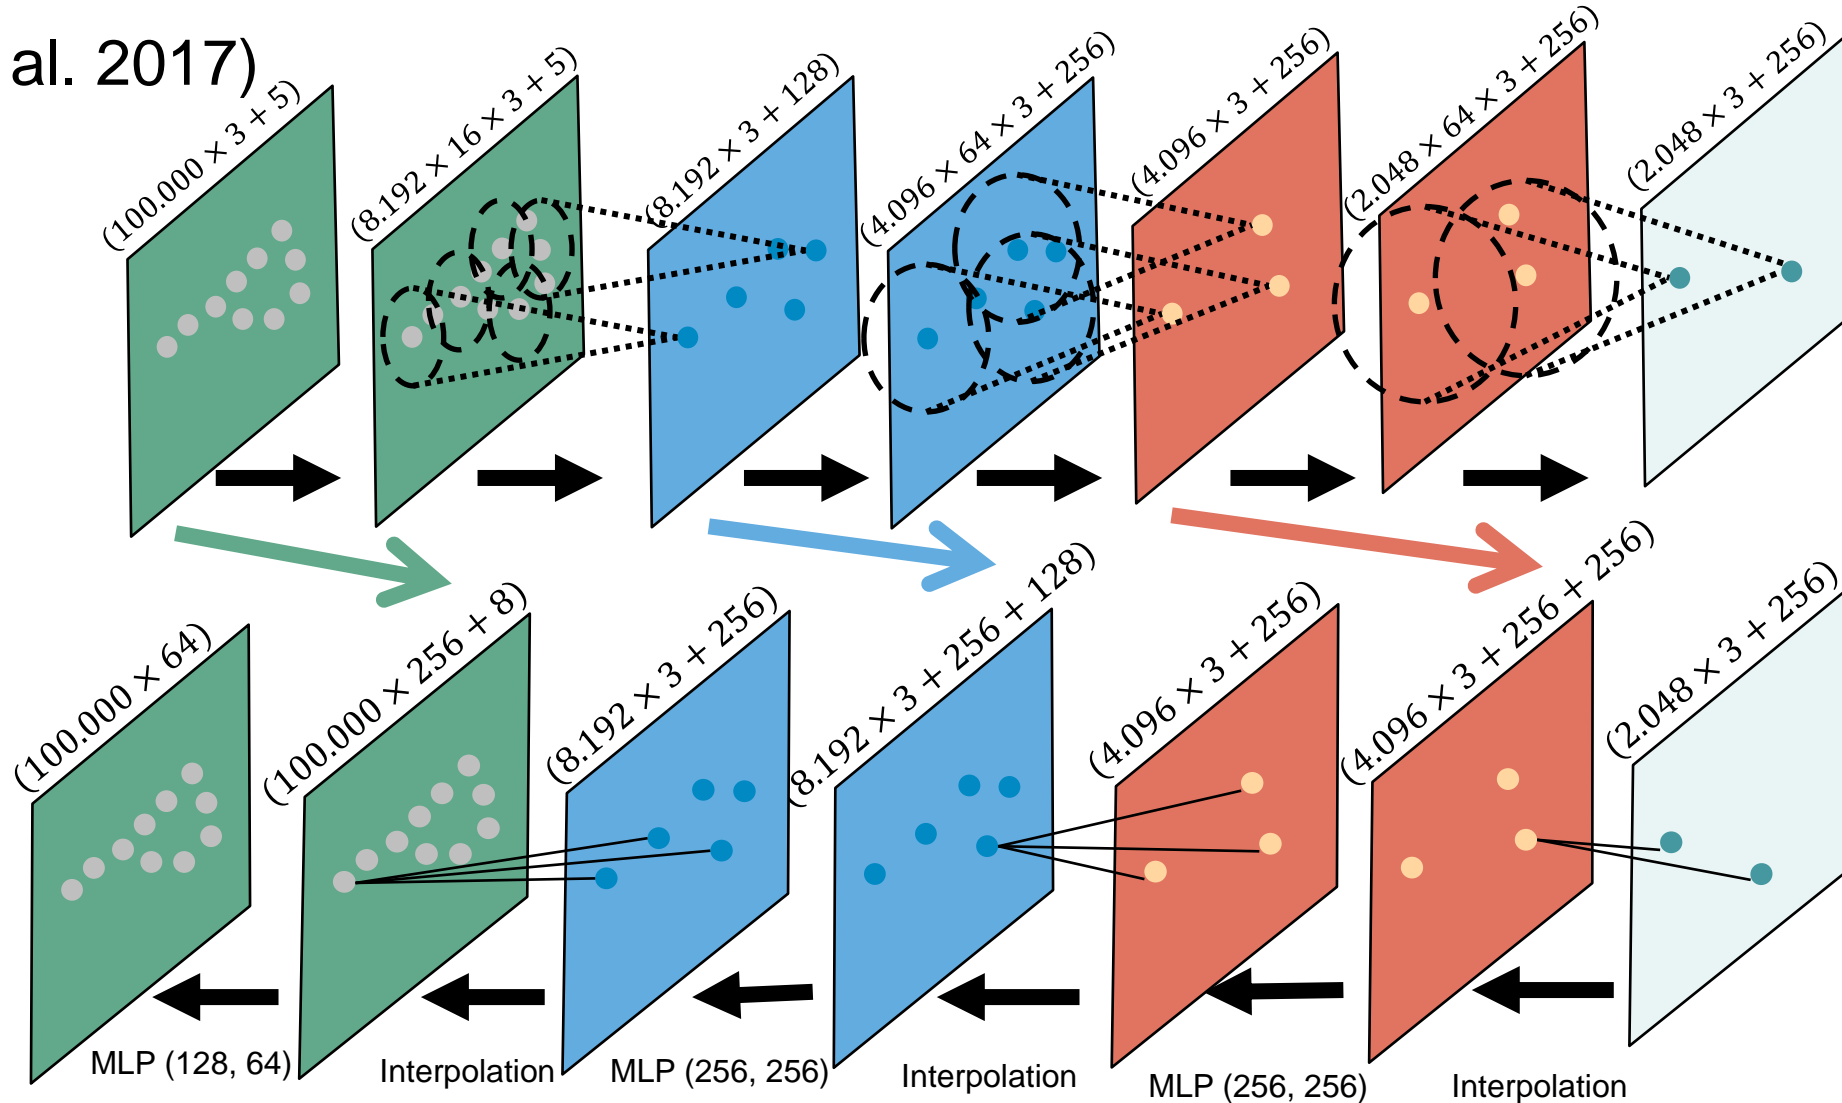
(Qi et al. 2017)



1. „zufällige“ Wahl einer bestimmten Punktzahl ($8.192 \rightarrow 4.096 \rightarrow 2.048$)
2. Betrachtung der Nachbarschaft ($1 m \rightarrow 5 m \rightarrow 15 m$)
3. Ableitung von Merkmalen für die Nachbarschaften durch ein neuronales Netz

Deep Learning Architektur: PointNet++

(Qi et al. 2017)









Trainingsparameter

- Verlustfunktion und Lernrate
- Dataset Augmentation: Rotation um Z-Achse
- Optimale Attributteilmenge
 - Training mit sechs Attributen (XYZ + HSV)
 - Photogrammetrische Attribute ohne Mehrwert




Ergebnisse des Modelltrainings

Gesamtgenauigkeit		96,5%
Boden		98,6%
Gebäude		95,9%
Vegetation		93,9%
Künstliche Objekte		38,1%
Brücken		90,5%

Ursachen:

- versch. Objekttypen in einer Klasse
- Keine guten Trainingsdaten
- Kleine Objekte

Ergebnisse des Modelltrainings



Durch das Modell
vorhergesagte
Klassifikation der
Validierungs-
punktvolke




Evaluierung

RGB

Ground Truth


Prediction

Probability



Fazit

- Sem. Segmentierung der photogrammetrischen Punktwolken möglich
- State-of-the-art Performance
 - OA: 96,5%
- Klassengenauigkeiten $> 90\%$
 - Mit Ausnahme der Klasse Künstliche Objekte (38%)



Ausblick

- Für flächendeckenden Einsatz weitere Trainingsdaten erforderlich
- Modell zur Generierung weiterer Trainingsdaten

Klassifizierung
weiterer
Punktwolken

de → M
ungsa

(geringfüge) manuelle
Nachbearbeitung

- Aktualisierung der Geländemodelle
- Ableitung von Gebäudemodellen

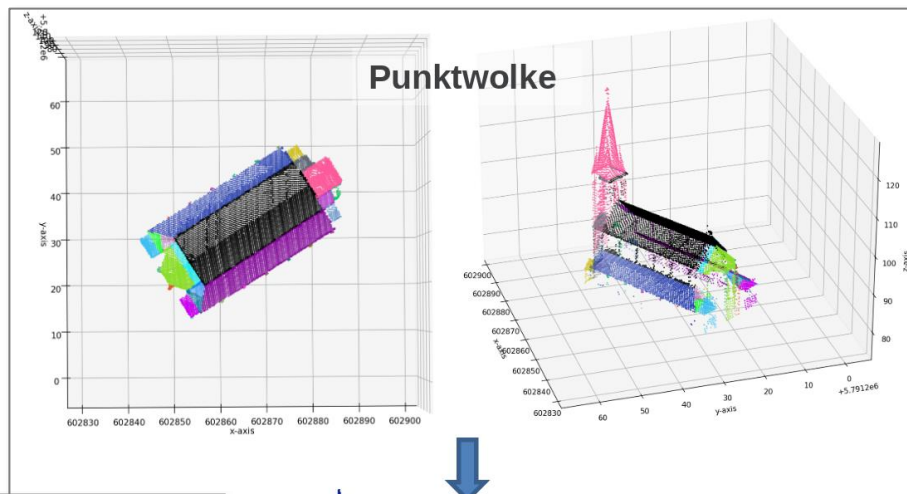


© LGLN – 3D Gebäudemodelle (LoD2)

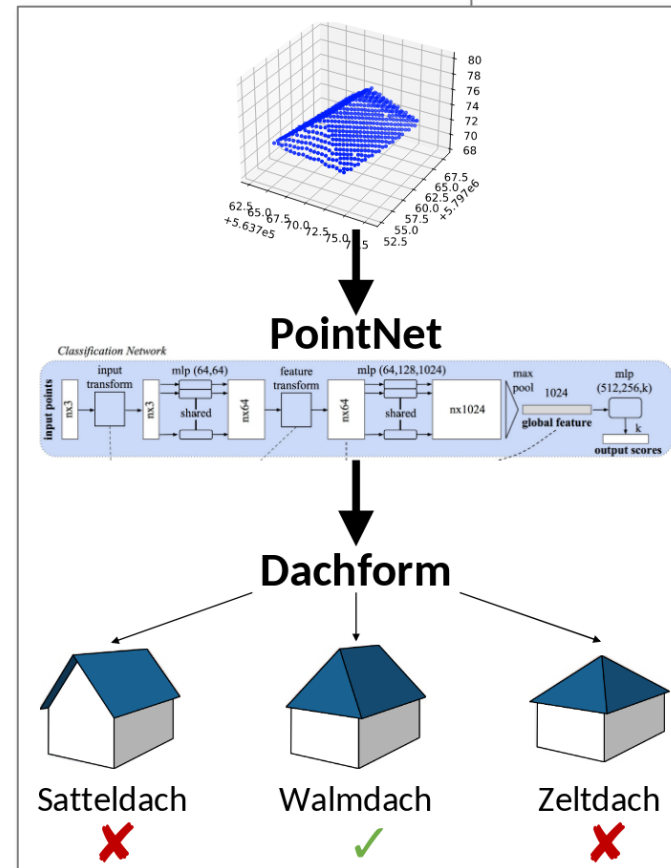

Programmtipp

Deep-Learning-Ansätze für die 3D-Gebäuderekonstruktion

- Mike Engel
- Morgen – 01.02.2024
- 13:30 – 15:00 Uhr
- Raum E24



↓
LOD2



Literatur

- Qi, C. R., L. Yi, H. Su & L. J. Guibas (2017): PointNet++: Deep Hierarchical Feature Learning on Point Sets in a Metric Space. 31st Conference on Neural Information Processing Systems (NIPS 2017). 04.-09. Dezember 2017 in Long-Beach (USA).
<https://doi.org/10.48550/arXiv.1706.02413>.
- Winiwarter, L & Mandlbürger, G. (2019): Classification of 3D Point Clouds using Deep Neural Networks. Publikationen der Deutschen Gesellschaft für Photogrammetrie, Fernerkundung und Geoinformation e.V., Band 28, Kersten, T. P. (Hrsg.), 39. Wissenschaftlich-Technische Jahrestagung der DGPF, 20.-22. Februar 2019 in Wien, 663-674.
- Zhang, W., J. Qi, P. Wan, H. Wang, D. Xie, X. Wang & G. Yan (2016): An Easy-to-Use Airborne LiDAR Data Filtering Method Based on Cloth Simulation. Remote Sensing 8(6).
<https://doi.org/10.3390/rs8060501>.

VIELEN DANK FÜR IHRE AUFMERKSAMKEIT.



Noch Fragen?

Markus Hülsen (M.Sc.)

Fachexperte für UAV & Punktwolken

Landesamt für Geoinformation und Landesvermessung
Niedersachsen (LGLN)

Regionaldirektion Otterndorf

E-Mail: markus.huelsen@lgl.niedersachsen.de

Telefon: +49 4751/90980-23

www.lgl.niedersachsen.de

