TECHNISCHE UNIVERSITÄT DRESDEN

DRESDEN concept

11. Dresdner Flächennutzungssymposium

Nutzung künstlicher Neuronaler Netze zur Detektion von Stadtgrün
Ergebnisse einer Pilotstudie

Amelie Haas, Pierre Karrasch, Lars Bernard
// Professur für Geoinformatik, TU Dresden

Vortrag vom 8. April 2019

Thematische Einführung
Erfassung von Stadtbäumen

Bäume in urbanen Gebieten sind eine wichtige Ressource.
Trotzdem gibt es wenig **Informationen** darüber.

Fernerkundungsdaten sind immer leichter verfügbar.

Zur Auswertung großer Datenmengen eignen sich **Methoden des maschinellen Lernens** (*machine learning*, ML).

► **Ziel** der Pilotstudie:
"Untersuchung des Potenzials künstlicher Neuronaler Netze zur Ableitung von Informationen über Stadtbäume aus Fernerkundungsdaten"

Quelle: FAO 2018

Theoretischer Hintergrund
Künstliche Neuronale Netze (kNN)

= vernetze Recheneinheiten (**Neuronen**)

in **Ebenen** *(layers)* organisiert:
- Eingabeebene (*input layer*)
- "Berechnungsebenen" (*hidden layers*)
- Ausgabeebene (*output layer*)

Die Modellparameter (Gewichte) werden durch **Training** angepasst (überwachtes Lernen).
→ **Beispieldaten** (*examples*)

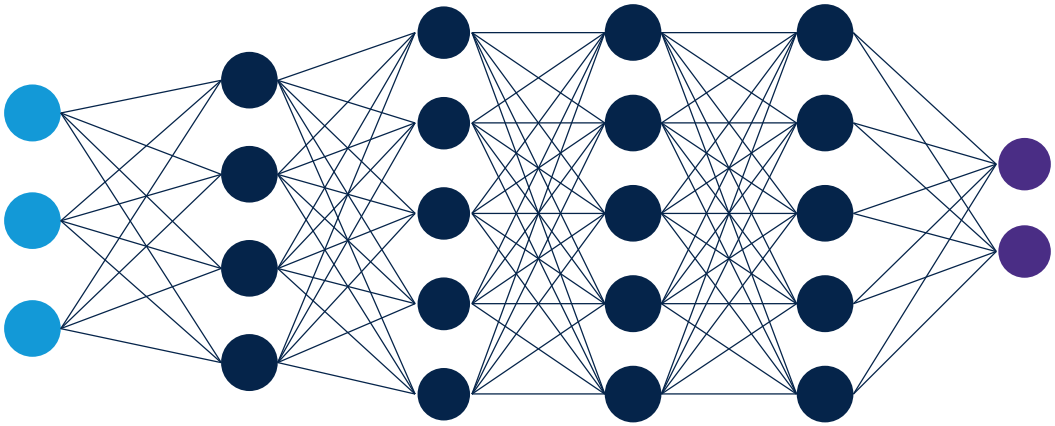

Klassifikation:	Regression:
$p_1 \in [0, 1]$	$y_1 \in \mathbb{R}$
$p_2 \in [0, 1]$	$y_2 \in \mathbb{R}$

► Spezielle kNNs zur Verarbeitung von Bild- bzw. Rasterdaten:
Convolutional Neural Networks (CNNs)

Methoden
Datengrundlage

Fernerkundungsdaten: Großraum Leipzig
- digitale Orthophotos (DOP) @ 20cm
- Gelände- und Oberflächenmodell (DGM, DOM) @ 2m

DOP (R, G, B, IR)

nDOM (DOM-DGM)

Quelle: GeoSN

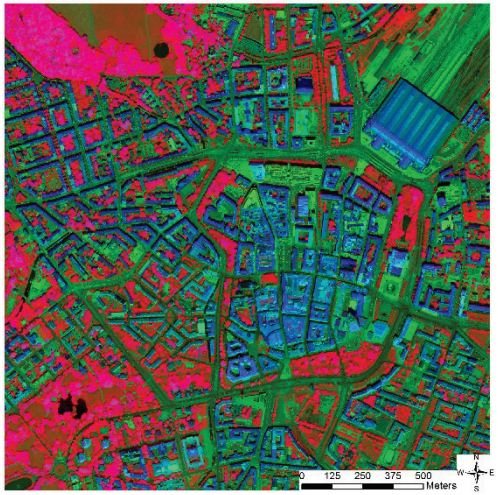

NDVI (R), Grün (G), nDOM (B)

Quelle: GeoSN

► **Beispieldaten (CNN-Input)**: Ausschnitte aus NDVI-G-nDOM-Komposit (@ 20cm)
- **3 Formate**: 24x24, 50x50, 100x100 Pixel
- Nutzung des **Straßenbaumkataster**s der Stadt Leipzig
- Kennzeichnung (*label*) anhand der Zielvariablen (*targets*) für verschiedene Modelle…

Methoden
Entwurf und Training der CNNs

3 verschiedene CNNs:

— **CNN1: Unterscheidung Baum / nicht-Baum** (binäre Klassifikation)

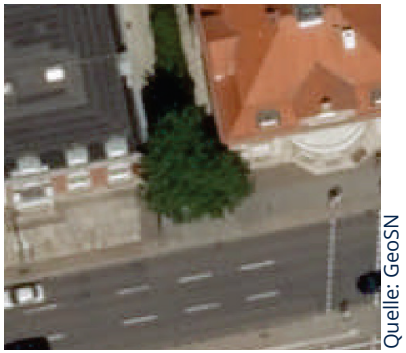

Quelle: GeoSN

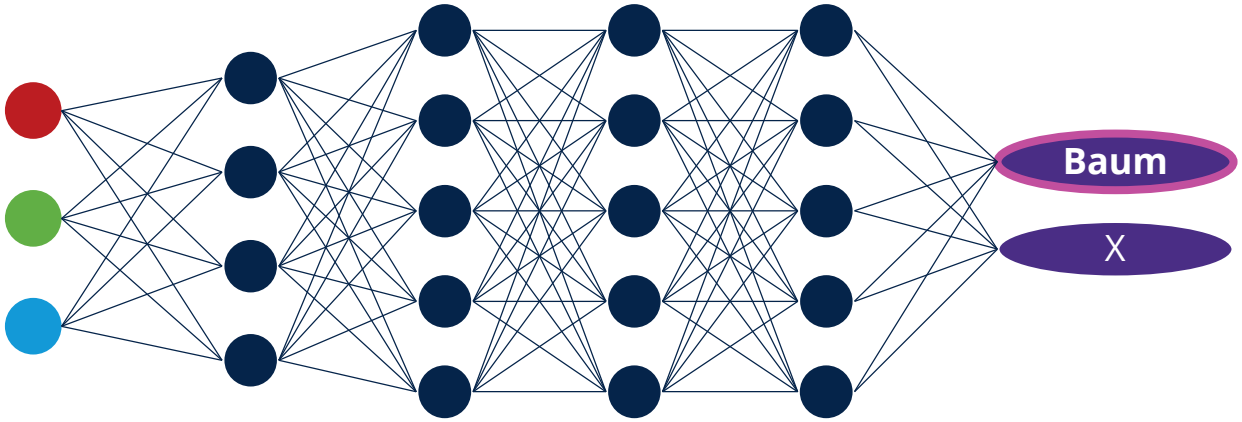

Methoden
Entwurf und Training der CNNs

3 verschiedene CNNs:

— **CNN1: Unterscheidung Baum / nicht-Baum** (binäre Klassifikation)

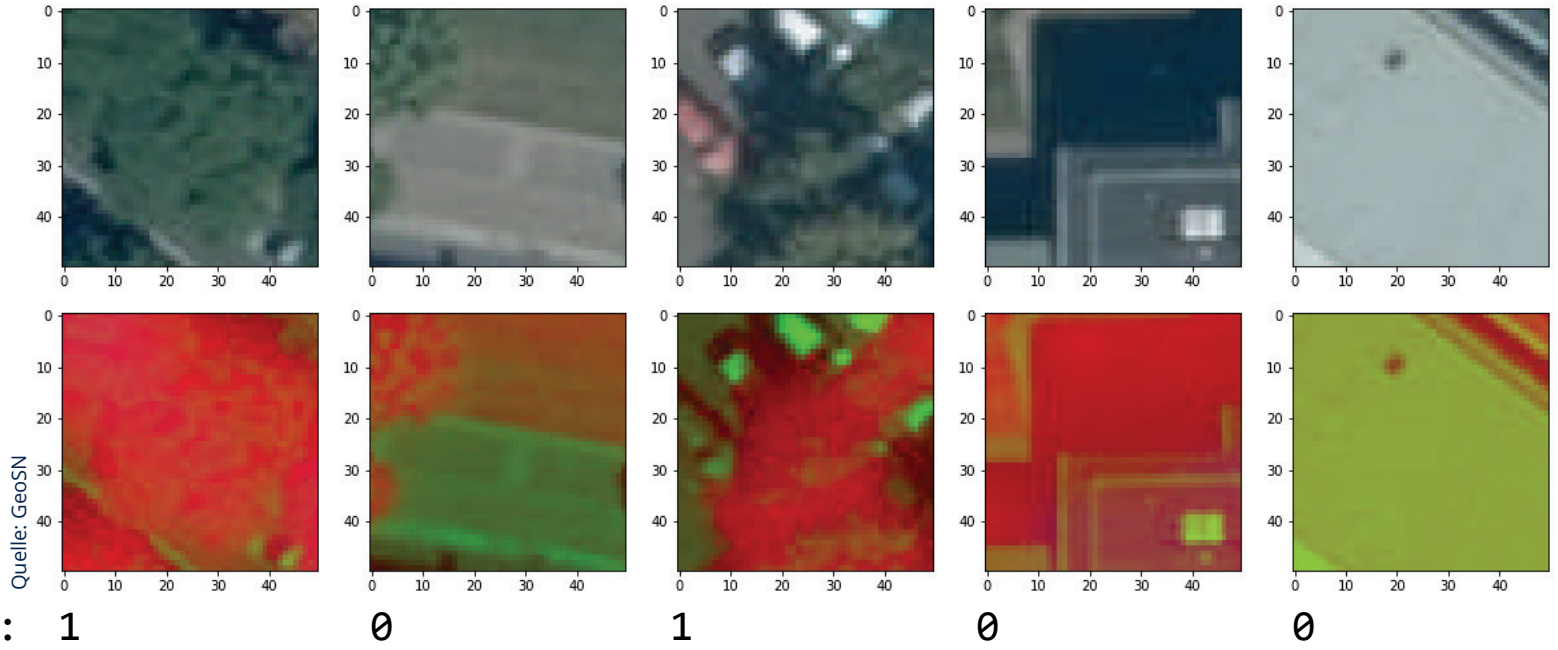

Methoden
Entwurf und Training der CNNs

3 verschiedene CNNs:

- CNN1: Unterscheidung Baum / nicht-Baum (binäre Klassifikation)
- **CNN2: Baumgattung** (Klassifikation, 5 Klassen)

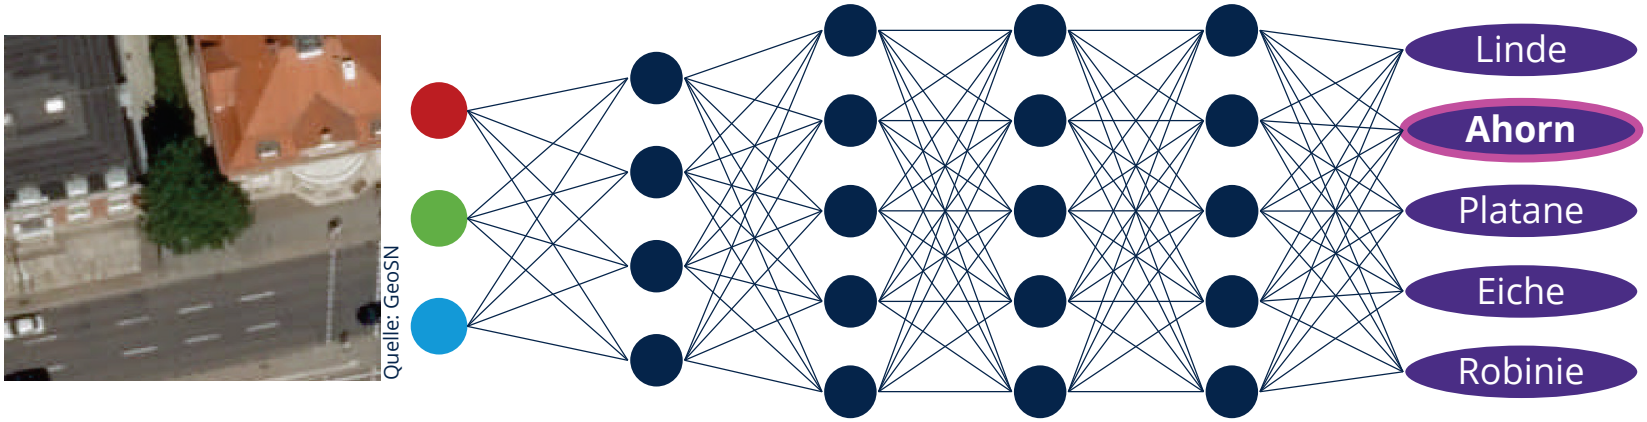

Methoden
Entwurf und Training der CNNs

3 verschiedene CNNs:

- CNN1: Unterscheidung Baum / nicht-Baum (binäre Klassifikation)
- **CNN2: Baumgattung** (Klassifikation, 5 Klassen)

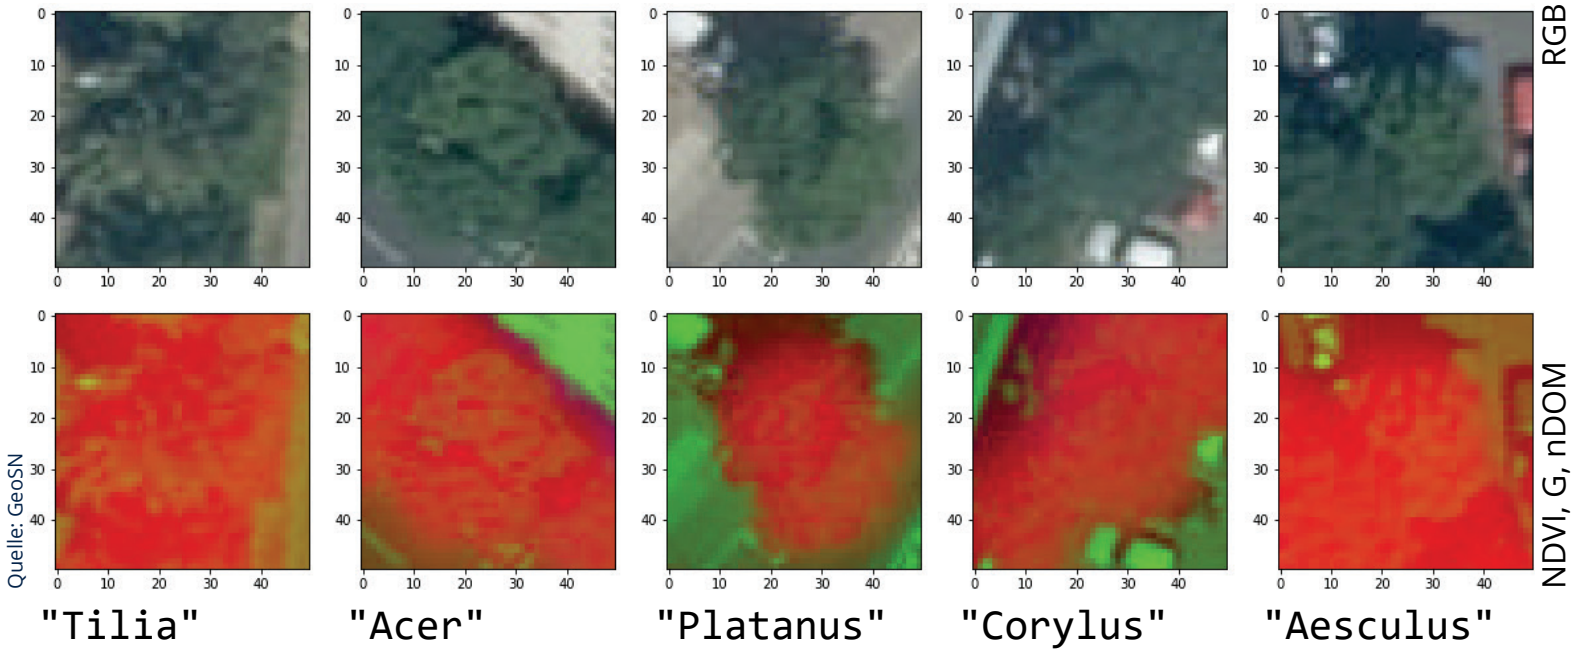

Methoden
Entwurf und Training der CNNs

3 verschiedene CNNs:

- CNN1: Unterscheidung Baum / nicht-Baum (binäre Klassifikation)
- CNN2: Baumgattung (Klassifikation, 5 Klassen)
- **CNN3: Baumalter, -höhe, Kronendurchmesser** (Regression)

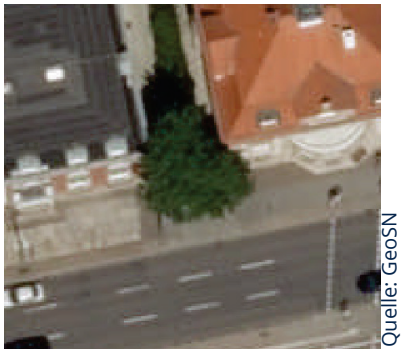

Quelle: GeoSN

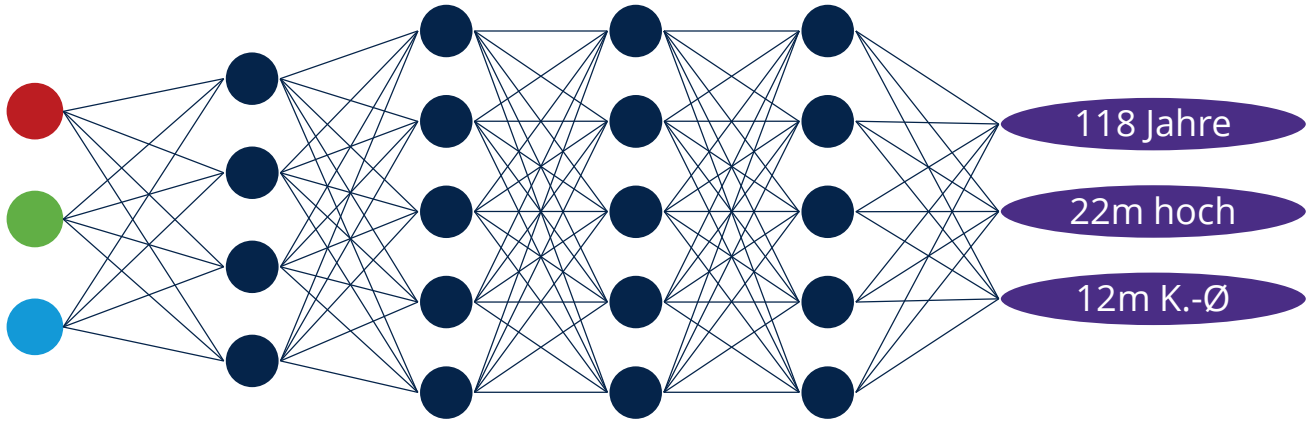

Methoden
Entwurf und Training der CNNs

3 verschiedene CNNs:

- CNN1: Unterscheidung Baum / nicht-Baum (binäre Klassifikation)
- CNN2: Baumgattung (Klassifikation, 5 Klassen)
- **CNN3: Baumalter, -höhe, Kronendurchmesser** (Regression)

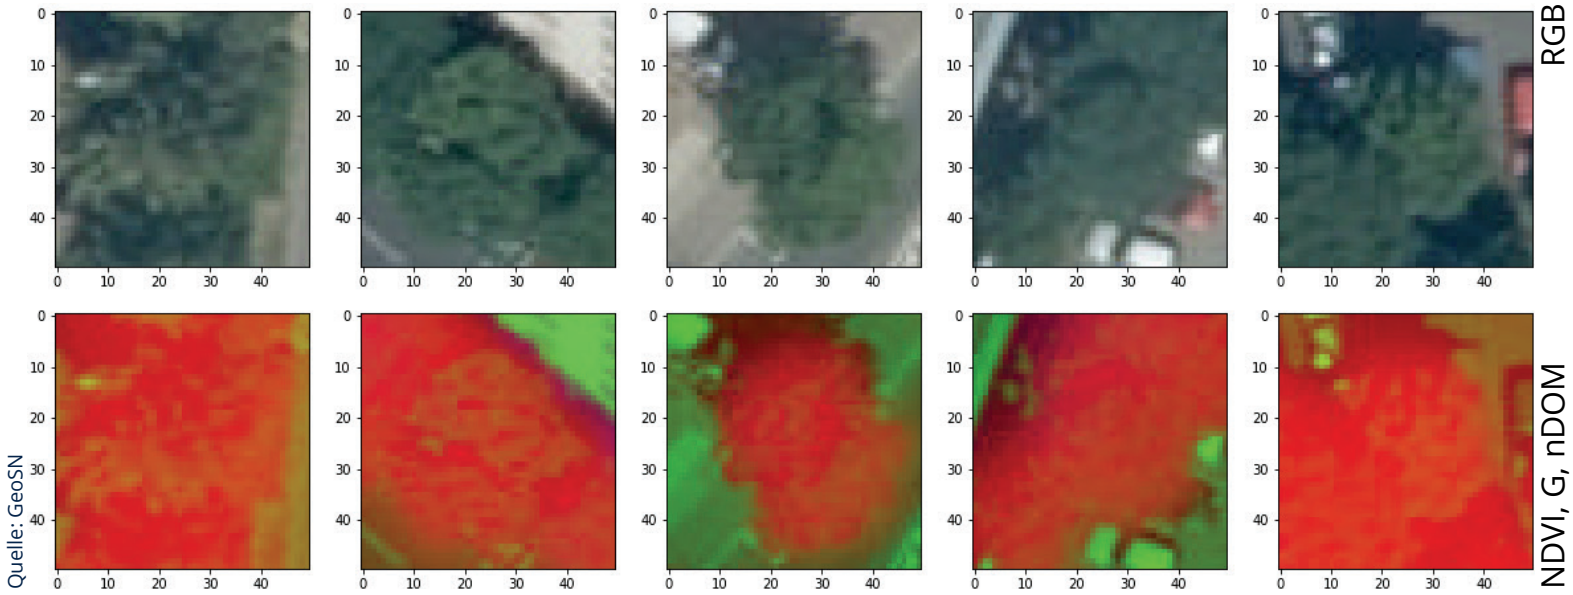

Alter:	26	88	18	19	19
Höhe:	14.0	12.0	11.0	12.0	10.0
Kronendm.:	7.0	9.0	8.0	8.0	7.0

Methoden
Anwendung der CNNs

Eingabeformate: 24x24, 50x50, 100x100 Pixel

↝ Problem: **Originaldaten** in sehr viel größerem Format (z. B. 10.000x10.000 Pixel)

► Verwendung eines **Suchfensters**

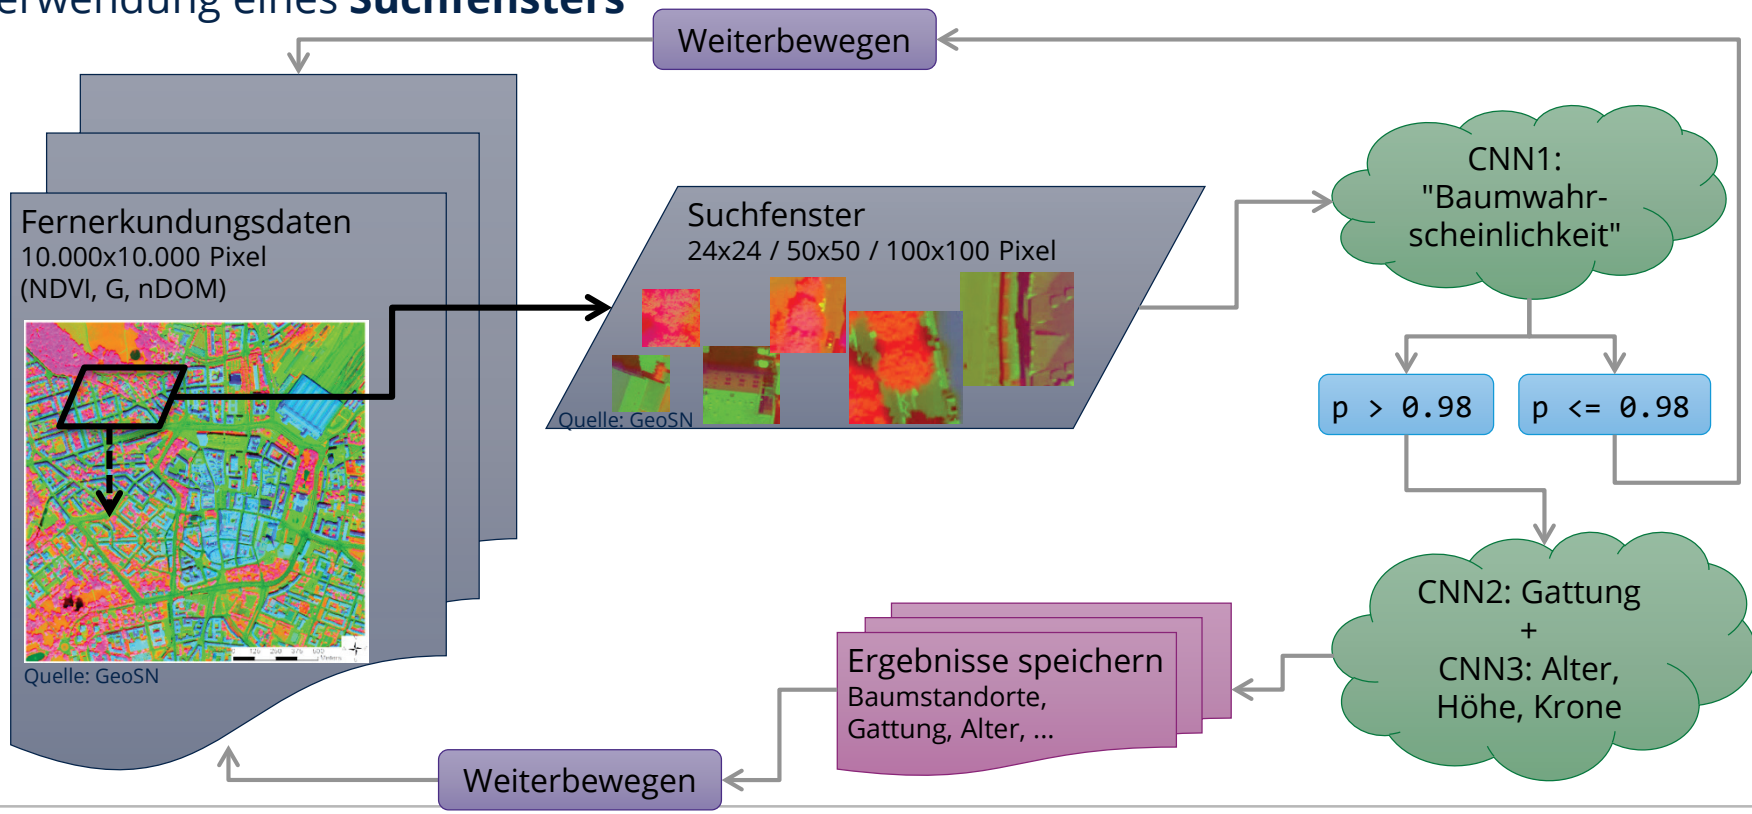

Ergebnisse
Evaluation der CNNs

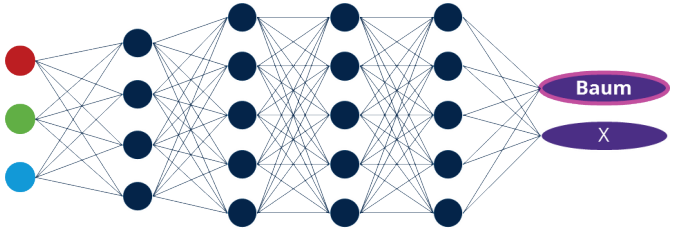

Mehrere Trainingsläufe mit verschiedenen Parametern, insgesamt 90 Modelle

► Vergleich anhand von **Testdaten** (10% der Beispieldaten), Auswahl der besten Modelle für jedes Eingabeformat

CNN1 (Baum/nicht-Baum): Gesamtgenauigkeit (*overall accuracy*)

	Format	Overall accuracy [%]
CNN1	24x24	97
	50x50	98
	100x100	**99**

Ergebnisse
Evaluation der CNNs

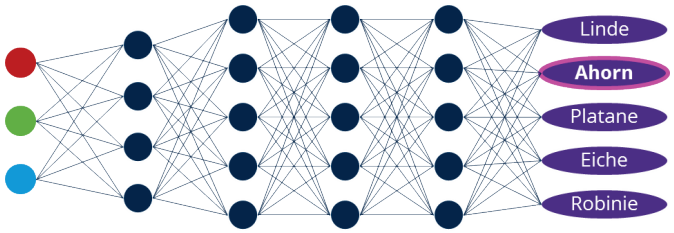

Mehrere Trainingsläufe mit verschiedenen Parametern, insgesamt 90 Modelle
► Vergleich anhand von **Testdaten** (10% der Beispieldaten),
Auswahl der besten Modelle für jedes Eingabeformat

CNN1: Gesamtgenauigkeit (*overall accuracy*)

CNN2 (Baumgattung): Gesamtgenauigkeit (*overall accuracy*) + Konfusionsmatrix

	Format	Overall accuracy [%]
CNN1	24x24	97
	50x50	98
	100x100	**99**

	Format	Overall accuracy [%]
CNN2	24x24	69
	50x50	65
	100x100	**72**

Ergebnisse
Evaluation der CNNs

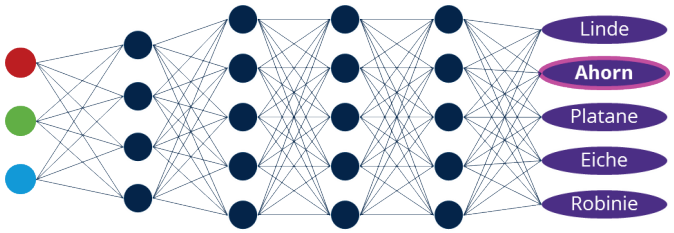

Konfusionsmatrix für **CNN2 (Baumgattung)**, Format 24x24

	Vorhersage						
	Acer	**Carpinus**	**Platanus**	**Pyrus**	**Tilia**	**Σ**	***user's accuracy***
Acer	0	0	14	1	41	56	0%
Carpinus	0	2	5	1	22	30	7%
Platanus	0	0	106	0	45	151	70%
Pyrus	0	0	5	13	31	49	27%
Tilia	0	0	28	4	320	352	91%
Σ	0	2	158	19	459		
producer's accuracy	-	100%	67%	68%	70%	***overall accuracy: 69%***	

Ergebnisse
Evaluation der CNNs

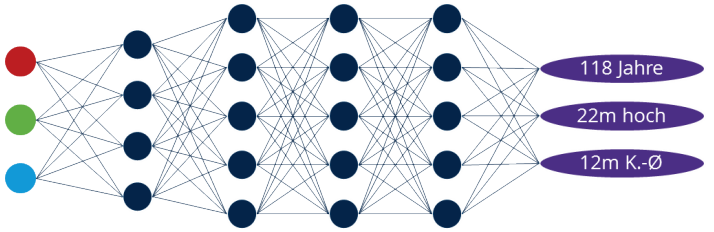

Mehrere Trainingsläufe mit verschiedenen Parametern, insgesamt 90 Modelle
► Vergleich anhand von **Testdaten** (10% der Beispieldaten),
Auswahl der besten Modelle für jedes Eingabeformat

CNN1: Gesamtgenauigkeit (*overall accuracy*)

CNN2: Gesamtgenauigkeit (*overall accuracy*) + Konfusionsmatrix

CNN3 (Baumalter, -höhe, Kronendurchmesser): *root mean squared error* (RMSE)

	Format	RMSE		
		Krone [m]	Höhe [m]	Alter [a]
CNN3	**24x24**	**1**	**1.8**	**9**
	50x50	1.5	3	28
	100x100	2.2	3.6	31

Ergebnisse
Anwendung der CNNs

Suchfenster-Ansatz
↯ Problem: keine Referenzdaten zur **Validierung** der Ergebnisse

CNN1: Baumstandorte = Mittelpunkte der positiv klassifizierten Bildausschnitte
► **Visualisierung** im Originalbild

CNN2/3: Ausgaben (Gattung, Baumalter, -höhe und Kronendurchmesser) können nicht verifiziert werden
► **statistische Auswertung**
► Visualisierung der Kronendurchmesser in Verbindung mit Baumstandorten

Ergebnisse
Anwendung der CNNs

Legende
- 100x100
- 50x50
- 24x24

CNN1: Baumstandorte
► Lokalisierung funktioniert für frei stehende Einzelbäume besser als in Beständen

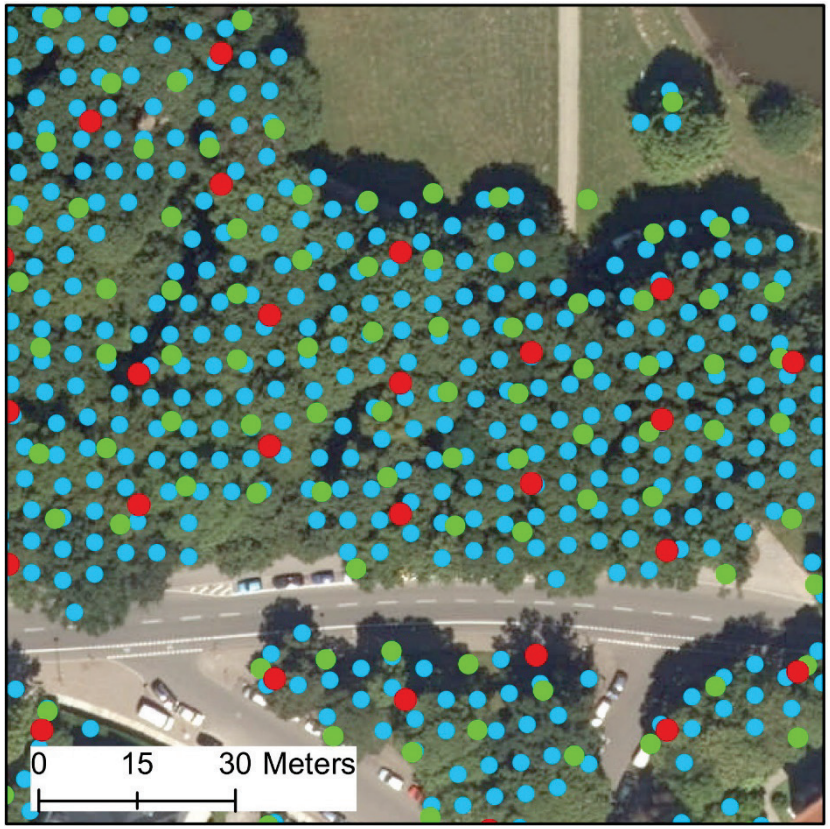

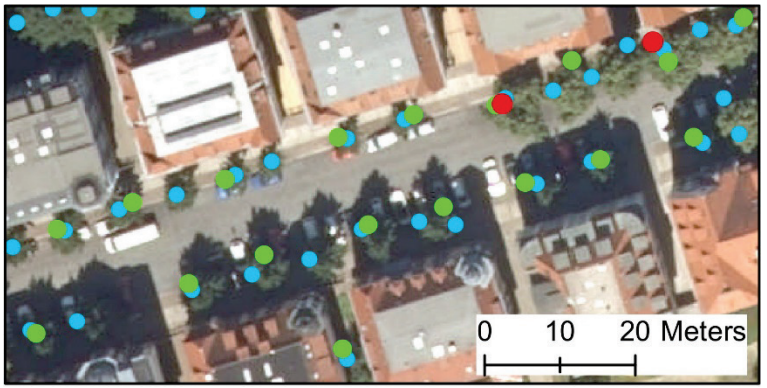

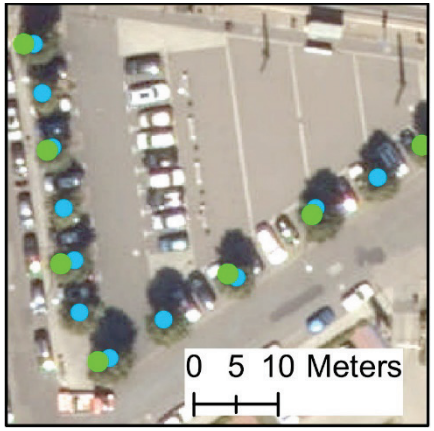

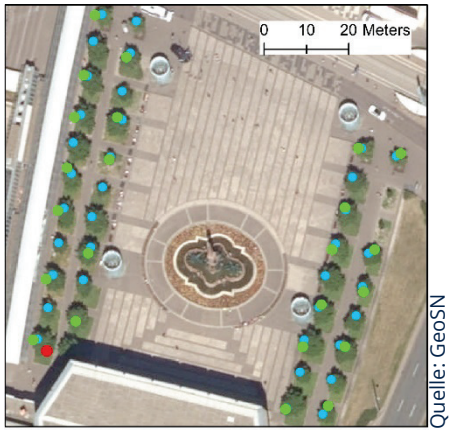

Quelle: GeoSN

Ergebnisse
Anwendung der CNNs

CNN2: Baumgattungen

► Vorhersagen beschränken sich auf dominante Gattungen (v. a. Linde)

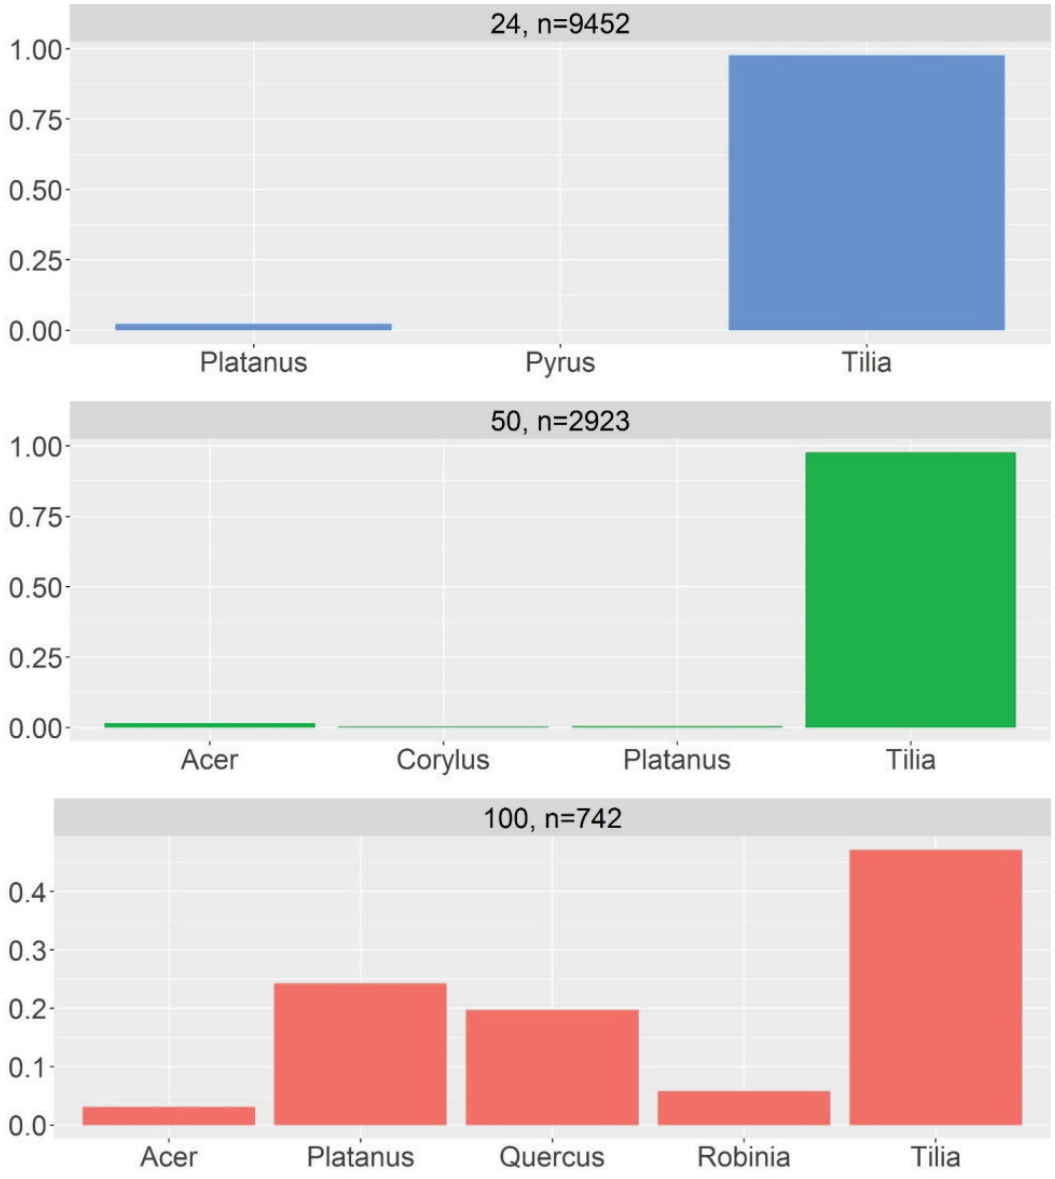

Ergebnisse
Anwendung der CNNs

CNN3: Baumalter, -höhe, Kronendurchmesser
► Vorhersagen beschränken sich auf bestimmten Wertebereich

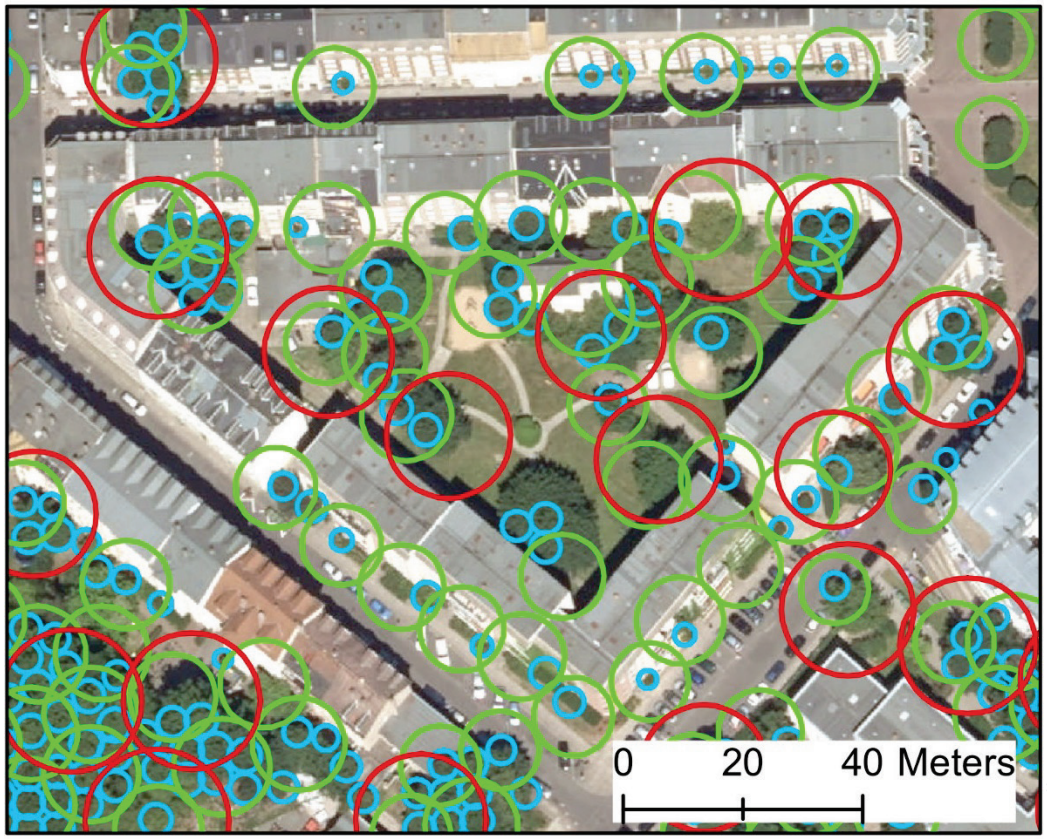

Fazit und Ausblick
Erkenntnisse aus der Pilotstudie

Anwendungspotenzial von CNNs,
z. B. zur (automatisierten) Erstellung / Ergänzung von Baumkatastern

☺ Nutzung **bestehender Daten** (kein zusätzlicher Aufwand für die Datenerhebung)

☺ **generischer Ansatz** (Ableitung verschiedener Informationen möglich)

☺ keine/kaum **Fachkenntnisse** nötig zur Datenvorverarbeitung

☹ ggf. lange **Rechenzeiten** bei der Anwendung der Modelle (Suchfenster-Ansatz)

☹ ggf. Erweiterung der **Datenbasis** nötig (mehr Beispieldaten)

Möglichkeiten zur **Übertragung** der Methode
… auf andere Gebiete/Städte, z. B. Dresden
… auf andere (städtische) Grünflächen, z. B. Wiesen, Gründächer

► Pilotstudie gibt Anhaltspunkte für **weitere Untersuchungen**

Kontakt

Amelie Haas M.Sc. (Referentin) | amelie.haas@tu-dresden.de

Dr.-Ing. Pierre Karrasch M.Sc. | pierre.karrasch@tu-dresden.de

Prof. Dr. Lars Bernard | lars.bernard@tu-dresden.de

TU Dresden, Professur für Geoinformatik
Helmholtzstr. 10
01069 Dresden

Bildquellen

Food and Agriculture Organisation of the United Nations (2018), Benefits of Urban Trees. Infografik. http://www.fao.org/resources/infographics/infographics-details/en/c/411348/ (09.04.2018).

Staatsbetrieb Geobasisinformation und Vermessung Sachsen (GeoSN). http://geosn.sachsen.de/