



Bayerische
Landesanstalt für Wald
und Forstwirtschaft

Gefördert durch:



aufgrund eines Beschlusses
des Deutschen Bundestages

NEUE PERSPEKTIVEN DER ERDBEOBACHTUNG


KIHBA – Künstliche Intelligenz für hochaufgelöste Baumartenerkennung

Peter Schauer, Bettina Felten, Nicole Schmeitzner, Dr. Adelheid
Wallner, Steffen Günster, Rudolf Seitz (IABG mbH / LWF)
27.06.2023, Bonn

01 Über das Projekt




- Es liegen nur **Schätzungen der Baumartenzusammensetzung** für Bayern vor, basierend auf der nationalen Waldinventur
- Die **Artenzusammensetzung ist nur für etwa 35 % der bayerischen Wälder bekannt**, wobei insbesondere für die Wälder in Privatbesitz (>50% der Waldfläche Bayerns) zu wenig Informationen vorliegen.
- Möglichst **flächige Kenntnis der Baumartenverteilung ist von großer Wichtigkeit** z.B. für Vorratsschätzungen und Aussagen über die Gesundheit des Waldes
- Hoffnungen hinsichtlich **KI-Verfahren**: die besondere Berücksichtigung von Spektralverhalten und Struktur / Textur könnte zum Erfolg führen



Ziele

- Entwicklung einer **KI-basierten Methodik** zur automatisierten Baumartenklassifikation auf Basis von Luftbildern und höchstauflösenden Satellitenbilddaten
- **Übertragbarkeit** soll für alle Waldflächen in Bayern sowie mit ggf. relativ geringem Mehraufwand für andere Regionen in Deutschland möglich sein
- Die Differenzierung der in Bayern (und Deutschland) **wirtschaftlich bedeutsamsten Baumarten** Fichte (*Picea abies*), Kiefer (*Pinus sylvestris*), Buche (*Fagus sylvatica*) und Eiche (*Quercus spec.*)

Nationale Waldinventur



Klassen




02 Datenaufbereitung




Trainingsdatengenerierung – Daten und Einflussfaktoren


- Umweltfaktoren
 - Einfluss auf Artenverteilung
- Bilddaten
 - Digitale True Orthophotos
 - 0,2 m x 0,2 m räumliche Auflösung
 - 4 Bänder (RGB+Nir)
 - 46 Befliegungszeitpunkte
 - 3 Jahre Befliegungszeitraum
- Weitere Datenquellen
 - Forstinventurdaten
 - UAV Bilddaten
 - nDOM Höhenmaske



Jahr der Befliegung




Befliegungszeitpunkt



Geländehöhe



Temperatur




Niederschlag

- AOI
 - 50m x 50m Quadrat um den Inventurpunkt
- Voraussetzung für eine AOI ist das Vorhandensein von:
 - Inventurdaten
 - UAV Daten
 - Verjüngungsmaske (aus nDOM, >12m Höhe, 1m x 1m)
- Es wurden 809 AOIs mit einer Fläche von insgesamt ca. 202 ha erstellt.



AOIs



Verteilung der AOIs




Trainingsdatengenerierung – Workflow





DOP (NIR,R,G)

~82000 Punkte !




~ 15500 Polygone
> 125ha Polygonfläche






Trainingsdatengenerierung – Feature/Label Datensatz

- Aufteilung der Features (Bilder) und Labels in Trainings-Validierungs- und Testdaten
 - 90% Training + Validierung / 10% Test
 - 90% Train / 10% Validierung
- Kriterien zur Auswahl der Testdaten
 - Ganze Fluglose (entweder Train/Val oder Test)
 - Anzahl der AOIs pro Fluglos
 - Räumliche Verteilung (Umwelteinflüsse)
 - Abdeckung mit dominanten Baumarten (Entsprechend dem Vorkommen, Eiche darf nicht unterrepräsentiert sein)
 - Berücksichtigung der verschiedenen Jahreszeiten (Monate) und Jahr der Befliegung
 - Unterschiedliche Bedeckungsgrade





Räumliche Verteilung der dominanten Baumarten in den Testdaten




03 Training



- Anforderung an die Methodik
 - Umgang mit Heterogenität der Bilddaten und geographischen Bedingungen
 - Großräumig anwendbar
 - **Keine Zeitreihe**
 - **Einzelbaum genaue Erfassung**
 - Auswahl der Deep Learning-Architektur
 - Semantische Segmentierung für pixelgenaue Abgrenzung und Klassifikation
 - Die lokale Nachbarschaft der Pixel soll vom Modell berücksichtigt werden (Strukturen, Texturen, Grauwerte)
 - Keine Instanz-Segmentierung (Trainingsdatenerzeugung zu aufwendig, Unterscheidung von Baumindividuen der gleichen Baumart teils schwierig (Label Uncertainty))
- U-Net basierter Ansatz







- Architektur
 - U-Net (klassisch)
 - U-Net 3+
- Modell Optimierung
 - Hyper-Parameter Tuning
 - Learning rate
 - Batchsize
 - Dropout
 - Layer weight initializers
 - Anzahl der Epochen
 - Minimale Anzahl der Filter
 - Filtergröße
 - Filter Faktor
 - Gewichtung der Klassen



Training – Optimierung (2)


- Datensatz
 - Segmentierte Label-Grenzen vs. manuell abgegrenzte Polygone
 - Erweiterung des Trainingsdatensatzes um aktuellere Befliegungen (2021, 2022)
 - Berücksichtigung der Güte der Bilddaten
 - Label Uncertainty (sicher, unsicher)
 - Augmentation (mit/ohne)
 - Zusätzliche Nutzung des nDOM als Eingabedatensatz



04 Ergebnisse




- Erkenntnisse aus den verschiedenen Experimenten (Konfigurationen) **vorläufig!**
 - Verbesserungen:
 - Image Augmentation
 - Verwendung des nDOM als zusätzlichen Eingangsdatensatz
 - Ausschließen der Bäume mit unsicherer Zuweisung der Baumart
 - Gewichtung der Klassen beim Training
 - Keine signifikante Verbesserung
 - Verwendung einer anderen Architektur (U-Net 3+)
 - Verwendung der segmentierten Label-Grenzen (zwischen Bäumen und Umgebung)
 - Farbraumtransformation (YUV, YCbCr)
- Bisher liegen die Genauigkeiten hinter den Anforderungen



Konfigurationen				Pixel-based		Point-based (50cm Buffer)		
Erweiterter Datensatz	nur sichere Bäume	nDOM	Data Augmentation	F1	IOU	Accuracy	Accuracy Bu, Ei, Fi, Kie	Accuracy Laub / Nadel
			x	0.59	0.44	0.57	0.65	0.88
x	x	x	x	0.64	0.49	0.61	0.73	0.88
x		x	x	0.62	0.48	0.59	0.69	0.89
x		x		0.59	0.44	0.50	0.61	0.85
x	x		x	0.62	0.47	0.61	0.70	0.88

Ergebnisse – Überblick




- Erkenntnisse aus den verschiedenen Experimenten (Konfigurationen)
 - Verbesserungen:
 - Image Augmentation
 - Verwendung des nDOM als zusätzlichen Eingangsdatensatz
 - Ausschließen der Bäume mit unsicherer Zuweisung der Baumart
 - Gewichtung der Klassen beim Training
 - Keine signifikante Verbesserung
 - Verwendung einer anderen Architektur (U-Net 3+)
 - Verwendung der segmentierten Label-Grenzen (zwischen Bäumen und Umgebung)
 - Farbraumtransformation (YUV, YCbCr)
- Bisher liegen die Genauigkeiten hinter den Anforderungen






Klasse	Precision	Recall	F1
Buche (Bu)	0.46	0.63	0.53
Eiche (Ei)	0.17	0.22	0.19
Fichte (Fi)	0.76	0.79	0.78
Kiefer (Kie)	0.83	0.79	0.81
Totholz (TH)	0.72	0.32	0.44
s. Laubholz (sLbh)	0.34	0.28	0.31
s. Nadelholz (sNdh)	0.51	0.14	0.22

Ergebnisse – Positive Beispiele

Laub-/Nadelwald-trennung



Differenzierung Fichte und Kiefer



Ergebnisse – Fehlklassifikation

Keine Trennung Buche
Eiche










Image RGBI_540000_5548000_2019_118



Buche als Fichte
klassifiziert trotz guter
Bildqualität




- **Auflösung (zu wenig Baumarten spezifische Strukturen)**
- **Artefakte**
- Anzahl der Trainingsdaten (z. B. Eiche)
- Anzahl der Klassen vs. Trainingsdaten
- Sehr heterogene Mischklassen (sonstiger Laubwald, sonstiger Nadelwald)
- (Label-Daten)




Vergleich mit anderen Ansätzen

Beloiu, M.; Heinzmann, L.; Rehush, N.; Gessler, A.; Griess, V.C. Individual Tree-Crown Detection and Species Identification in Heterogeneous Forests Using Aerial RGB Imagery and Deep Learning. *Remote Sens.* 2023, 15, 1463. <https://doi.org/10.3390/rs15051463> ↗

- Vergleichbarkeit der Ergebnisse
 - U-Net vs. Detektor Ansatz
 - Keine gemeinsamen Testdaten
 - Schwierig, aber Aussage zu Größenordnungen
- Ziel
 - Ursachenfindung und Einordnung der Ergebnisse
 - Auflösung (10cm vs. 20cm)
 - Artefakte (DOP vs. tDOP)
- Umsetzung der Vergleichs noch nicht abgeschlossen
 - Punkte in Bounding Boxen umgewandelt (wie in Paper)
 - Erste Experimente durchgeführt



□ Bu
□ Ei
□ Fi
□ Kie



Detected trees: □ Spruce □ Pine □ Beech
○ Ground truth

Tree detection in a mixed forest. Beloiu et al. (2023)

05 Ausblick



Weitere Schritte

- Weiter gefasstes Hyper-Parameter Tuning (auf noch leistungsfähiger Hardware)
- Abschluss des Vergleiches zur Einordnung der Ergebnisse und Ursachenfindung
- Bewertung der Einflussfaktoren
- Domain Adaption (neue Regionen, neue Bilddaten)



Ihr Kontakt

Peter Schauer

Phone: +49 351 8923 127

E-Mail: schauer@iabg.de

Web: www.iabg.de

IABG mbH

Abteilung Geospatial Solutions

Dr. Adelheid Wallner

Phone: +49 8161 4591 143

E-Mail: Adelheid.Wallner@lwf.bayern.de

Bayerische Landesanstalt für
Wald und Forstwirtschaft (LWF)
Abteilung 1 Informationstechnologie