



Standortmonitoring und Aktivitätsdetektion von Windenergieanlagen mit Planet und Sentinel-2 Daten

Anwendungslabor für Künstliche Intelligenz und Big Data am Umweltbundesamt

Philipp Gärtner
Claudius Wehner
Jan Siegismund
Johannes Albert
Johannes Zschache




Standortmonitoring

Aktivitätsdetektion



Work in Progress




Marktstammdatenregister (MaStR) der Bundesnetzagentur

Der Ausbau der Windkraft

Im Jahr 2022 in Betrieb gegangene Windkraftanlagen an Land und Leistung dieser Anlagen in Gigawatt



Verschieben Sie den Regler. Stand: 31.12.2022



Quelle: Marktstammdatenregister

rdn.de

Streit über Abstandsregeln | Wie Bayern den Windkraftausbau blockiert

ZEIT ONLINE

Windkraftwerke

Hier könnten all die Windräder stehen

Um die Energiewende zu schaffen, braucht Deutschland Zehntausende neue Windräder. Platz gibt es genug, zeigt unsere Datenauswertung. Welche Standorte infrage kommen.


Von Paul Blicke, Christian Endt, Veronika Fritz, Maria Mast, Julius Tröger und Benja Zehr

19. April 2023, 10:11 Uhr / 292 Kommentare /

Standort wäre zulässig	
Nächste Siedlung mindestens zehnfache Höhe des Windrads entfernt	
Gemeinde:	Bad Iburg
Nabenhöhe:	305 m
Rotor (F):	90 m
Bruttoleistung:	2,3 MW
In Betrieb seit:	15.11.2006

Welche Windkraftstandorte wären mit der 10H-Regel noch zulässig? Der

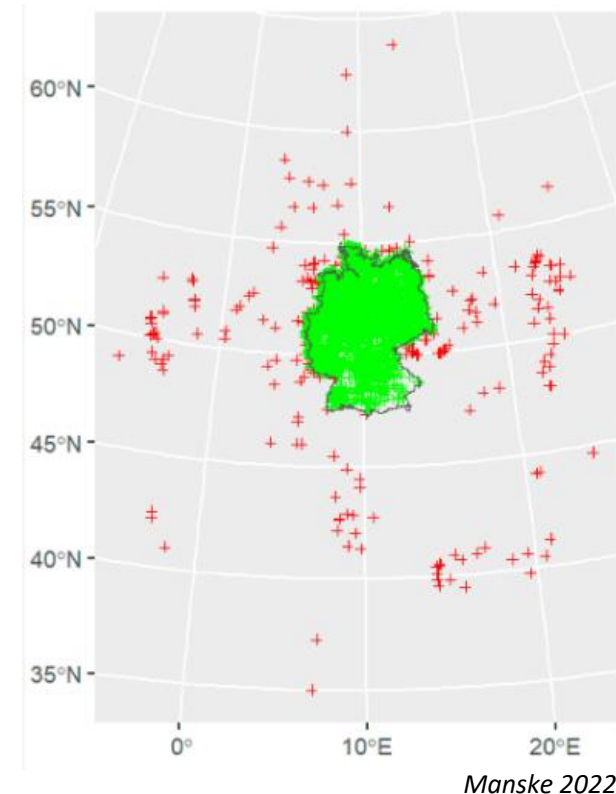
<https://www.spiegel.de/wissenschaft/mensch/windkraftausbau-in-bayern-und-deutschland-so-blockiert-die-10-h-regel-die-energiewende-a-452401ea-aac0-41ad-9b20-504b74a6f2d2>




<https://www.zeit.de/wissen/umwelt/2023-04/energiewende-deutschland-windkraft-ausbau-windraeder-flaechen-karte>

Marktstammdatenregister (MaStR) der Bundesnetzagentur

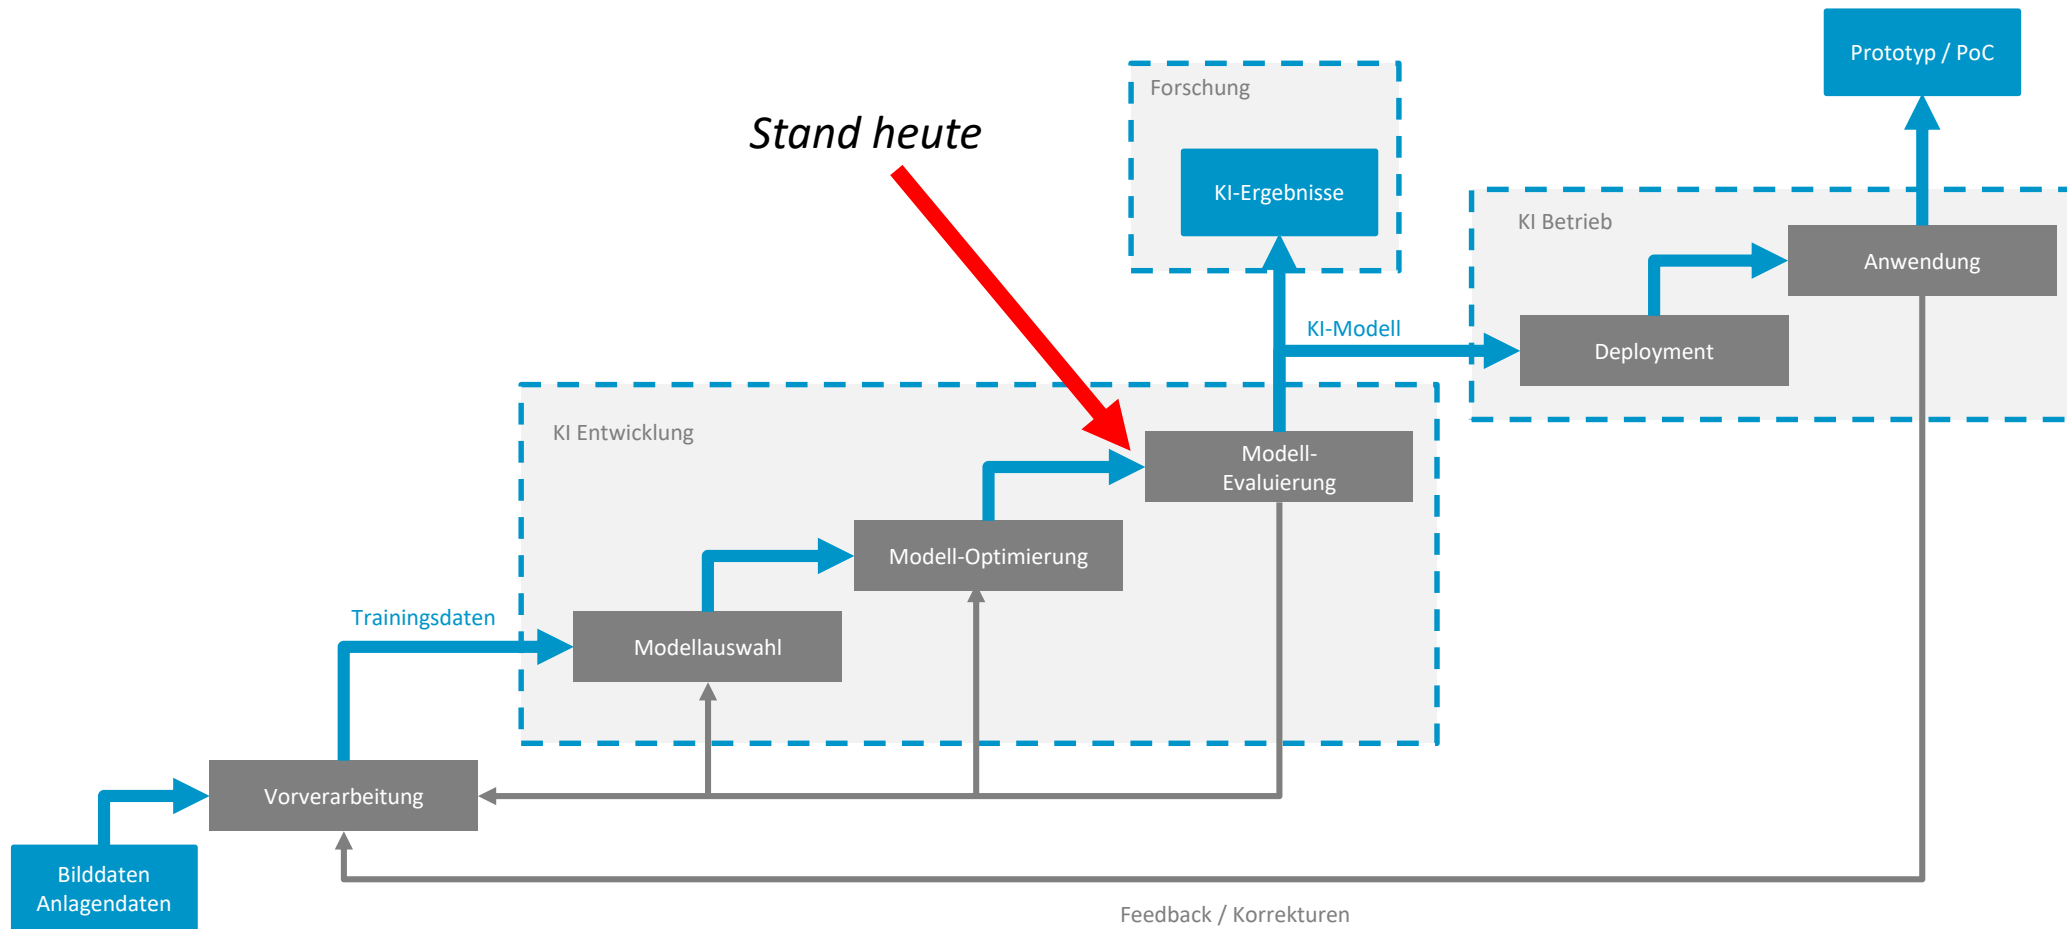
- MaStR enthält alle Stammdaten von Stromerzeugungsanlagen (u.a. Windenergieanlagen)
- **Problem:** inhomogene Genauigkeiten der Anlagenstandorte
- Genaue Anlagenstandorte sind notwendig für
 - strategische Energieplanung,
 - ein effektives Repowering,
 - Aus- bzw. Rückbau
 - der nahtlosen Integration von Windenergie in das Stromnetz und
 - die Ermittlung der Standortgüte im Rahmen von Ertragsmodellen & Verfügbarkeit von Flächen



Marktstammdatenregister (MaStR) der Bundesnetzagentur



Workflow




nach Bostelmann 2023

Satellitendaten - Planet Basemaps

- monatlich erstellte Produkte
- “best scene on top” Methode
- Oberflächenreflektanz
- 16 bit / 8 Bänder
- 4.77 x 4.77 m Pixelgröße
- Monate: April, Juni, August, Oktober
- Jahre: 2021 / 2022
- 2844 Kacheln (Dtl.)

- Neue Basemaps können über BKG geordert werden
 - Rahmenvertrag



Trainingsdaten

<https://zenodo.org/records/6920931>


Open Access Data Descriptor

Geo-Locations and System Data of Renewable Energy Installations in Germany


by David Manske^{1,*}, Lukas Grosch¹, Julius Schmiedt¹, Nora Mittelstädt¹ and Daniela Thrän^{1,2}

¹ Department of Bioenergy, Helmholtz Centre for Environmental Research GmbH—UFZ, Permoserstraße 15, 04318 Leipzig, Germany
² Bioenergy Systems Department, DBFZ Deutsches Biomasseforschungszentrum gGmbH, Torgauer Str. 116, 04347 Leipzig, Germany
* Author to whom correspondence should be addressed.

Data 2022, 7(9), 128; <https://doi.org/10.3390/data7090128>



- BBOXen für 2 Klassen
- 2.000 Trainingsbilder (x 4 Monate x 2 Jahre)
- 250 Bilder ohne WEA (x 4 Monate x 2 Jahre)
- WEA Verteilung mit breiter Streuung im Bild

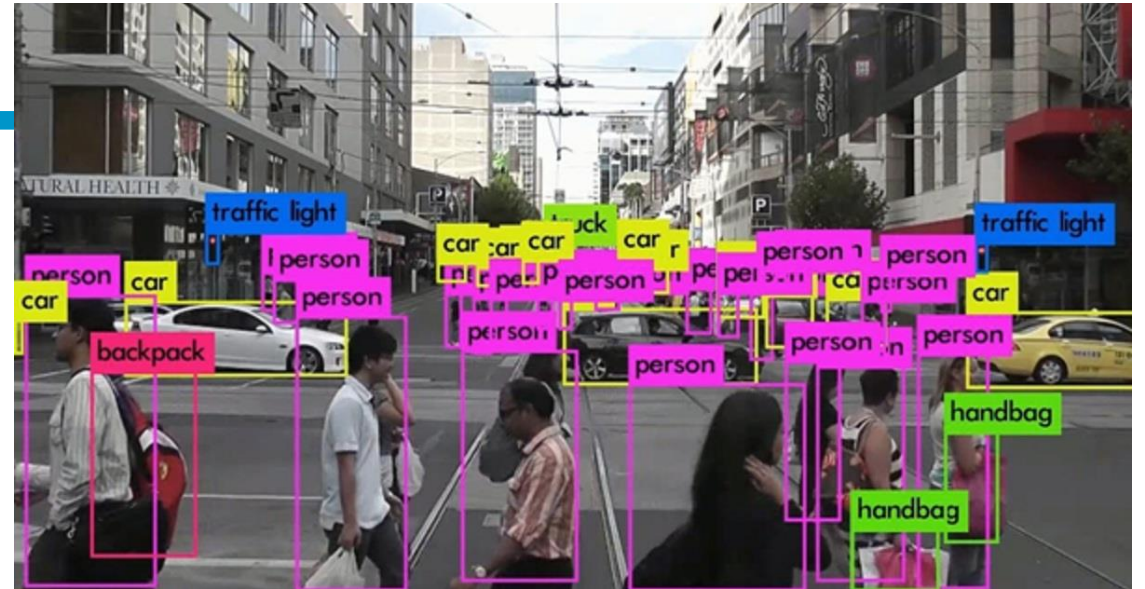


1. WEA mit Schatten
2. WEA ohne Schatten

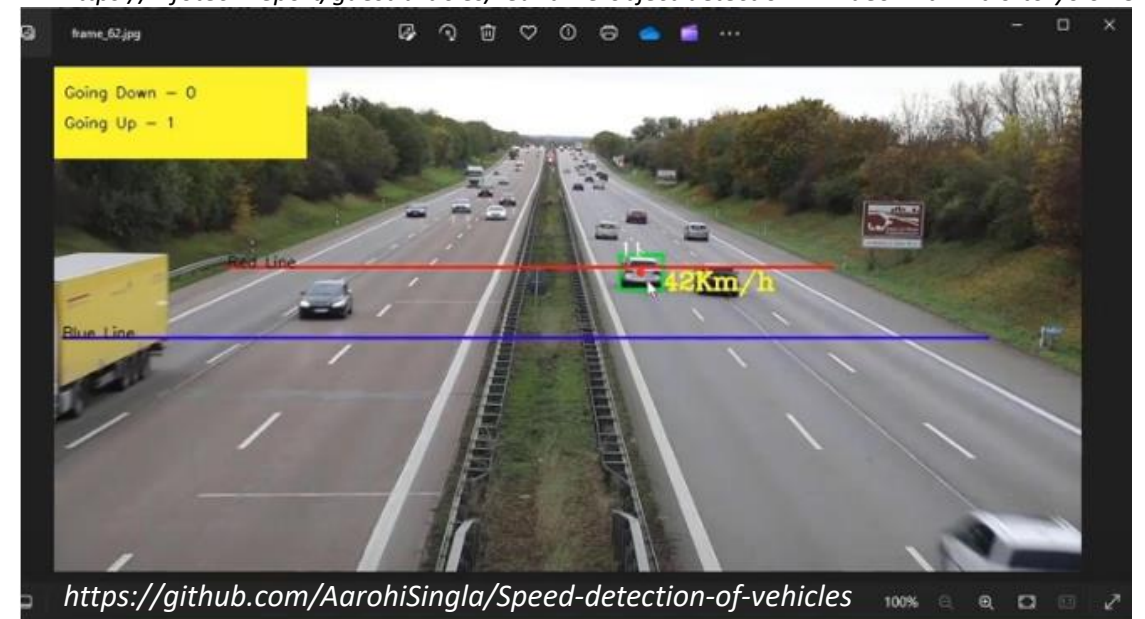
Modell

YOLO (You Only Look Once)

- hohe Verarbeitungsgeschwindigkeit
- beeindruckende Genauigkeit
- Open Source
- von *Ultralytics* unter der AGPL-3.0-Lizenz angeboten



<https://infotech.report/guest-articles/real-time-object-detection-in-video-with-intro-to-yolo-v3>



<https://github.com/AarohiSingla/Speed-detection-of-vehicles>

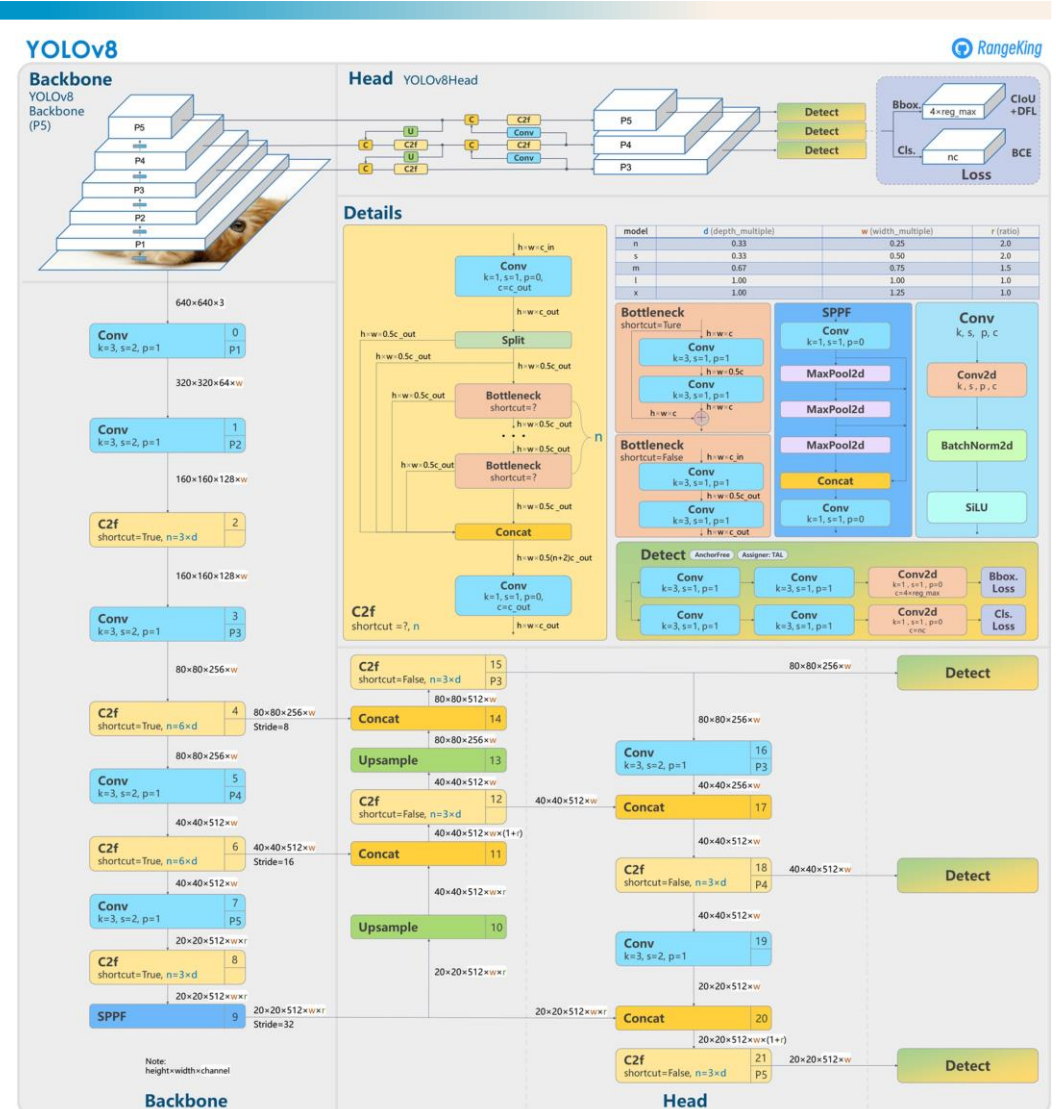
Modell

YOLO (You Only Look Once)

- hohe Verarbeitungsgeschwindigkeit
- beeindruckende Genauigkeit
- Open Source
- von *Ultralytics* unter der AGPL-3.0-Lizenz angeboten

Unterschiedliche Varianten

- sehr klein (n), klein (s), mittel (m), groß (l) und extra groß (x).
- Jede dieser Varianten bietet unterschiedliche Genauigkeitsraten und benötigt unterschiedlich viel Zeit zum Trainieren



<https://github.com/ultralytics/ultralytics/issues/189>

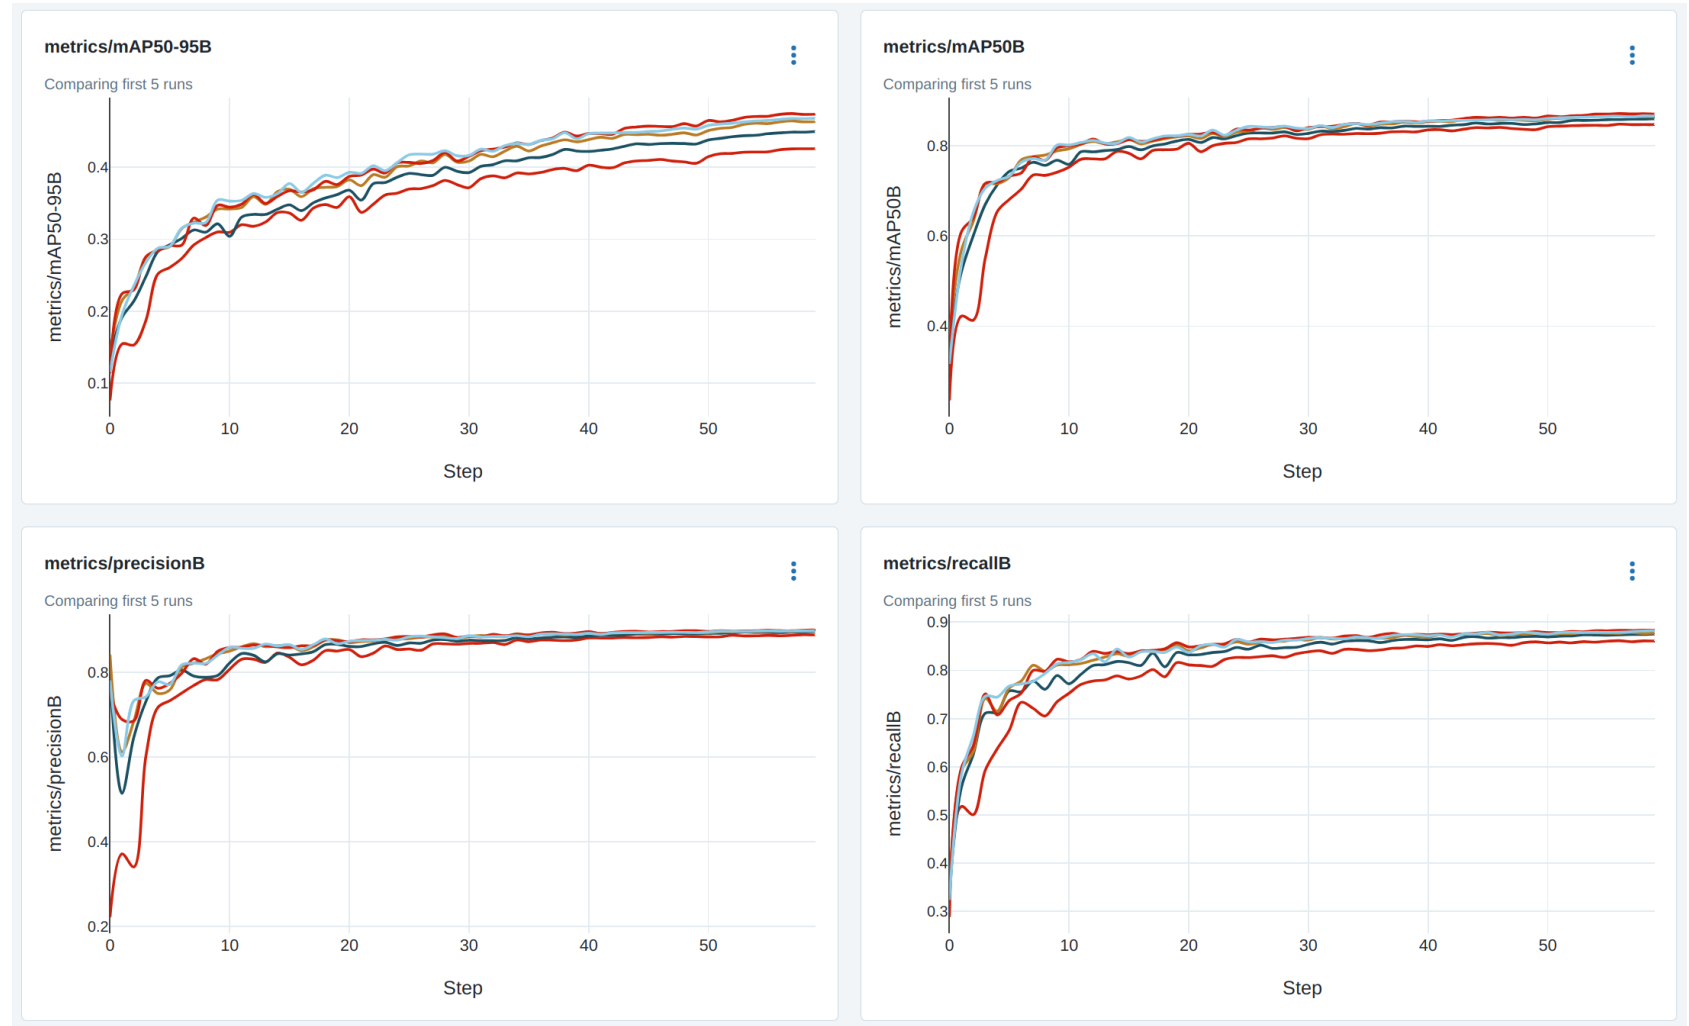
Ergebnisse




Ergebnisse

Epochen: 60 | Batch size: 10

- Precision und Recall sind nach 60 Epochen in etwa gleich groß
- deutet darauf hin, dass unser Modell eine ausgewogene Leistung zwischen der korrekten Vorhersage von positiven Beispielen und der Minimierung von falschen Positiven erbringt



Ergebnisse



Ergebnisse



mAP 50B => Durchschnitt der durchschnittlichen Präzisionen
0.86 – 0.87 (für 2 Klassen)

YOLO betrachtet ein Objekt als erkannt, wenn:

Konfidenz-Score: > 0.5 +

Überlappungsbereich (Intersection over Union, IoU): > 50%

Ausblick

- Bessere Kontrolle der Trainingsdaten Qualität
- Mehr nicht gelabelt Daten (Hochspannungsleitungen, Schornsteine, Baukräne)
- Mehr Trainingsdaten generieren ⇔ Modell-Optimierung ⇔ Modell Evaluation
- Von Bounding Box zu Punktkoordinate
- Abgleich zwischen unseren Ergebnissen mit daten aus Markstammdatenregister

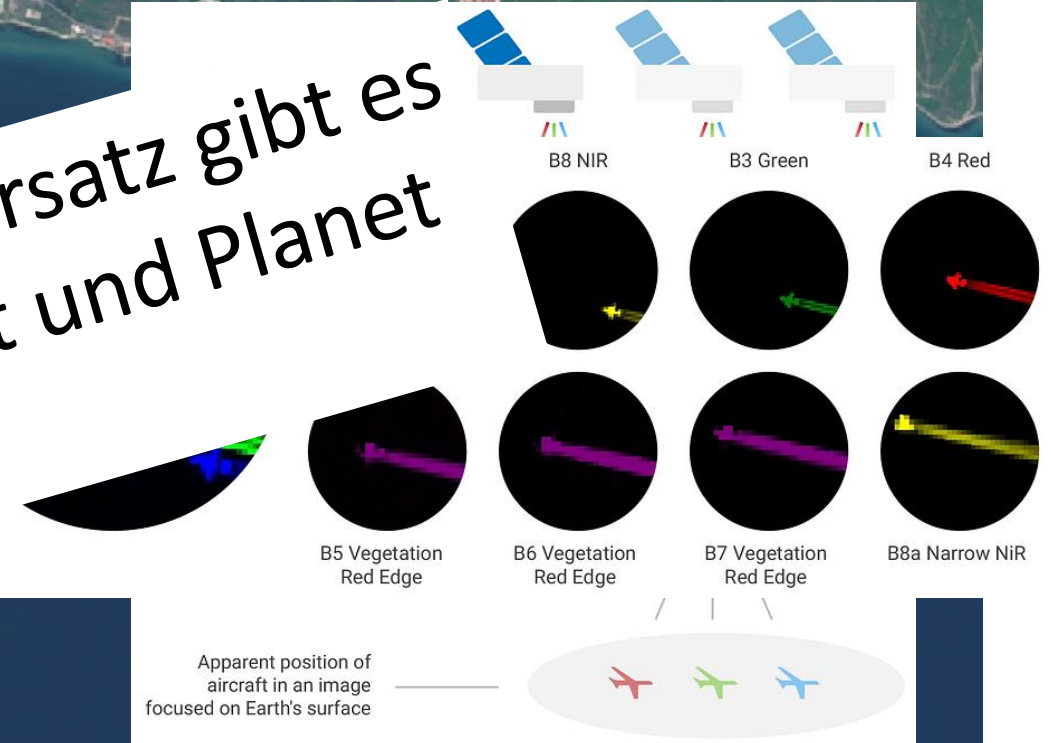
Zeitlicher Versatz zwischen Spektralbändern



Den zeitlichen Versatz gibt es auch bei Landsat und Planet Daten






Inter-band Pair	Temporal offset between bands (seconds)
B08 / B02	0.264
B03 / B08	0.264
B11 / B02	1.483
B06 / B11	0.057
B06 / B02	1.525
B07 / B06	0.265

Detecting Moving Trucks on Roads Using Sentinel-2 Data (Fisser 2022)



<https://medium.com/google-earth/planespotting-465ee081c168>

Aktivitätsdetektion




Ist es möglich die Aktivität von Windenergieanlagen in einer Sentinel-2 Szene zu erkennen?


Bachelorarbeit: Felix Nahrstedt

Trainingsdaten


- Download von 4.800 WEA Positionen von OpenStreetMap
- Download von 4.800 Sentinel-2 RGB Bildkacheln mit GEE
 - 40 x 40 Pixel (400 x 400 m)



Blau



Grün




Rot




RGB


- Wolkenmaskierung & Histogramm Matching
- .GIF Erstellung
- Labelling Entscheidung basiert auf Schattenbewegung
- aktiv (2996) | nicht aktiv (110) | nicht erkennbar (1662)



Trainingsdaten



Gute Qualität




Wolken




Wald



Grenzen




Wasserfläche



Vegetation



Windrichtung



andere Obj.


Modellergebnisse

```
from torchvision import models
import torch.nn as nn

model = models.densenet121(pretrained =
↳ True)

model.classifier =
↳ nn.Sequential(nn.Linear(1024,512),
↳ nn.ReLU(), nn.Dropout(0.2),
↳ nn.Linear(512,256), nn.ReLU(),
↳ nn.Dropout(0.1), nn.Linear(256,2))
```

- Modell: vortrainiertes DenseNet-121
- Ausgabeschicht: eine lineare Schicht mit 1024 Merkmalen, die mit einem sequentiellen Modell reinitialisiert wird, um die Ausgabe in zwei Klassen aufzuteilen.



- Trotz hoher Genauigkeit (99.4 %) macht das Modell während des Trainings noch zu viele Fehler
- Lernt das Modell die Trainingsdaten zu genau (Overfitting)?
- Ausreißer oder besonders schwierig zu klassifizierende Beispiele?

Verschlusssensibilität



Der Mensch schaut beim Labeling auf die Bewegung des Schattens. Das Modell fokussiert auf die Bewegung der Windräder & Turbine.




(a) Brandenburg, Germany

(b) Maojing, China

(c) Adama, Ethiopia

(d) Cuchilla de Peralta, Uruguay



Ausblick

- Alternative zu manuellem Labeling finden
- Log Daten von WEA Betreibern als Input
- Modell Robustheit verbessern
- Inferenz => Deutschland => Europa

KI-Anwendungslabor@uba.de

Vielen Dank für Ihre Aufmerksamkeit! Gibt es Fragen?

Eine Initiative des



Bundesministerium
für Umwelt, Naturschutz, nukleare Sicherheit
und Verbraucherschutz

Umgesetzt durch das

Umwelt 
Bundesamt