

PreTrainAppEO

Pre-Training Applicability in Earth Observation

Neue Perspektiven der Erdbeobachtung:
4. Symposium zur angewandten Satellitenerdbeobachtung

Projektdetails

Kooperation: dida Datenschmiede GmbH, Lehrstuhl für Methodik der Fernerkundung der TU München



Konrad Schultka
dida



Jan Macdonald
dida



Tiago Sanona
dida



Joana Reuss
TUM

Finanzierung: Bundesministerium für Wirtschaft und Klimaschutz (BMWK)

Projektzeitraum: 05/2021 – 04/2025

Ziel: Steigerung der Effizienz und Attraktivität von KI-Anwendungen in der Erdbeobachtung

Ansatz: Methodenentwicklung zur besseren Generalisierbarkeit vortrainierter KI-Modelle auf verschiedene Standardanwendungen im Bereich der Erdbeobachtung

Welche Probleme gibt es bei der Anwendung von KI-Methoden in der Erdbeobachtung?

Deep-Learning-Modelle: hohe Kosten durch zeitintensive Datenbeschaffung

Deep-Learning-Modelle

- benötigen meist sehr große, annotierte Trainingsdatensätze, um akzeptable Leistungen zu erreichen
- lassen sich schwer auf neue Szenarien anpassen

Situation in der Erdbeobachtung

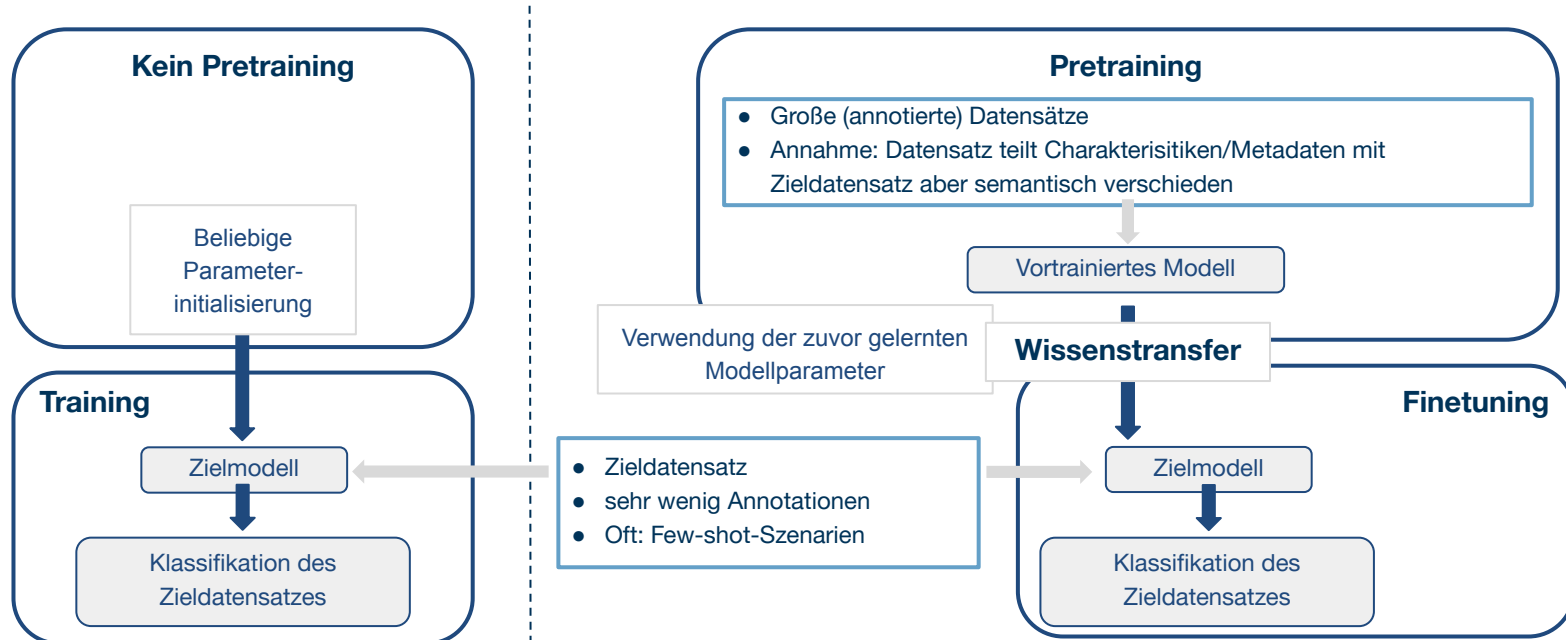
- Große Unterschiede zu anderen Bilddaten
- Große Datenmenge
- Annotierte Datensätze meist knapp
 - Fachwissen nötig
 - Globale Unterschiede
 - Zeitintensiv

Resultierende Probleme

- Zeitintensive Datenbeschaffung
 - Hoher Trainingsaufwand
- ➡ Hohe Kosten

Wie können wir auf kleinen Datensätzen trotzdem eine gute Performance erhalten?

Transfer-Learning: Leistungssteigerung durch Wissenstransfer



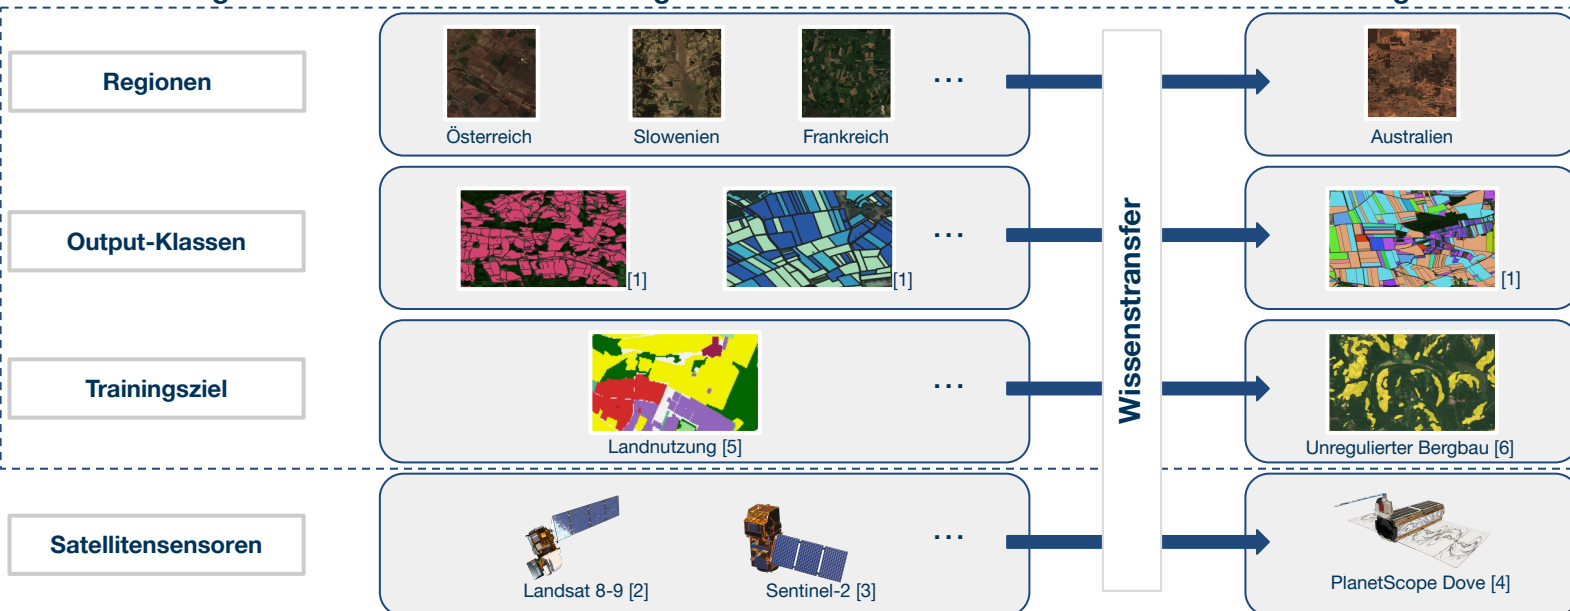
Wie sieht Transfer-Learning in der Erdbeobachtung aus?

Transfer-Learning: Leistungssteigerung durch Wissenstransfer

Generalisierung über

Pretraining: datenreich

Finetuning: datenarm





Welche Pretraining-Ansätze betrachten wir?

Ziel des Pretrainings: gute Generalisierbarkeit auf neue Szenarien

Reguläres Pretraining

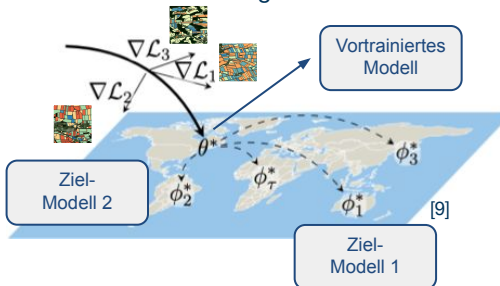
- Reguläres Training auf großen, annotierten Datensätzen



* Quelle der annotierten Bilddaten: [1]


Meta-Learning

- Gezielte Verwendung der in den Daten enthaltenen Metadaten
- Schnelle Anpassung auf unbekannte Datensätze durch optimale Parameterinitialisierung [7]
- Hauptanwendungsszenario: Few-shot-Learning



Self-supervised Pretraining

- Pretraining erfolgt auf nicht-annotierten Daten
- Automatisiertes Generieren von Annotationen



Bisherige Ergebnisse: Meta-Learning hilfreich in Few-Shot-Szenarien

Klassifizierung von Agrarfeldern in Europa: Generalisierung über Output-Klassen

Meta-Learning Algorithmen

- Sehr aufwendig und schwer zu tunen
- Zeigen beste Ergebnisse für Few-Shot-Szenarien
- Differenz zu beliebiger Parameterinitialisierung bisher teilweise nur marginal

Accuracy (%) auf dem Testset

Max. Anzahl Datenpunkte	Beliebige Parameterinitialisierung	Reguläres Pretraining	Meta-Learning ¹
10 pro Klasse	74,2	79,6	83,9
20 pro Klasse	80,1	83,3	83,9
100 pro Klasse	88,7	91,4	89,8

¹ Gezeigt wird der jeweils beste Meta-Learning Algorithmus.

Kontakt



Konrad Schultka
konrad.schultka@dida.do



Jan Macdonald
jan.macdonald@dida.do



Tiago Sanona
tiago.sanona@dida.do



Joana Reuss
joana.reuss@tum.de

www.dida.do

www.asg.ed.tum.de/lmf

Quellen

- [1] Schneider, M., and Korner, M.. (2022). EuroCrops.
- [2] Kreuzinger, R., Chase, T., Irons, J. R., Radcliff, M.. (2022). NASA/Goddard Space Flight Center Conceptual Image Lab Pavel. https://svs.gsfc.nasa.gov/10812#media_group_30207. Accessed: 2023-06-09.
- [3] Rama. (2012). Model of Sentinel 2. This file is licensed under the [Creative Commons Attribution-Share Alike 2.0 France](#) license.
- [4] A PlanetScope satellite. PlanetScope Image courtesy.
- [5] Johnson, N., Treible, W., and Crispell, D. 2022. OpenSentinelMap: A Large-Scale Land Use Dataset Using OpenStreetMap and Sentinel-2 Imagery. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR) Workshops* (pp. 1333-1341).
- [6] Moritz Besser. (2023). AMSSpotter Demo. <https://dida.do/de/asmspotter-demo>. Accessed: 2023-06-05
- [7] Chelsea Finn, Pieter Abbeel, and Sergey Levine. Model-agnostic meta-learning for fast adaptation of deep networks. In Doina Precup and Yee Whye Teh, editors, *Proceedings of the 34th International Conference on Machine Learning*, volume 70 of *Proceedings of Machine Learning Research*, pages 1126–1135. PMLR, 06–11 Aug 2017.
- [8] Aniruddh Raghu, Maithra Raghu, Samy Bengio, and Oriol Vinyals. Rapid learning or feature reuse? Towards understanding the effectiveness of MAML. *CoRR*, abs/1909.09157, 2019.
- [9] Marc Rußwurm, Sherrie Wang, Marco Körner, and David Lobell. (2020). Meta-Learning for Few-Shot Land Cover Classification.