

Skalierbare KI-Methoden für globales Waldmonitoring (AI4Forest)


Prof. Dr. Fabian Gieseke
Lehrstuhl für Maschinelles Lernen und Data Engineering
Institut für Wirtschaftsinformatik
Universität Münster

Lehrstuhl für Maschinelles Lernen und Data Engineering (MLDE)

Web: <https://mlde-lab.github.io>




Dr. Una Kelly



Sven Ligensa




Dr. Jens Lechtenbörger



Gabriel Belouze



Dr. Nina Herrmann




Minjoo Park




Jan Stenkamp



Jan Pauls



Dr. Karsten Schrödter



Dr. Leonard Papenmeier



Jorunn Mense



Julia Seither




Dr. Aurora Sugandha




Prof. Dr. Fabian Gieseke




Forschung (MLDE)




Machine Learning



Beispiel I (TinyAloT)



Data Engineering



Beispiel II (AI4Forest)

Wälder → Holz: Wichtiger Rohstoff + CO₂-Senke

Quelle: <https://pixabay.com>





Wälder & Forstwirtschaft

- Wälder liefern Holz, das unverzichtbar ist für ...
 - ▶ **Bauwesen und Architektur:** Gebäude, Dächer, Türen, ...
 - ▶ **Möbel und Innenausstattung:** Tische, Stühle, Betten, Regale, ...
 - ▶ **Papier und Verpackung:** Papier, Karton, ...
 - ▶ **Energieerzeugung:** Brennholz, Pellets, ...
 - ▶ **Industrieprodukte:** Sperrholz, Spanplatten, ...
 - ▶ **Transport und Logistik:** Paletten, Kisten, ...
 - ▶ ...



Wälder & Forstwirtschaft

- Wälder liefern Holz, das unverzichtbar ist für ...
 - ▶ **Bauwesen und Architektur:** Gebäude, Dächer, Türen, ...
 - ▶ **Möbel und Innenausstattung:** Tische, Stühle, Betten, Regale, ...
 - ▶ **Papier und Verpackung:** Papier, Karton, ...
 - ▶ **Energieerzeugung:** Brennholz, Pellets, ...
 - ▶ **Industrieprodukte:** Sperrholz, Spanplatten, ...
 - ▶ **Transport und Logistik:** Paletten, Kisten, ...
 - ▶ ...
- Wälder wandeln **Kohlendioxid** (CO₂) in organisches Material um und speichern den Kohlenstoff im Holz über Jahrzehnte/Jahrhunderte. Sie stellen eine der wichtigsten **Kohlenstoffsinken** der Erde dar!



tagesschau

Sendung verpasst?



[Startseite](#) ▶ [Wissen](#) ▶ [Klima & Umwelt](#) ▶ Erhebung von Satellitendaten: Immer mehr Wald geht verloren



Erhebung von Satellitendaten

Der deutsche Wald schrumpft

Stand: 23.09.2025 16:40 Uhr

Lange Dürrephasen, viele Schädlinge: Der Baumbestand in Deutschland wird immer kleiner. Das zeigen neue Satellitendaten. Besonders betroffen: Regionen, in denen viele Fichten gepflanzt wurden.

Der Baumbestand in Deutschland schrumpft. In der Zeit zwischen Herbst 2017 und Herbst 2024 gingen mehr als 900.000 Hektar Wald verloren - das hat das Deutsche Zentrum für Luft- und Raumfahrt (DLR) [anhand von Satellitendaten ausgewertet](#) . Das sind rund 8,5 Prozent der deutschen Waldfläche. Nach Angaben des DLR haben sich die Verluste seit 2021 fast


Bedrohungen: Waldbrände





tagesschau

Sendung verpasst?



Zerstörung tropischer Wälder

"Das ist weltweit Alarmstufe Rot"

Stand: 21.05.2025 12:01 Uhr

Die Zerstörung tropischer Wälder schreitet in hohem Tempo voran: Eine Fläche fast so groß wie Bayern ging laut einer Studie 2024 verloren. Das ist demnach der höchste Wert seit 20 Jahren.

Vergangenes Jahr hat die Zerstörung von tropischem Regenwald den höchsten Stand seit 20 Jahren erreicht. Wie [eine Studie](#) des World Resources Institute (WRI) und der Universität Maryland zeigt, wurden 6,7 Millionen Hektar tropischer Urwald zerstört. Das entspricht fast der Fläche



Philippe
Ciais

LSCE



Alexandre
D'Aspremont

CNRS - ENS



Fabian
Gieseke

UNIVERSITY OF MÜNSTER



Sebastian
Pokutta

ZUSE INSTITUTE, BERLIN






Cornelius
Senf

TU MUNICH

*"AI4Forest aims at the use of **scalable AI methods** in the field of **sustainability** as well as at the development of **conceptually novel and highly-efficient AI methods**. It will, hence, have a direct impact on the national AI strategies of both France and Germany. AI4Forest aims at intensifying ongoing research activities conducted by the project partners with the goal of establishing a **long-term collaboration** between the hosting institutes, and more generally between France and Germany, in this interdisciplinary and data-driven field."*

Projektübersicht

	PM					2023		2024		2025		2026		2027	
Work Package	LSCE	CNRS	WWU	ZIB	TUM	Q3	Q4	Q1	Q2	Q3	Q4	Q1	Q2	Q3	Q4
WP 1 Data Curation and Infrastructure															
WP1.1: Data Curation	8	6	3	3	1										
WP1.2: Storage and Computing Infrastructure	4	6	9	6	1										
WP 2: High-Resolution AI-Based Forest Maps															
WP2.1: Detecting Individual Trees	9	10	9	3	1										
WP2.2: Quantification of Forest Biomass	9	6	12		2										
WP2.3: Global High-Resolution Forest (Biomass) Maps	9	6	9		2										
WP2.4: Detecting Forest Disturbances Over Time	12	10	3	6	2										
WP3: Scalable Machine Learning for Global-Scale Monitoring															
WP3.1: Accelerated Training of (Sparse) Neural Networks		14		12											
WP3.2: Compute and Data-Efficient Deep Inference		10	9												
WP3.3: High-Performance Distributed Training and Inference		5	12	9											
WP3.4: Global-Scale Forest Maps	12	8	9	6	2										
WP 4: Project and Dissemination	3	3	3	3	1										
Sum / Milestones	66	84	78	48	12	M1	M2		M3		M4	M5		M6	M7
														M8	M9
															M10



Welche Aktie ist das?

Bildquelle: <https://www.finanzen.net>



Maschinelles Lernen → High-Performance Computing



Bildquelle: <https://www.nvidia.com/en-us/deep-learning-ai/>

DEEP LEARNING AI

WHAT'S NEW

INDUSTRIES ▼

DEVELOPER

SOLUTIONS


EDUCATION

AI STARTUPS

EVERY INDUSTRY IS AWAKENING TO AI.

Deep learning is already being used in the automotive industry, healthcare, and many more.

LEARN MORE




SEE YOUR LIFE'S WORK REALIZED, WITH AI.

Preventing disease. Building smart cities. Revolutionizing analytics. These are just a few things

Tiefe Neuronale Netzwerke?

Bildquelle: Christian Szegedy, Wei Liu, Yangqing Jia, Pierre Sermanet, Scott Reed, Dragomir Anguelov, Dumitru Erhan, Vincent Vanhoucke und Andrew Rabinovich. *Going Deeper with Convolutions*. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2015.



Moderne Architekturen besitzen oft **Milliarden von Parametern** → „Erstellung“ der Modelle kann extrem rechenintensiv sein!

Tiefe Neuronale Netzwerke: Training (Teil der Vorlesung „Machine Learning“)

Batch Gradient Descent

Require: Set $T = \{(\mathbf{x}_1, y_1), \dots, (\mathbf{x}_n, y_n)\} \subset \mathbb{R}^d \times \mathcal{Y}$, loss function L , and learning rate $\eta > 0$.

Ensure: Weights $\mathbf{W}$, $\mathbf{b}$ for the model $f(\mathbf{x}; \mathbf{W}, \mathbf{b})$

- 1: // small random values (e.g., normally distributed)
- 2: Initialize $\mathbf{W}$ and $\mathbf{b}$
- 3: **repeat**
- 4: // gradient of the cost function based on all training instances
- 5: Compute $\nabla C(\mathbf{W}, \mathbf{b}) = \frac{1}{n} \sum_{i=1}^n \nabla L(f(\mathbf{x}_i; \mathbf{W}, \mathbf{b}), y_i)$
- 6: // model parameter update
- 7: $(\mathbf{W}, \mathbf{b}) \leftarrow (\mathbf{W}, \mathbf{b}) - \eta \nabla C(\mathbf{W}, \mathbf{b})$
- 8: **until** stopping criterion is met

L1/L2 Regularization

One can also regularize the weights of a neural network. That is, one optimizes for


$$C(\mathbf{W}, \mathbf{b}) = \frac{1}{n} \sum_{i=1}^n L(f(\mathbf{x}_i; \mathbf{W}, \mathbf{b}), y_i) + \lambda (\|\mathbf{W}\|^2 + \|\mathbf{b}\|^2)$$

with regularization hyperparameter $\lambda \geq 0$. Typically: L1/L2 norm per layer


Tiefe Neuronale Netzwerke: Beispiel

Bildquelle: <https://poloclub.github.io/cnn-explainer/>

CNN EXPLAINER Learn Convolutional Neural Network (CNN) in your browser!









2014/2016 → Sentinel-1A/1B
(pro Tag: 4 TB)



2015/2017 → Sentinel-2A/2B
(pro Tag: 3,2 TB)



2016/2018 → Sentinel-3A/3B
(pro Tag: 6 TB)



2023 → Sentinel 4
(pro Tag: 2 TB)



2017/2021 → Sentinel 5
(pro Tag: 4 TB)



2020/2026 → Sentinel-6A/6B
(pro Tag: 0,3 TB)



2014/2016 → Sentinel-1A/1B
(pro Tag: 4 TB)



2015/2017 → Sentinel-2A/2B
(pro Tag: 3,2 TB)



2016/2018 → Sentinel-3A/3B
(pro Tag: 6 TB)



2023 → Sentinel 4
(pro Tag: 2 TB)



2017/2021 → Sentinel 5
(pro Tag: 4 TB)



2020/2026 → Sentinel 6
(pro Tag: 1 TB)

> 20 TB
(≈ 20 Laptops)
pro Tag



Was ist das?!

Satellitendaten: PlanetLabs → Scannt unsere Erde 1x pro Tag!

Bildquelle: PlanetLabs



Satellitendaten: PlanetLabs → Scannt unsere Erde 1x pro Tag!

Bildquelle: PlanetLabs



Satellitendaten: PlanetLabs → Scannt unsere Erde 1x pro Tag!

Bildquelle: PlanetLabs




Satellitendaten: PlanetLabs → Scannt unsere Erde 1x pro Tag!

Bildquelle: PlanetLabs



Satellitendaten: PlanetLabs → Scannt unsere Erde 1x pro Tag!

Bildquelle: PlanetLabs



120 Nano-Satelliten ($10\text{cm} \times 10\text{cm} \times 30\text{cm}$)

Satellitendaten: PlanetLabs → Scannt unsere Erde 1x pro Tag!

Bildquelle: PlanetLabs



120 Nano-Satelliten ($10\text{cm} \times 10\text{cm} \times 30\text{cm}$)





Auflösung?
→ 10cm und besser!

Satellitendaten: Anwendungen




Energie



Landwirtschaft




Smart Cities



Krisenmanagement




Finanzwesen



Logistik/Schifffahrt



Klimawandel




Infrastruktur



Covid-19



Bildquellen: PlanetLabs (<https://www.planet.com/gallery>; CC BY-NC 2.0)

Beispiel I: ?




Beispiel I: Bäume zählen!

Daten: (c) DigitalGlobe Inc.




Beispiel I: Bäume zählen!

Daten: (c) DigitalGlobe Inc.



Brandt, M., Tucker, C., Kariryaa, A., Rasmussen, K., Abel, C., Small, J., Chave, J., Rasmussen, L., Hiernaux, P., Diouf, A., Kergoat, L., Mertz, O., Igel, C., Gieseke, F., Schöning, J., Li, S., Melocik, K., Meyer, J., Sinno, S., Romero, E., Glennie, E., Montagu, A., Dendoncker, M., & Fensholt, R. *An unexpectedly large count of trees in the West African Sahara and Sahel*, Nature, 2020.

Beispiel I: Bäume zählen!



Reiner, F., Brandt, M., Tong, X., Skole, D., Kariyaa, A., Ciaia, P., Davies, A., Hiernaux, P., Chave, J., Mugabowindekwe, M., Igel, C., Oehmcke, S., Gieseke, F., Li, S., Liu, S., Saatchi, S. S., Boucher, P., Singh, J., Taugourdeau, S., Dendoncker, M., Song, X.-P., Mertz, O., Tucker, C., und Fensholt, R. **More than one quarter of Africa's tree cover is found outside areas previously classified as forest**, Nature Communications, 2023.

Beispiel II: 3D-Höhenmodell (von Bäumen)



Bild: Masterarbeit (Jan Pauls)

Beispiel II: 3D-Höhenmodell (von Bäumen)




Bild: Masterarbeit (Jan Pauls)

Beispiel II: ChatGPT → 3D-Höhenmodell (von Bäumen)?

ChatGPT 5.1 ▾



What can I help with?

Verarbeite Sentinel-Daten und erstelle ein 3D-Höhenmodell (canopy height map) für die gesamte Welt!



Beispiel II: ChatGPT → 3D-Höhenmodell (von Bäumen)?

ChatGPT 5.1 ▾

Share ...

Verarbeite Sentinel-Daten und erstelle ein 3D-Höhenmodell (canopy height map) für die gesamte Welt!

Thought for 1m 1s >

Challenge accepted 😊 — aber zuerst die ehrliche Antwort:

So eine globale 10 m-Canopy-Height-Map aus Sentinel-Daten gibt es inzwischen schon, und zwar u.a.:


- **ETH Global Canopy Height 2020, 10 m (Lang et al., Nature Ecology & Evolution 2023)** – fusionsbasiertes Modell (GEDI + Sentinel-2, probabilistische CNN).
 - Auf GEE als: `users/nlang/ETH_globalCanopyHeight_2020_10m_v1` verfügbar. [Gee Community ... +1](#)
- Andere globale/nahezu globale Produkte:
 - **Landsat+GEDI 30 m, jährlich** (Potapov et al. 2021). [sciencedirect.com](#)
 - **1 m Global Canopy Height (meta_trees)**, aus sehr hochauflösender Optik für 2009–2020. [Gee Community ...](#)
 - Neuere Arbeiten zu temporalen Dynamiken und kontinentalen Zeitreihen (z.B. 10 m CH-Zeitreihe 2019–2022 für Europa). [maximiser.org +1](#)

Wenn dein Ziel ist „jetzt sofort ein globales 3D-Höhenmodell nutzen“, dann würdest du heute typischerweise einfach **einen dieser Datensätze laden** und ggf. mit einem DEM kombinieren.

1. „Fertige Lösung“ nutzen (ETH Global Canopy Height)

a) In Google Earth Engine laden

In GEE (Code Editor):



ChatGPT can make mistakes. Check important info. See [Cookie Preferences](#)

Beispiel II: ChatGPT → 3D-Höhenmodell (von Bäumen)?

ChatGPT 5.1 ▾

Share ...

1. „Fertige Lösung“ nutzen (ETH Global Canopy Height)

a) In Google Earth Engine laden

In GEE (Code Editor):

```
js
// ETH Global Canopy Height 2020 (10 m)
var ch = ee.Image('users/nlang/ETH_GlobalCanopyHeight_2020_10m_v1');

// Darstellungsparameter
var vis = {min: 0, max: 50};

// Kartenzentrum setzen (z.B. Amazonas)
Map.setCenter(-60, -5, 6);

// Layer hinzufügen
Map.addLayer(ch, vis, 'Canopy height 2020 (ETH, 10m)');
```

Copy code

Export einer Kachel als GeoTIFF:

```
js
Export.image.toDrive({
  image: ch,
  description: 'canopy_height_tile',
  region: geometry, // deine Region
  scale: 10,
  maxPixels: 1e13
});
```

Copy code

b) 3D-Visualisierung

1. Canopy-Height-Raster + DEM nach GeoTIFF exportieren (z.B. Copernicus GLO-30 oder SRTM).

3m25 esa.tif



2. In QGIS:

+ Ask anything



ChatGPT can make mistakes. Check important info. See [Cookie Preferences](#)

Beispiel II: ChatGPT → 3D-Höhenmodell (von Bäumen)?

ChatGPT 5.1 ▾

}};

Copy code

Share ...

b) 3D-Visualisierung

1. **Canopy-Height-Raster + DEM** nach GeoTIFF exportieren (z.B. Copernicus GLO-30 oder SRTM).

gs25.exe -i

2. In QGIS:

- „Raster → 3D-Ansicht“ bzw. QGIS-3D verwenden.
- CHM als Höhenraster, optional mit Schummerung/Orthofoto als Textur.

3. Alternativ: CHM in **CesiumJS** oder ähnliches pushen und als Web-Globe visualisieren.

Damit hast du faktisch dein **globales 3D-Höhenmodell der Baumkronen**, ohne selbst Petabytes Sentinel-2 zu verarbeiten.

2. Wenn du es *wirklich* selbst bauen willst: High-Level-Pipeline

Angenommen, du willst ein eigenes globales Sentinel-basiertes CHM aufsetzen (z.B. andere Zielgröße, Zeitreihe, neue Losses etc.):

Schritt 1 – Zieldefinition

- **Auflösung:** 10 m (S2-Native), evtl. 20 m re-sampling.
- **Zielgröße:** z.B. GEDI RH98 als „top-of-canopy height“. at30w = 1
- **Zeitpunkt:** Referenzjahr (z.B. 2020) oder Zeitserie (jährlich, multi-year median etc.).
- **Maske:** Waldmaske (z.B. ESA WorldCover, Global Forest Change, eigene Definition).

Schritt 2 – Eingangsdatensätze

- **Sentinel-2 L2A** global (BRDF/Top-of-Canopy korrigiert, cloud-masked).
- Optional **Sentinel-1** (VH/VV, Texturen) für Struktur in borealen/tropischen Wolkengürteln. geoservice.dlr.de = 1
- **GEDI L2A/L2B** (Height metrics, Qualitätsflags, Beam, Degradation-Handling).
- **DEM + Topographie:** Copernicus GLO-30, SRTM, Hangneigung, Exposition.
- **Hilfsdaten:** Klimazonen, Vegetationszonen, Land ↓ deckung.

Schritt 3 – Feature Engineering / Preprocessing

+ Ask anything



ChatGPT can make mistakes. Check important info. See [Cookie Preferences](#)

Beispiel II: ChatGPT → 3D-Höhenmodell (von Bäumen)?

ChatGPT 5.1 ▾

Share ...

- **DEM + Topographie:** Copernicus GLO-30, SRTM, Hangneigung, Exposition.
- **Hilfsdaten:** Klimazonen, Vegetationszonen, Landbedeckung.

Schritt 3 – Feature-Engineering / Preprocessing

- **S2 Zeitserien-Kacheln** (z.B. 120×120 px für 1,2×1,2 km):
 - saisonale Komposite (leaf-on, annual median, percentiles),
 - Spektralindizes (NDVI, NDRE, EVI, NBR, Textur).
- **GEDI-S2-Matching:**
 - GEDI footprints → Rasterisierung auf S2-Grid,
 - Qualitätsfilter (slope, sensitivity, degradation, beam type),
 - Aggregation pro Pixel oder Patch.

Schritt 4 – Modellierung

Typische Architekturen (global):

- **CNN/FCN/U-Net auf Patch-Ebene**, Input: S2-Kacheln (+ Koordinaten-Embedding), Output: Höhenraster + Unsicherheit (Varianz). Nico Leng · 1
- Alternativ/ergänzend **GBDT / RF** auf tabularen Features (Pixelweise).

Wichtige Punkte:

- Stratifizierte **Tile-CV** (z.B. 100×100 km Sentinel-Tiles, Biome-Strata). ETH Zürich
- **Loss-Design:**
 - Huber / quantile loss (für robuste/unsicherheitsbewusste Schätzungen),
 - ggf. explizite Regularisierung der Tall-Canopy-Biases (Underestimation-Problem).

Schritt 5 – Globales Inferenz-Setup

- **Tiling-Strategie:** z.B. Sentinel-2 MGRS-Tiles oder 1°-Grids.
- Pro Tile:
 - S2-Zeitserien laden (GEE, Sentinel Hub, DIAS, eigenes Data Lake),
 - Feature-Stack erzeugen,
 - Modell inference (GPU/TPU-Cluster).
- Output: **COG-GeoTIFFs** (10 m, tiled, compressor^h ↓, Uncertainty-Layer).

Schritt 6 – Validierung & Vergleich

+ Ask anything



ChatGPT can make mistakes. Check important info. See [Cookie Preferences](#)

Beispiel II: ChatGPT → 3D-Höhenmodell (von Bäumen)?

ChatGPT 5.1 ▾

Share ...

- Feature-Stack erzeugen,
- Modell inference (GPU/TPU-Cluster).
- Output: **COG-GeoTIFFs** (10 m, tiled, compressed) + Uncertainty-Layer.

Schritt 6 – Validierung & Vergleich

- **Holdout-GEDI** (räumlich getrennt).
- Regionale/ALS-Datensätze (LVIS, nationale ALS-Kampagnen).
- Vergleich mit existierenden CHMs (ETH, Potapov, etc.). [sciencedirect.com +2](#)
- Reporting:
 - RMSE, Bias, R^2 nach Biomen, Höhenklassen, Kontinenten,
 - Fehlerstrukturen (Underestimation tall canopies, Overestimation low veg).

3. Was du praktisch *jetzt* tun kannst

1. **ETH-CHM in GEE/HPC-Workflow integrieren**
 - Für Prototyping/Anwendungen (Carbon Accounting, Disturbance-Analysen, etc.).
2. **Eigene Modelle darauf aufsetzen**
 - z.B. fine-tuning für bestimmte Regionen/Ökosysteme,
 - Kombination mit Zeitreihen-Ansätzen, um **dynamische CHMs** zu erzeugen (2019–202X).
3. **Vergleich & Benchmarking**
 - Eigene Produkte vs. ETH-Produkt vs. Landsat+GEDI vs. 1 m meta_trees,
 - Regionale Validierung in euren Testgebieten.

Wenn du magst, kann ich dir im nächsten Schritt ein **konkretes GEE-Skript** oder ein **HPC-Workflow-Sketch (Snakemake/Nextflow)** für ein **eigenes Sentinel-2+GEDI-CHM** aufziehen – inklusive Feature-Liste, Modell-API und Dateistruktur.


     ...  Sources

+ Ask anything




ChatGPT can make mistakes. Check important info. See [Cookie Preferences](#)

Beispiel II: Deep Learning → 3D-Höhenmodell (von Bäumen)



Beispiel II: Deep Learning → 3D-Höhenmodell (von Bäumen)



Jan Pauls, Max Zimmer, Una Kelly, Martin Schwartz, Sassan Saatchi, Philippe Ciais, Sebastian Pokutta, Martin Brandt, Fabian Gieseke.


Estimating Canopy Height at Scale, ICML, 2024

Beispiel II: Satellitendaten + Deep Learning → 3D-Höhenmodell → Überwachung Abholzung



tagesschau

Sendung verpasst?



Zerstörung tropischer Wälder

"Das ist weltweit Alarmstufe Rot"

Stand: 21.05.2025 12:01 Uhr

Die Zerstörung tropischer Wälder schreitet in hohem Tempo voran: Eine Fläche fast so groß wie Bayern ging laut einer Studie 2024 verloren. Das ist demnach der höchste Wert seit 20 Jahren.

Vergangenes Jahr hat die Zerstörung von tropischem Regenwald den höchsten Stand seit 20 Jahren erreicht. Wie [eine Studie](#) des World Resources Institute (WRI) und der Universität Maryland zeigt, wurden 6,7 Millionen Hektar tropischer Urwald zerstört. Das entspricht fast der Fläche


Beispiel II: Satellitendaten + Deep Learning → Höhendifferenzen

Jan Pauls, Max Zimmer, Berkan Turan, Sassan Saatchi, Philippe Ciais, Sebastian Pokutta, Fabian Gieseke.

Capturing Temporal Dynamics in Large-Scale Tree Canopy Height Estimation, ICML, 2025

Google Earth Engine Apps

Search places



Capturing Temporal Dynamics in Large-Scale Tree Canopy Height Estimation

To download/use the predictions, access the dataset for each year (2019-2022) as follows:

```
ee.ImageCollection("projects/
worldimag/assets/
europe_2022").mosaic();
```

Select analysis mode and years below.

Analysis Mode:

Year:

Height (cm)




Beispiel II: Satellitendaten + Deep Learning → Höhendifferenzen

Google Earth Engine Apps

Demo: <https://europetreemap.projects.earthengine.app/view/europeheight>




Beispiel III: Suchmaschine für Satellitendaten?



<https://images.google.com/>


Beispiel III: Suchmaschine für Satellitendaten



Christian Lülfi, Denis Martins, Yongluan Zhuo, Marcos Vaz Salles, Fabian Gieseke.

Fast Search-By-Classification for Large-Scale Databases Using Index-Aware Decision Trees and Random Forests, VLDB, 2023


Beispiel III: Suchmaschine für Satellitendaten



Christian Lülfi, Denis Martins, Yongluan Zhuo, Marcos Vaz Salles, Fabian Gieseke.

Fast Search-By-Classification for Large-Scale Databases Using Index-Aware Decision Trees and Random Forests, VLDB, 2023



Beispiel III: Suchmaschine für Satellitendaten



Christian Lülfi, Denis Martins, Yongluan Zhuo, Marcos Vaz Salles, Fabian Gieseke.

Fast Search-By-Classification for Large-Scale Databases Using Index-Aware Decision Trees and Random Forests, VLDB, 2023

Beispiel III: Suchmaschine für Satellitendaten



Christian Lül, Denis Martins, Yongluan Zhuo, Marcos Vaz Salles, Fabian Gieseke.

Fast Search-By-Classification for Large-Scale Databases Using Index-Aware Decision Trees and Random Forests, VLDB, 2023

Beispiel III: Suchmaschine für Satellitendaten

← → ↺ web.search-engine.space

+

+

+

Ringkøbing

Choose searcher:

Decisionbranches

Start search

Reset

Area selection ☐

Add non rare images

15000

Found objects 25834

Query time 0.912 s

50 m
200 ft

Leaflet

Skalierbare KI + Waldmonitoring




Satellitendaten

- Große (!) Datenmengen
- → Speicherung der Daten?
- → Analyse der Daten?




Künstliche Intelligenz

- Maschinelles Lernen
- Deep Learning
- Rechenintensiv



AI4Forest

- Deep Learning → Bäume zählen
- Deep Learning → 3D-Höhenmodell
- KI + Datenbanken → Suchmaschine



Skalierbare KI + Waldmonitoring




Satellitendaten

- Große (!) Datenmengen
- → Speicherung der Daten?
- → Analyse der Daten?



Künstliche Intelligenz

- Maschinelles Lernen
- Deep Learning
- Rechenintensiv



AI4Forest

- Deep Learning → Bäume zählen
- Deep Learning → 3D-Höhenmodell
- KI + Datenbanken → Suchmaschine

