



Maschinelles Lernen in der Fernerkundung: Fortschritt mit Nebenwirkungen

Dr. John Friesen, Dr. Jakob Schwalb-Willmann

2. Oktober 2025

Was bedeutet *Lernen*?


- sich Wissen, Kenntnisse aneignen
- sich, seinem Gedächtnis einprägen
- Fertigkeiten erwerben
- im Laufe der Zeit [durch Erfahrungen, Einsichten] zu einer bestimmten Einstellung, einem bestimmten Verhalten gelangen

Warum lernen wir Menschen?

- Wir wollen die Welt **verstehen**.
- Wir wollen die Welt **modellieren**.
- Wir wollen die Welt **vorhersagen**.

„The Brain is a prediction machine.“

Anil Seth



Was bedeutet *Maschinelles Lernen*?

Worin unterscheidet sich *Maschinelles Lernen*
von *Künstlicher Intelligenz*?

Was hat es mit *künstlicher allgemeiner Intelligenz*
auf sich?

Definition

Künstliche allgemeine
Intelligenz

Maschine, die in der Lage ist, jegliche Aufgaben ähnlich gut oder besser als ein Mensch auszuführen

Künstliche Intelligenz

Maschine, die in der Lage ist, eine spezifische Aufgabe ähnlich oder besser als ein Mensch auszuführen

Maschinelles
Lernen

Techniken, mit denen eine Maschine aus Daten lernen kann

Deep
Learning

Methoden, die ähnlich wie das menschliche Gehirn lernen, Dinge zu unterscheiden, zu strukturieren und in einen Kontext zu setzen

Definition

Künstliche allgemeine
Intelligenz

Maschine, die in der Lage ist, jegliche Aufgaben ähnlich gut oder besser als ein Mensch auszuführen

Künstliche Intelligenz

Maschine, die in der Lage ist, eine spezifische Aufgabe ähnlich oder besser als ein Mensch auszuführen

Maschinelles
Lernen

Techniken, mit denen eine Maschine aus Daten lernen kann

Deep
Learning

Methoden, die ähnlich wie das menschliche Gehirn lernen, Dinge zu unterscheiden, zu strukturieren und in einen Kontext zu setzen


Grundidee maschinellen Lernens

Bayerisches Staatsministerium für
Wirtschaft, Landesentwicklung und Energie




Wie können wir die Zusammenhänge in der Natur **gut** vorhersagen?

Statistische Modellierungsansätze



Algorithmische Modellierungsansätze



Statistical Science
2001, Vol. 16, No. 2, 199-231

Statistical Modeling: The Two Cultures
Leo Breiman

Breiman, L. (2001). Statistical modeling: The two cultures (with comments and a rejoinder by the author). *Statistical science*, 16(3), 199-231.

Abstract. There are two cultures in the use of statistical modeling to reach conclusions from data. One assumes that the data are generated by a given stochastic data model. The other uses algorithmic models and treats the data mechanism as unknown. The statistical models and methods have been committed to the almost exclusive use of the first culture.

Modellansätze

Statistische Modellierungsansätze

Hypothesenbasierte Modellierung

Algorithmische Modellierungsansätze

Maschinelles Lernen

Klassisches Maschinelles Lernen
Manual Feature Engineering

Support Vector
Machines

Decision Trees

Repräsentationslernen
Feature recognition

Artificial Neural Networks

Convolutional Neural
Networks (CNN)

Recurrent Neural Networks
(RNN)

Modellierungsansätze

Bayerisches Staatsministerium für
Wirtschaft, Landesentwicklung und Energie



Ära / Ansatz

Klassische ML (SVM, etc.)


Typische Zeit

< 2010

Vorteil ggü. Vorgänger

einfache, transparente
Modelle


Klassisches Maschinelles Lernen




- labeled sample of *class 1*
- labeled sample of *class 2*
- unlabeled sample
- separating hyperplane

Beispiel 1:



Klassischer ML Ansatz



Virtual SVM (VSVM):
Objekt-basierter Ansatz



Reference



$\kappa = 69.67$ | $F_1 = 77.78$ | $OA = 77.86$

Ansatz

- diskriminierender Klassifizierer wird **direkt** auf Eingangsdaten trainiert
- geringe Anzahl an Eingangs-Samples (< 200)

Anwendung

- Landbedeckungs-Klassifikation von hochauflösenden multi-spektralen Satellitenaufnahmen im urbanen Raum


Fazit

- Einfacher Ansatz, der auch in komplexer Umgebung gute Ergebnisse liefert
- Kollinearität in Features beeinflusst Ergebnisse
- Aufwendig bei vielen Features

Modellierungsansätze

Ära / Ansatz	Typische Zeit	Vorteil ggü. Vorgänger	Grenzen
Klassische ML (SVM, etc.)	< 2010	einfache, transparente Modelle	wenig leistungsfähig, viel Feature Engineering
Random Forest & Ensembles	2010–2015	robust, interpretierbar, weniger Feature Engineering	

Beispiel 2: Random Forest



Ansatz

- *Random Forest*: trainiert Entscheidungsbäume, nutzt häufigste Vorhersage, um Pixel zu klassifizieren
- diskriminierender Klassifizierer wird direkt an Eingangsdaten trainiert
- geringe Anzahl an Eingangs-Samples (ca. 3000-4200 plots)

Anwendung


- Pixel-basierte Klassifikation von Wald und Baumarten aus Satelliten-Fernerkundungsdaten (Sentinel-1- & Sentinel-2) für ganz Deutschland

Fazit

- Algorithmus kann gut mit vielen Features umgehen und deren Beitrag zum Ergebnis darstellen

Beispiel 3:

Random Forest – Ensemble-Modelle



Ansatz

- *Ensemble-Modelle*: kombiniert mehrere ML-Modelle, um höhere Genauigkeit und Robustheit zu erzielen (hier: Durchschnitt der 10 besten *Random Forest*-Modelle)
- Regressor wird direkt auf den ausgewählten Eingangsdaten trainiert
- geringe Anzahl an Eingangs-Samples (1559 Erdrutsch-Instanzen)

Anwendung

- Pixel-basiert Vorhersage der Erdrutschanfälligkeit in Kärnten, Österreich

Fazit

- Unsicherheit des Modells kann durch Ensemble abgebildet werden
- Weiterhin Feature-Engineering notwendig
- Keine Generalisierbarkeit

Modellierungsansätze

Ära / Ansatz	Typische Zeit	Vorteil ggü. Vorgänger	Grenzen
Klassische ML (SVM, etc.)	< 2010	einfache, transparente Modelle	wenig leistungsfähig, viel Feature Engineering
Random Forest & Ensembles	2010–2015	robust, interpretierbar, weniger Feature Engineering	nicht optimal für Bildmuster, brauchen Features
Deep Learning (CNN, U-Net)	2015–2021	automatisch Features lernen, sehr gute Genauigkeit	


Deep Learning

Methoden, die das Lernverhalten des Gehirns imitieren


Bayerisches Staatsministerium für
Wirtschaft, Landesentwicklung und Energie




Nobelpreise 2024




Neuronen des Kleinhirns



Santiago Ramón y Cajal
Nobelpreis 1906



Deep Learning Segmentation



Lucas, M., Pukrop, M., Beckschäfer, P., & Waske, B. (2024). Individual tree detection and crown delineation in the Harz National Park from 2009 to 2022 using mask R-CNN and aerial imagery. *ISPRS Open Journal of Photogrammetry and Remote Sensing*, 13, 100071.

Ansatz

- *Mask-R-CNN*: erkennt, klassifiziert und segmentiert Objekte in Bildern
- erlernt Repräsentationen der Eingangsdaten, die für die Aufgabe relevante Muster repräsentieren
- Klassifizierer lernt, Klassen in den erlernten Repräsentationen zu unterscheiden
- vortrainiert auf COCO-Datensatz
- hohe Anzahl an Eingangs-Samples (1.5 mio. COCO-Objekte, > 9000 Kronen)

Anwendung

- Erkennung von Baumkronen aus Luftbildaufnahmen im Nationalpark Harz



Fazit

- Modell lernt selbst aus Daten
- Kein Feature Engineering notwendig
- Nur ein Modell pro Aufgabe

Modellierungsansätze

Ära / Ansatz	Typische Zeit	Vorteil ggü. Vorgänger	Grenzen
Klassische ML (SVM, etc.)	< 2010	einfache, transparente Modelle	wenig leistungsfähig, viel Feature Engineering
Random Forest & Ensembles	2010–2015	robust, interpretierbar, weniger Feature Engineering	nicht optimal für Bildmuster, brauchen Features
Deep Learning (CNN, U-Net)	2015–2021	automatisch Features lernen, sehr gute Genauigkeit	Black Box, Daten- & Ressourcenintensiv
Foundation Models (Self-Supervised)	ab 2021	nutzen unlabelled Daten, universell einsetzbar, Transfer Learning	

Deep Learning Foundation Models



Ansatz

- *Foundation Models*: große KI-Modelle, die verschiedene Datenquellen (z. B. Sentinel 1 & 2) global integrieren
- *Embeddings*: Repräsentationen der Eingangsdaten, die deren semantische und räumliche Eigenschaften optimal repräsentieren
- sehr hohe Anzahl an Eingangsdaten (3.5 Mio. Sentinel-1/-2-Bilddatensätze, 9,3 Billionen Pixel, 62 TB)

Anwendung


- Globale Embeddings können als Eingangsdaten für task-spezifische Modelle dienen, ohne das grundlegende Muster in Eingangsdaten erlernt werden

Modellierungsansätze

Ära / Ansatz	Typische Zeit	Vorteil ggü. Vorgänger	Grenzen
Klassische ML (SVM, etc.)	< 2010	einfache, transparente Modelle	wenig leistungsfähig, viel Feature Engineering
Random Forest & Ensembles	2010–2015	robust, interpretierbar, weniger Feature Engineering	nicht optimal für Bildmuster, brauchen Features
Deep Learning (CNN, U-Net)	2015–2021	automatisch Features lernen, sehr gute Genauigkeit	Black Box, Daten- & Ressourcenintensiv
Foundation Models (Self-Supervised)	ab 2021	nutzen unlabelled Daten, universell einsetzbar, Transfer Learning	Black Box bleibt, neue Abhängigkeiten

Spannung zwischen Problemskala und Komplexität der Modelle

Bayerisches Staatsministerium für
Wirtschaft, Landesentwicklung und Energie



Ockhams Rasiermesser

Bayerisches Staatsministerium für
Wirtschaft, Landesentwicklung und Energie



*“Wesenheiten dürfen **nicht**
über das **Notwendige** hinaus
vermehrt werden.“*

Wilhelm von Ockhām - from a manuscript of Ockham's Summa
Logicae, MS Gonville and Caius College, Cambridge, 464/571, fol. 69r}

Alles ändert sich rasend schnell.
Was bedeutet das für die Praxis?

Generative Künstliche Intelligenz in der Arbeitswelt

Bayerisches Staatsministerium für
Wirtschaft, Landesentwicklung und Energie



- Unternehmen haben weltweit zwischen **30-40 Mrd. US-Dollar** in generative KI investiert
- **95%** der Organisationen berichten von **keinen messbaren Erträgen**
- **Consumer-Tools** (ChatGPT oder Microsoft CoPilot) verzeichnen hohe Akzeptanz, **steigern** aber v.a. **individuelle Produktivität**
- **Interne KI-Tools** werden (trotz hoher Investitionen) oft **abgelehnt**



Generative Künstliche Intelligenz in der Arbeitswelt

Bayerisches Staatsministerium für
Wirtschaft, Landesentwicklung und Energie



- AI-Generated “Workslop” vermindert Produktivität
- **Workslop** wird definiert als KI-generierte Arbeitsinhalte, die sich als gute Arbeit tarnen, aber nicht über die Substanz verfügen, um eine bestimmte Aufgabe sinnvoll voranzubringen.
- **40%** der über 1000 Befragten Vollzeitbeschäftigten gaben an im letzten Monat Workslop erhalten zu haben
- Jeder Workslop Vorfall erfordert durchschnittlich **zwei Stunden** zusätzliche Arbeit und **Verluste von 186 US\$** pro Mitarbeitenden und Monat



Wie sieht die Zukunft aus?

Kombination von Expertenwissen und maschinellem Lernen

„Wir unterstützen bayerische Behörden und Entscheidungsträger mit fernerkundungsbasierten Informationen, Analysen und Szenarien bei der Definition und der Bewertung von Maßnahmen für die Anpassung an den klimatischen Wandel.“



Urbaner Raum: thermale Belastung/Hitzeinseln, Gründächer, Flächenversiegelung, Solarflächen, Stadtklimamodellierung, ...



Forstwirtschaft: Klassifikation von Waldtypen, Artenzusammensetzung, Waldschäden, Bodenwasserhaushalt, ...



Landwirtschaft: Historische und aktuelle Klassifikationen von Feldfrüchten und Fruchtfolgen, Ertragsprognosen, Entwicklung von Hecken/Blühstreifen, ...

Querschnittsthemen



Gesundheit



Biodiversität




Georisiken






Beispiel 1: Kombination von physiologischem Modell und ML

Bayerisches Staatsministerium für
Wirtschaft, Landesentwicklung und Energie




How landscape structure, climate variability, and soil quality influence crop biomass?



Beispiel 1:

Kombination von physiologischem Modell und ML


Bayerisches Staatsministerium für
Wirtschaft, Landesentwicklung und Energie



Beispiel 2:

Lernen von interpretierbaren Gleichungen aus Daten

Bayerisches Staatsministerium für
Wirtschaft, Landesentwicklung und Energie



Beispiel 2:


Lernen von interpretierbaren Gleichungen aus Daten

Bayerisches Staatsministerium für
Wirtschaft, Landesentwicklung und Energie



Das Verhalten der Wolken kann mit der Navier-Stokes Gleichung beschrieben werden:

$$\omega_t + \mathbf{u} \nabla \omega = \frac{1}{100} \nabla^2 \omega$$



1b. Build nonlinear library of data and derivatives

$$\omega_t = \Theta(\omega, u, v) \xi$$

1c. Solve sparse regression

$$\arg \min_{\xi} \|\Theta \xi - \omega_t\|_2^2 + \lambda \|\xi\|_0$$



d. Identified dynamics

$$\omega_t + 0.9931 u \omega_x + 0.9910 v \omega_y = 0.0099 \omega_{xx} + 0.0099 \omega_{yy}$$

Compare to true Navier-Stokes ($Re = 100$)


$$\omega_t + (\mathbf{u} \cdot \nabla) \omega = \frac{1}{Re} \nabla^2 \omega$$

Beispiel 3: Nutzen Kausaler Inferenz in der digitalen Landwirtschaft





Postulieren eines Mechanismus
des Schädlingsbefalls

Frage aus der Praxis:
Wie soll die Ausbreitung von
Schädlingen verhindert werden?



Testen der Hypothese



Überprüfbare Handlungs-
empfehlungen

Zusammenfassung

- **Maschinelles Lernen** ist eine **mächtige Technik**, um mithilfe von Daten der Fernerkundung Vorhersagen zu tätigen
- Bewusstsein für die Spannung zwischen **Komplexität** des Modells, **Genauigkeit** der Vorhersagen und **Problemverständnis** ist unerlässlich
- Ziel ist es, **Modelle verständlich** und interpretierbar zu gestalten und wenn möglich **Expertenwissen einzubeziehen**

Es muss nicht immer **ChatGPT** sein.

Manchmal lernt man vom **Duden** mehr.

