

Wettervorhersage-Methoden im Vergleich: Der Weg von traditionellen zu KI-basierten Modellen

Deifilia To | 16. April 2024

Numerische Wettervorhersage-Methoden (NWP)

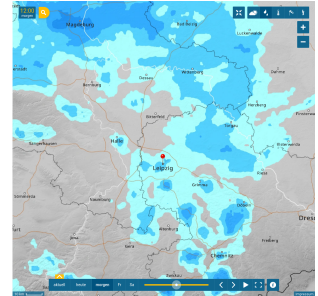
Messungen



Numerische Modelle




Wettervorhersagen




Was machen die Modelle?

- Fluide unterliegen der Massenerhaltung, Impulserhaltung und Energieerhaltung
- Messungen sind auf einem Gitter diskretisiert
- Die Differenz zwischen Zeitpunkt t und $t + \Delta t$ wird gelöst



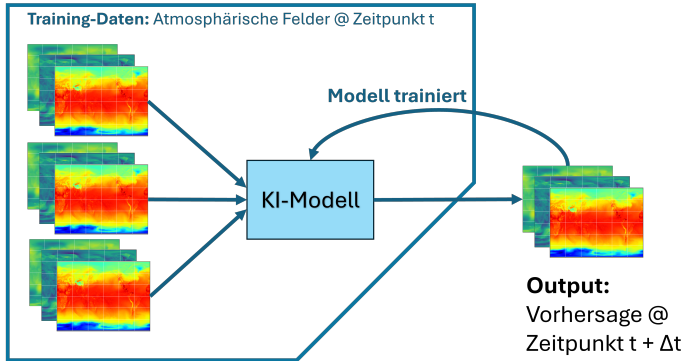
Schwierigkeiten bei den Wettervorhersagen

- Die Strömung bewegt sich Zelle für Zelle durch das Gitter
- Daten werden immer lokal gehalten
- Änderungen im Strömungsfeld müssen sich über viele Berechnungsschritte ausbreiten
- **Jede Vorhersage ist rechenintensiv**



KI-basierter Ansatz zur numerischen Wettervorhersage

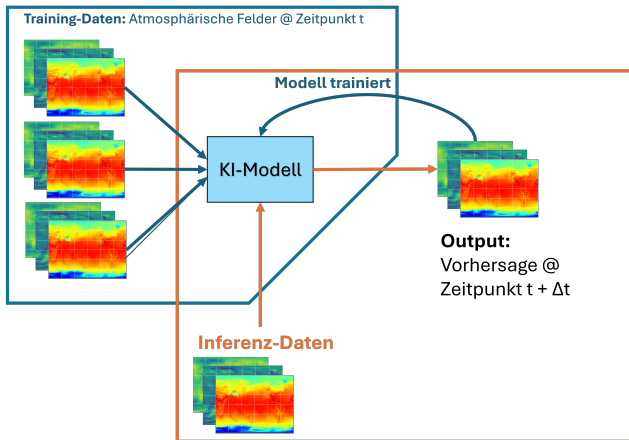
Rechenintensiv



- Produzieren Vorhersagen mit $\Delta t = 1 \dots 24$ Std.
- Durch Autoregressive Modelle können Zwei-Wochen-Vorhersagen getroffen werden

KI-basierter Ansatz zur numerischen Wettervorhersage

Rechenintensiv




Recheneffizient

- Beispiele: Graphcast (2023) [6], Pangu-Weather (2023) [1], FourcastNet (2022) [9], FuXi (2023) [3], ClimaX (2023) [8], FengWu (2023) [2]
- Besser als klassische Methode!

1) Verfügbarkeit von Daten in Wettervorhersagen

ECMWF Reanalysis v5 (ERA5)

- Frei zugängliche und annotierte Datensätze
- Stündliche, globale Reanalyse-Daten von 1979 bis zum heutigen Tag
 - Kombination von Messdaten und Simulationen
- Felder wie Temperatur, Feuchtigkeit und Geschwindigkeit auf einem Gitter von 31 km x 31 km, verteilt auf 137 Ebenen
- 5 PBs = Speicherplatz von 10000 iPhone 14s



2) Methodische Verbesserungen

Transformer-Architektur

- Ein Foto bzw. atmosphärisches Datenfeld wird als Sequenz betrachtet
- Jeder Ausschnitt lernt den Bezug zu anderen Ausschnitten in der Sequenz
 - Weitreichende Längenskalen können betrachtet werden
- Transformer braucht viel Daten, um trainiert zu werden

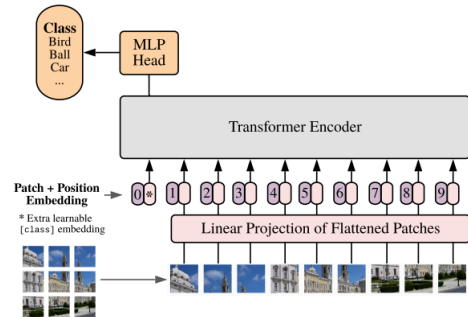


Abbildung: Von einem Foto bis zur Sequenz im Vision-Transformer [5]

3) Technologische Fortschritte von Hardware

- GPUs sind 1000x schneller als vor 10 Jahren
- Große Computercluster ermöglichen das parallele Trainieren von Modellen

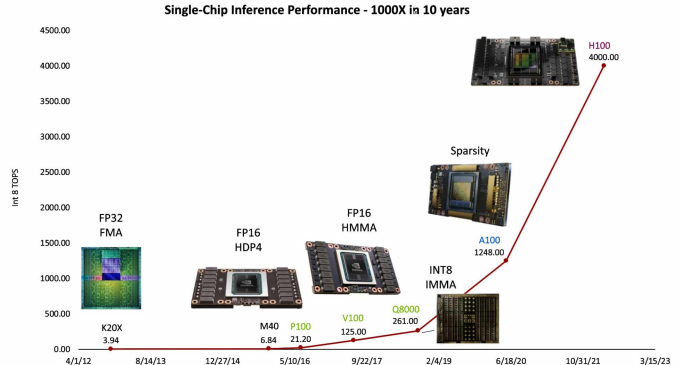


Abbildung: FLOPs in KI-Modelle [4]

Case Study: Pangu-Weather [1]

- 1 Verfügbarkeit von Daten: Stündliche ERA5 Daten von 1979 bis 2018, verwendet als Training-Daten
- 2 Methodische Verbesserung: 3D Transformer-basierte Architektur
- 3 Technologische Fortschritte:
 - 256 Millionen Parameter
 - 192 GPUs \times 16 Tage Trainingszeit pro Model

Ergebnisse:

- Erzielt bessere Ergebnisse als klassische numerische Wettervorhersage-Methoden




Abbildung: Pangu-Weather
2m-Temperatur-Vorhersagen [1]

Nächste Schritte

Numerische Wettervorhersage

- Erfüllt die Massen- und Energieerhaltungssätze
- Entwickelt von Meteorologen

Offene Frage

- Müssen wir physikalische Gleichungen in KI-Modelle einbauen?

KI-Modelle

- Das Ziel von KI-Modellen ist die Minimierung einer Fehlerfunktion
- Bei KI-Modellen sind Erhaltungssätze nicht automatisch erfüllt
- Entwickelt von Informatikern

CO₂-Fußabdruck von KI-Modellen

- Training von KI-Modellen ist ressourcen-intensiv
 - Stromverbrauch des Trainings von KI-Modellen
 - Kühlsysteme für die Rechner
 - Große Datenspeichersysteme
- Der ökologische Fußabdruck von KI ist nicht vernachlässigbar
 - Wir brauchen effiziente, skalierbare Modelle

CO₂ Equivalent Emissions (Tonnes) by Selected Machine Learning Models and Real Life Examples, 2022

Source: Luccioni et al., 2022; Strubell et al., 2019 | Chart: 2023 AI Index Report




Abbildung: CO₂ Äquivalente im Vergleich [7]

References I

- [1] Kaifeng Bi u. a. „Accurate medium-range global weather forecasting with 3D neural networks“. In: *Nature* 619.7970 (Juli 2023), S. 533–538. ISSN: 1476-4687. DOI: 10.1038/s41586-023-06185-3. URL: <http://dx.doi.org/10.1038/s41586-023-06185-3>.
- [2] Kang Chen u. a. „FengWu: Pushing the Skillful Global Medium-range Weather Forecast beyond 10 Days Lead“. In: (2023). DOI: 10.48550/ARXIV.2304.02948. URL: <https://arxiv.org/abs/2304.02948>.
- [3] Lei Chen u. a. „FuXi: a cascade machine learning forecasting system for 15-day global weather forecast“. In: *npj Climate and Atmospheric Science* 6.1 (Nov. 2023). ISSN: 2397-3722. DOI: 10.1038/s41612-023-00512-1. URL: <http://dx.doi.org/10.1038/s41612-023-00512-1>.
- [4] Charlotte Debus u. a. „Reporting electricity consumption is essential for sustainable AI“. In: *Nature Machine Intelligence* 5.11 (Nov. 2023), S. 1176–1178. ISSN: 2522-5839. DOI: 10.1038/s42256-023-00750-1. URL: <http://dx.doi.org/10.1038/s42256-023-00750-1>.

References II

- [5] Alexey Dosovitskiy u. a. *An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale*. 2020. DOI: 10.48550/ARXIV.2010.11929. URL: <https://arxiv.org/abs/2010.11929>.
- [6] Remi Lam u. a. „GraphCast: Learning skillful medium-range global weather forecasting“. In: (2022). DOI: 10.48550/ARXIV.2212.12794. URL: <https://arxiv.org/abs/2212.12794>.
- [7] Nestor Maslej u. a. „Artificial Intelligence Index Report 2023“. In: (2023). eprint: arXiv:2310.03715.
- [8] Tung Nguyen u. a. „ClimaX: A foundation model for weather and climate“. In: (2023). DOI: 10.48550/ARXIV.2301.10343. URL: <https://arxiv.org/abs/2301.10343>.
- [9] Jaideep Pathak u. a. „FourCastNet: A Global Data-driven High-resolution Weather Model using Adaptive Fourier Neural Operators“. In: (2022). DOI: 10.48550/ARXIV.2202.11214. URL: <https://arxiv.org/abs/2202.11214>.