

KLIM-QML: Verbesserung von Klimamodellen mit QML für robuste Technologiefolgenabschätzung und Mitigationsempfehlungen

Mierk Schwabe¹ und Veronika Eyring^{1,2}

¹Deutsches Zentrum für Luft- und Raumfahrt, Institut für Physik der Atmosphäre, Oberpfaffenhofen

²Universität Bremen, Institut für Umweltphysik, Bremen

Klimamodelle sind sehr erfolgreich, aber Unsicherheiten bleiben

Klimasensitivität: Temperaturänderung bei einer Verdoppelung des vorindustriellen CO₂-Gehalts

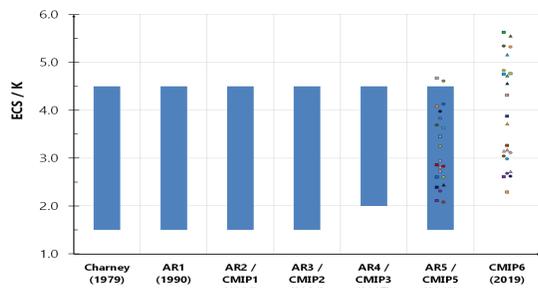


Abb. 1: Vorhergesagt Klimasensitivität mit verschiedenen Modellensembeln. Adaptiert aus Schlund et al., Earth Syst. Dynam., 11, 1233–1258, (2020) CC-BY 4.0

→ Unsicherheit (z.B. Werte von 1.5 - 4.5°C) seit 1979 nicht verringert

Parametrisierungen in Klimamodellen

- Klimamodelle haben typischerweise eine horizontale Auflösung von 50 – 100 km
- Viele wichtige Phänomene sind dabei nicht aufgelöst, z.B. Wolken oder Turbulenz
- Die statistischen Auswirkungen von nicht aufgelösten Phänomenen auf das Klima werden mit „Parametrisierungen“ dargestellt
- Parametrisierungen führen zu Unsicherheiten in Klimaprojektionen, wie in den Spannen der Klimaprojektionen (Abb. 1 und 2) sichtbar

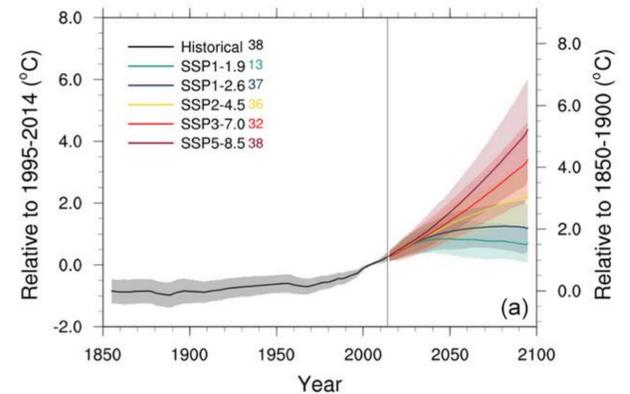


Abb. 2: Mittlere globale Temperaturänderung als Funktion der Zeit im Vergleich mit Referenzwerten für verschiedene Szenarien (SSPxx). Der jeweilige schattierte Bereich um die Linien (Ensemble-Mittelwert) entspricht dem $\pm 1.64\sigma$ -Intervall (σ : Standardabweichung). Aus Tebaldi et al. ESD 12, 253-293 (2021) (CC-BY 4.0)

Maschinelles Lernen hilft, die Unsicherheiten zu beheben

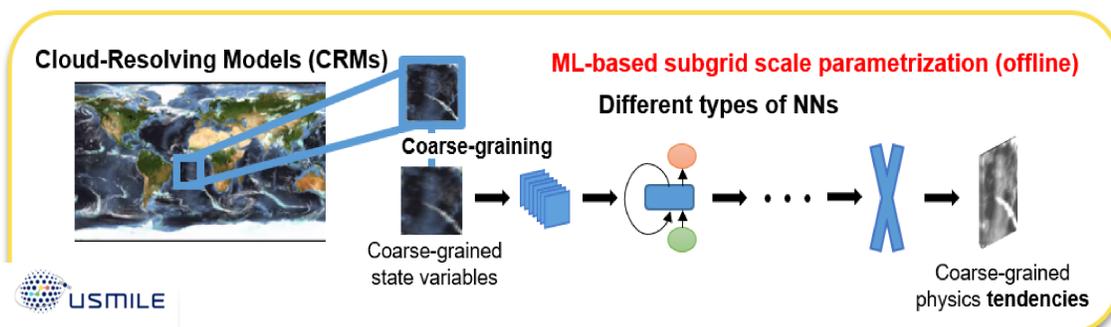


Abb. 3: Ansatz des ERC-Projekts USMILE zu maschinellem Lernen zur Verbesserung von Klimamodellen und für ein besseres Verständnis des Erdsystems - Eyring, V. & P. Gentine, Better Better - machine learning for improved climate models and projections, AI4Good Seminar, <https://youtu.be/SYC7ZVLxomI>, 2021

Erfolgreich z.B. für den Wolkenbedeckungsgrad (Grundner et al., JAMES 14, e2021MS002959, 2022) und Konvektion (Behrens et al., JAMES 14, e2022MS003130, 2022)

Maschinelles Lernen (ML) für Klimamodellierung

- Für einen kurzen Zeitraum kann man Klimamodelle mit einer hohen Auflösung (\sim km) laufen lassen, so dass Wolken, Konvektion usw. aufgelöst sind
- Diese wolkenauflösende Modelle werden zum Trainieren von ML-Algorithmen verwendet
- Damit werden ML-basierte Parametrisierungen entwickelt, die die Parametrisierungen in herkömmlichen Klimamodellen ersetzen
- Außerdem können ML-Algorithmen interpretiert werden, um ein besseres Verständnis des Erdsystems zu erlangen

Verbesserung von Klimamodellen mit Quantencomputing

Ziele KLIM-QML

Exploration von Methoden des Quantencomputings für Klimamodelle, aufbauend auf und in Kollaboration mit dem USMILE Projekt:

- Entwicklung von Parametrisierungen für Klimamodelle, die mit Quantenmaschinellen Lernen verbessert wurden
- Beschleunigung des Entwicklungsprozesses von Klimamodellen durch Optimierung von Parametern mittels Quantencomputing
- Anwendung des verbesserten Modells zur Untersuchung des Einflusses von Schiffsemissionen

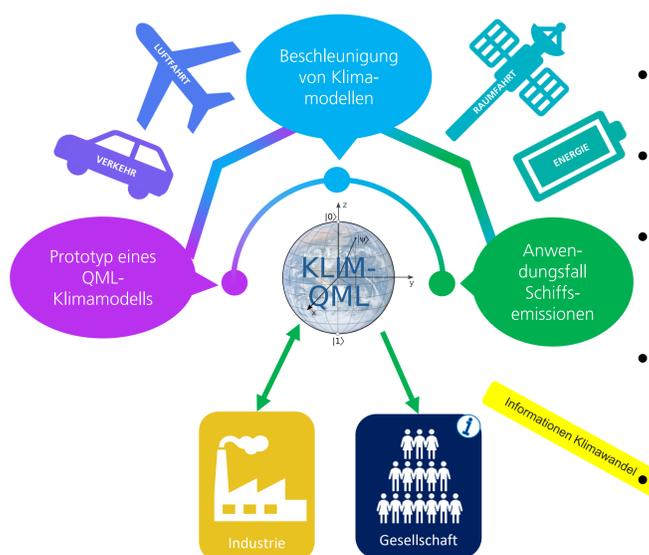


Abb. 4: Das KLIM-QML Projekt.

- Projektleiterinnen Dr. Mierk Schwabe und Prof. Veronika Eyring
- Projektstart 01.12.2022, Laufzeit vier Jahre
- Acht Mitarbeiter:innen am DLR Institut für Physik der Atmosphäre
- Standorte Oberpfaffenhofen bei München und DLR Quanteninnovationszentren in Ulm und Hamburg
- Verwendung der DLR Quantencomputer, sobald diese zur Verfügung stehen
- Kollaboration mit Industriepartner geplant

Kontakt: mierk.schwabe@dlr.de
veronika.eyring@dlr.de



Gefördert durch:



aufgrund eines Beschlusses des Deutschen Bundestages

