



# Quantum for Climate - Die Zukunft der Klimamodellierung?

GDS-Herbsttagung 2025


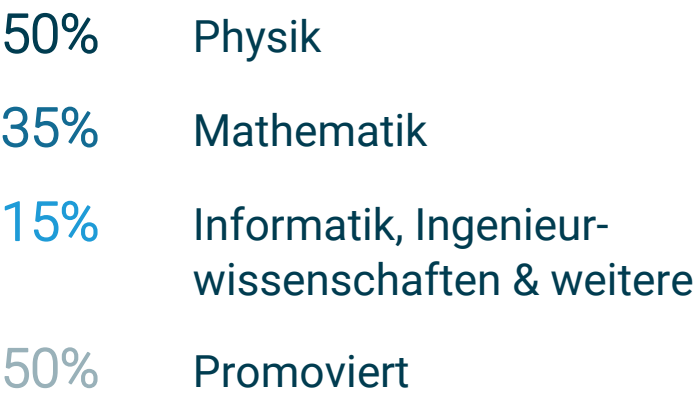
Frankfurt, 20.11.2025

d-fine

analytisch. technologisch. quantitativ.

# Unsere DNA – analytisch. technologisch. quantitativ.

Die geballte Kompetenz von über 1800 Expertinnen und Experten der Physik, Mathematik, Informatik und Ingenieurwissenschaften vereint in einem europäischen Unternehmen mit einer über 20-jährigen Geschichte, das den Fokus auf mathematische Modellierung, technologischen Fortschritt und Data Science legt – das ist d-fine.



## Unsere Branchenkompetenz



Banking &  
Capital Markets



Insurance & Asset  
Management



Energy &  
Industrials



Healthcare



Consumer &  
Services



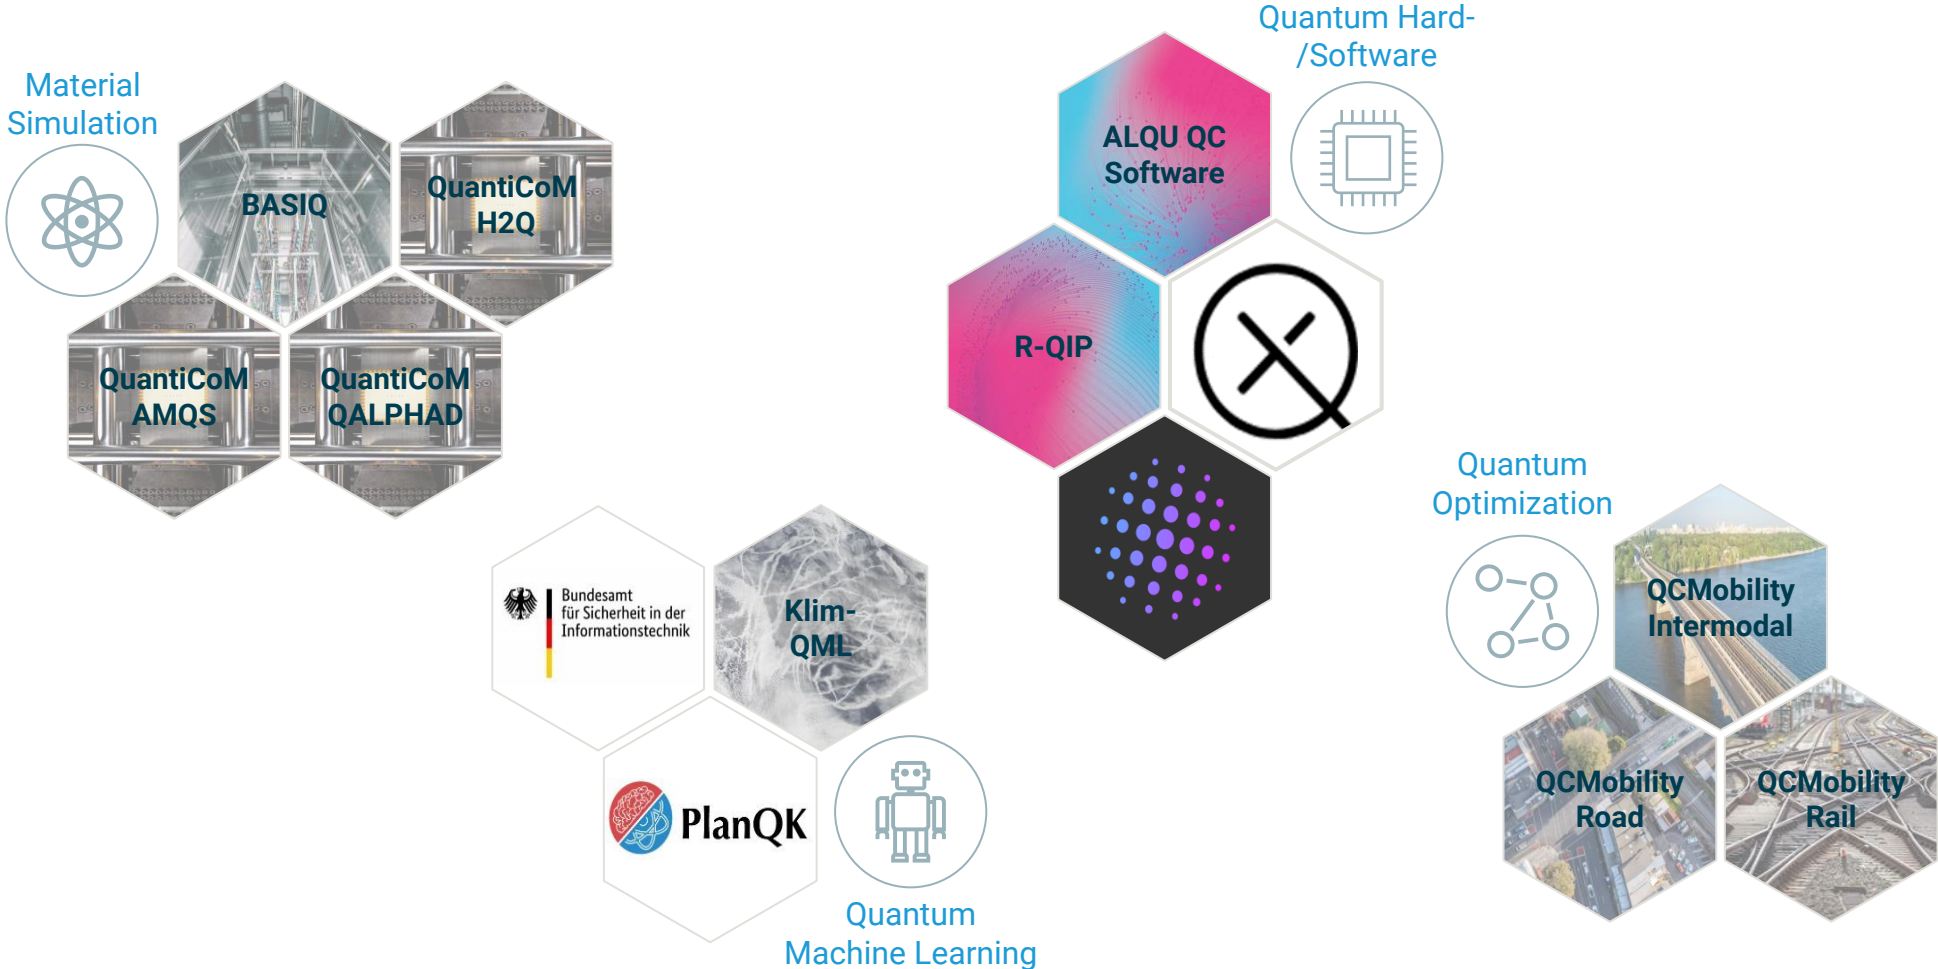
Technology



Public  
Sector

Quantum for  
Climate

# Unsere Projekte im Quantum Computing



Quantum for  
Climate


QUANTUM FOR CLIMATE

# 01 Quantum Computing in a nutshell




# Fundamentale Eigenschaften von Quantensystemen

## Superposition




Ein Quantensystem kann sich gleichzeitig in einer von vielen möglichen Konfigurationen befinden.

## Verschränkung



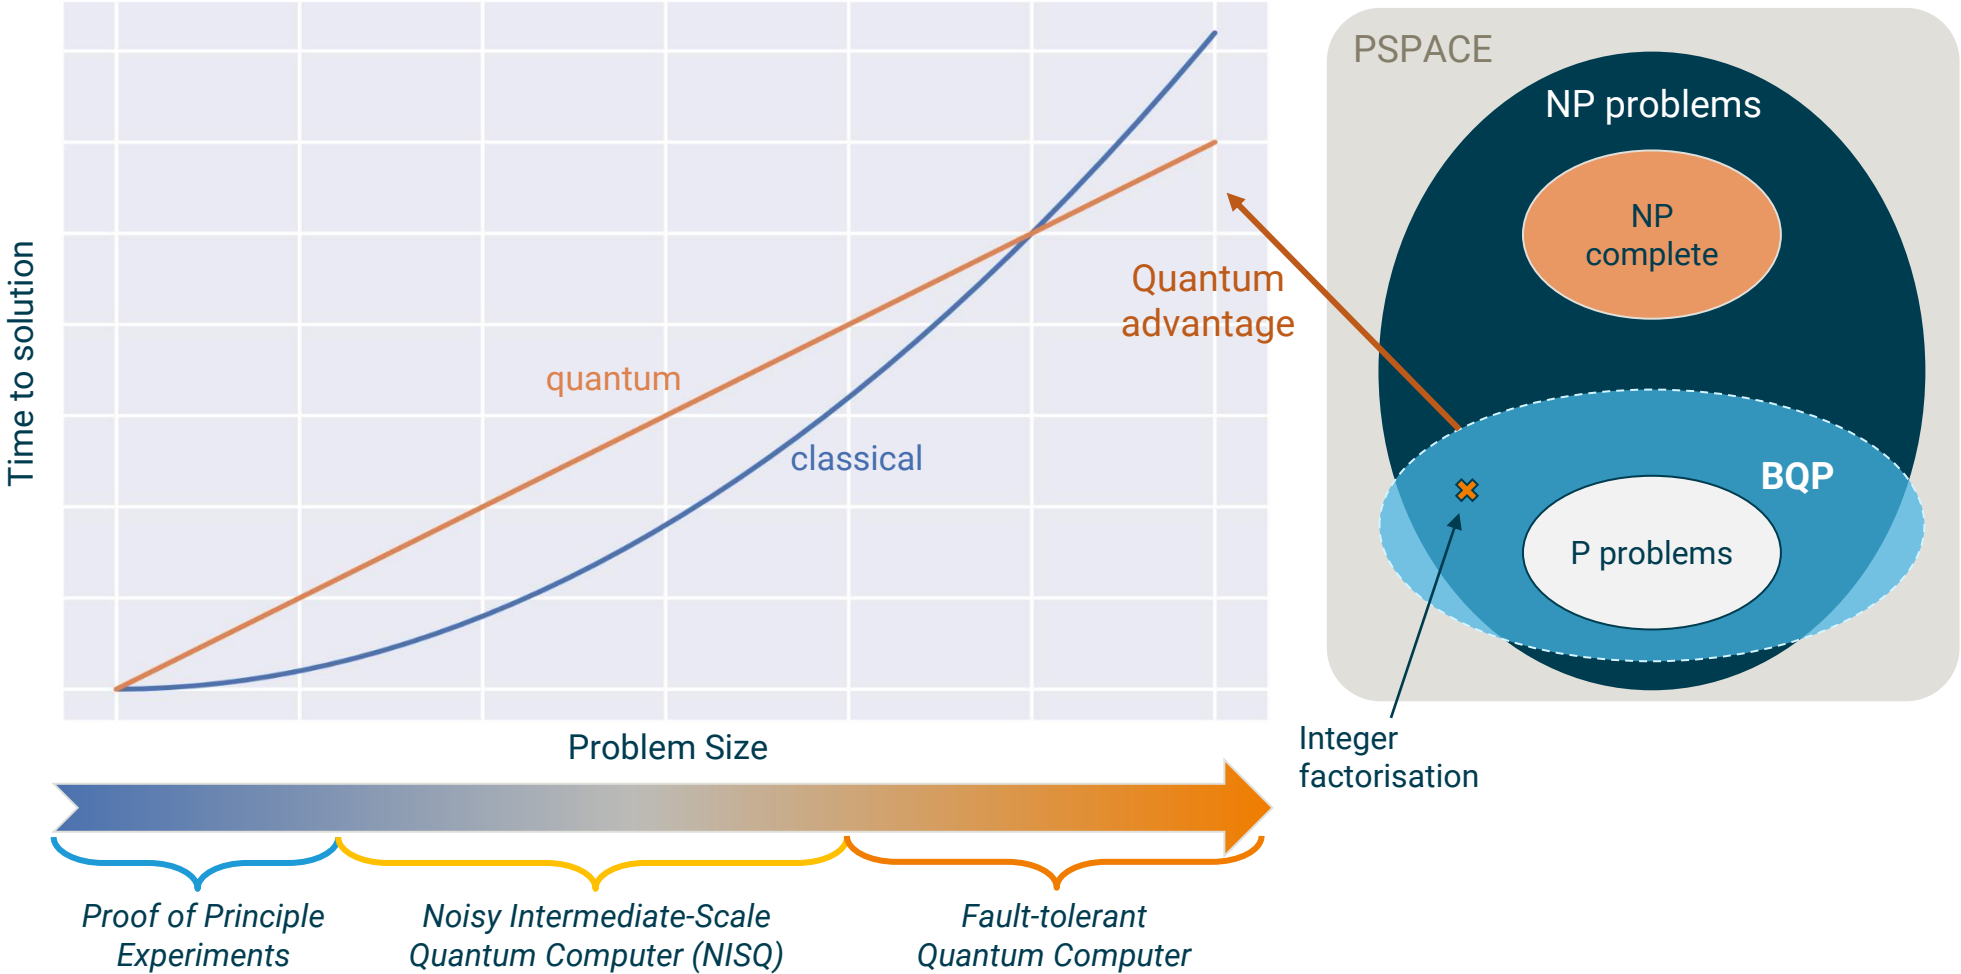
Zwei Quantenobjekte sind miteinander korreliert, unabhängig davon, wie weit sie räumlich voneinander entfernt sind.

## Interferenz

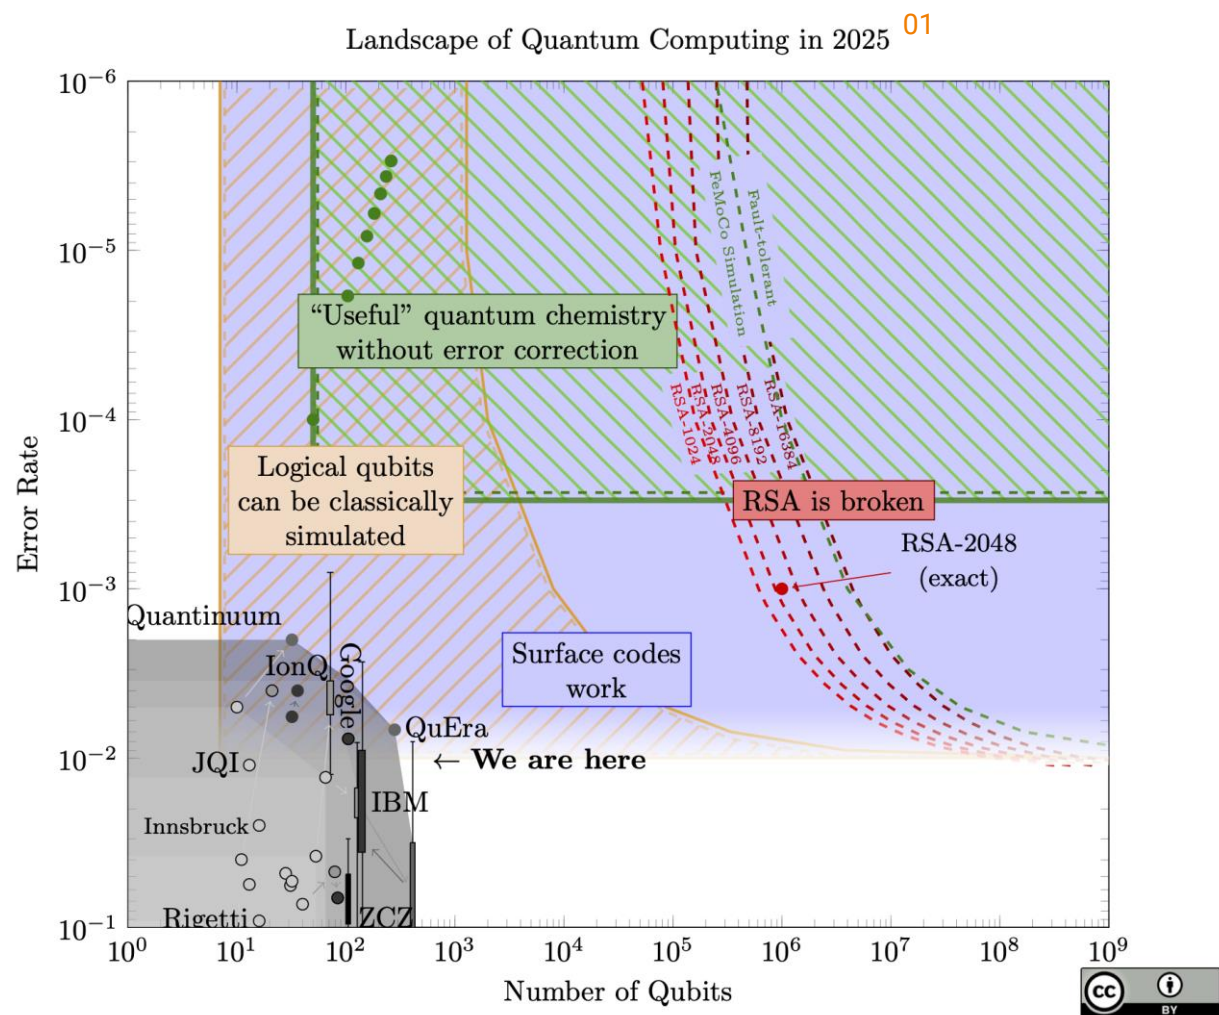


Quantenobjekte werden durch eine Wellenfunktion beschrieben, die definiert, wie sie sich ausbreiten und interagieren.

# Das Versprechen des Quantencomputings...




# Der Fortschritt in den letzten Jahren ist ermutigend, aber noch ist viel zu tun.



# Grundkonzepte des Quantum Machine Learning


## Quanten-Embedding

- Eine Quanten-Feature-Map<sup>01,02</sup> wird verwendet, um die (klassischen) Daten in einen Quantenzustand einzubetten.



## Variationelle Circuits

- Die Parameter des Schaltkreises werden optimiert, um eine bestimmte Verlustfunktion zu minimieren.
- Da Quantenschaltkreise differenzierbar sind, können sie ähnlich wie klassische neuronale Netze trainiert werden.
- Die Verlustfunktion wird durch Messung des resultierenden Quantenzustands ausgewertet.



Images: PennyLane

## Vorteile

- Zugang zu einem feature space (=Hilbertraum), der mit  $2^N$  in der Zahl der Qubits skaliert → größere Expressivität als klassische neuronale Netze
- Möglichkeit zur Implementierung klassisch nicht simulierbarer Kernel-Funktionen
- Robustheit gegenüber Fehlern macht die Methode NISQ-freundlich (=noisy, intermediate-scale quantum)
- Algorithmischer Vorteil für bestimmte ML-Aufgaben<sup>03,04</sup>

## Herausforderungen

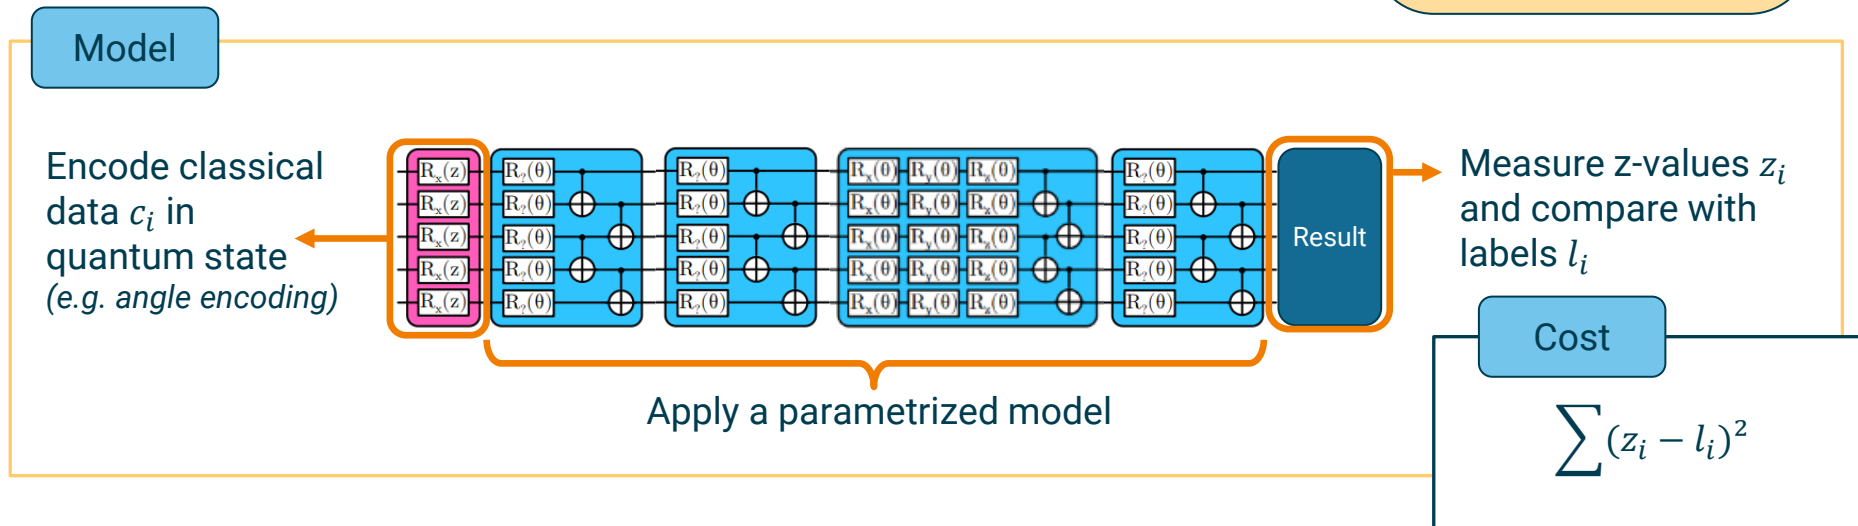

- Solider mathematischer Beweis für Quantenvorteil fehlt (vor allem für klassische Daten)
- Training der Modelle dauert sehr lange und bleibt oft in „barren plateaus“ stecken
- Große Datensätze können nicht effizient auf einen Quantencircuit gemappt werden

<sup>01</sup> arXiv:1803.07128v1 <sup>02</sup> arXiv:1804.11326v2  
<sup>03</sup> arXiv:2010.02174v2 <sup>04</sup> arXiv:2112.00778v1

Ein echter Quantenvorteil im NISQ-Regime wird nicht erwartet, sondern benötigt wahrscheinlich fehlertolerante Quantencomputer.



# QML-Modelle werden ähnlich wie klassische NN trainiert



Ein Quantencircuit wird anhand gelabelter Daten trainiert, um Werte für neue Datenpunkte vorherzusagen. Gatter-Parameter werden nach Evaluierung der Kostenfunktion angepasst.

QUANTUM FOR CLIMATE

# 02 Können Klimamodelle durch Quantencomputer verbessert werden?

DLR-Projekt KLIM-QML

---

d-fine



planqc



DLR



DLR  
Quantencomputing  
Initiative

# Klimawandel: Bedrohung für Mensch und Umwelt<sup>01</sup>




Quantum for  
Climate

02 - KLIM-QML


# Klimaprognosen sind umfangreiche und aufwendige Computersimulationen

## Schematische Darstellung eines Klimamodells



## Parametrisierungen und Tuning


- Fokus auf die **Atmosphäre**: Modellierung durch ein System nichtlinear gekoppelter PDEs (**Navier-Stokes-Gleichungen**) auf einem relativ groben Gitter (~50–150 km).



- **Subgrid-Skalen-Phänomene**, wie (tiefe) Konvektion und (Wolken-)Mikrophysik, oder Multiskalen-Phänomene, wie atmosphärische Turbulenzen, **können nicht explizit aufgelöst werden**.
- Sie werden in der Regel durch **semi-empirische, parametrisierte Funktionen modelliert** und dann mit dem globalen Klimamodell gekoppelt.
  - Dieses Verfahren wird als **Parametrisierung** bezeichnet.
  - Freie Parameter müssen angepasst werden, um den Beobachtungen zu entsprechen: **Parameter tuning**.

Klimamodellierung ist äußerst anspruchsvoll und kostspielig. Parametrisierungen und sorgfältiges Tuning sind essenziell.

# Unsicherheiten in bestehenden Klimamodellen<sup>01</sup>

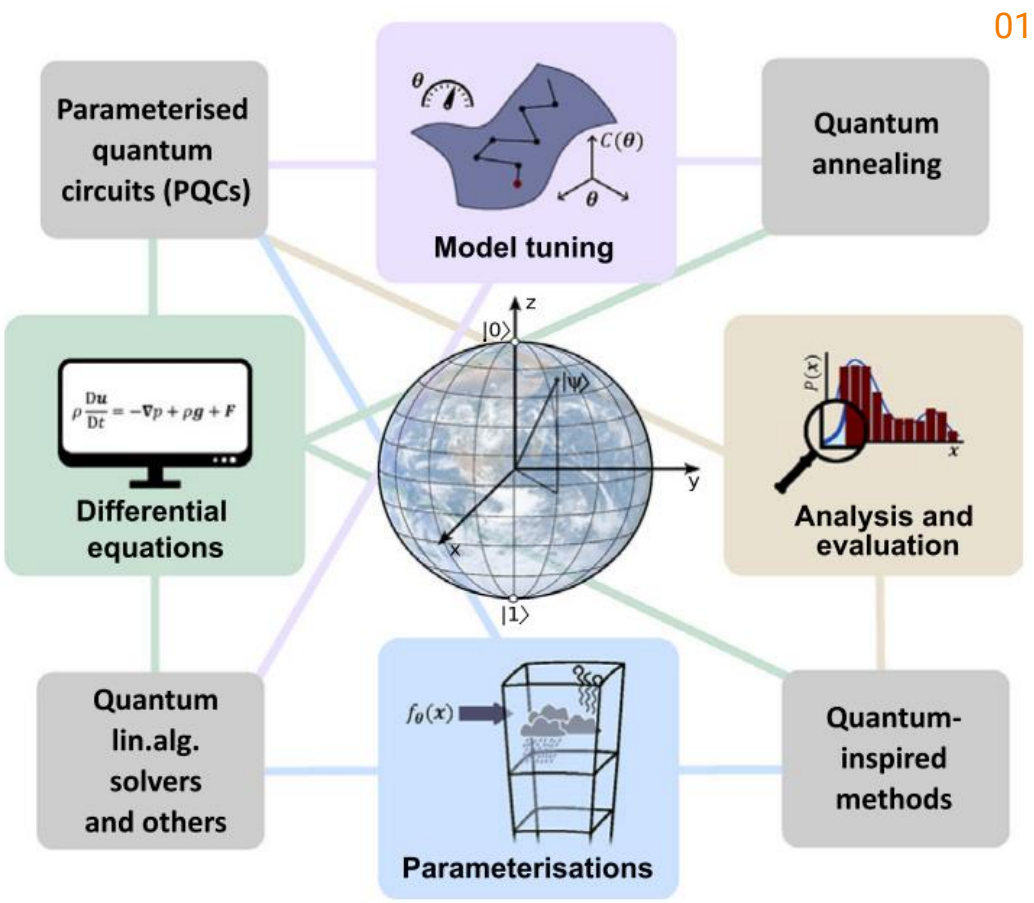


<sup>01</sup> Eyring et al., IPCC AR6 WGI, Chapter 3: "Human influence on the climate system", 2021

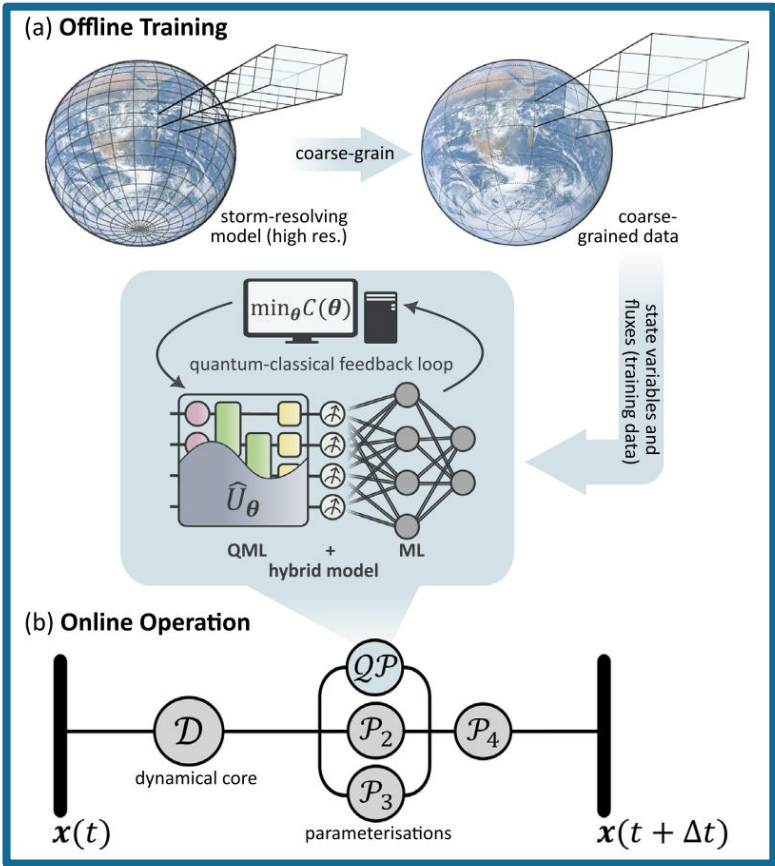
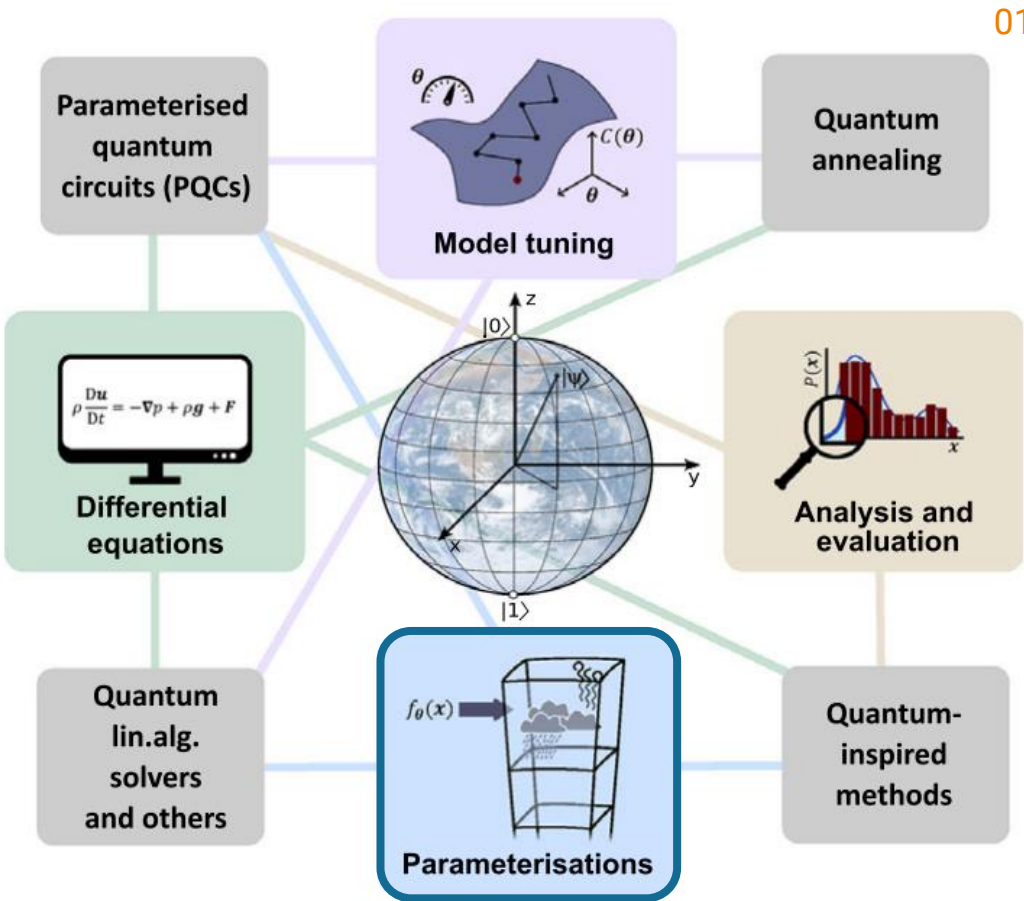
Selbst moderne Klimamodelle weisen systematische Verzerrungen auf, insbesondere bei den Niederschlägen.




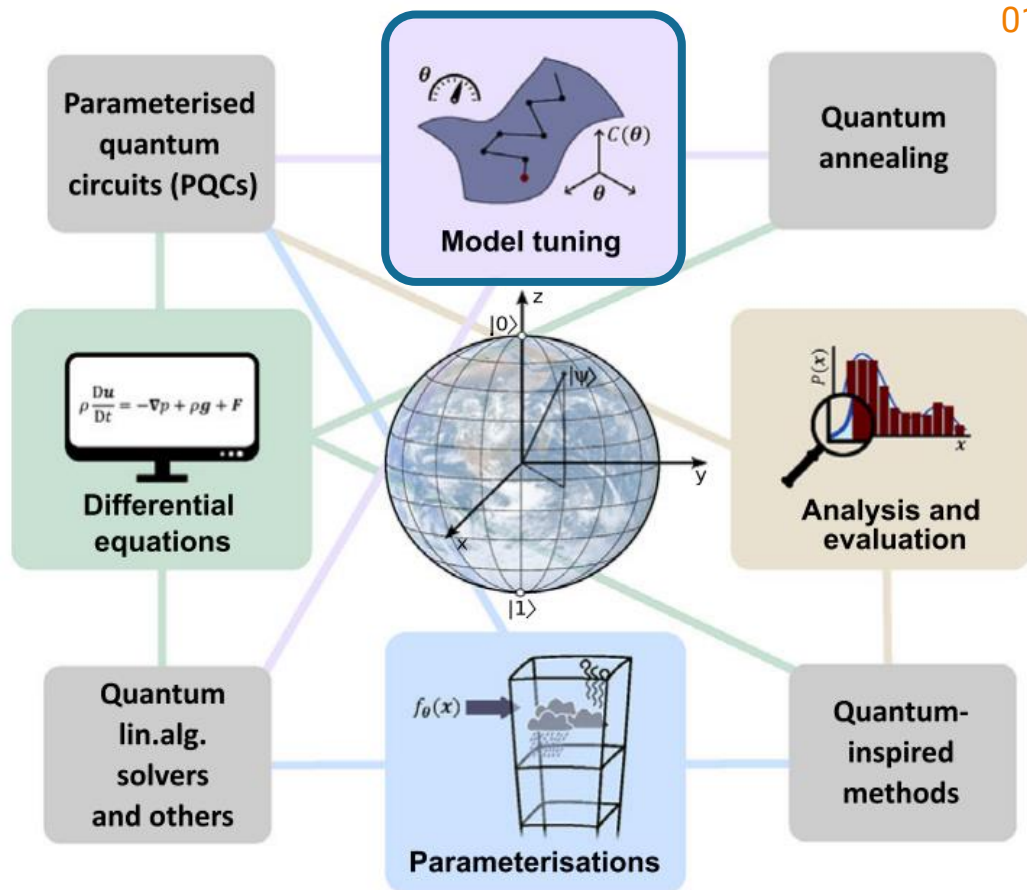
# Wo kann Quantencomputing helfen?



# Wo kann Quantencomputing helfen?

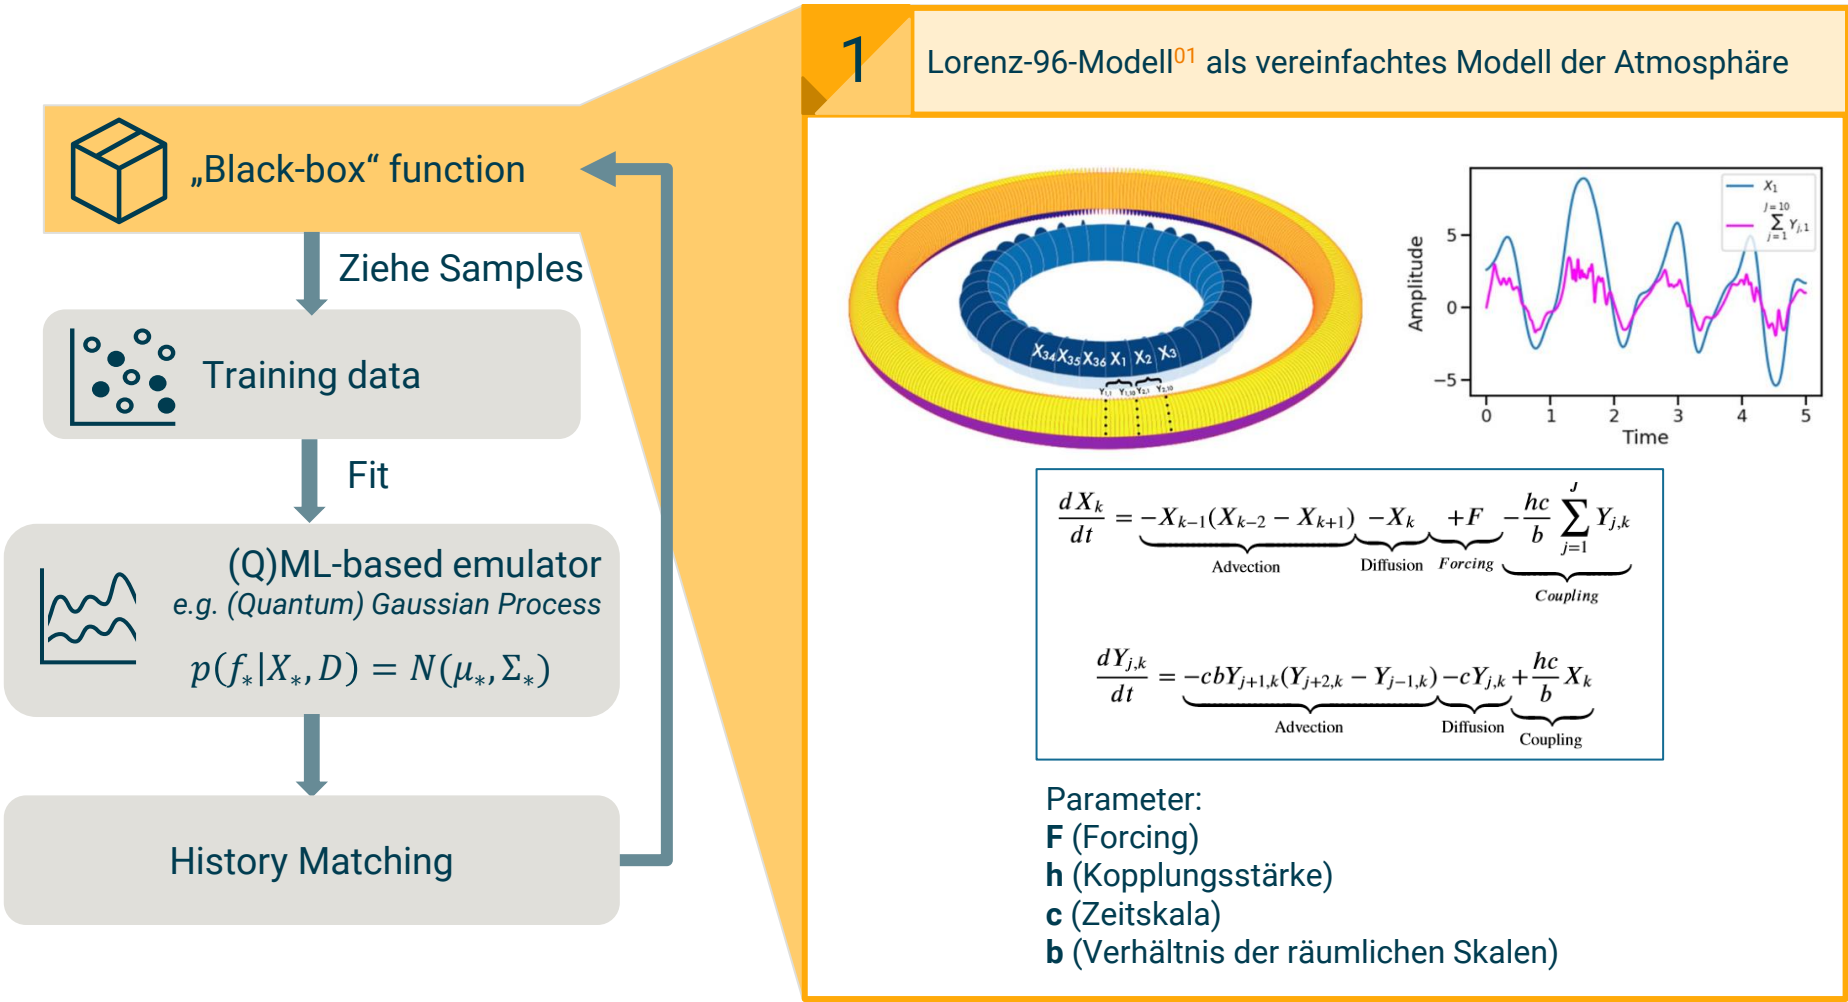


# Wo kann Quantencomputing helfen?

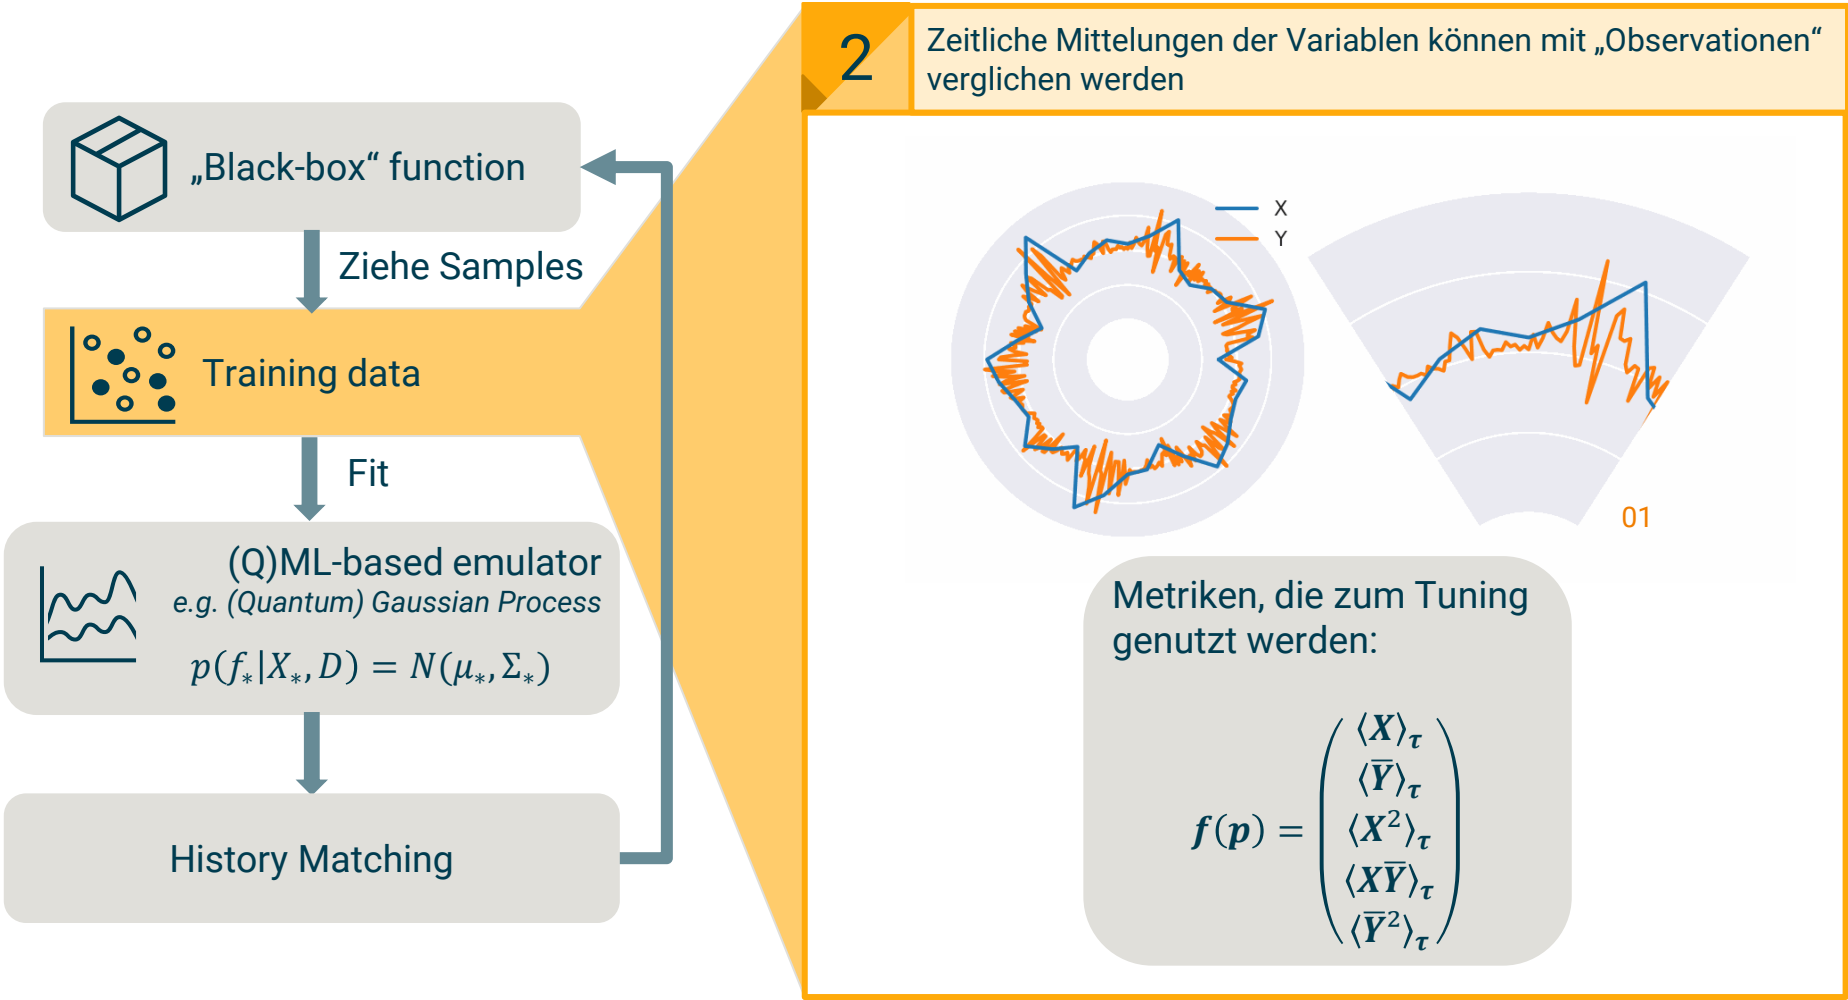




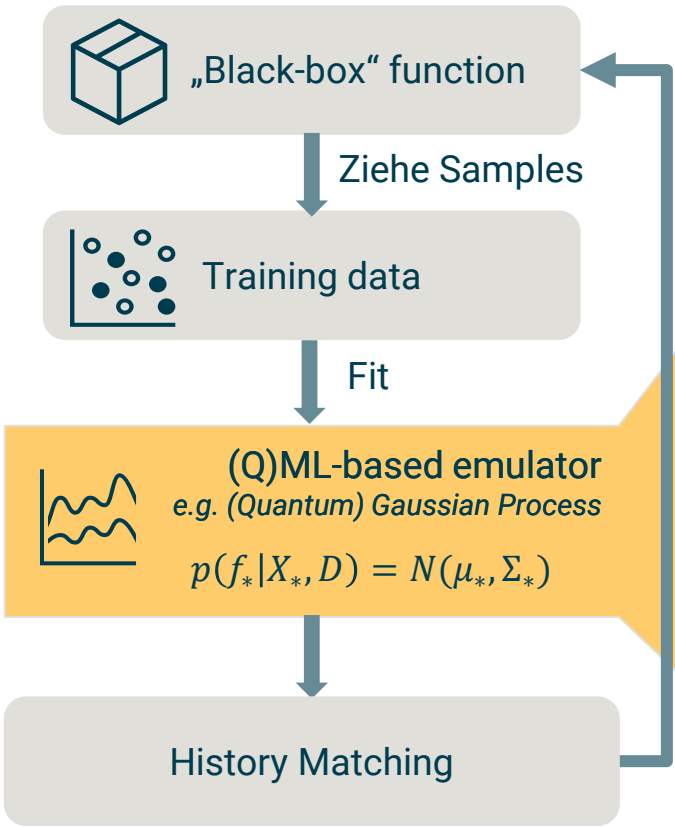
# Dieses Problem kann als Bayesianische Optimierung verstanden werden



# Dieses Problem kann als Bayesianische Optimierung verstanden werden



# Dieses Problem kann als Bayesianische Optimierung verstanden werden



3

## Gaußprozesse mit Quanten-Kernels

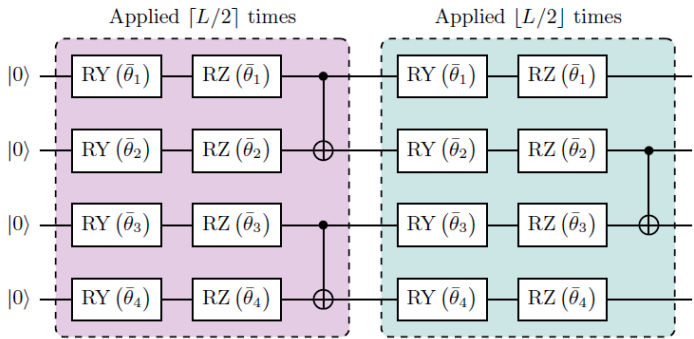
Klassischer GP:

$$f(x) \sim GP(m(x), k(x, x'))$$

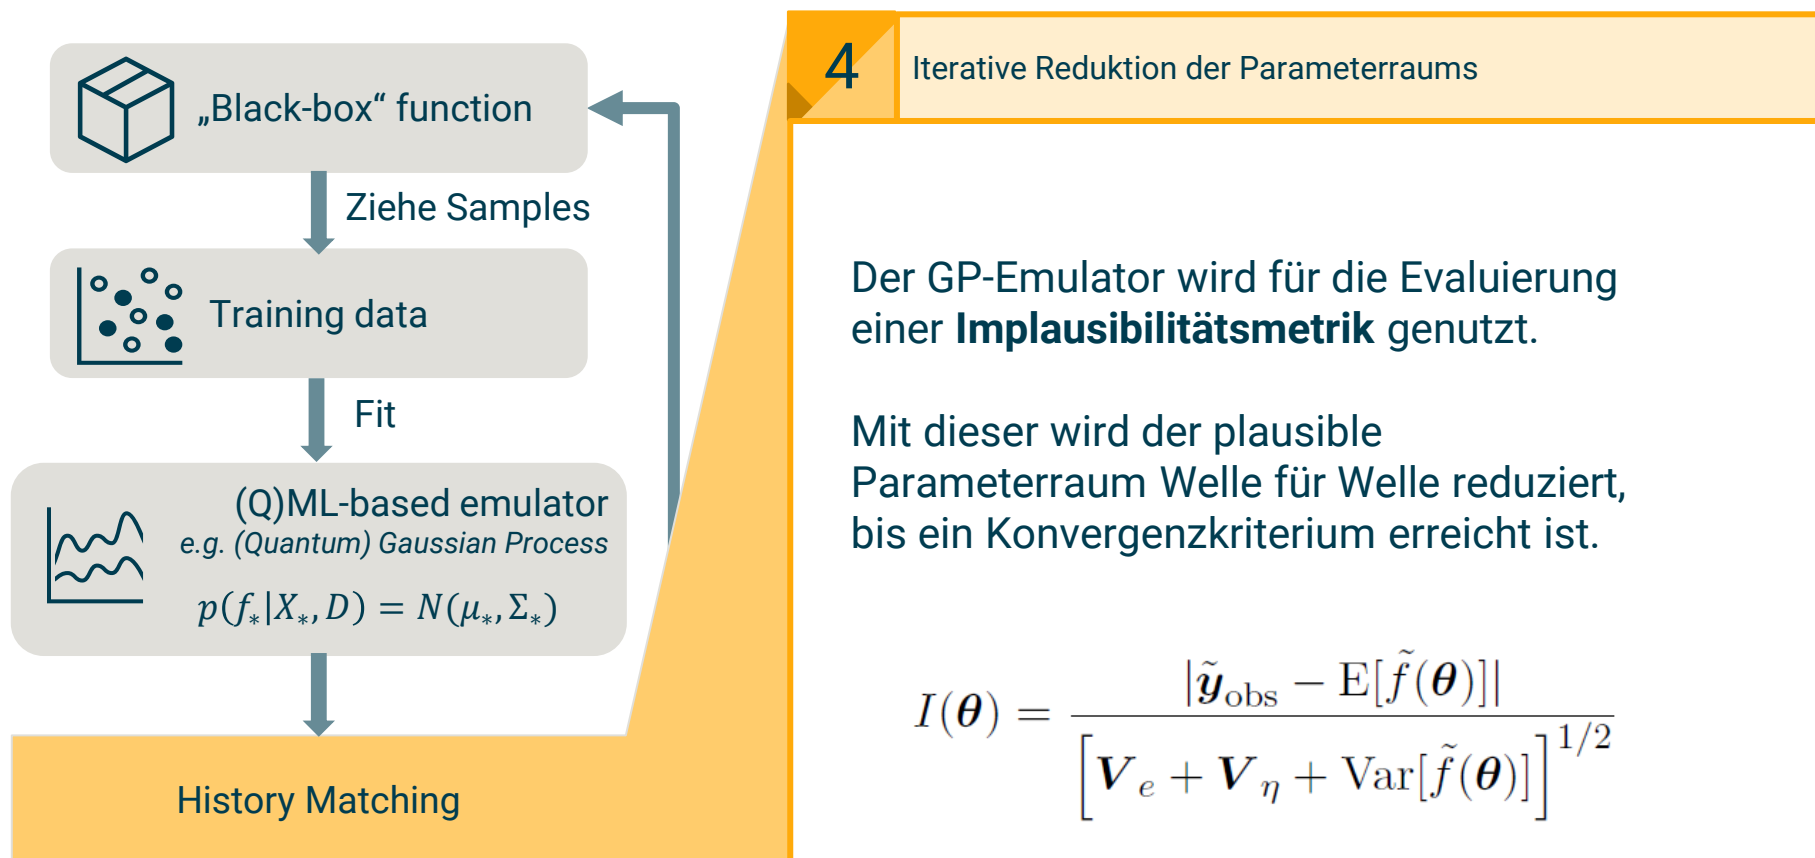
Quanten-GP:

$$k(x, x') = \text{Tr}[\rho(x)\rho(x')] = |\langle \phi(x') | \phi(x) \rangle|^2$$

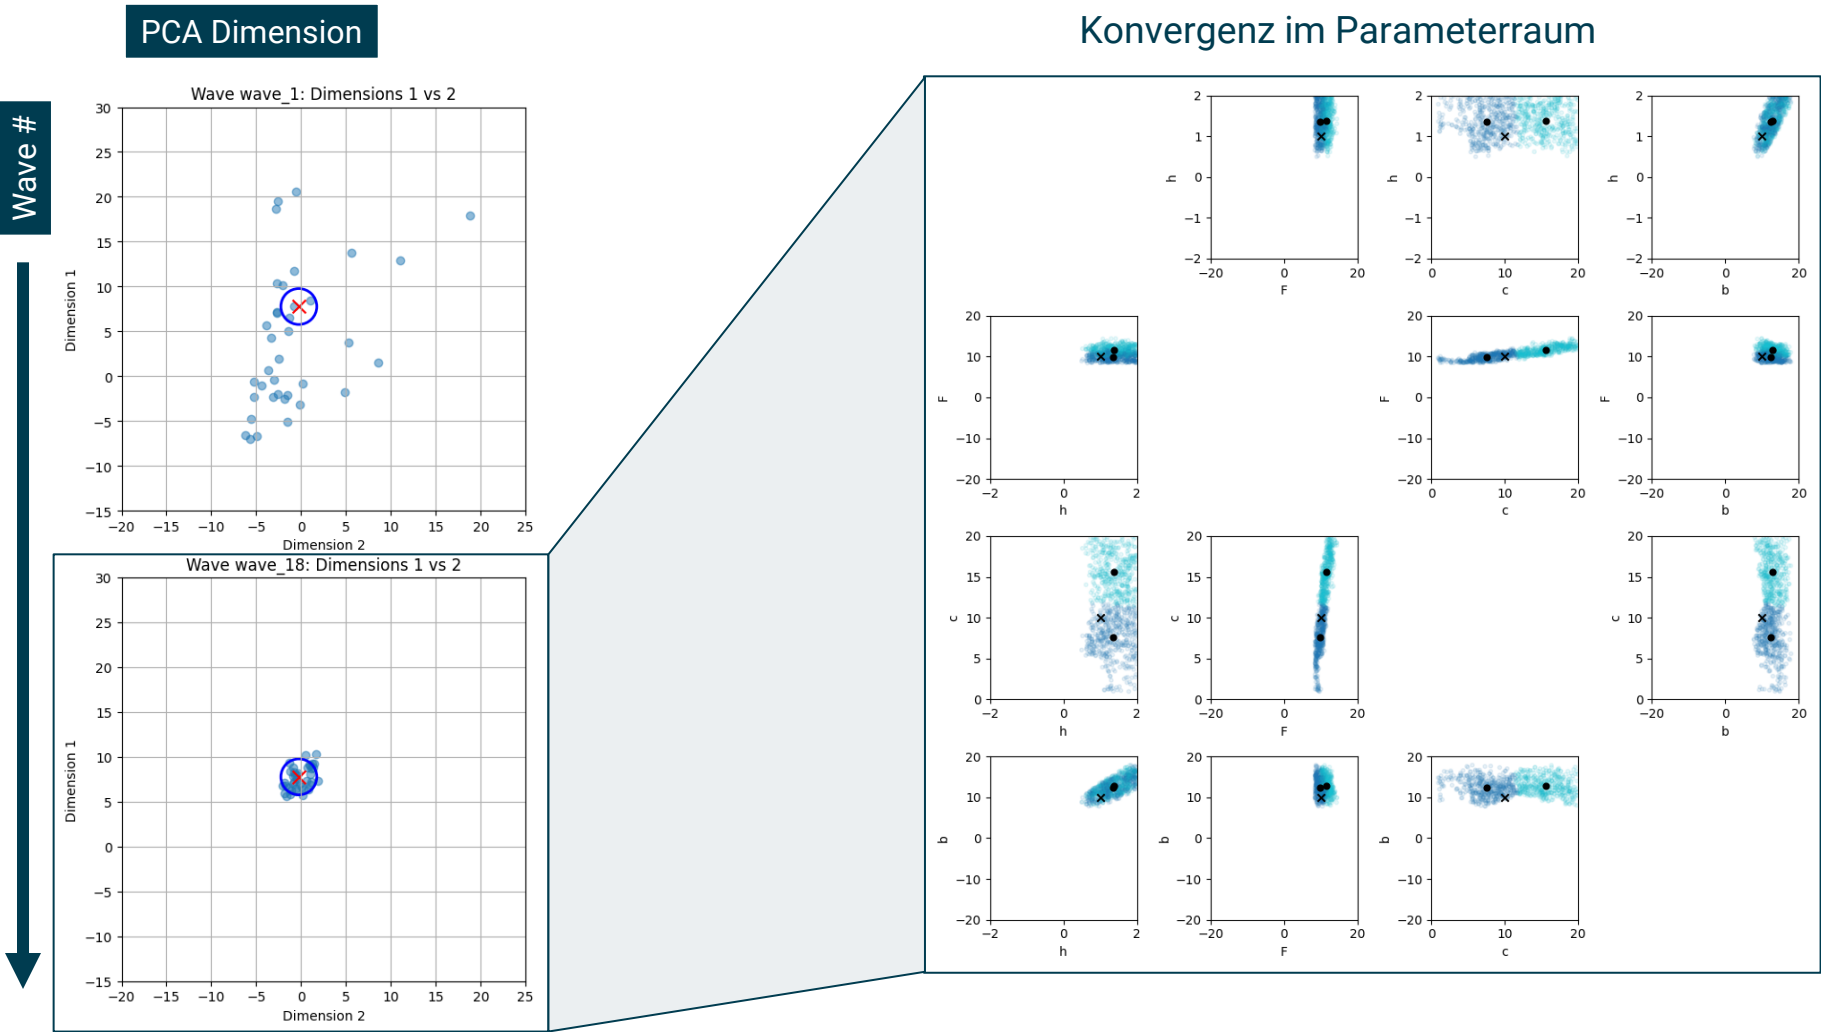
Beispielhafte Feature map (YZ-CX kernel):




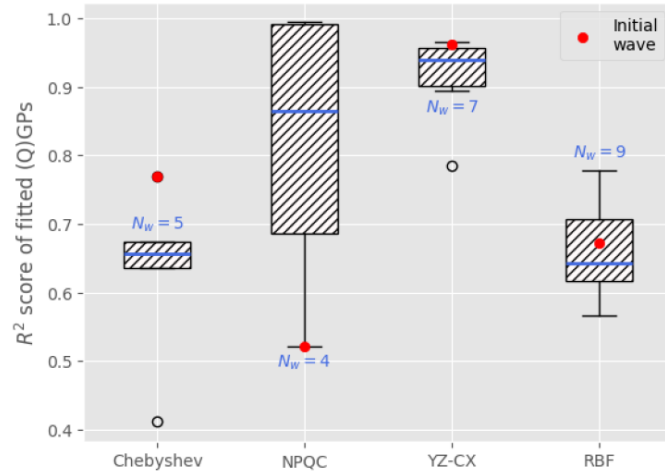
# Dieses Problem kann als Bayesianische Optimierung verstanden werden



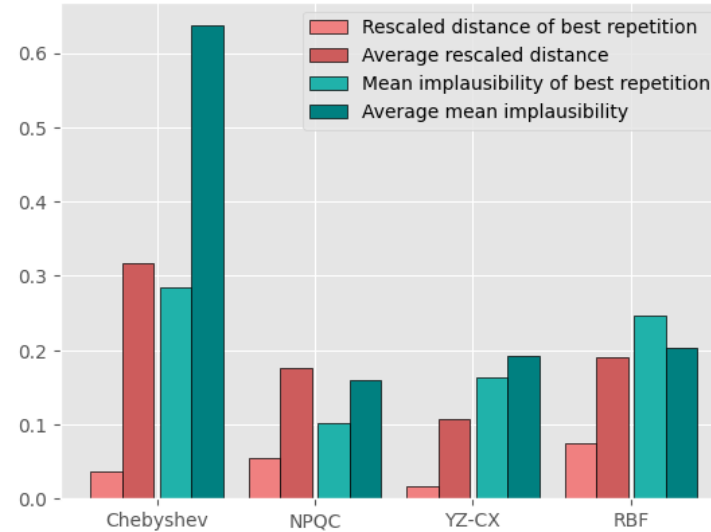
# Nach genügend Iterationen ist die Varianz der Metriken konvergiert



# Die Ergebnisse sind vielversprechend, auch ohne einen klaren “Quantenvorteil”



Untersucht wurden drei verschiedene Quanten-Kernel-Architekturen mit jeweils 4-8 Qubits

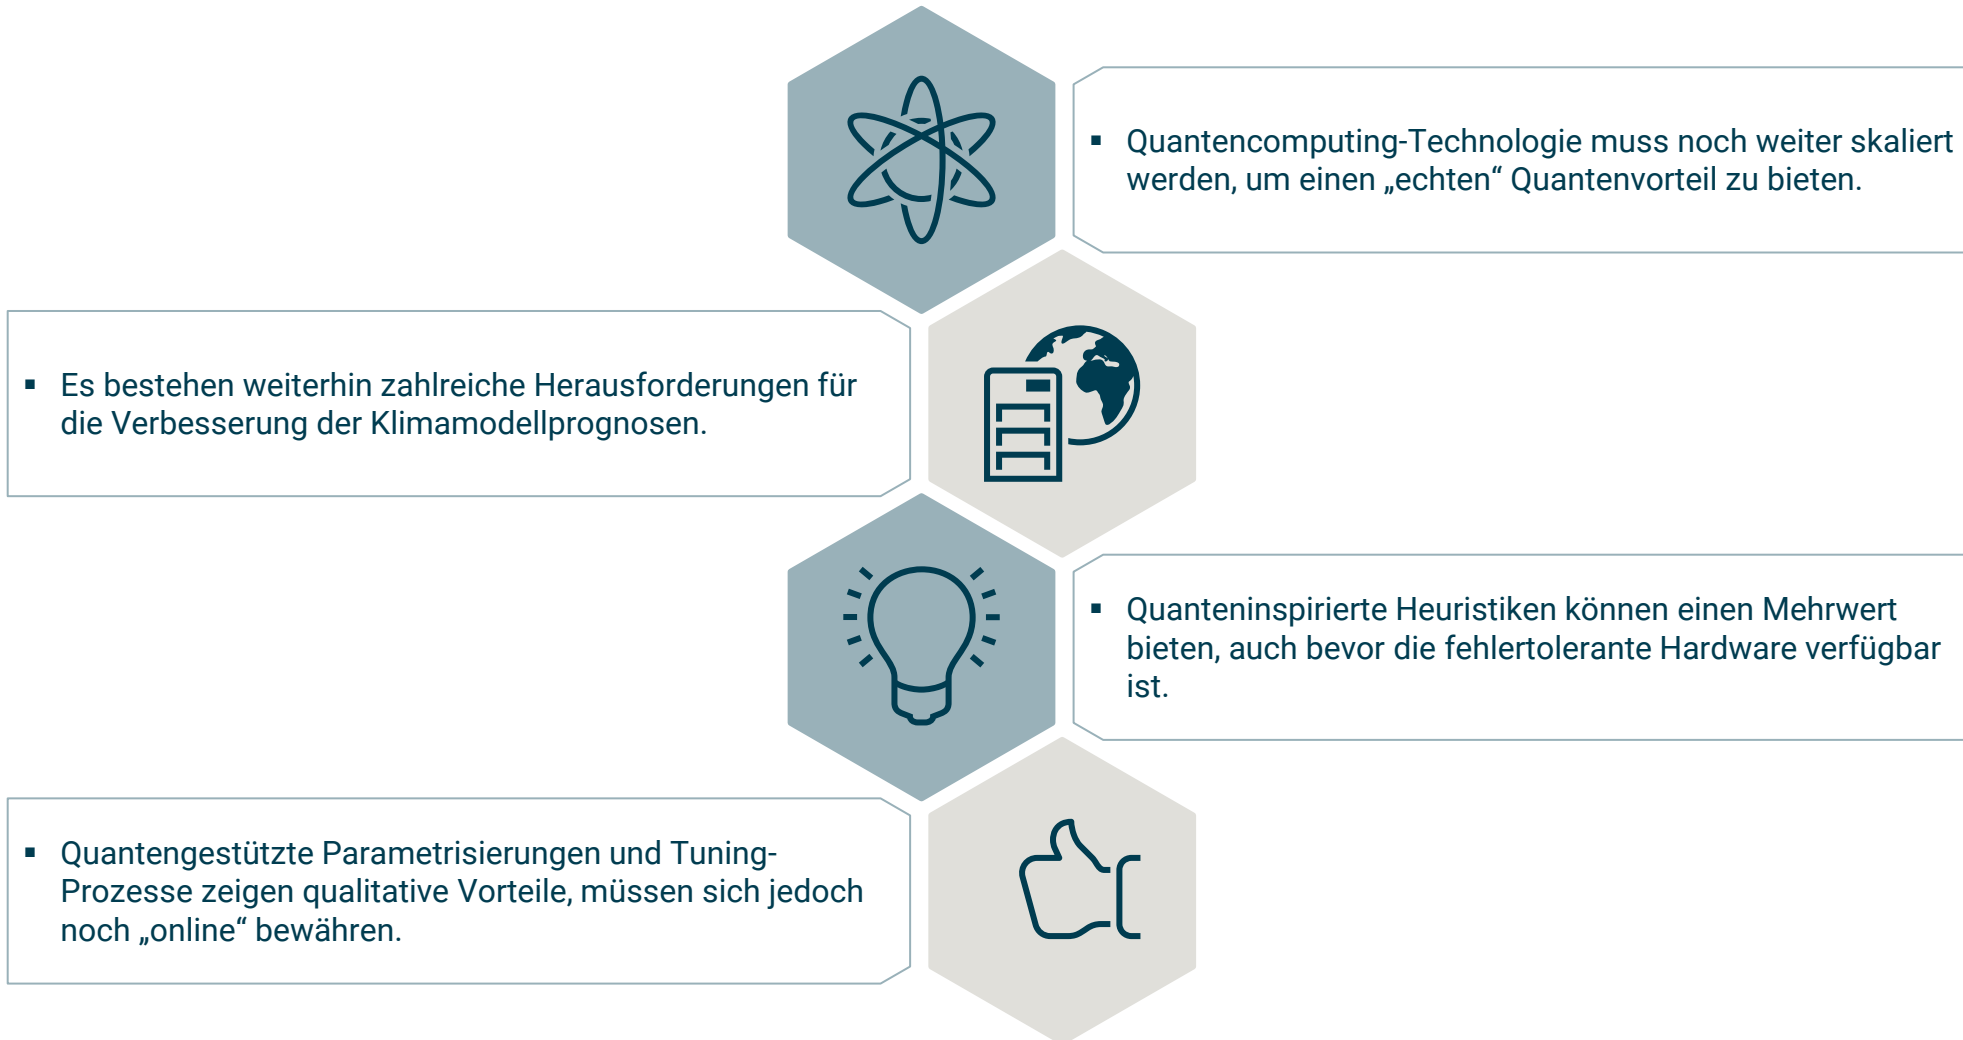


Zwei der untersuchten (simulierten) Quantenkernels führen zu besseren Ergebnissen und schnellerer Konvergenz als klassische RBF-Kernel.

Dies zeigt, dass quanteninspirierte Heuristiken auch ohne „Quantenvorteil“ einen Mehrwert bieten können.

*P. Christiansen, D. Ohl de Mello et al., Quantum Bayesian Optimization for the Automatic Tuning of Lorenz-96 as a Surrogate Climate Model, arXiv preprint (to be published)*

# Zusammenfassung





# Kontakt



**Dr Daniel Ohl de Mello**  
Manager  
Tel +49 69 90737-1672  
Mobile +49 152 57975495  
[Daniel.Ohl.de.Mello@d-fine.com](mailto:Daniel.Ohl.de.Mello@d-fine.com)

---



d-fine GmbH  
An der Hauptwache 7  
D-60313 Frankfurt/Main  
Deutschland

Frankfurt

Berlin

Düsseldorf

Hamburg

London

Mailand

München

Stockholm

Utrecht

Wien

Zürich

d-fine

analytisch. technologisch. quantitativ.