

Kontinuierlich selbstlernende Methoden für Leistungsprognosen zur Automatisierung im Netzbetrieb

Dominik Beinert¹, Yujiang He², Raphael Riege¹, Tobias Westmeier^{1,2}, Alexander Lipskij¹

Kontakt: Dominik Beinert | Fraunhofer IEE | dominik.beinert@iee.fraunhofer.de

Fraunhofer IEE¹
Universität Kassel²

Motivation

Die zunehmende Volatilität im elektrischen Energieversorgungssystem durch neue Verbraucher sowie erneuerbare Energien wie Wind- und Solarenergie erfordert eine stetige Verbesserung von Leistungsprognosen. Diese bilden für Netzbetreiber die Grundlage für den sicheren Betrieb des Stromnetzes. Die fortschreitende Kleinteiligkeit des Energiesystems ändert grundlegend die Anforderungen an Leistungsprognosen: In Zukunft werden digitale Prognosemodelle für viele Tausende verschiedener technischer Erzeugungskomponenten gefordert sein.




Abb. 1: Durch das Training wird eine feste statistische Beziehung zwischen Eingangsgrößen X und Zielgröße y erlernt.




Abb. 2: Fluktuierendes, z.B. wetterabhängiges Verhalten ist mit passenden Eingangsvariablen prognostizierbar.

Typische Modelle basieren auf statischen datengetriebenen Methoden (Abb. 1 und Abb. 2). Diese erfordern häufige manuelle Trainingsprozesse, damit neue Verhaltensmuster (Abb. 3) abgebildet sowie neu hinzukommende Erzeugungskomponenten adäquat prognostiziert werden können. Dies ist zeitaufwendig und teuer.

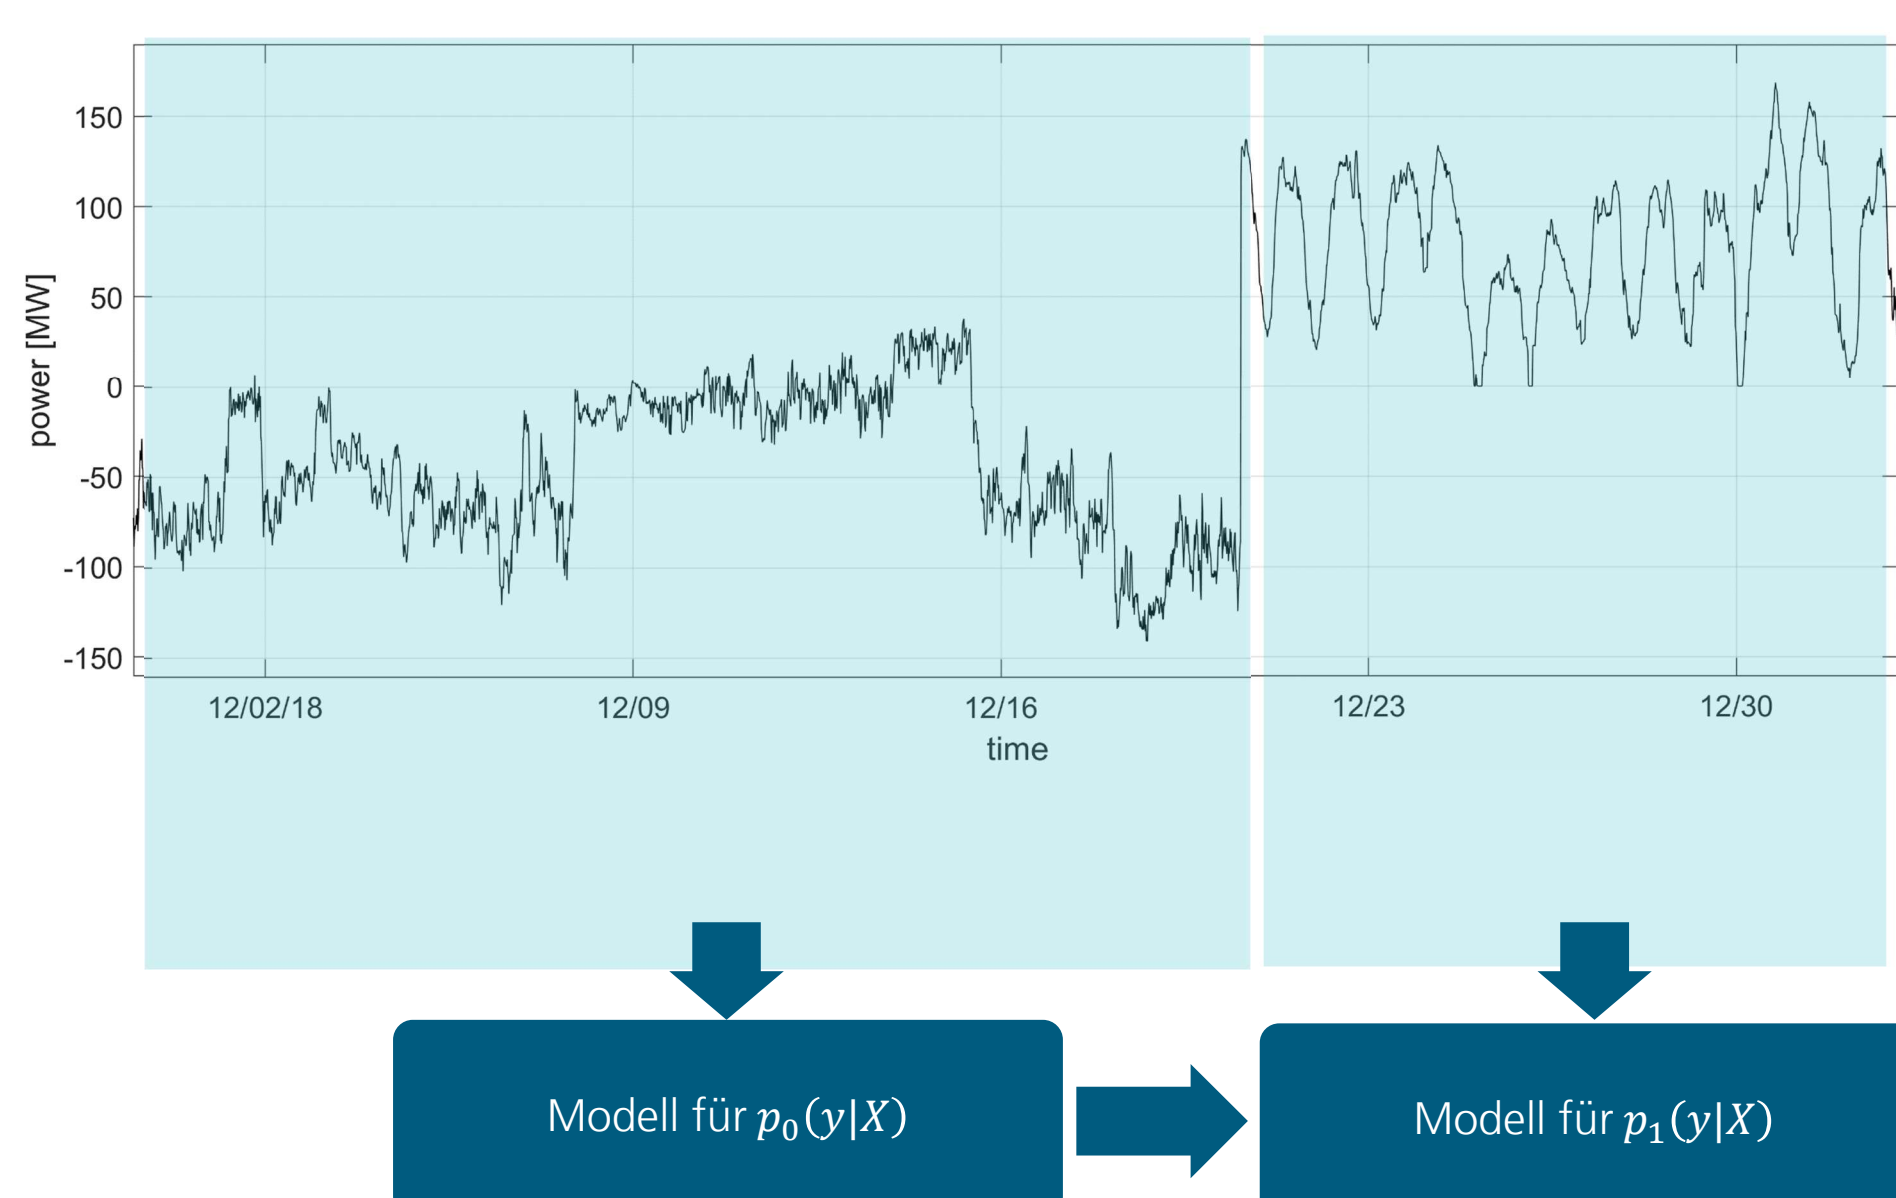


Abb. 3: Beispiel des Leistungsflusses an einem Transformator mit plötzlichem Shift: Neue Verhaltensmuster erfordern eine schnelle Anpassung oder Neutraining des Modells, um eine hohe Prognosequalität beizubehalten.

Ziel

Das Ziel ist die schnelle und automatisierte Anpassung oder Neuerstellung von Prognosemodellen durch eine Kombination von Continual Learning und Transfer Learning.

Prozess im automatisierten Betrieb

Der zentrale Aspekt ist die Erforschung des regelmäßig automatisch ausgeführten Moduls in der Mitte von Abb. 4.

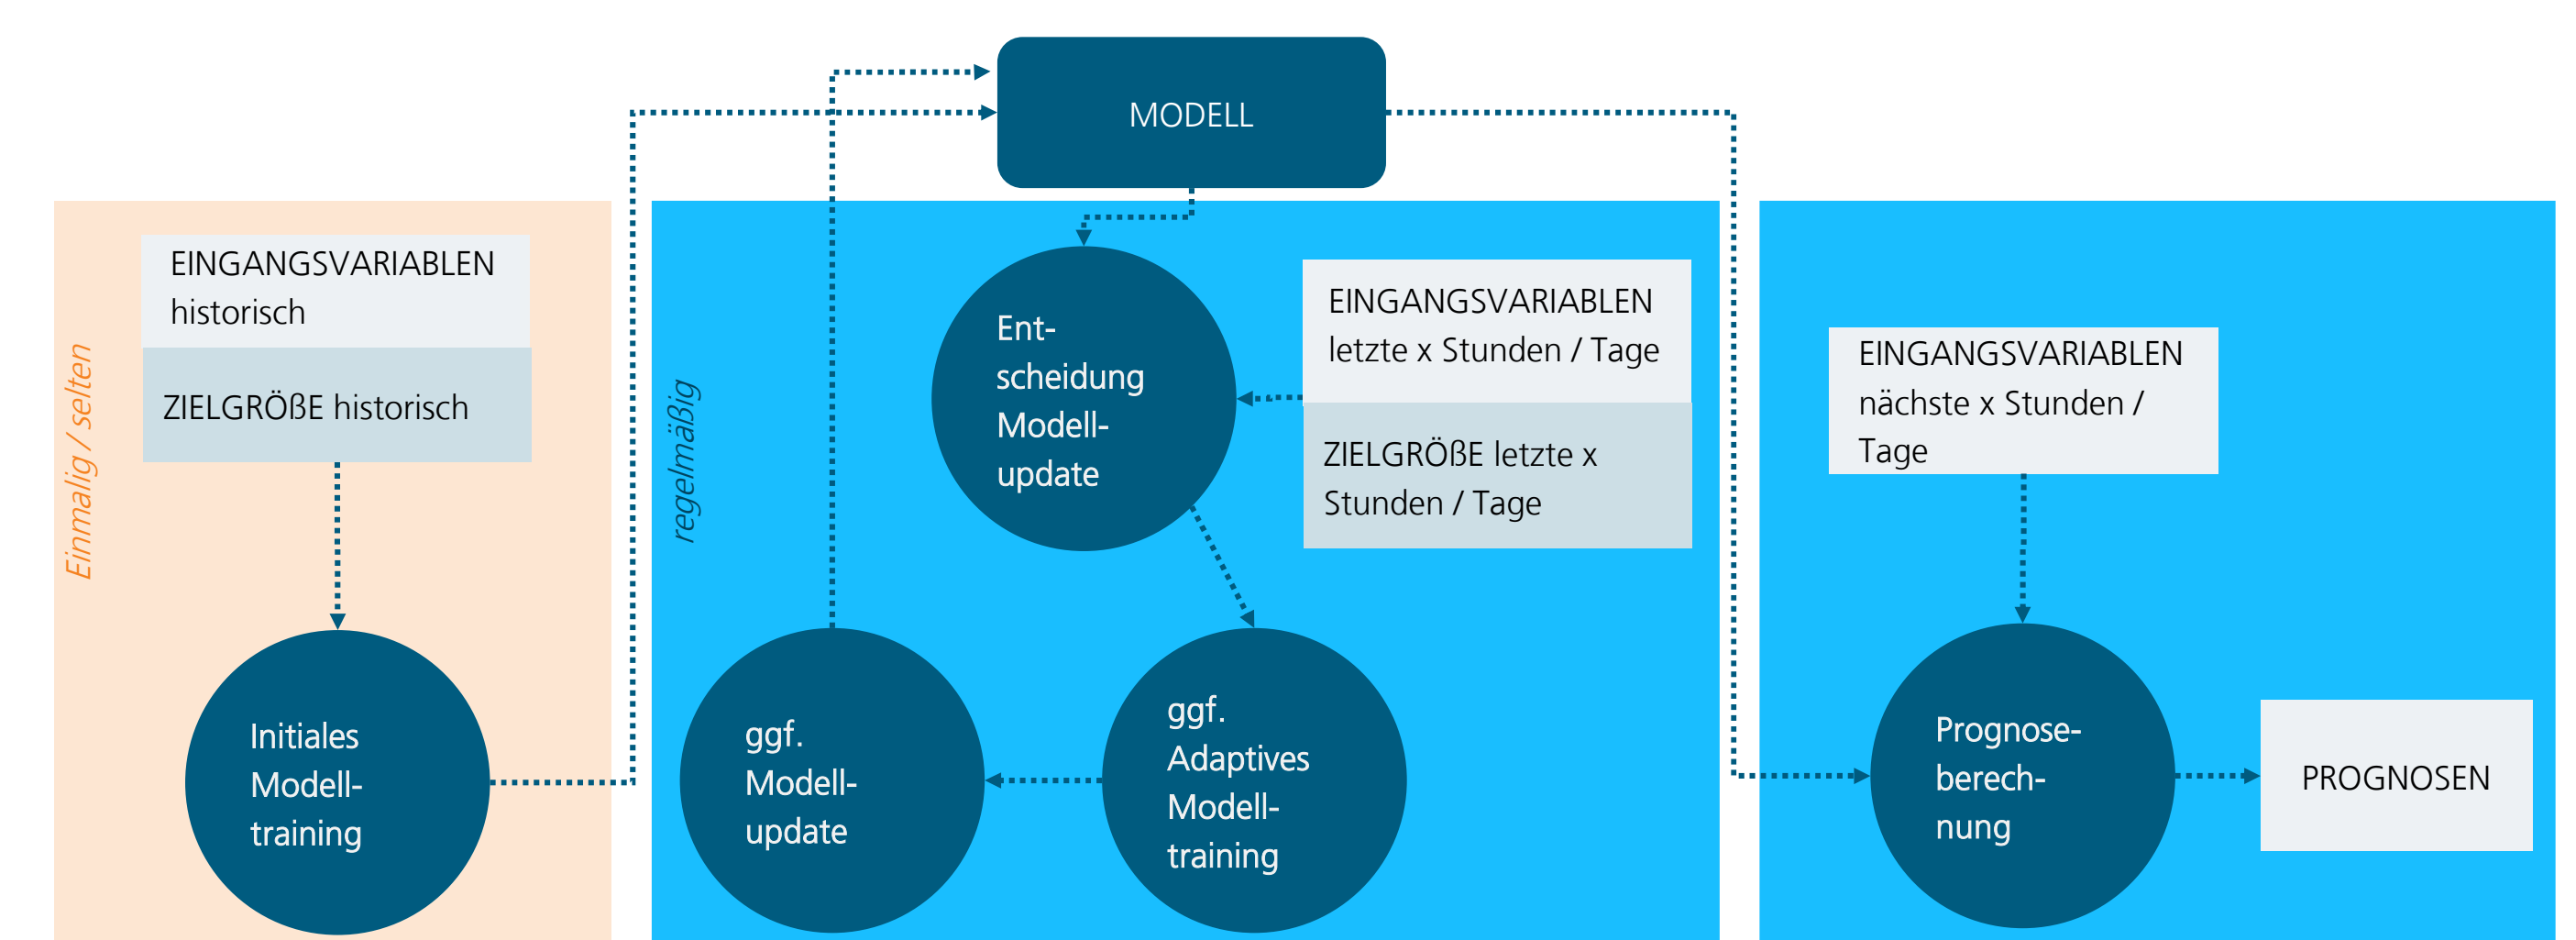
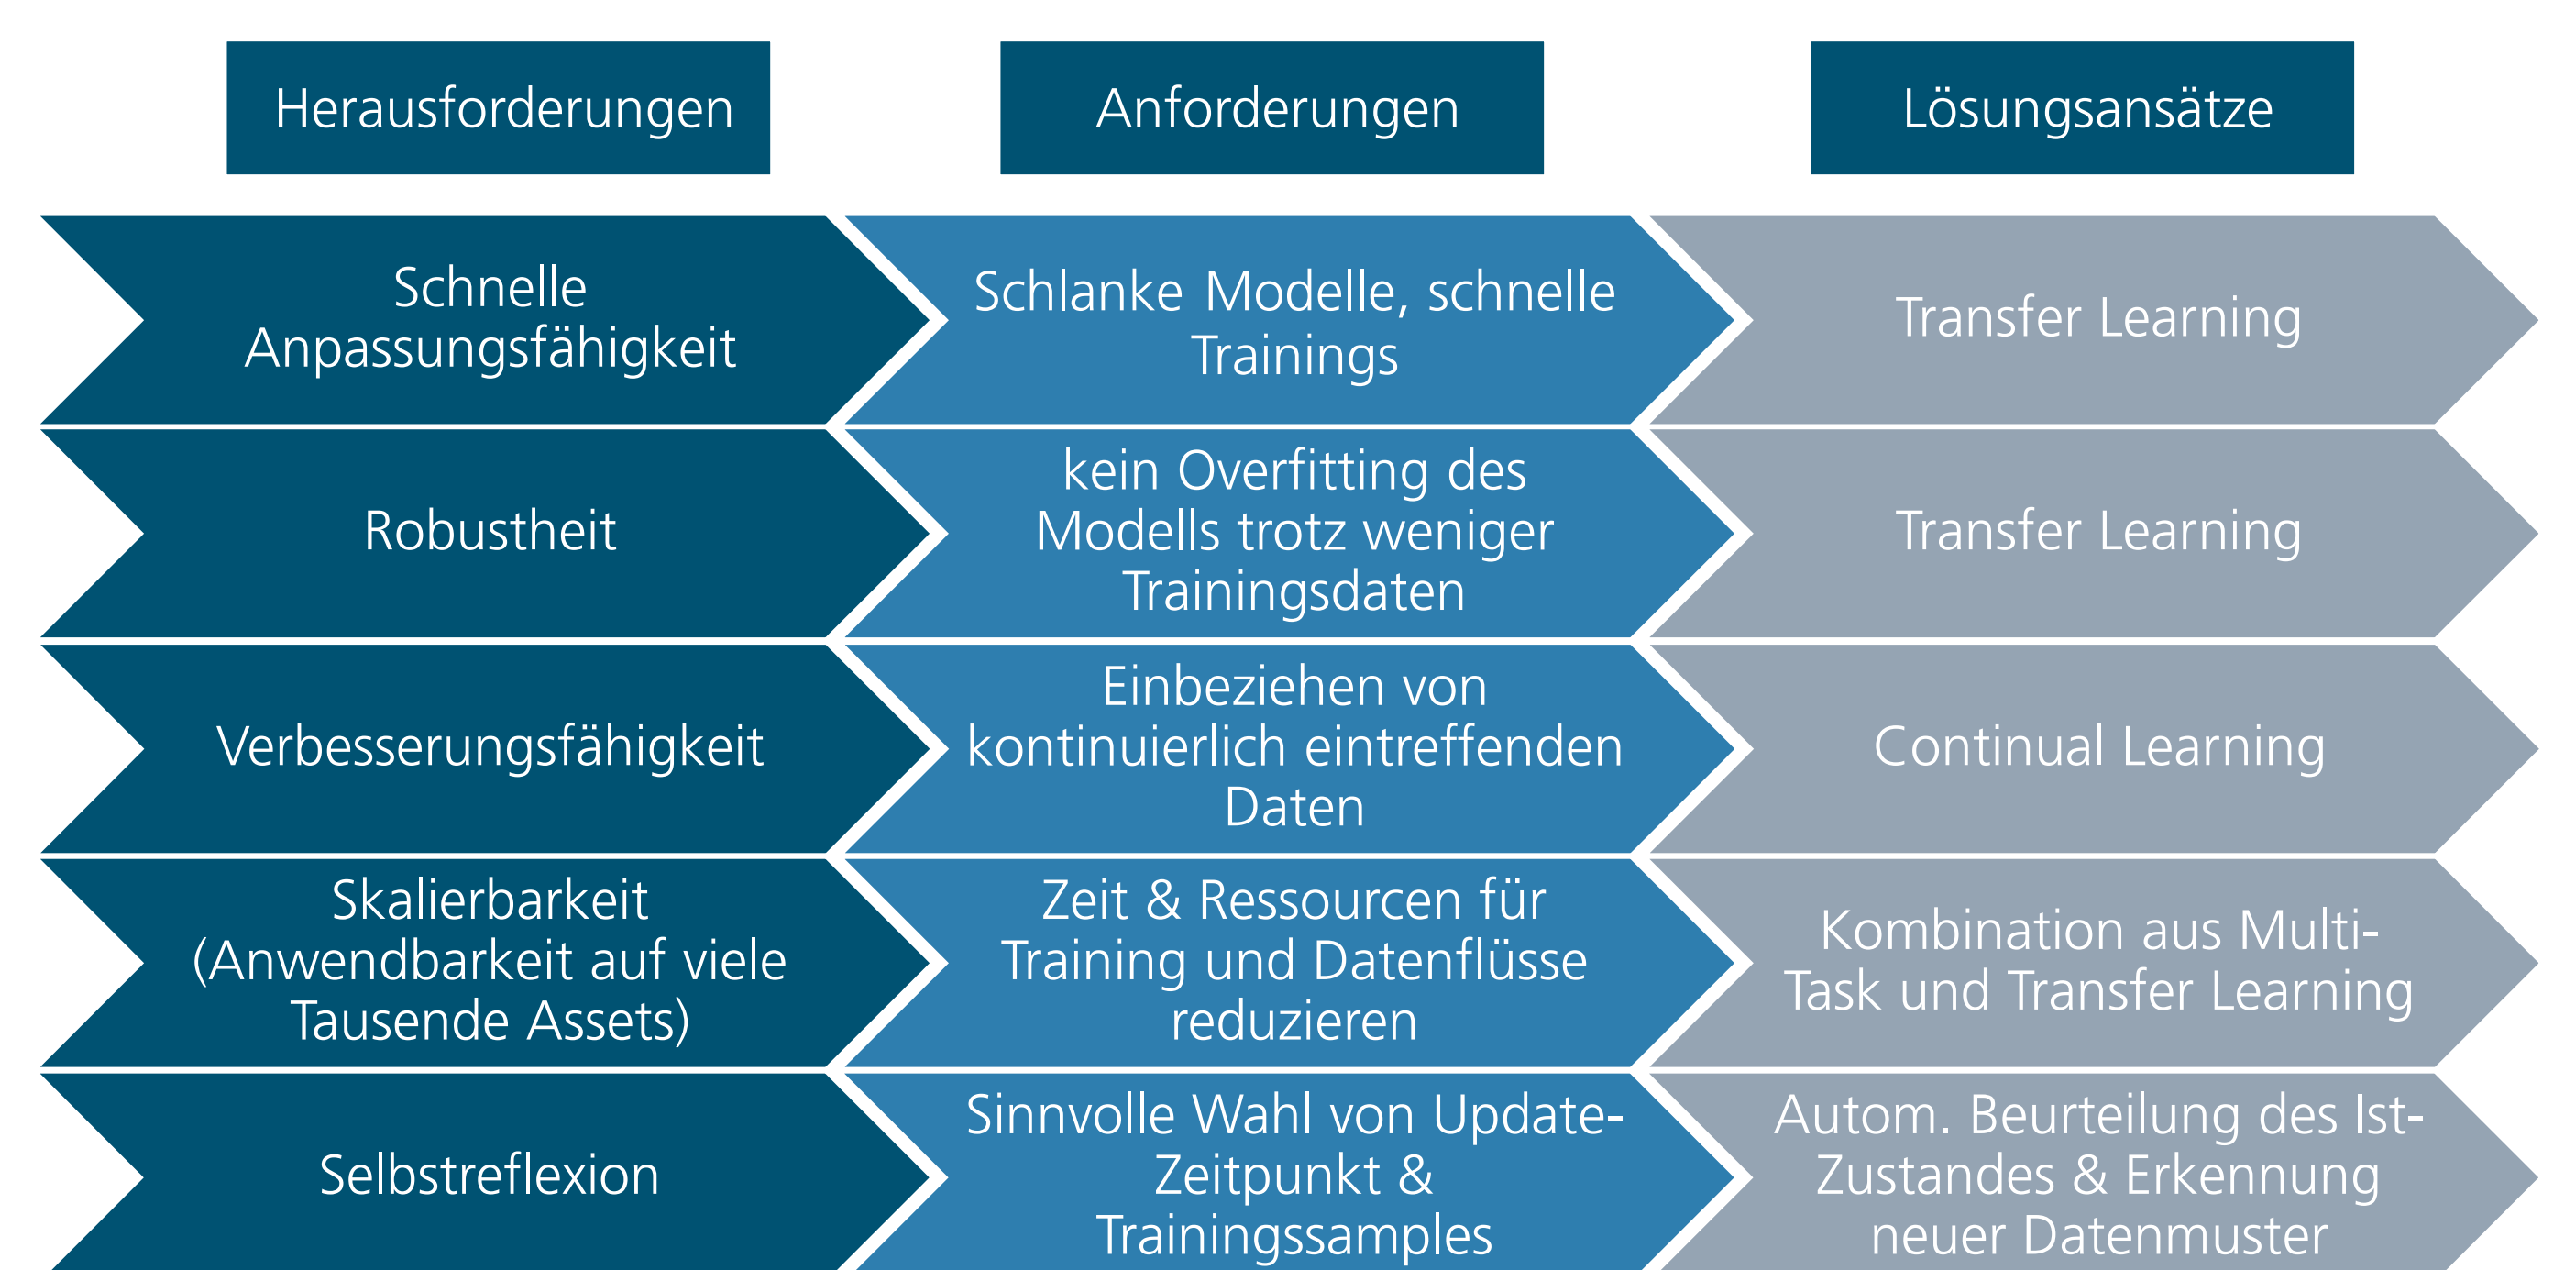


Abb. 4: Im Live-Betrieb muss zu jeder Zeit ein Modell für die Prognoseberechnung (rechts) vorhanden sein. Der typische Ansatz ist das einmalige Modelltraining auf einem großen historischen Datensatz (links). Neu ist hier das regelmäßig ausgeführte Modul (Mitte), das automatisiert kontinuierliche Modellupdates ermöglicht.

Erste Ergebnisse

Erste Ergebnisse von He et al. zeigen, dass Online-Modellupdates Verbesserungen des Prognosefehlers insbesondere dann bewirken können, wenn nur wenige Trainingsdaten für ein initiales Training verfügbar waren [(1), 2021] [(2), 2021]. Der Fokus bisheriger Arbeiten lag auf Continual-Learning-Ansätzen.

Methodische Herausforderungen, Anforderungen, Lösungsansätze



Zusammenfassung

Adaptive, selbstlernende Modelle bieten eine vielversprechende Lösung, da sie sich schnell an neue Bedingungen anpassen und damit eine hohe Prognosegüte erhalten können, was für die zukünftige Stabilität und Effizienz der Energieversorgung unerlässlich ist.