

Kombination von Windleistungsprognosen

Jonas Koch, Alina Herzog, Dr. Axel Braun, Jens Hoppe, Vitalij Kasselmann, Wolfgang Slaby

Kontakt: Jonas Koch | +49 561 7294-1756 | jonas.koch@iee.fraunhofer.de

Eine der größten Herausforderungen bei der Leistungsprognose von nahezu vollständig wetterabhängigen erneuerbaren Energiequellen wie Wind und PV ist die Ungenauigkeit der verwendeten Wetterprognosen (Numerical Weather Prediction – NWP). Für den Energiemarkt sind diese Prognosen – insbesondere die Prognosehorizonte 0-4 h – essentiell. Unsicherheiten und Prognosefehler reduzieren bei Direktvermarktern die Gewinne oder führen zu Verlusten und gefährden bei Netzdienstleistern unter Umständen die Netzstabilität.

Auf dem Weg zu einem selbstlernenden Prognosesystem soll die Prognosegüte weiter verbessert werden, indem Kombinationsmethoden vorhandener Prognosen aus verschiedenen NWP getestet und in Echtzeit (re)kalibriert werden. Dazu wird ein zusätzliches Modell (häufige Updates, von IBM) herangezogen und dessen Mehrwert für die Kombination ermittelt.

Ziele

- Untersuchung des Mehrwertes des IBM GRAF Wettermodellblends für unsere Windleistungsprognose
- Entwicklung eines *continuous-delivery-for-machine-learning* (CD4ML) konformen Frameworks zur Kombination verschiedener Windleistungsprognosen durch unterschiedliche Methoden
- Passende Kombinationsmethoden auswählen und optimieren
- Optimierung der Parameter wie z. B. Länge des Trainingszeitraums oder Ermöglichen einer Bias-Korrektur
- Verbesserung der Prognosegüte
- Entwicklung robuster Verfahren, für den operativen Betrieb geeignet

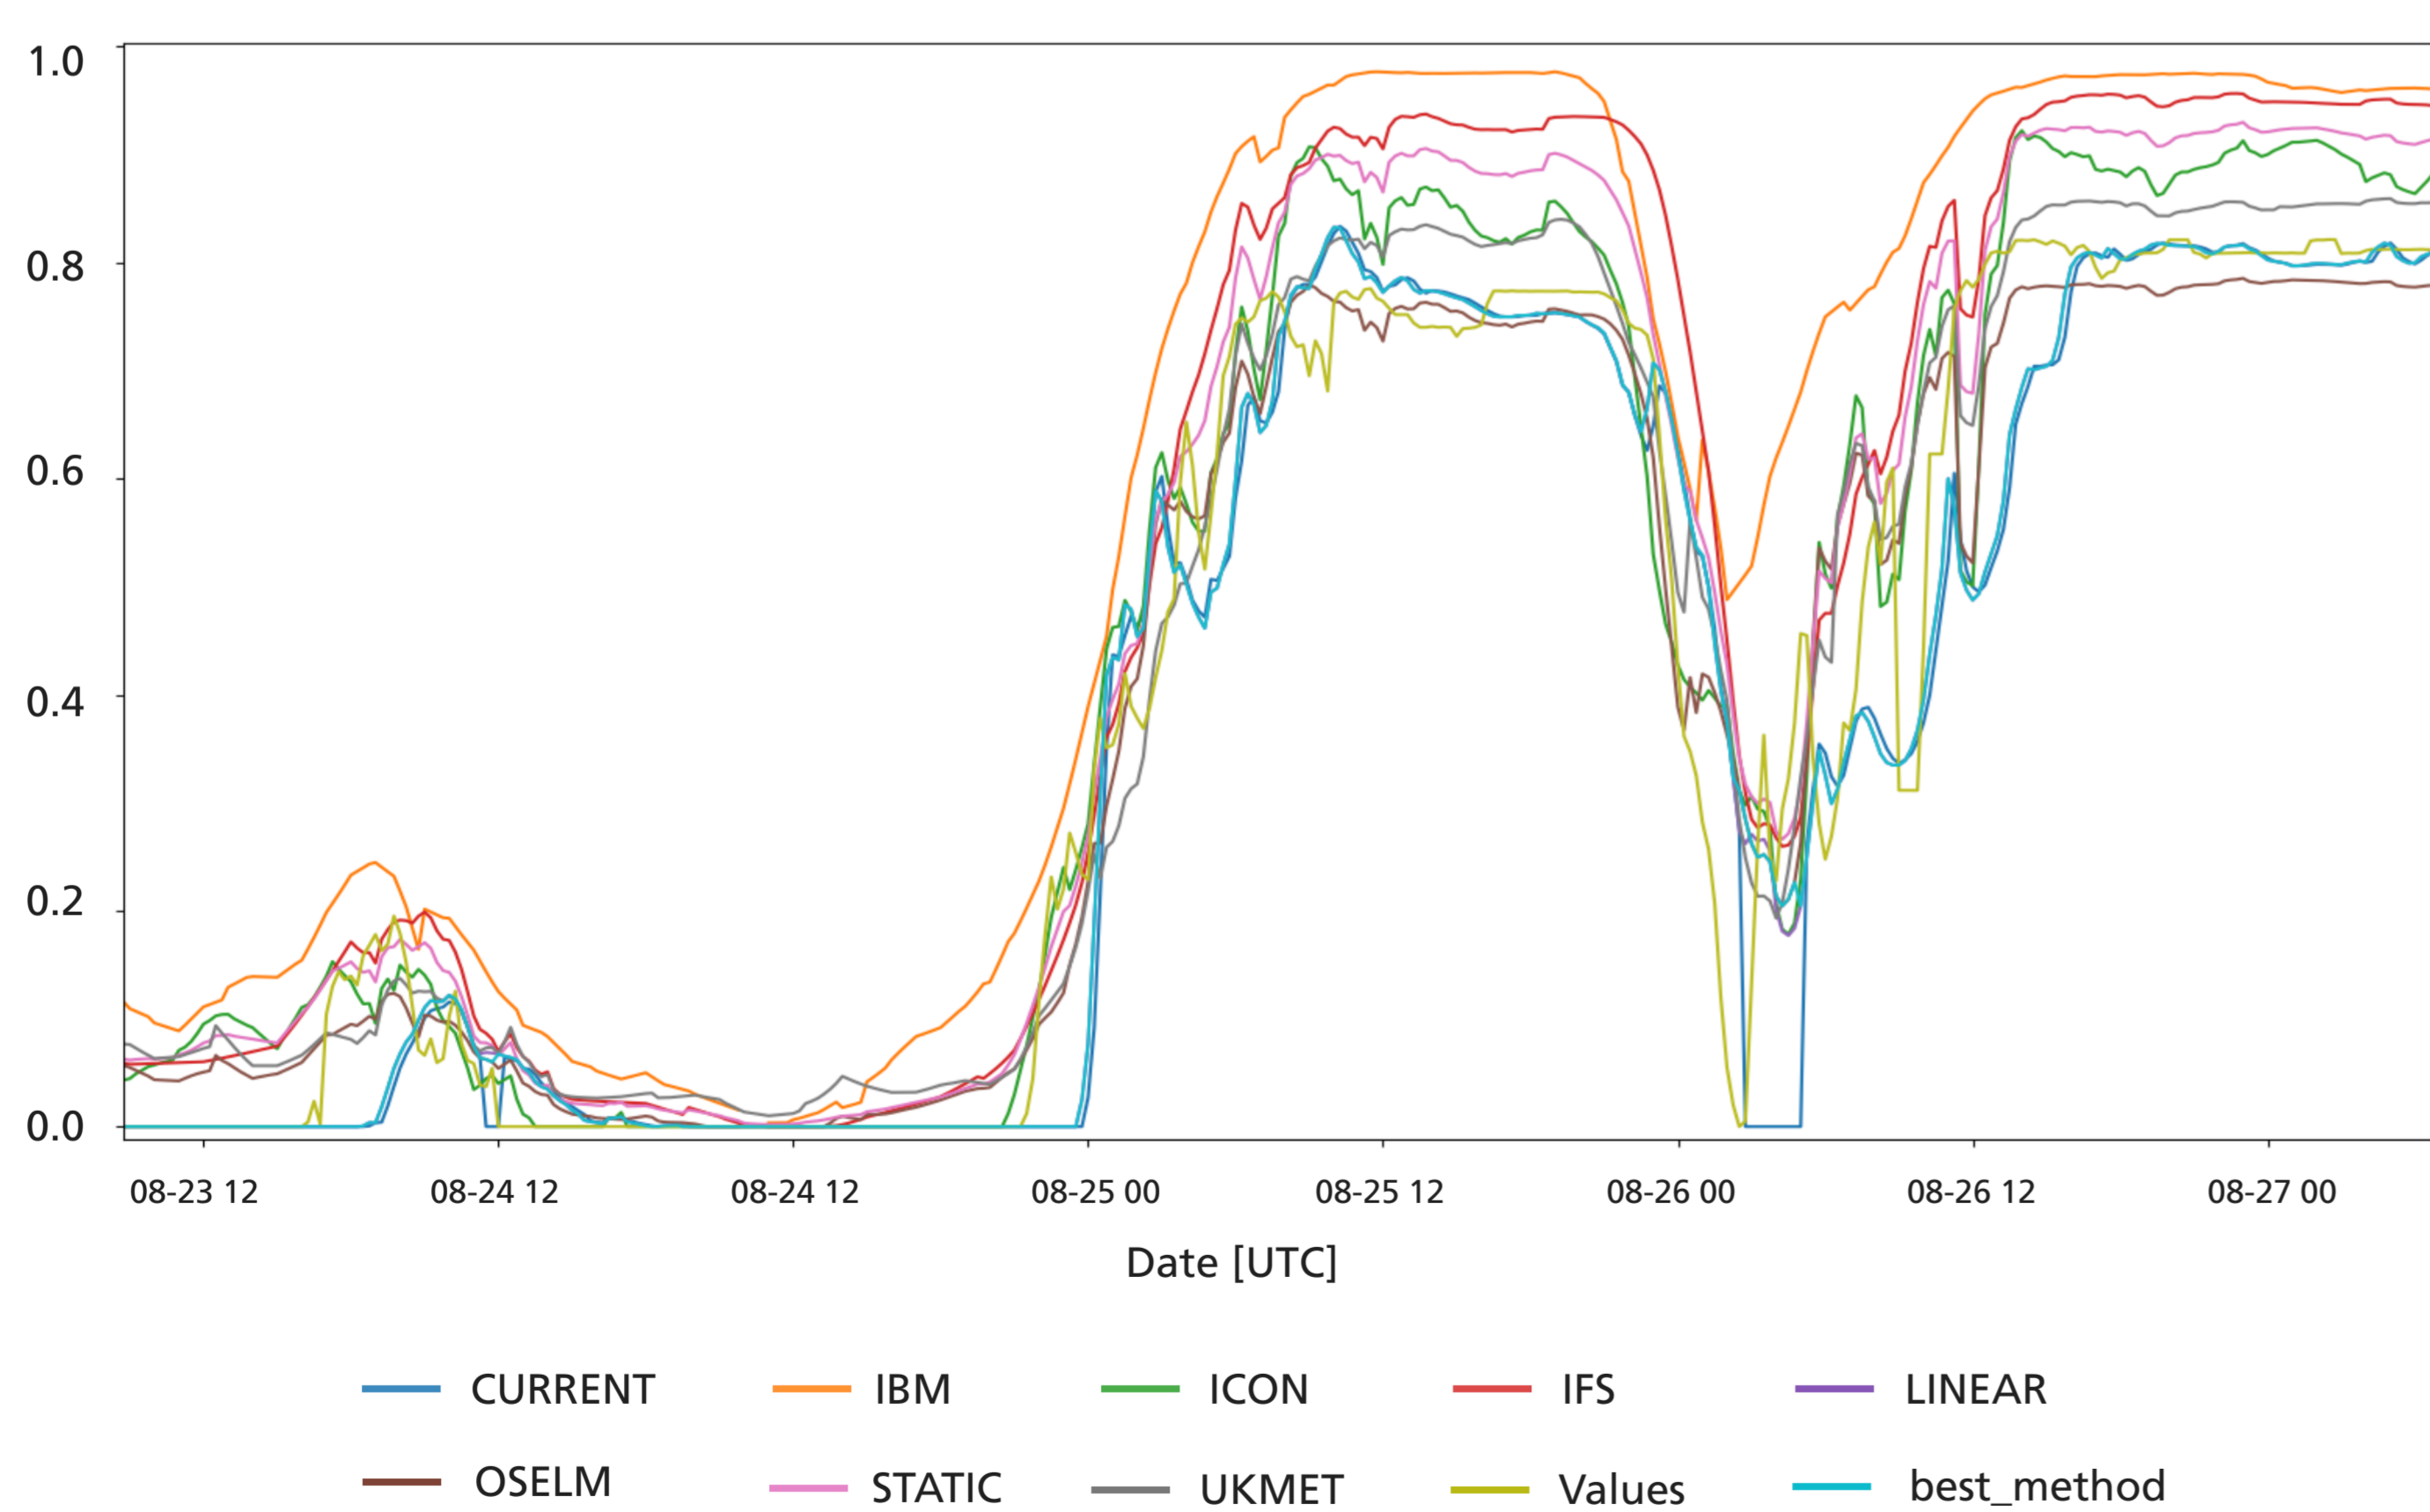


Abbildung 1: Unterschiedliche Verläufe von Wettermodellen und Kombinationen verschiedener Methoden

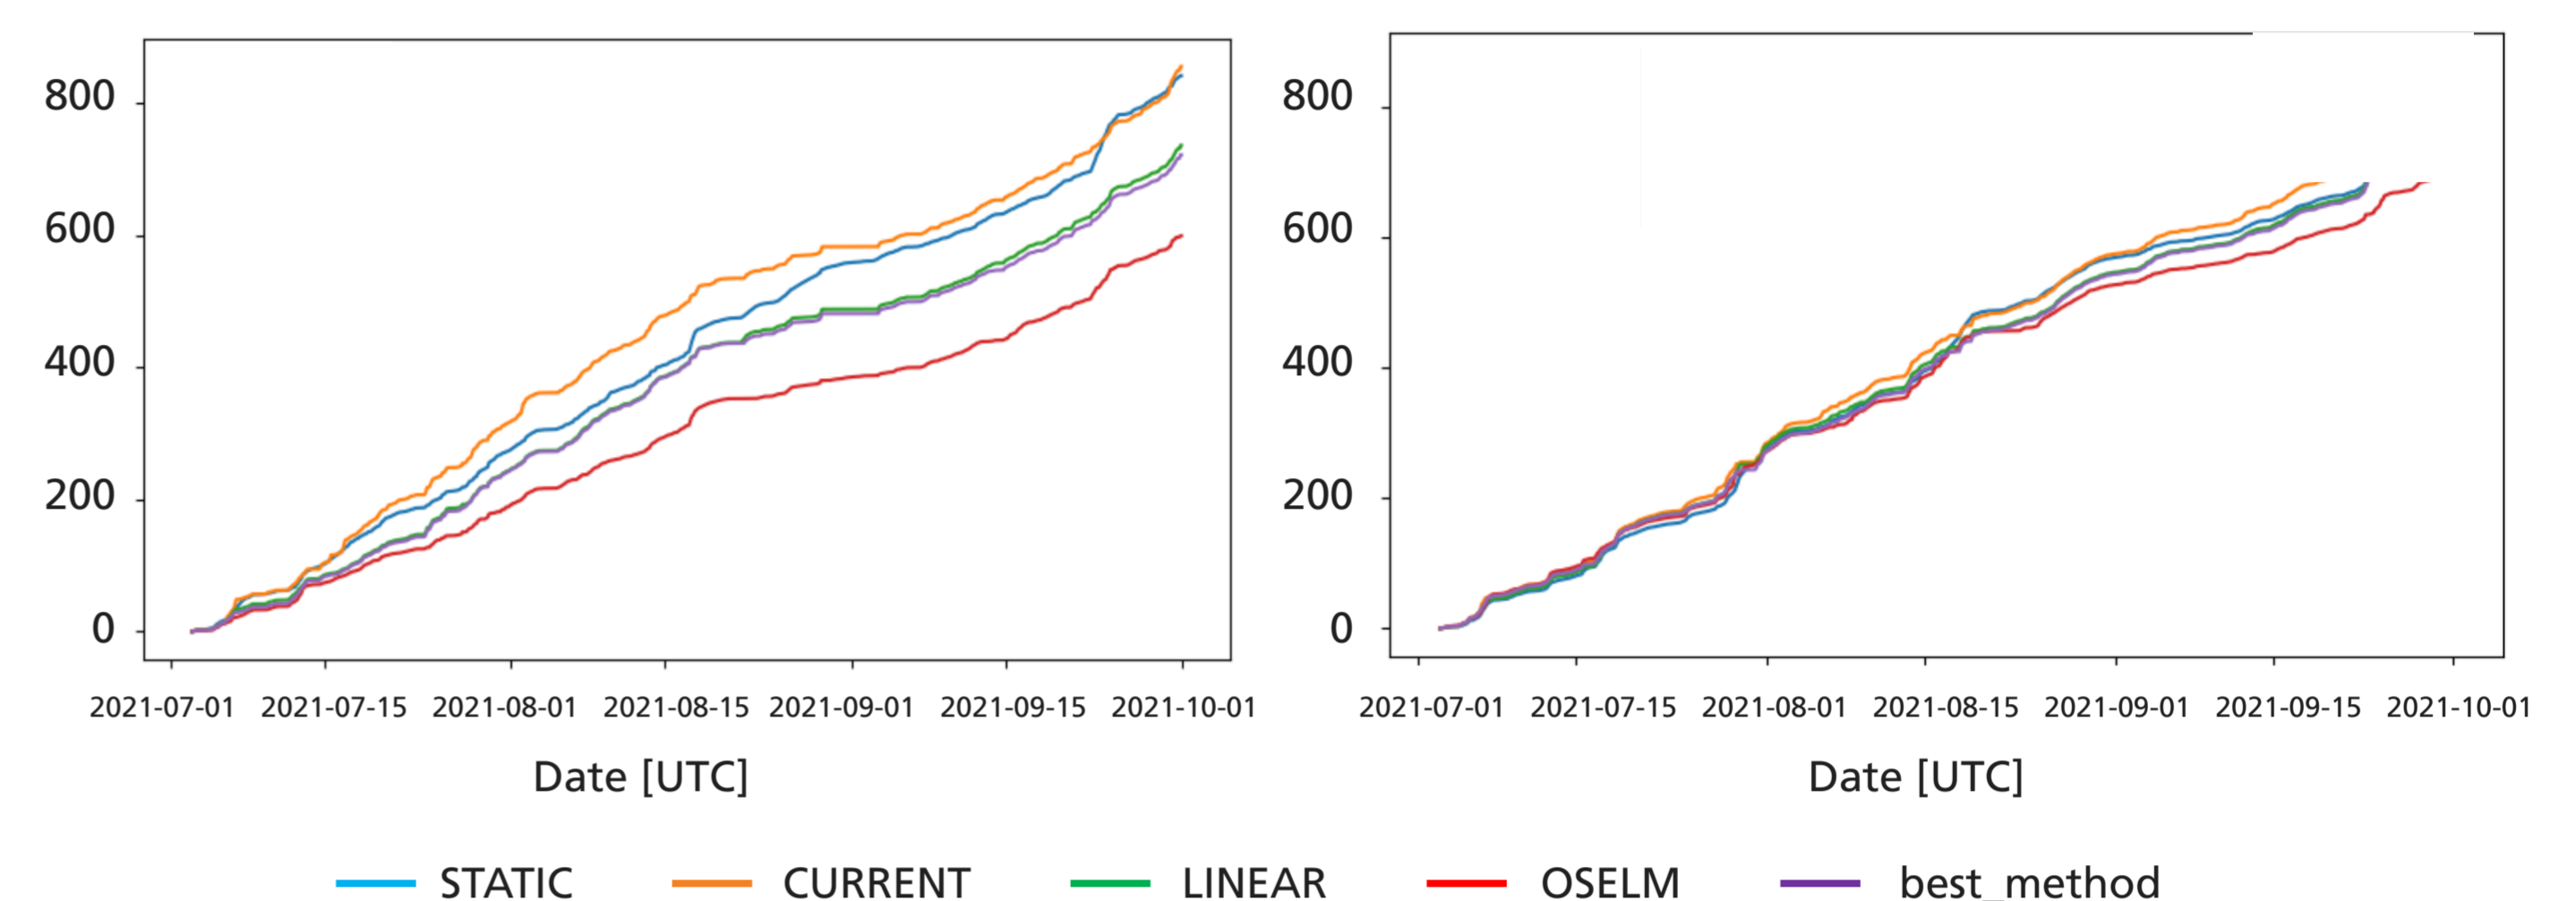


Abbildung 2: Kumulierter Fehler verschiedener Methoden für zwei verschiedene Windparks




Abbildung 3: Gewichte für einzelne Wettermodelle bei einem gleitenden Trainingszeitraum von 7 Tagen

Ergebnisse

Performance Kombination

- Güteverbesserung / -verschlechterung stark parkspezifisch
- Parks mit stellenweise falscher Nennleistung und vielen Abregelungen profitieren am stärksten
- *Overfitting* kann zu schlechten Ergebnissen bei linearer Regression führen
- Güteverbesserung durch *Merge* über statische Gewichte hinaus herausfordernd
- Adaptive ML-Verfahren bereiten noch Probleme, *Online-Learning ELM* vorerst nicht robust genug für operativen Einsatz

Weitere Erkenntnisse IBM GRAF

- Performance der IBM-Leistungsprognose stark schwankend aber im Vergleich meist unterdurchschnittlich. Mögliche Gründe:
 - phys. Modell
 - kurze Historie -> phys. Modell nicht ausreichend kalibriert
- In *Merge* Methode aber mit stellenweise hoher Gewichtung (skaliert)
- »Verlauf« scheint gut zu passen, Amplitude nicht
- Mehrwert vorhanden

Lessons learned

- Bereits vorhandene Historie von Daten essentiell
- Anpassungen frei verfügbarer Methoden nötig
- Abfangen von Spezialfällen -> kostet viel Zeit
- Entwicklung für operativen Betrieb unterschätzt
- Nachhaltige Codeentwicklung mit hohem Initialaufwand
- Große Testabdeckung
- Verbesserungspotential zu optimistisch eingeschätzt

Gefördert durch: