

Day-Ahead Netzzustandsprognose auf Mittelspannungsebene mit neuronalen Netzen

18. Symposium Energieinnovation 2024, Graz



Sebastian Storch, M. Sc.
Hochspannungs- und Anlagentechnik
Fakultät für Elektrotechnik, Technische Hochschule Augsburg

1. Motivation und Problemstellung
2. Prognosemodell
 - a. Datenbasis
 - b. Aufbau und Training des Prognosemodells
 - c. Basismodell
 - d. Vermeidung von Abweichungen in Spitzenwerten
3. Sensitivitätsanalyse
4. Fazit und Ausblick

1. Motivation und Problemstellung
2. Prognosemodell
 - a. Datenbasis
 - b. Aufbau und Training des Prognosemodells
 - c. Basismodell
 - d. Vermeidung von Abweichungen in Spitzenwerten
3. Sensitivitätsanalyse
4. Fazit und Ausblick

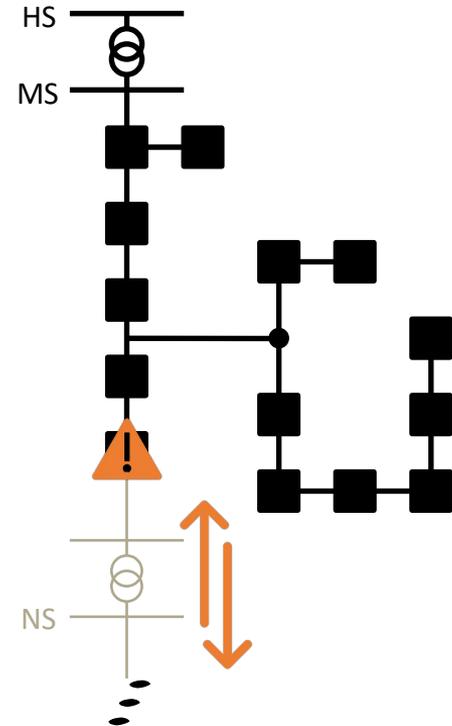
Motivation und Problemstellung

- Zunehmende Verbreitung dezentraler Erzeugungsanlagen
- Elektrifizierung des Wärmesektors und des Verkehrs
- Schwächen in der Überwachung und Steuerung des MS-Netzes

Optimierungspotenzial
in Netzüberwachung
und -steuerung

Day-Ahead Netz-
zustandsprognose
auf MS-Ebene

- Digitalisierung
- Fortschritt in der KI-Forschung
- Erkennung komplexer Datenmuster / Erstellung von Prognosen



Motivation und Problemstellung

- Zunehmende Verbreitung dezentraler Erzeugungsanlagen
- Elektrifizierung des Wärmesektors und des Verkehrs
- Schwächen in der Überwachung und Steuerung des MS-Netzes

Optimierungspotenzial
in Netzüberwachung
und -steuerung

Day-Ahead Netz-
zustandsprognose
auf MS-Ebene



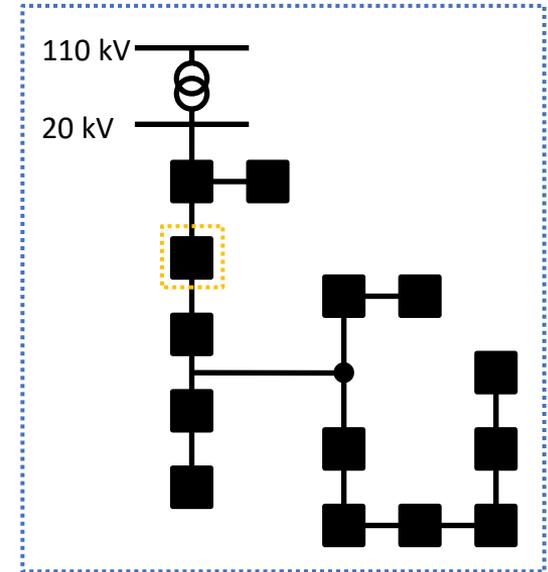
- Auskunft über Flexibilitäten
- Koordinierung von Maßnahmen wie Redispatch, Wartungsarbeiten etc.
- Integrierte Online-Überwachung

- Digitalisierung
- Fortschritt in der KI-Forschung
- Erkennung komplexer Datenmuster / Erstellung von Prognosen

1. Motivation und Problemstellung
2. Prognosemodell
 - a. Datenbasis
 - b. Aufbau und Training des Prognosemodells
 - c. Basismodell
 - d. Vermeidung von Abweichungen in Spitzenwerten
3. Sensitivitätsanalyse
4. Fazit und Ausblick

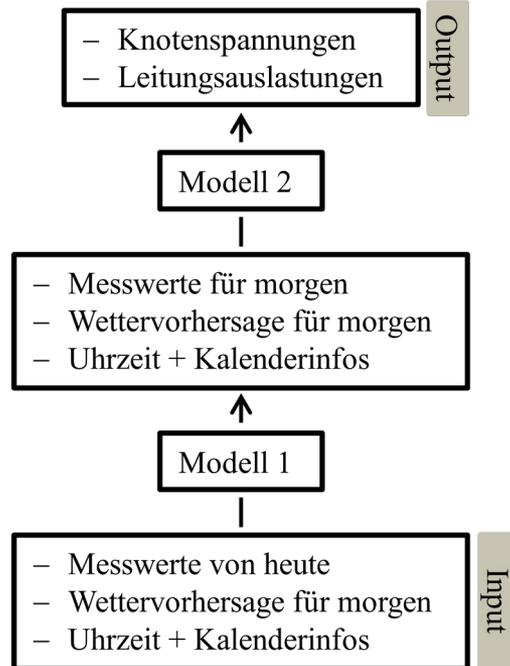
Auswertungen basieren auf den Daten eines kleinstädtischen Verteilnetzbetreibers:

- Mittelspannungsnetzabschnitt mit 14 Netzstationen
 - Wohngebiete
 - Größere PV-Anlagen
 - Industrie
- Wirk- und Blindleistungsmesswerte für 2022 an allen Stationen in 15-minütiger Auflösung
- Daten zur Verbraucherstruktur der Stationen
 - Anzahl der H0-, G0- und L0-Profile
 - Anzahl der registrierten Wärmepumpen
 - Anzahl der RLM-Kunden



Aufbau und Training des Prognosemodells

Die Day-Ahead Netzzustandsprognose wird durch eine Verkettung von zwei neuronalen Netzen durchgeführt:



Aufbau und Training des Prognosemodells

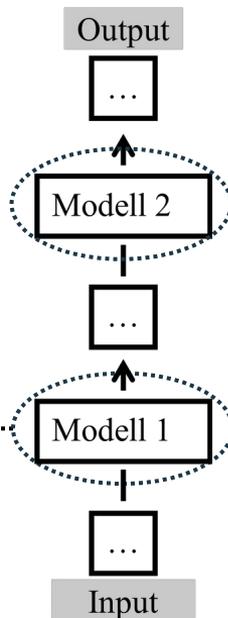
Modell 1 wird als LSTM umgesetzt:

- Prognose der Live-Messwerte für den Folgetag
- Trainings- und Validierungsdaten: Januar – Mai + Juli – November 2022
- Testdaten: Juni + Dezember 2022

UW	0	...	95
Station 1	0	...	95
...	0	...	95
Station k	0	...	95

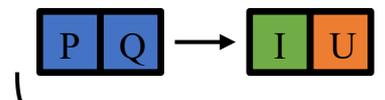
Modell 1

96	...	191
96	...	191
96	...	191
96	...	191



Modell 2 wird als neuronales Feed-Forward Netz umgesetzt:

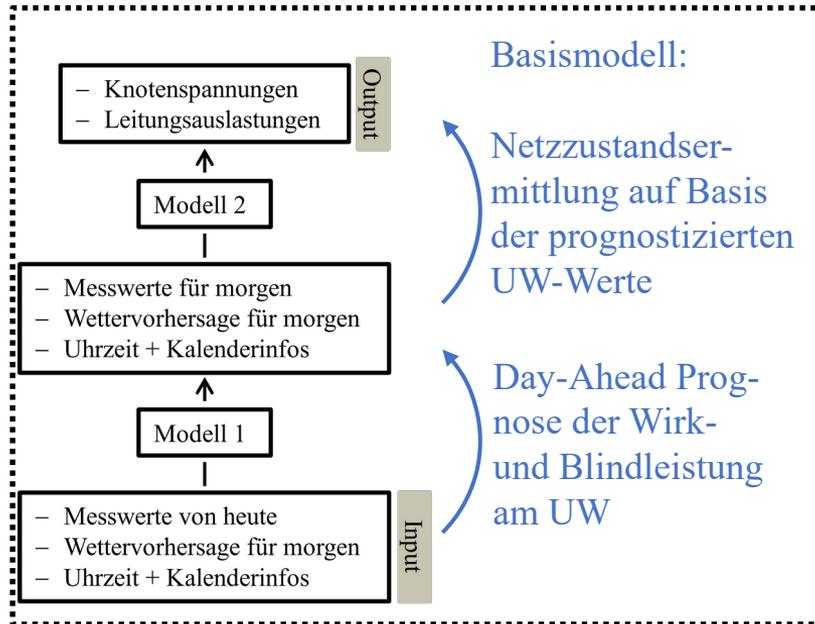
- Netzzustand wird auf Basis der prognostizierten Live-Messwerte approximiert
- Trainings- und Validierungsdaten: Januar – Mai + Juli – November 2022
- Testdaten: Juni + Dezember 2022
- Erstellung der Trainingsdaten durch Netzberechnungen:



Modell 2

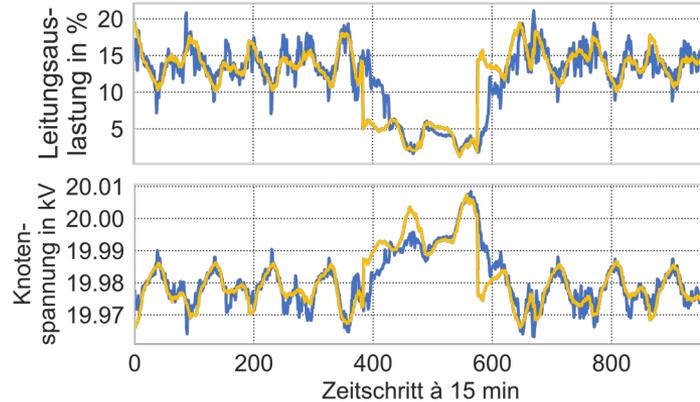
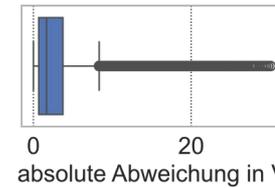
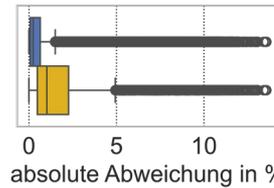
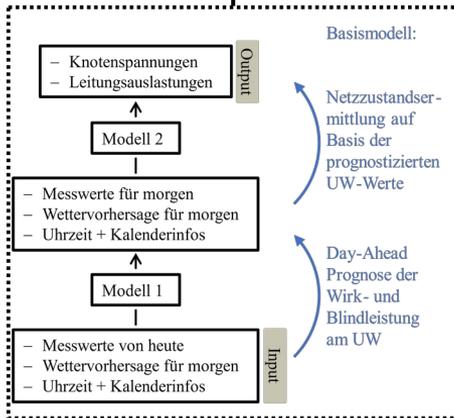
96	...	191
96	...	191

Für das Basismodell wird angenommen, dass nur die UW-Messwerte live übertragen werden



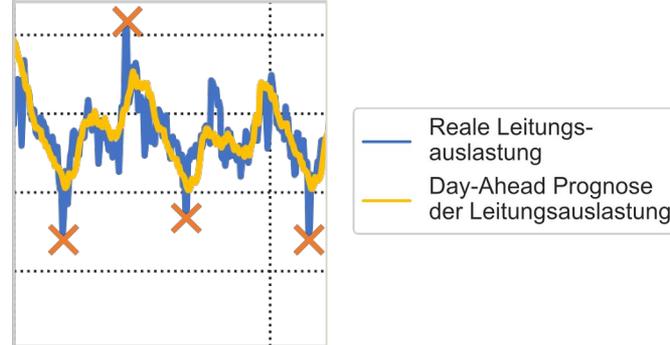
Für das Basismodell wird angenommen, dass nur die UW-Messwerte live übertragen werden

Prognosequalität:



Vermeidung von Abweichungen in Spitzenwerten

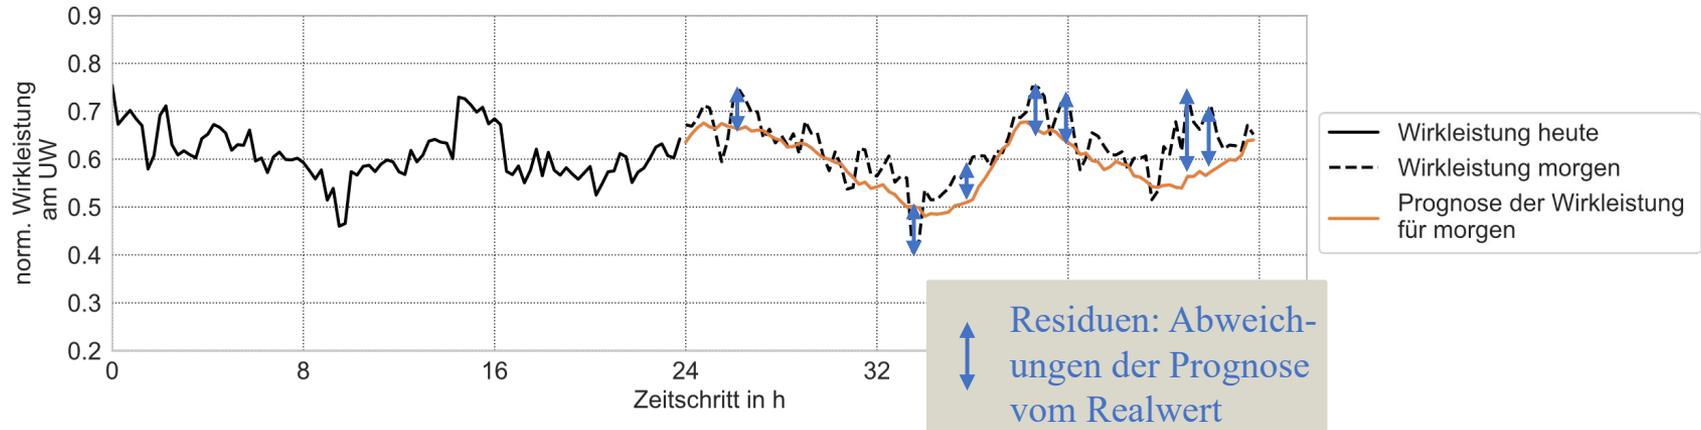
Infolge des Trainingsalgorithmus der Modelle werden Tagesmaxima und -minima strukturell unterschätzt!



Präzise Prognose in den Tagesextremwerten für Netzbetreiber von hoher Relevanz
→ Verfahren, das die Qualität in diesen Punkten erhöht

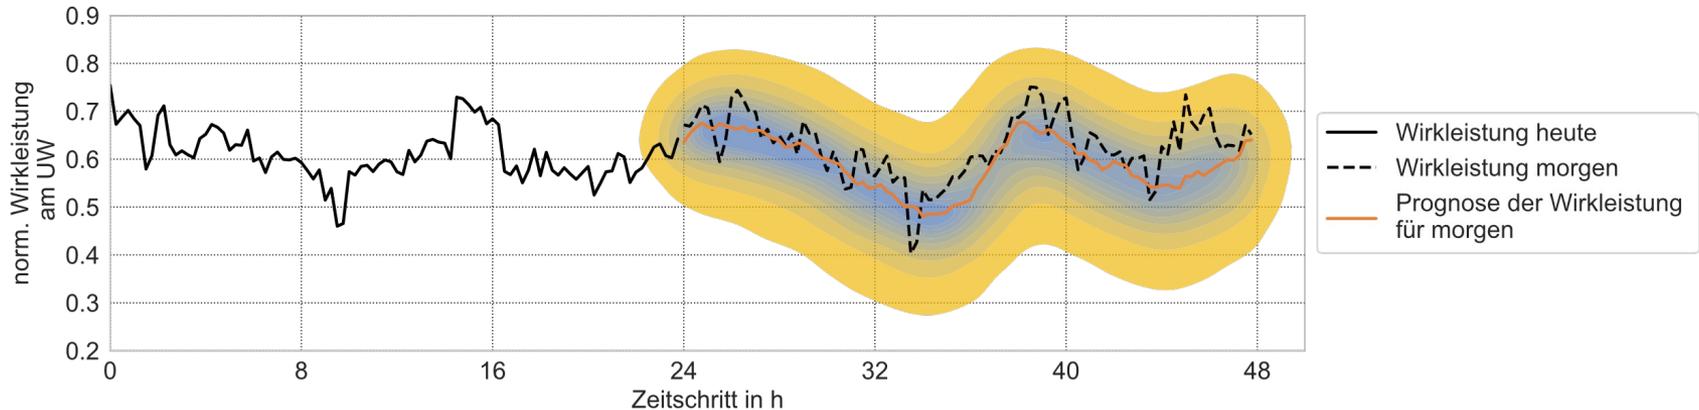
Vermeidung von Abweichungen in Spitzenwerten

Ansatz am Modell 1: Kern-Dichte-Schätzung der Residuen



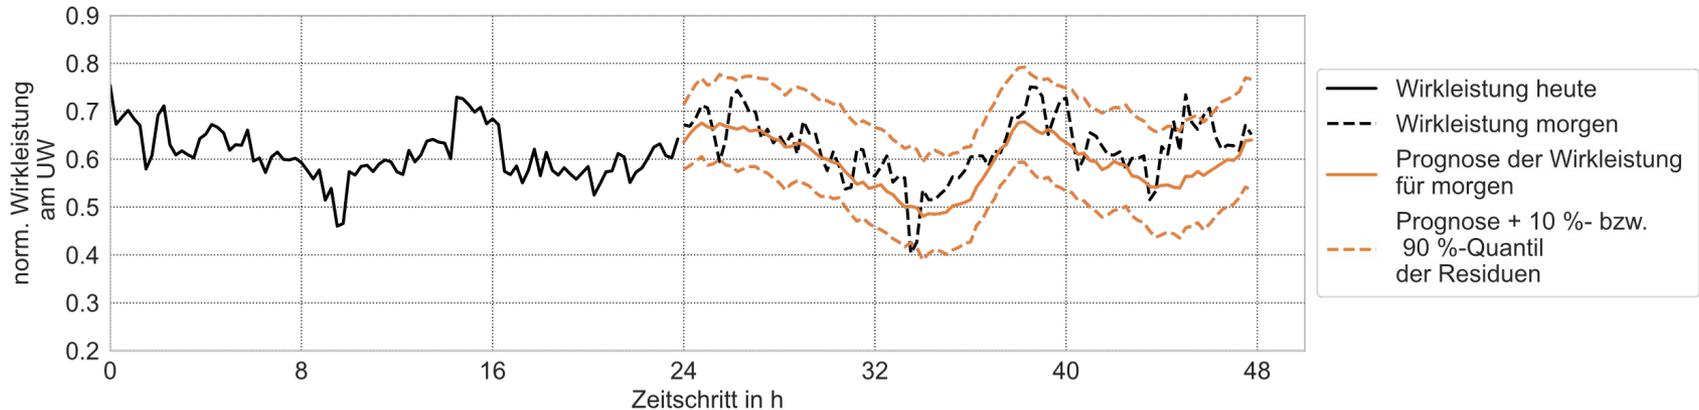
Vermeidung von Abweichungen in Spitzenwerten

Ansatz am Modell 1: Kern-Dichte-Schätzung der Residuen



Vermeidung von Abweichungen in Spitzenwerten

Ansatz am Modell 1: Kern-Dichte-Schätzung der Residuen

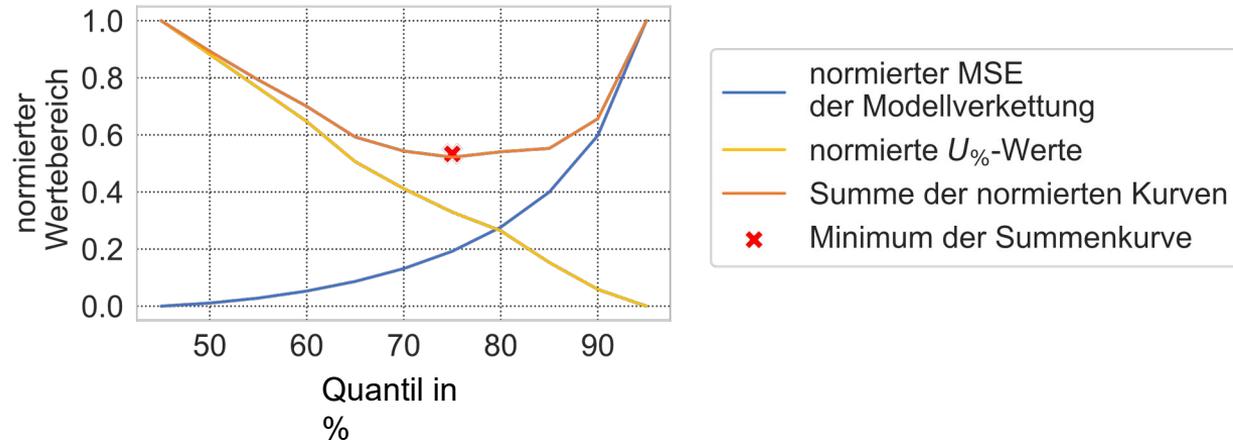


→ Durch den Übergang zu einem höheren Abweichungsquantil wird eine Unter- bzw. Überschätzung von Spitzenwerten reduziert

Vermeidung von Abweichungen in Spitzenwerten

Kern-Dichte-Schätzung der Residuen → Optimale Wahl des Quantils:

- Übergang zu einem Abweichungsquantil reduziert die Unterschätzung von Tagesmaxima
- Gleichzeitig steigt der Gesamtfehler des Prognosemodells
- Trade-Off wird durch eine Optimierung gelöst



1. Motivation und Problemstellung
2. Prognosemodell
 - a. Datenbasis
 - b. Aufbau und Training des Prognosemodells
 - c. Basismodell
 - d. Vermeidung von Abweichungen in Spitzenwerten
3. Sensitivitätsanalyse
4. Fazit und Ausblick

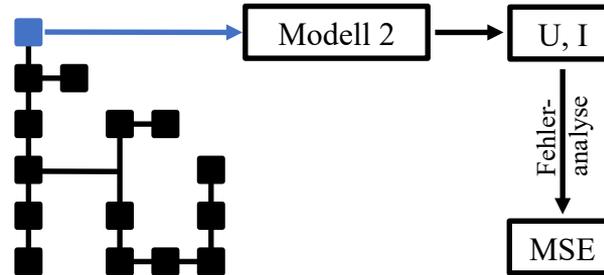
Wie wirkt sich eine veränderte Datenlage auf das Prognosemodell aus?



Was passiert, wenn im Netzabschnitt zusätzliche Messgeräte eingebaut werden? Wie wirkt sich das auf das Prognosemodell aus?

Basismodell:

- Live-Messwerte:
 - nur am UW
- Input für Modell 2 besteht nur aus den UW-Messwerten



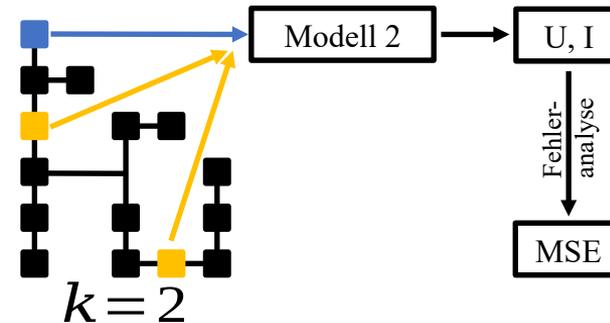
Wie wirkt sich eine veränderte Datenlage auf das Prognosemodell aus?



Was passiert, wenn im Netzabschnitt zusätzliche Messgeräte eingebaut werden? Wie wirkt sich das auf das Prognosemodell aus?

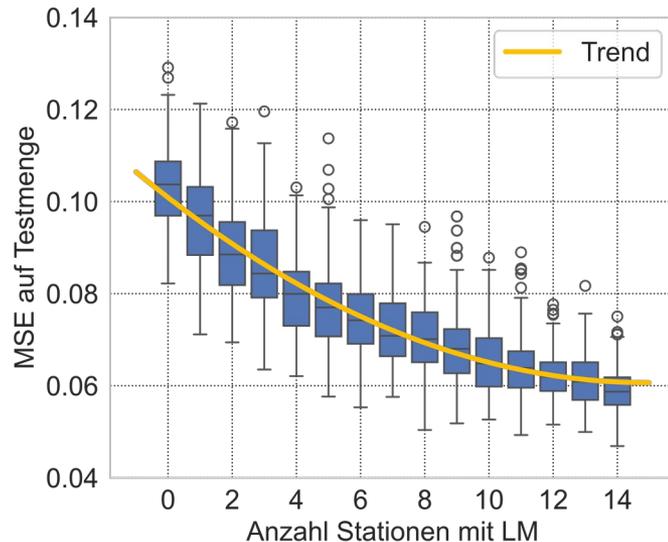
Verändertes Modell:

- Live-Messwerte:
 - am UW
 - an anderen Stationen
- Input für Modell 2 besteht aus allen verfügbaren Live-Messwerten



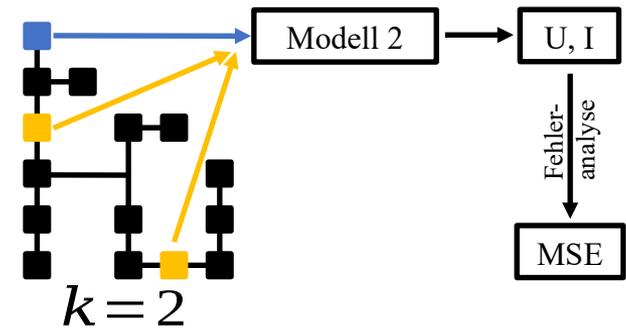
Wie wirkt sich eine veränderte Datenlage auf das Prognosemodell aus?

→ Fehlerveränderung von Modell 2 in Abhängigkeit der Anzahl an Stationen mit Live-Messwerten:



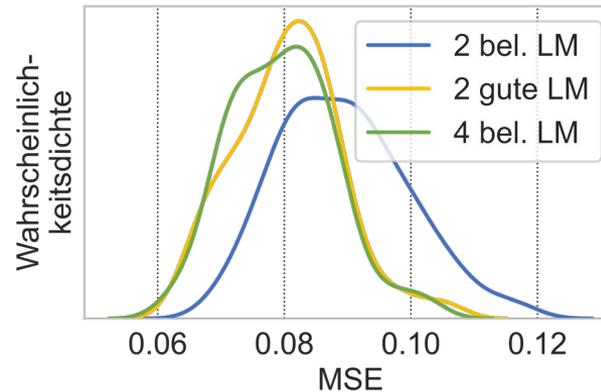
Verändertes Modell:

- Live-Messwerte:
 - am UW
 - an anderen Stationen
- Input für Modell 2 besteht aus allen verfügbaren Live-Messwerten

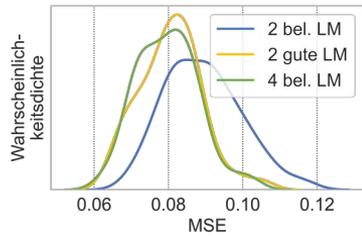


An welchen Stationen sollten die Messgeräte eingebaut werden?

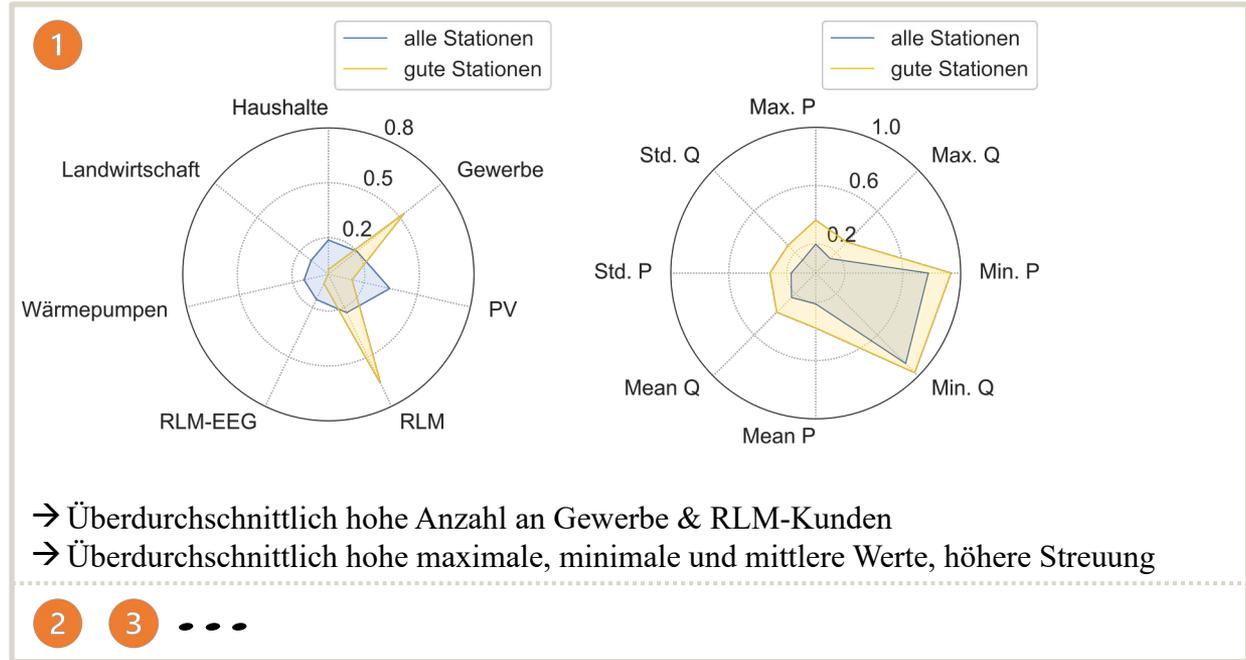
- Um die Fehlerveränderung zu untersuchen, wurden zufällige Stationen gewählt, für die angenommen wird, dass sie Live-Messwerte liefern → Es gibt „gute“ Stationen, die stets einen niedrigeren Fehler liefern
- Zwei gute Messungen führen zur selben Prognosequalität wie vier zufällige Messungen:



An welchen Stationen sollten die Messgeräte eingebaut werden?



Was zeichnet gute Stationen aus?



Agenda

1. Motivation und Problemstellung
2. Prognosemodell
 - a. Datenbasis
 - b. Aufbau und Training des Prognosemodells
 - c. Basismodell
 - d. Vermeidung von Abweichungen in Spitzenwerten
3. Sensitivitätsanalyse
4. Fazit und Ausblick

Fazit:

- Potenzialanalyse KI: Modelle liefern gute Prognoseergebnisse → Anforderungen für einen Einsatz im Netzbetrieb sind erfüllt
- Unterschätzung von Tagesspitzenwerten: Kann auf Kosten des Gesamtfehlers vermieden werden. Je nach Anforderung kann das Modell leicht angepasst werden
- Sensitivitätsanalyse:
 - Quantifiziert den Nutzen eines Messgeräts → Kosten-Nutzen-optimales Modell
 - Impliziert Strategien zur Platzierung von Messgeräten

Weitere Schritte:

- Analyse der Auswirkungen von Pseudo-Messwerten
- Verallgemeinerung der Methodik auf andere Netzabschnitte und -ebenen

Vielen Dank für die Aufmerksamkeit!



Sebastian Storch, M. Sc.
Technische Hochschule Augsburg
Fakultät für Elektrotechnik
An der Hochschule 1
86161 Augsburg
Tel.: +49 821 5586-3095
E-Mail: sebastian.storch@hs-augsburg.de

