Fraunhofer IEE

PINNs – Genauere Surrogate-Modelle für die Schätzung von Lasten bei elektrischen Komponenten

Inhalt

1. Fraunhofer IEE und das Projekt Otello
2. Lastprognose
3. Surrogatemodelle am Beispiel Generator
4. Physikinformierte Neuronale Netze (PINN)
5. Experimente und Ergebnisse
6. Zusammenfassung und Ausblick

 © Fraunhofer IEE

Fraunhofer IEE

Fraunhofer IEE und das Projekt Otello

Fraunhofer IEE und das Projekt Otello

Fraunhofer IEE

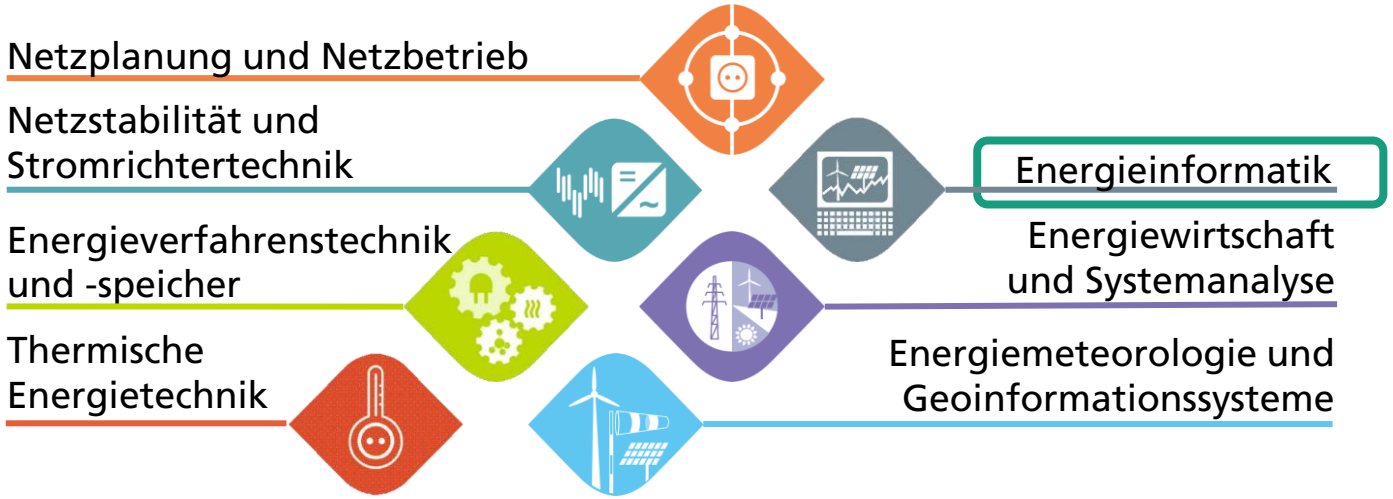

 © Fraunhofer IEE

Fraunhofer IEE

Motivation

Otello

Strompreisvorhersage (day-ahead)

Wind und Turbulenz-vorhersage (day-ahead)

Leistungs- und Lastprognose

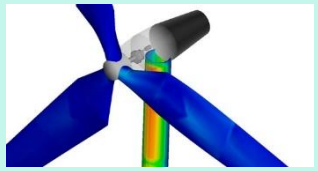

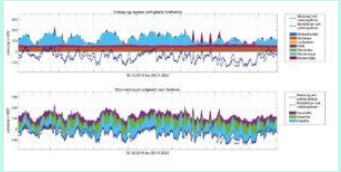

Fahrplanoptimierung (day-ahead)

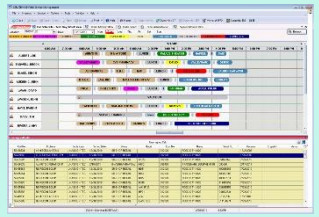

Abgeregelter Betrieb = Reduktion von Lasten

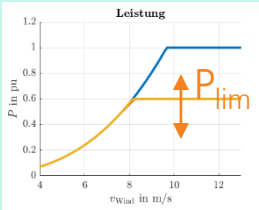

- Reduzierte Abnutzung
- Längere Nutzungszeit
- Bessere Netzintegration

Reduzierte Komponentenabnutzung führt zu niedrigeren Instandhaltungskosten (relevant für Hersteller in Vollwartungsverträgen).

 © Fraunhofer IEE

Fraunhofer IEE

Lastprognose

Lastprognose

Schätzung von Lasten

Mechanische Lasten

- Turm
- Rotorblätter
- Getriebe
- …

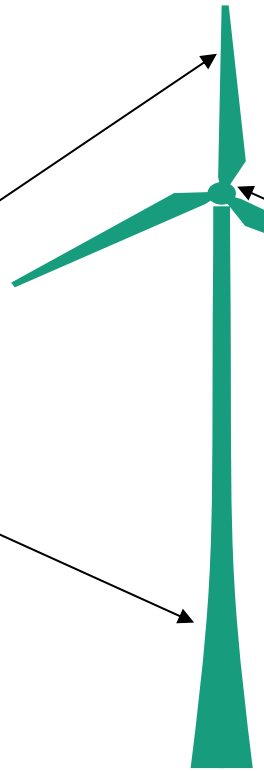

Elektrische und thermische Lasten

- Generator
- Transformator
- Wechselrichter

Schätzung der Gesamtlast durch Modellierung der Komponentenlasten.

 © Fraunhofer IEE

Fraunhofer IEE

Lastprognose

Schätzung von Lasten

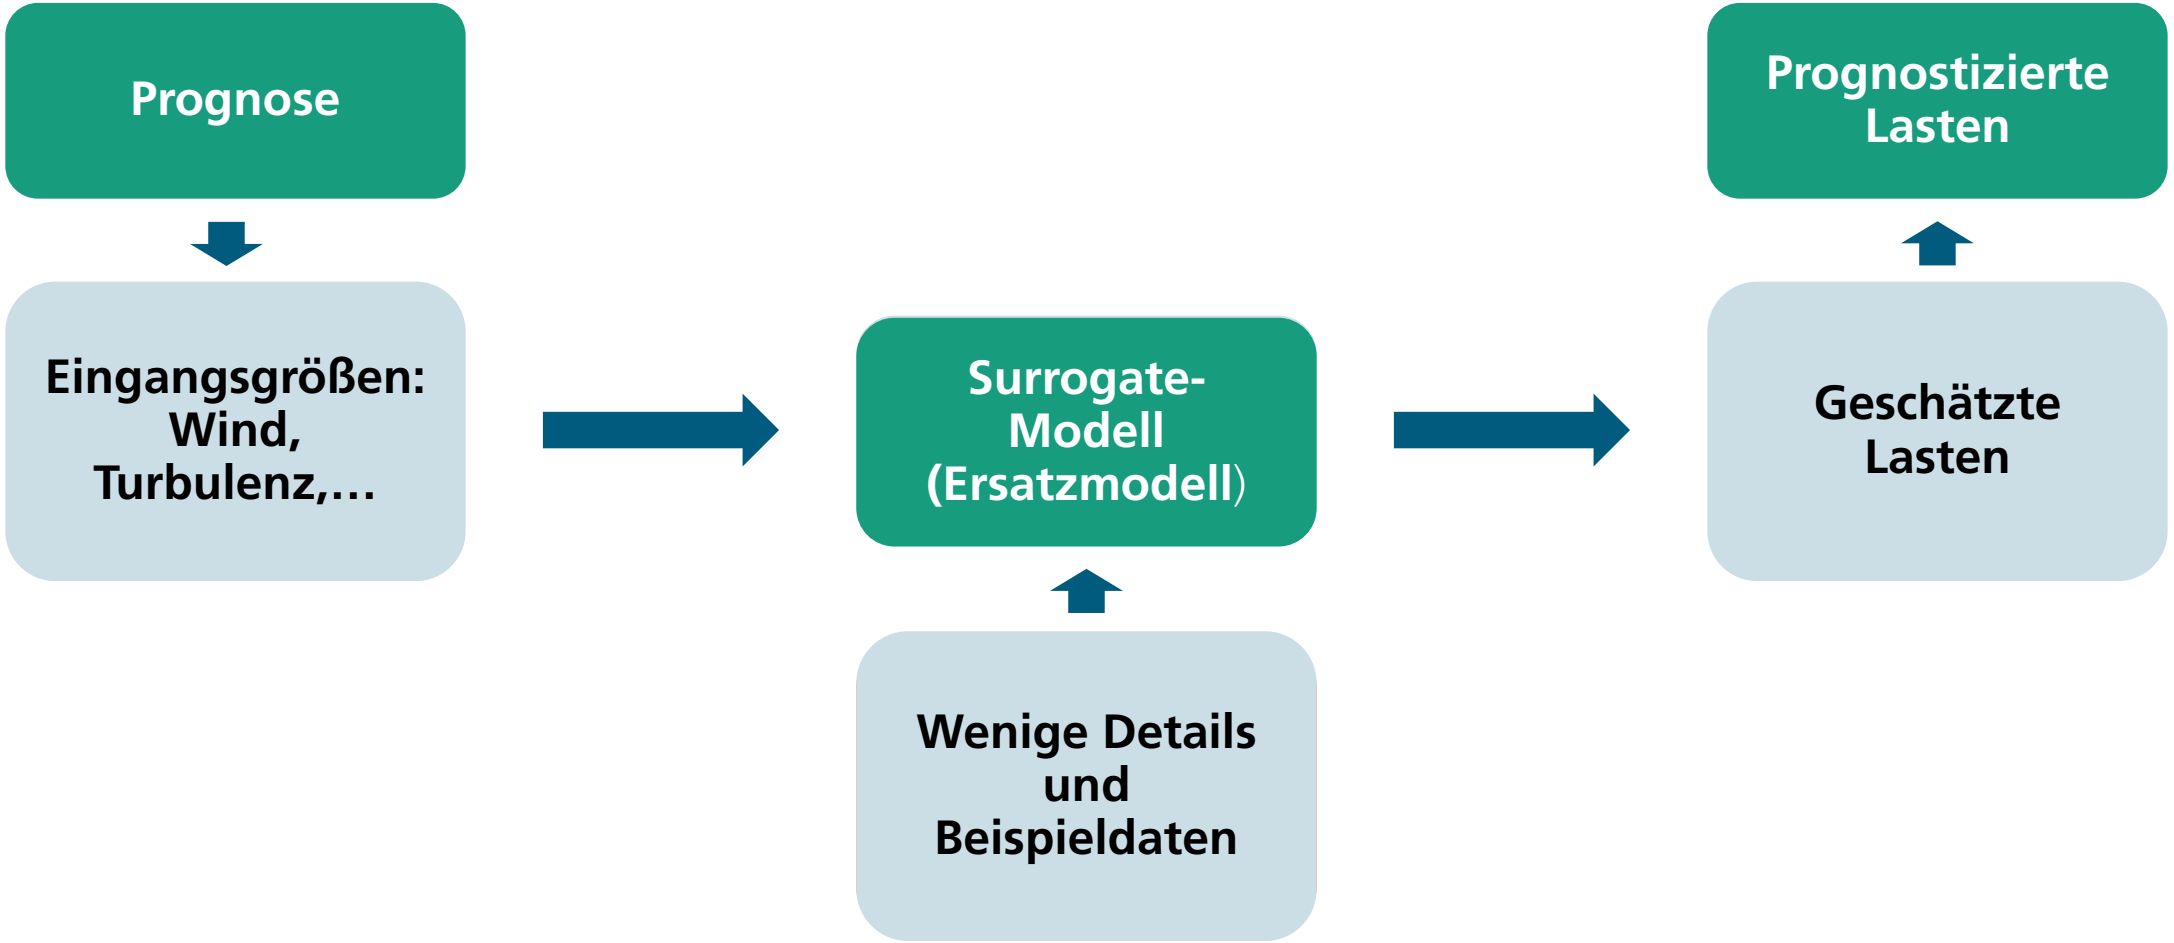

 © Fraunhofer IEE

Fraunhofer IEE

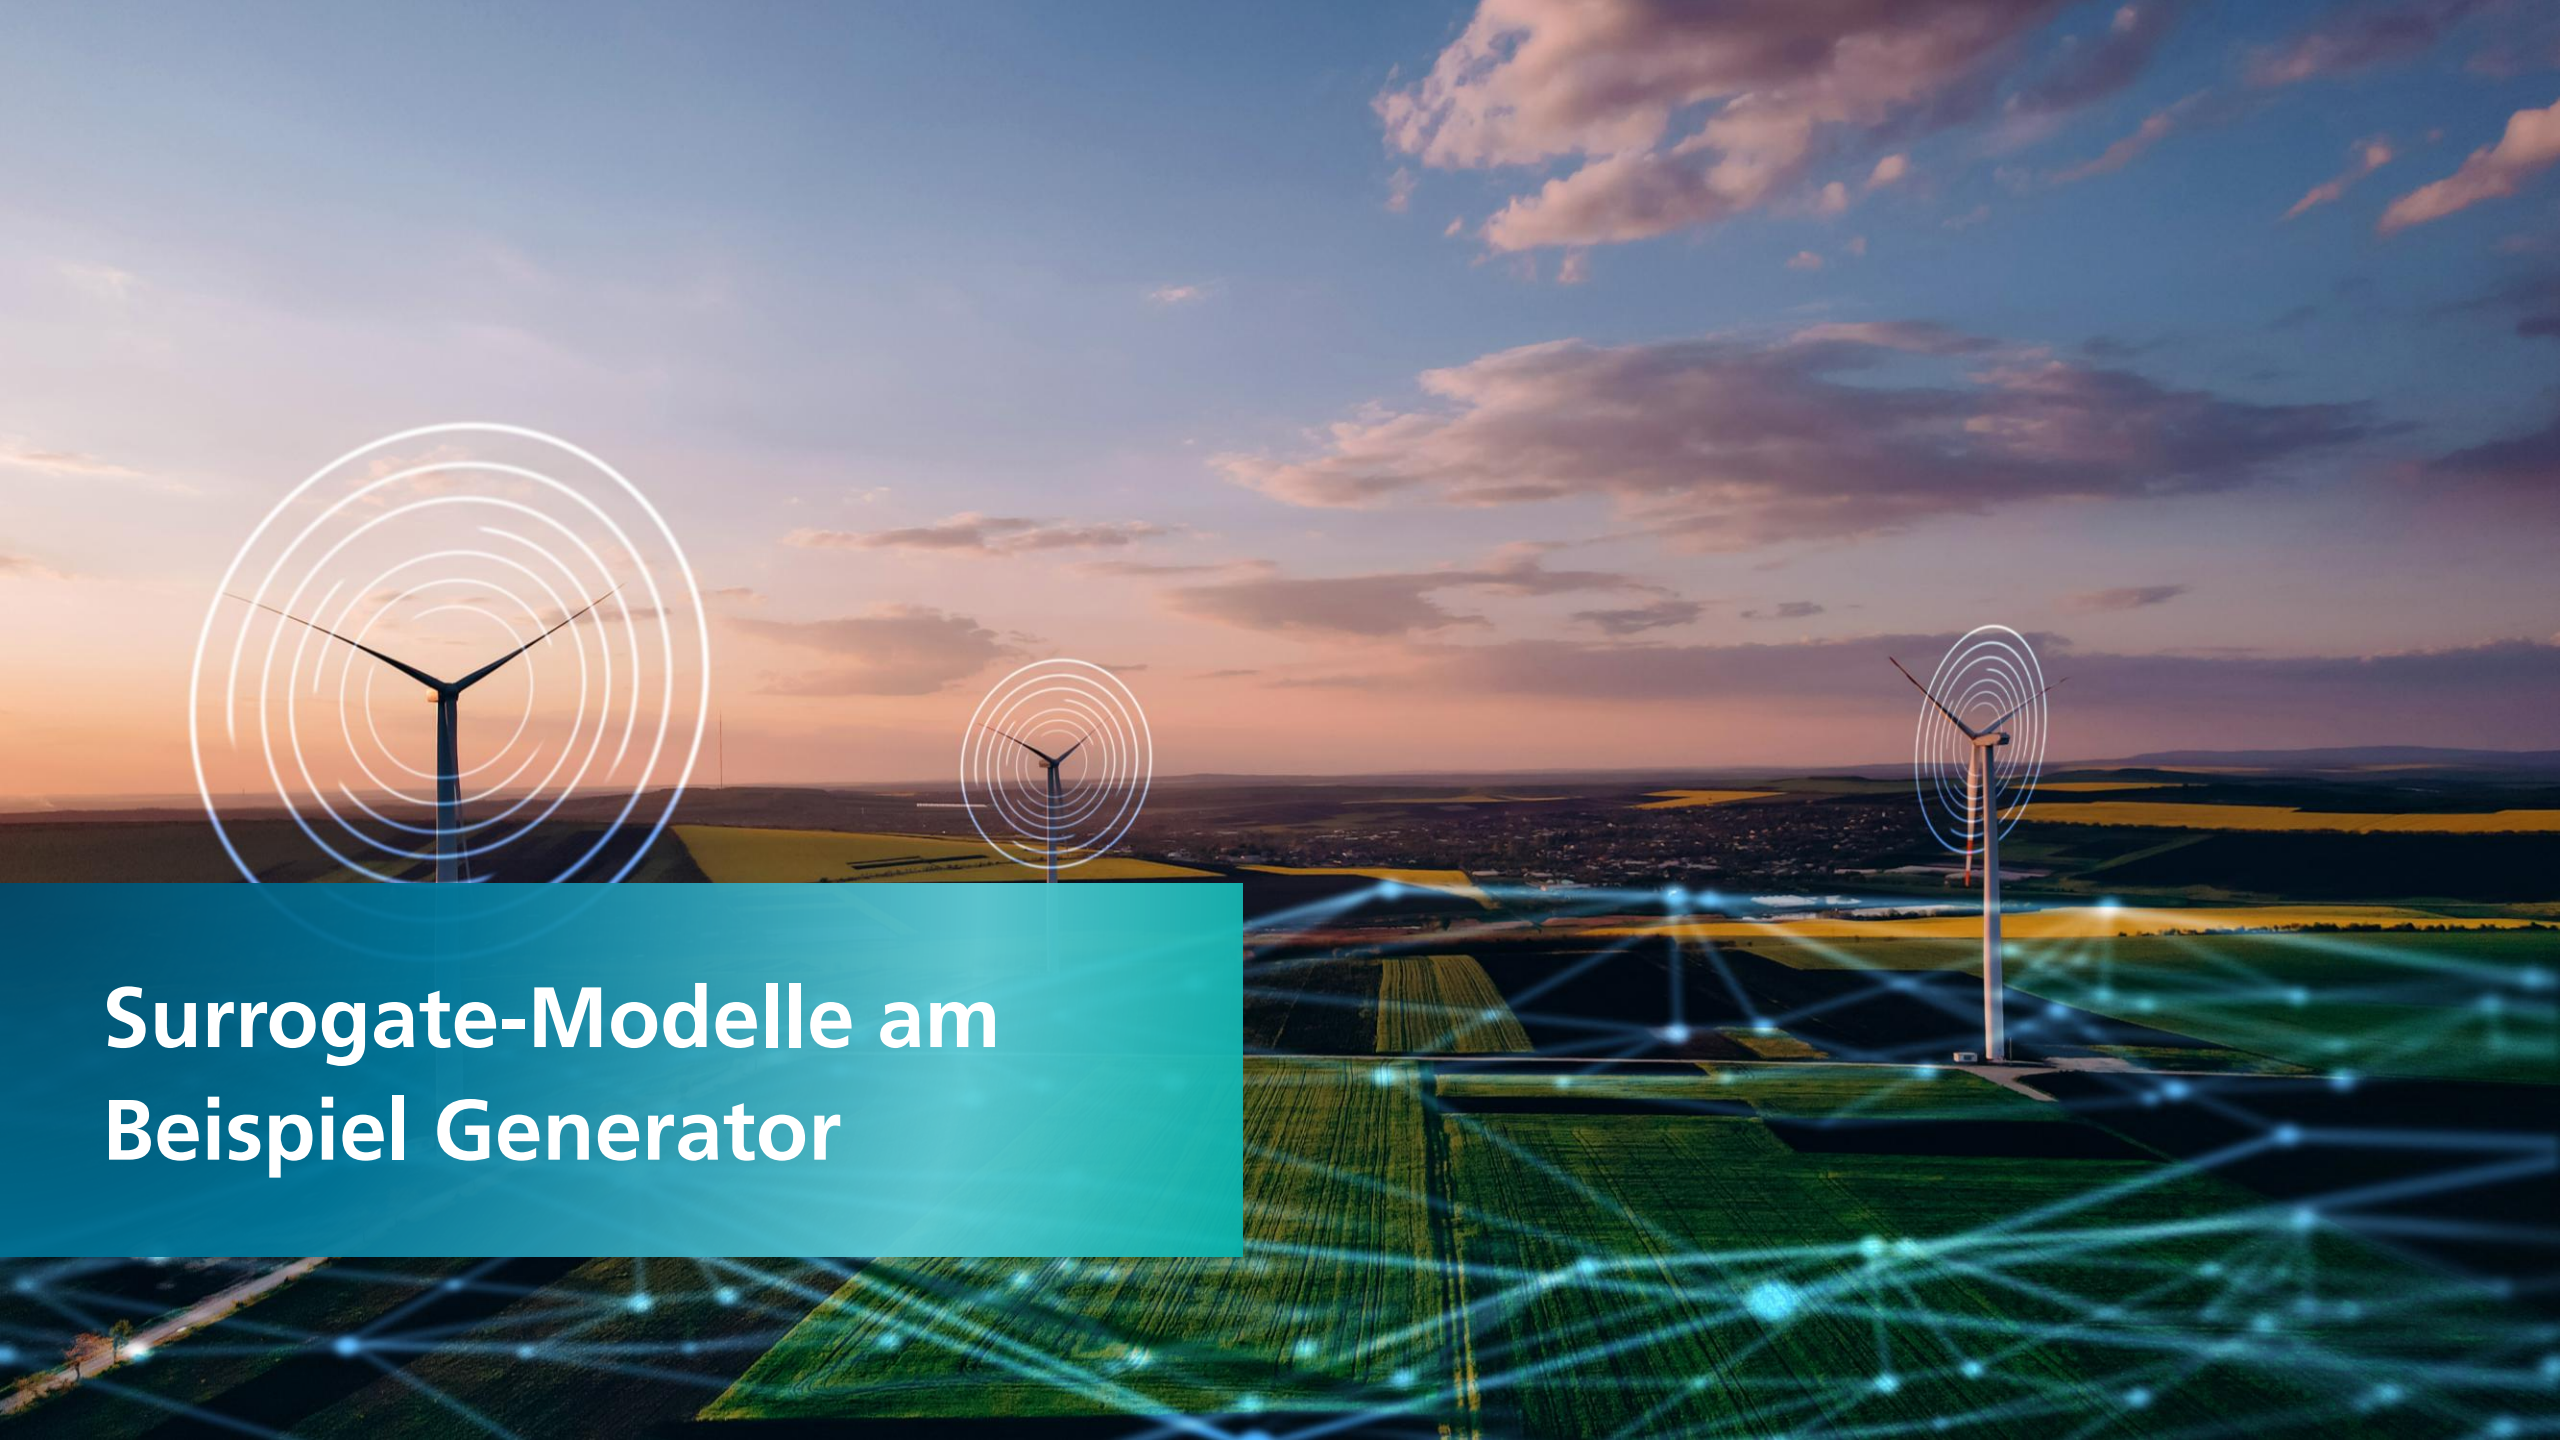

Surrogate-Modelle am Beispiel Generator

Surrogate-Modelle am Beispiel Generator

Beispiel: Isolierungsalterung am Generator

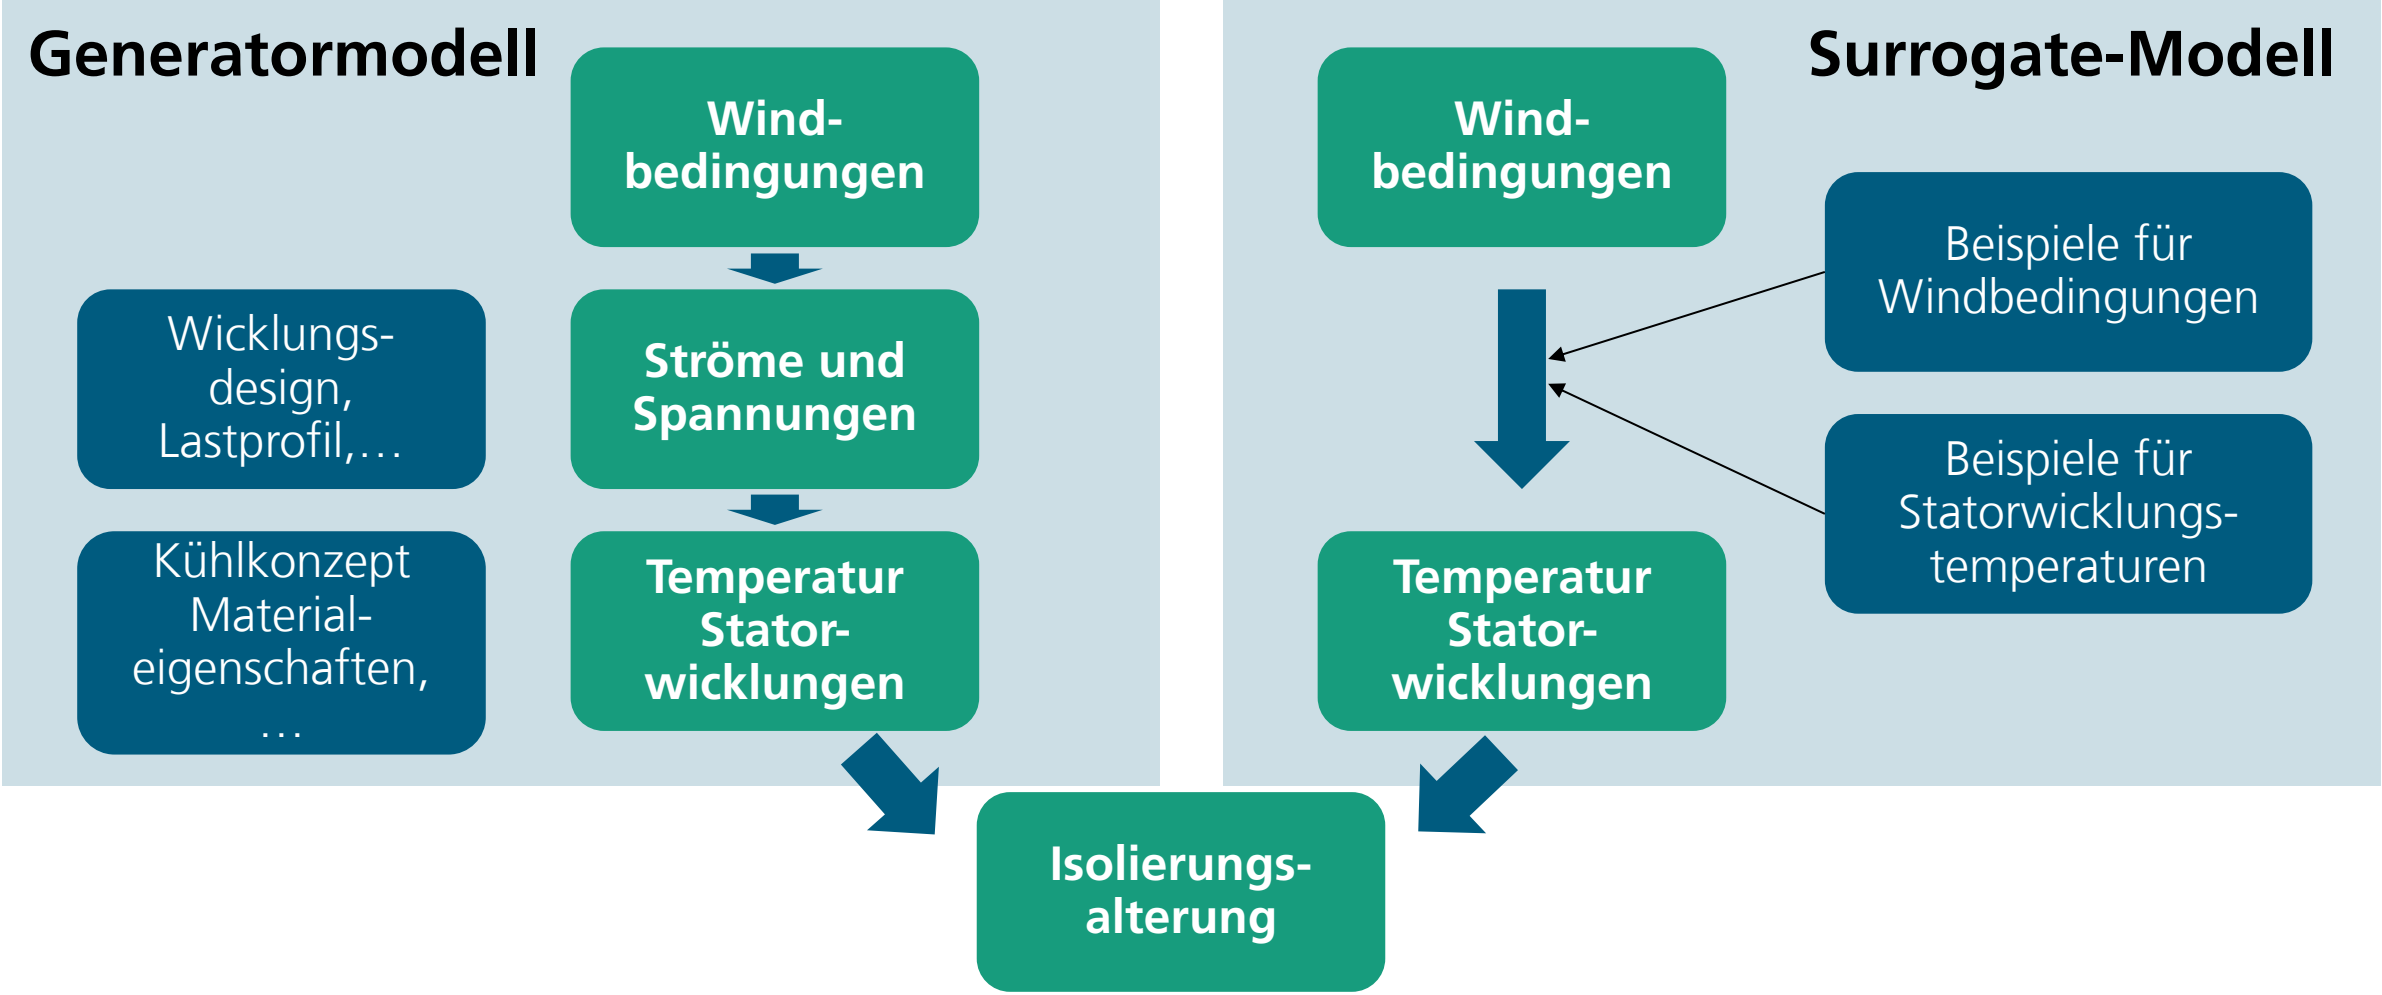

 © Fraunhofer IEE

Fraunhofer IEE

Surrogate-Modelle am Beispiel Generator

Beispiel: Isolierungsalterung am Generator

Kriterium	Generatormodell	Surrogate-Modell (rein datengetrieben)
Genauigkeit	+	-
Generalisierungsfähigkeit	+	-
Benötigt großen Trainingsdatensatz	+	-
Auswertungszeit	-	+
Erstellungsaufwand	-	+
Metadaten	-	+
Übertragbarkeit des Konzepts	-	+

Beide Modellarten haben Vorteile aber auch große Nachteile -> Kombination der Ideen

 © Fraunhofer IEE

Fraunhofer IEE

Physikinformierte Neuronale Netze (PINN)

Physikinformierte Neuronale Netze (PINN)

Datengetriebene Modelle

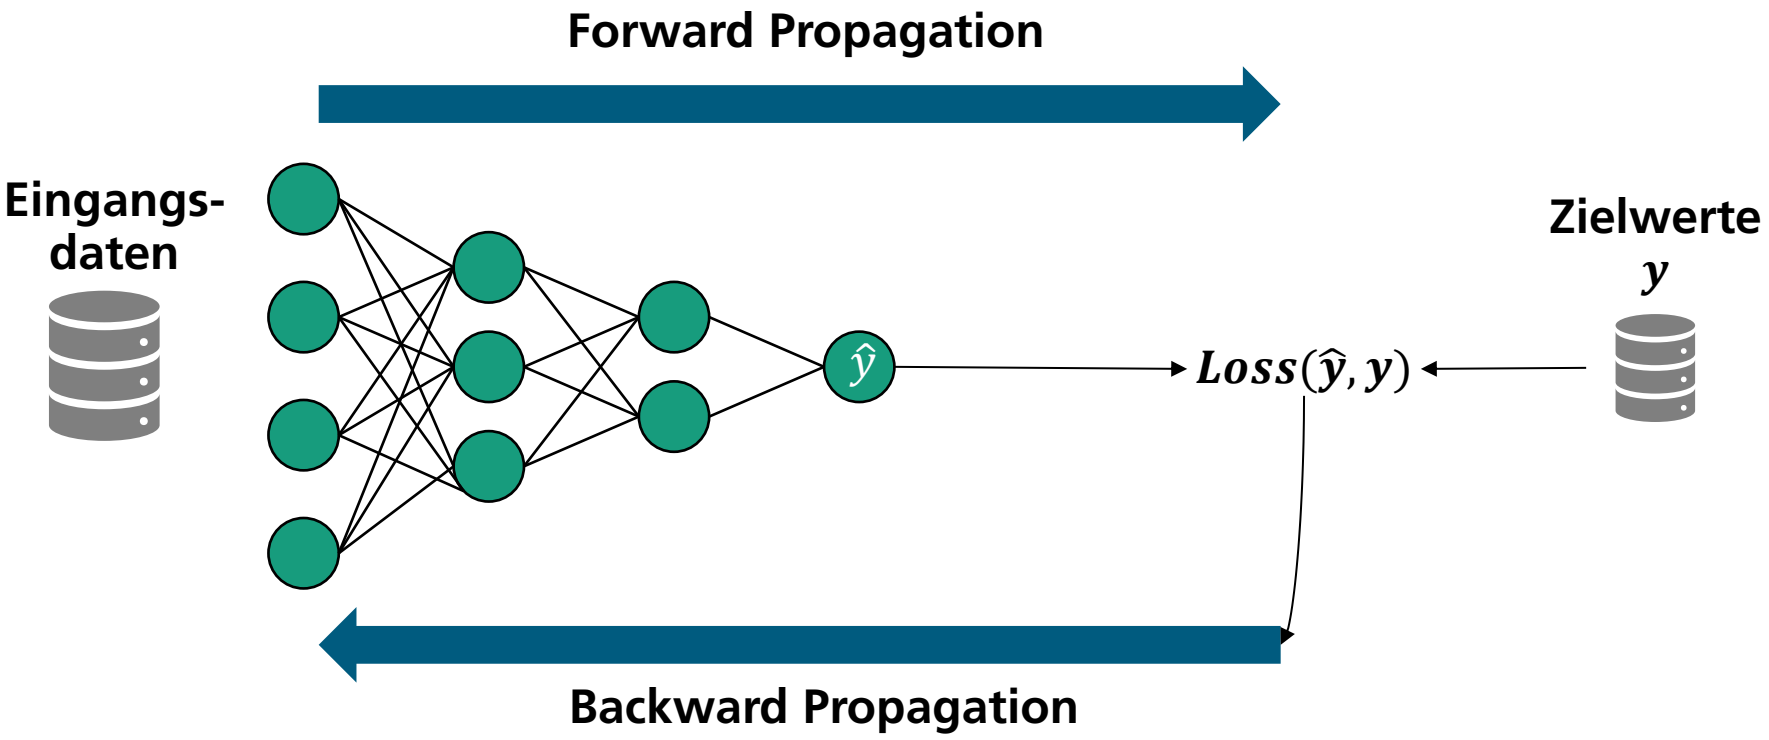

 © Fraunhofer IEE

Fraunhofer IEE

Physikinformierte Neuronale Netze (PINN)

Wie kann physikalisches Vorwissen integriert werden?

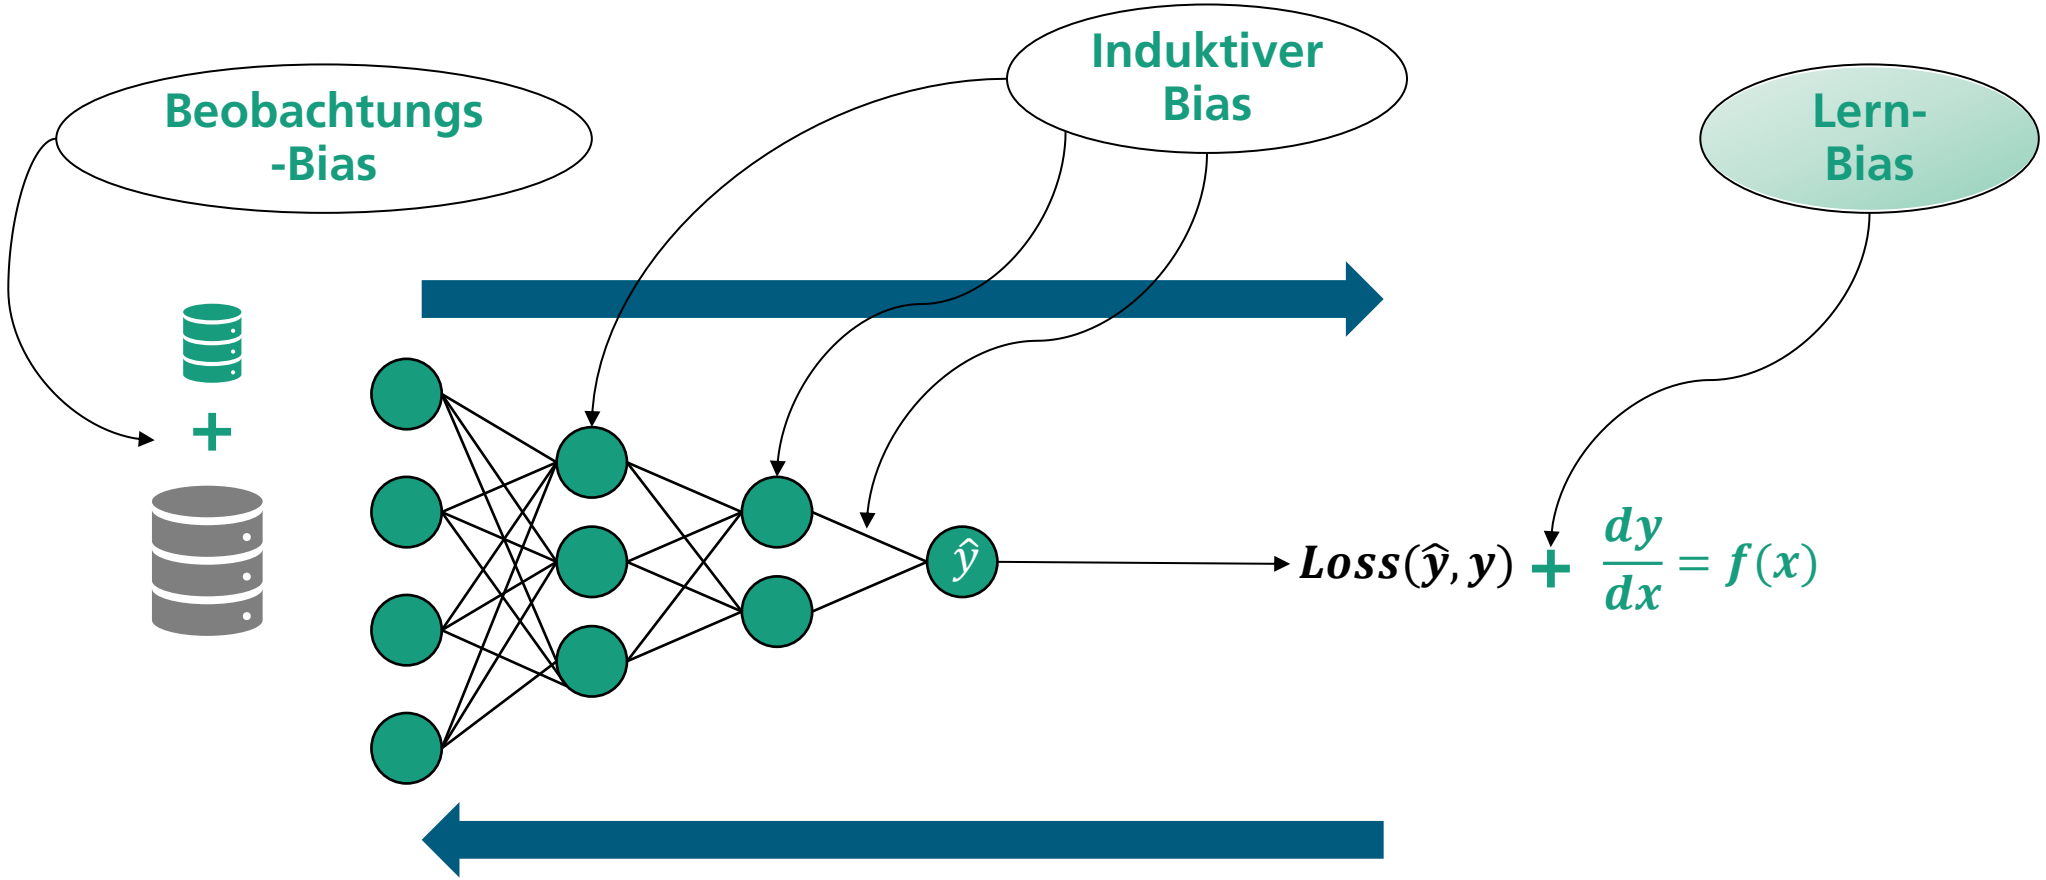

 © Fraunhofer IEE

Fraunhofer IEE

Physikinformierte Neuronale Netze (PINN)

Verwendete Daten

Datenquelle: Öffentlich verfügbare CARE to Compare Daten + Zusätzliche Turbinendokumentation

CARE to Compare

10 min SCADA-Daten

- Windgeschwindigkeit
  - Mittelwert
  - Standardabweichung
- Außentemperatur
- Luftdruck
- Leistung
- Statorwicklungstemperatur
- Temperatur Generatorkühlung

- Nennleistung
- Kennlinie der Generatorverluste (11 Messwerte)

 © Fraunhofer IEE

Fraunhofer IEE

Physikinformierte Neuronale Netze (PINN)

Abgeleitete Daten

- **Luftdichte (auf Basis von Temperatur + Luftdruck)**

Windgeschwindigkeit

Leistung

Nennleistung

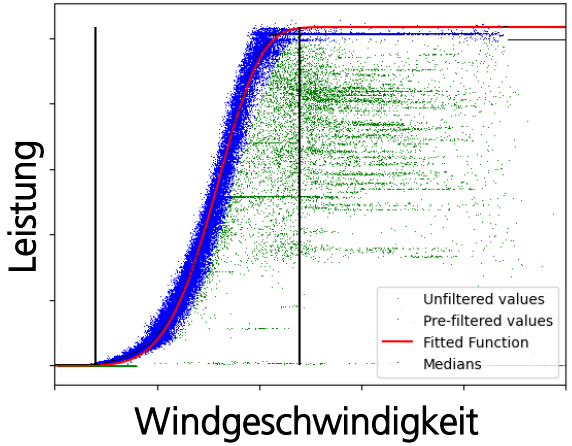

Abregelungsgrad

Generatorverluste

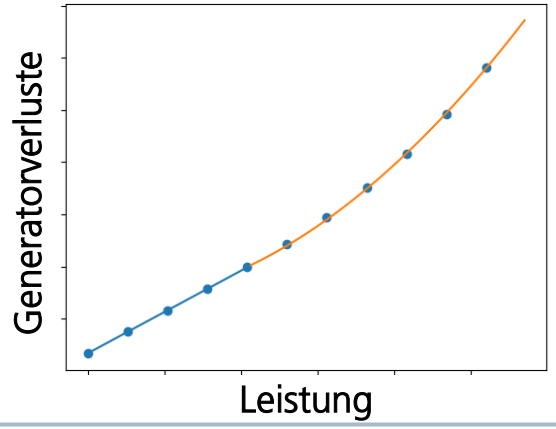

Statorverluste

 © Fraunhofer IEE

Fraunhofer IEE

Physikinformierte Neuronale Netze (PINN)

Abgeleitete Daten

Statorwicklungs-temperatur
Kühltemperatur

Statorverluste

Thermischer Widerstand der Statorwicklungen
$R = P_{Stator}/\Delta T$

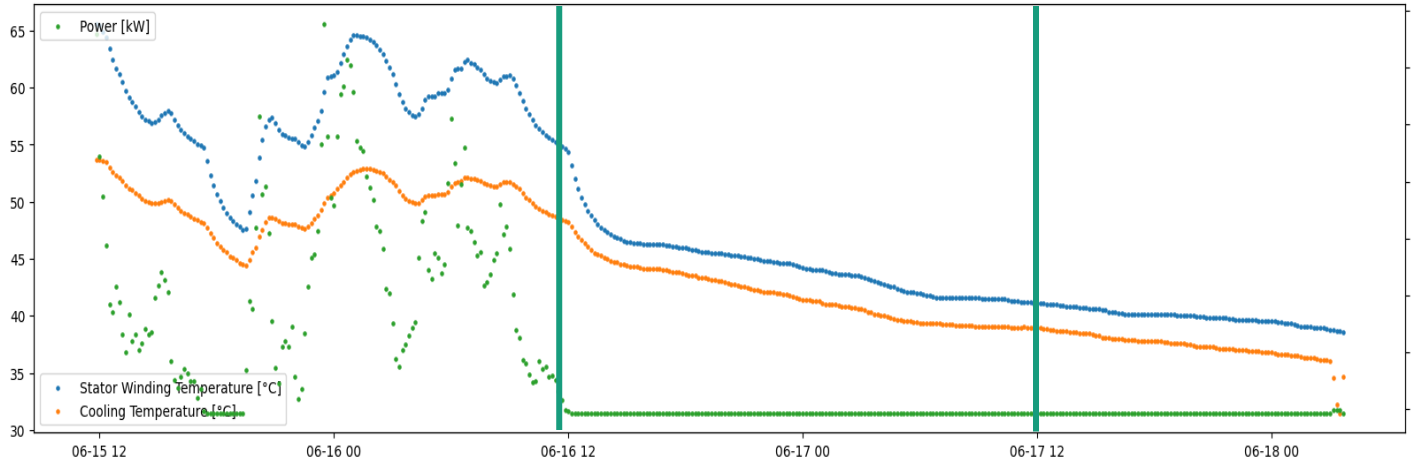

Thermische Zeitkonstante der Statorwicklungen τ

 © Fraunhofer IEE

Fraunhofer IEE

Physikinformierte Neuronale Netze (PINN)

Physikalisches Vorwissen

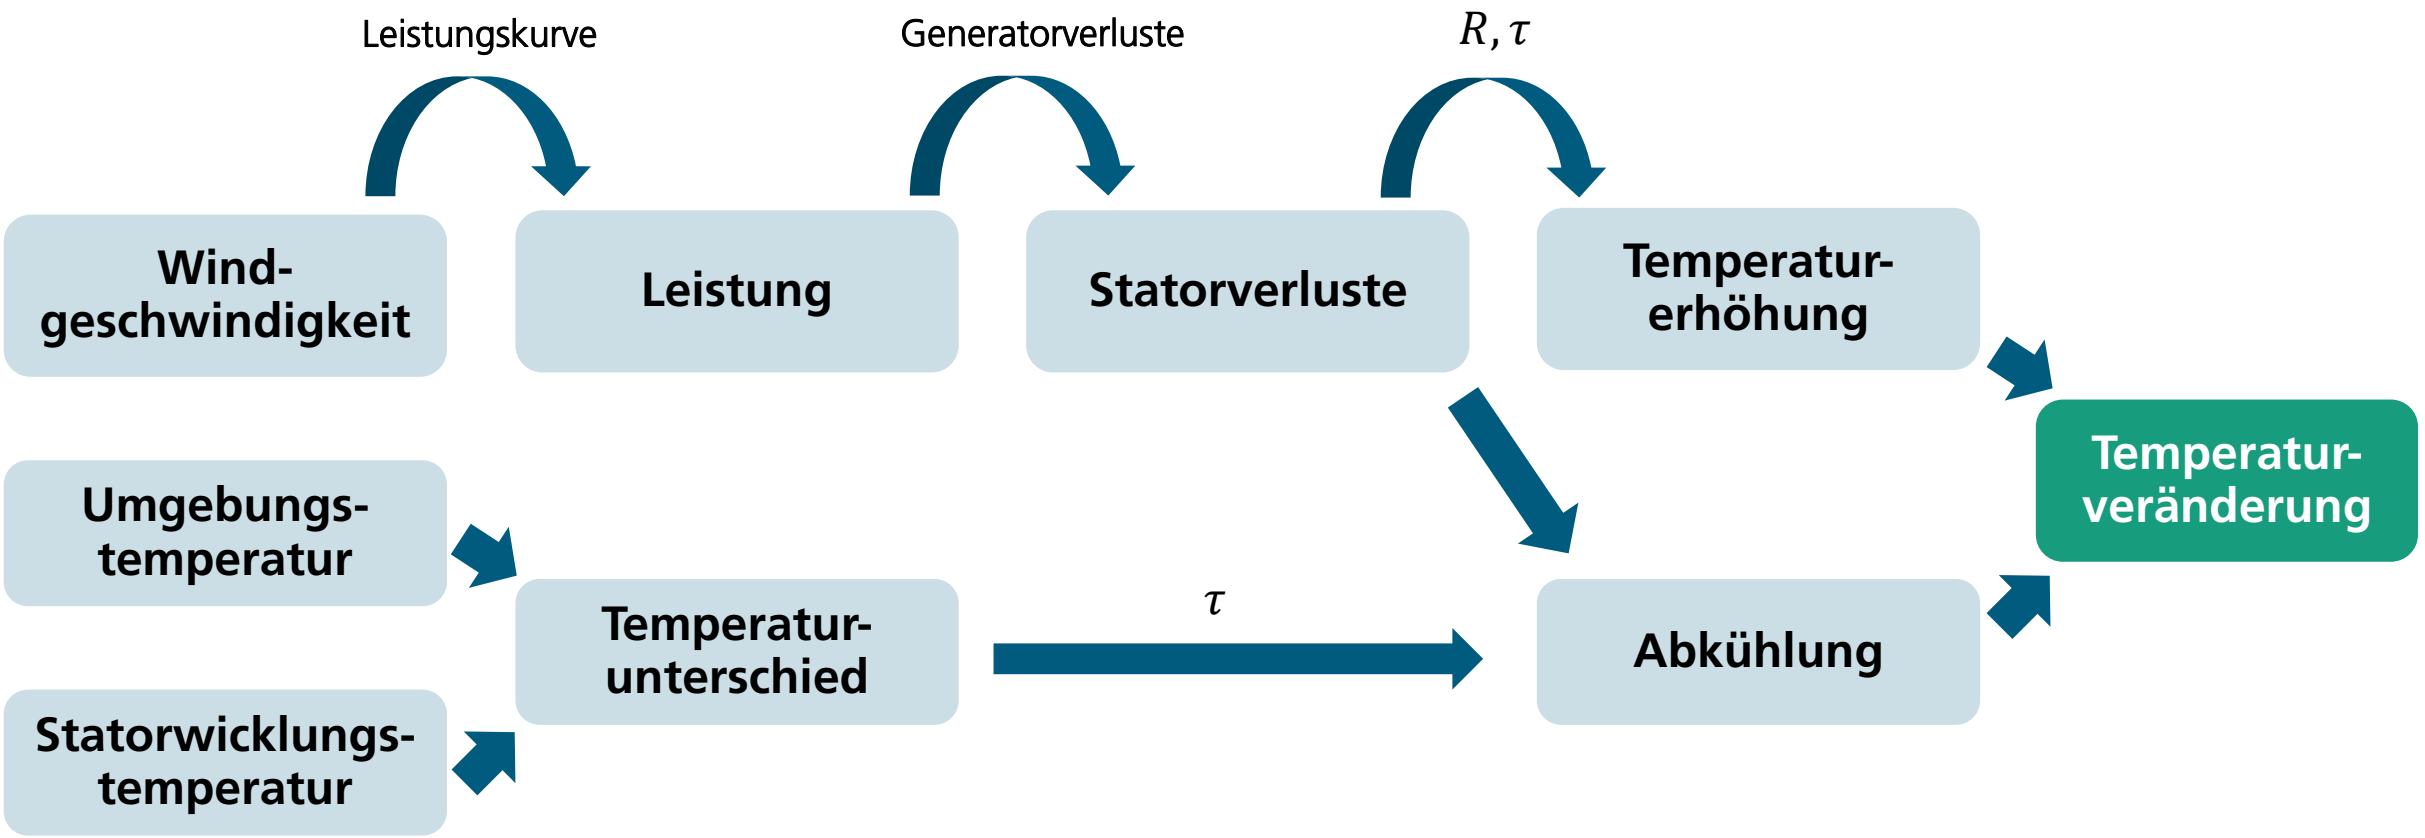

 © Fraunhofer IEE

Fraunhofer IEE

Physikinformierte Neuronale Netze (PINN)

PINN-Loss

Statorwicklungs -temperaturen

$y_1, y_2, \dots, y_N$

Neuronales Netz

$\hat{y}_1, \hat{y}_2, \dots, \hat{y}_N$

$\widehat{\Delta y}_2, \widehat{\Delta y}_3, \dots, \widehat{\Delta y}_N$

Temperatur Modell

$\Delta y_2, \Delta y_3, \dots, \Delta y_N$

$$Loss_{data} = \sum_{i=1}^{N} (y_i - \hat{y}_1)^2$$

$$Loss_{phy} = \sum_{i=2}^{N} \left(\Delta y_i - \widehat{\Delta y}_1\right)^2$$

$$\boldsymbol{Loss_{PINN} = (1 - \alpha) * Loss_{data} + \alpha * Loss_{phy}}$$

- **Für Auswertungen wird $\alpha = 0{,}5$ verwendet.**

 © Fraunhofer IEE

Fraunhofer IEE

Experimente und Ergebnisse

Experimente und Ergebnisse

Experimentdefinition

Kriterium	Generatormodell	Surrogate-Modell (rein datengetrieben)	PINN
Genauigkeit	+	-	?
Generalisierungsfähigkeit	+	-	?
Benötigt großen Trainingsdatensatz	+	-	?
Auswertungszeit	-	+	+
Erstellungsaufwand	-	+	+
Metadaten	-	+	+
Übertragbarkeit des Konzepts	-	+	(+)

➢ **Vergleich: Rein datengetriebene Modell vs. PINN (Generatormodell ist noch nicht verfügbar).**

 © Fraunhofer IEE

Fraunhofer IEE

Experimente und Ergebnisse

Experimentaufbau

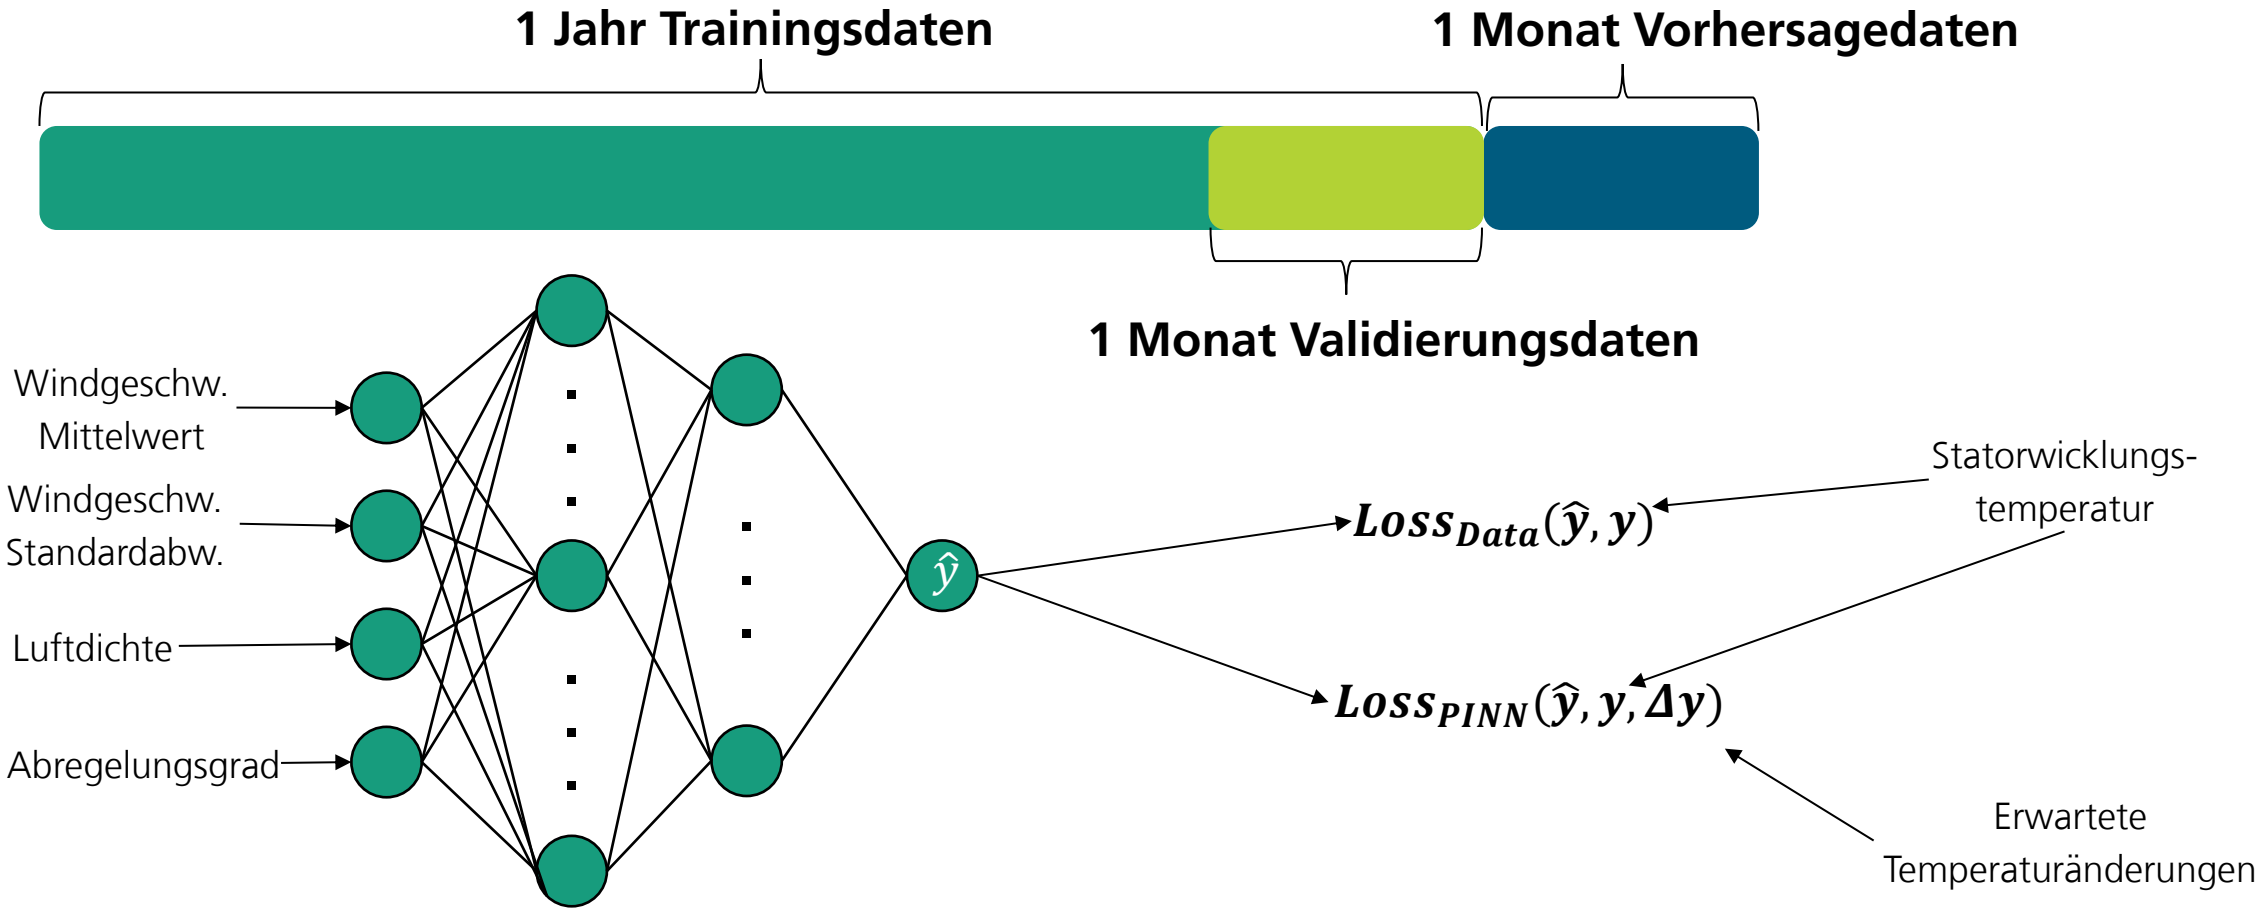

➢ **Experimente nutzen gleiches Grundmodell und variieren die Lossfunktion.**

 © Fraunhofer IEE

Fraunhofer IEE

Experimente und Ergebnisse

Experimentaufbau

Gemessene Temperaturänderungen

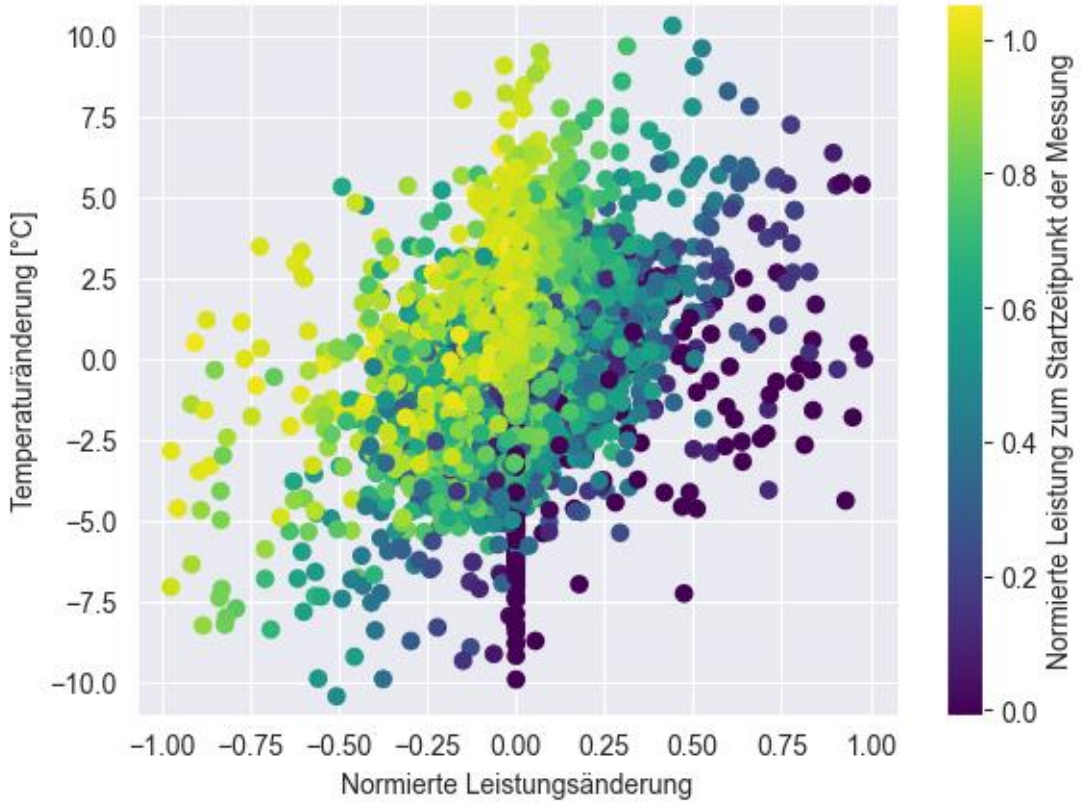

Temperaturmodell

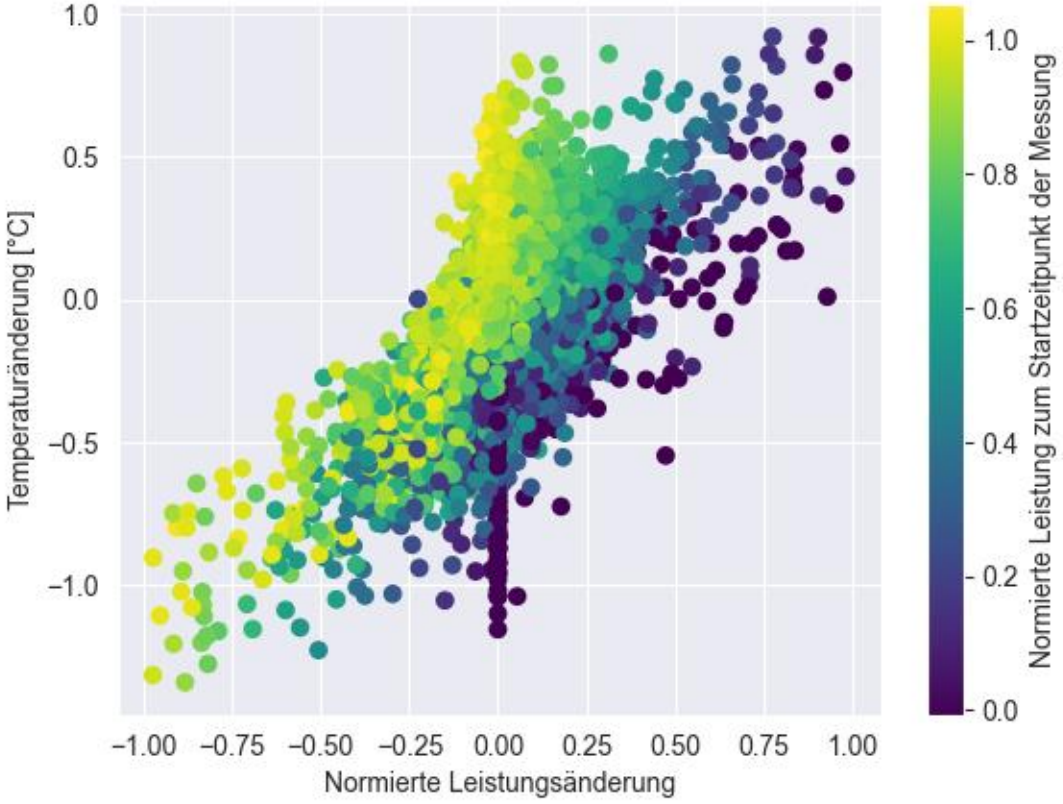

➢ **Temperaturmodell vermittelt nicht die korrekten Werte, aber die Auswirkungen von Leistungsänderungen/zuständen auf die Temperatur.**

 © Fraunhofer IEE

Fraunhofer IEE

Experimente und Ergebnisse

Genauigkeit

PINN

MAE: 1,89°C | MAE>90°C: 2,12°C

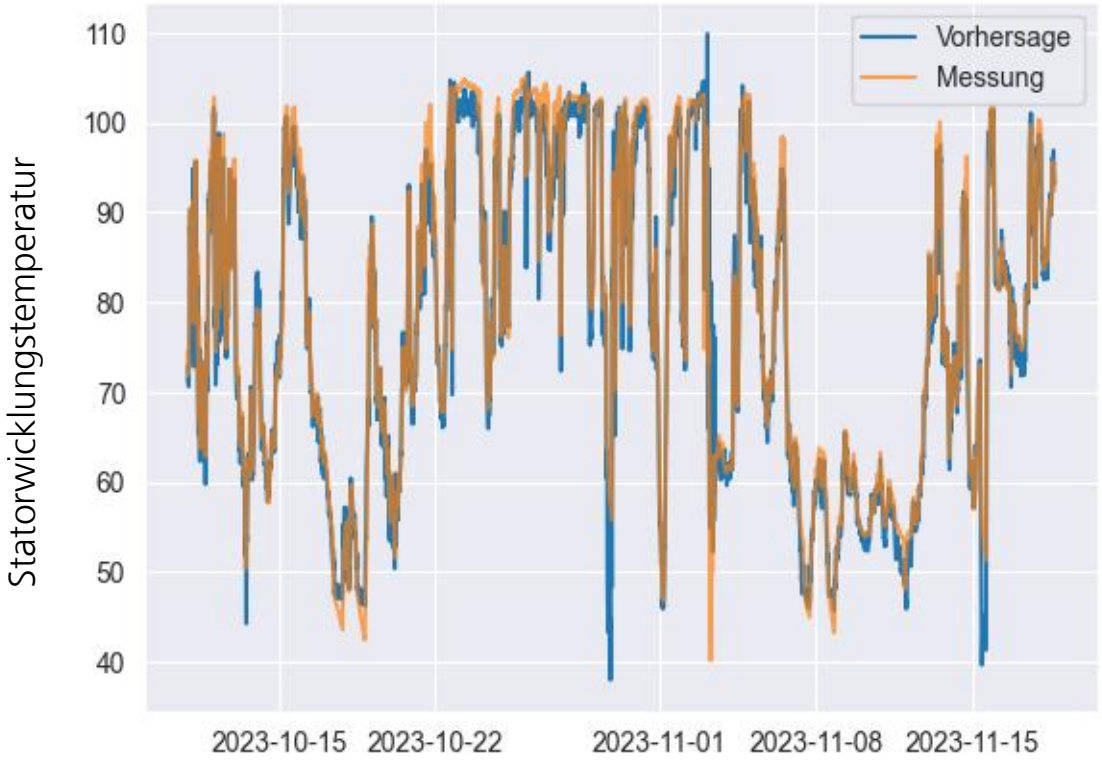

Standard CNN

MAE: 2,44°C | MAE>90°C: 3,53°C

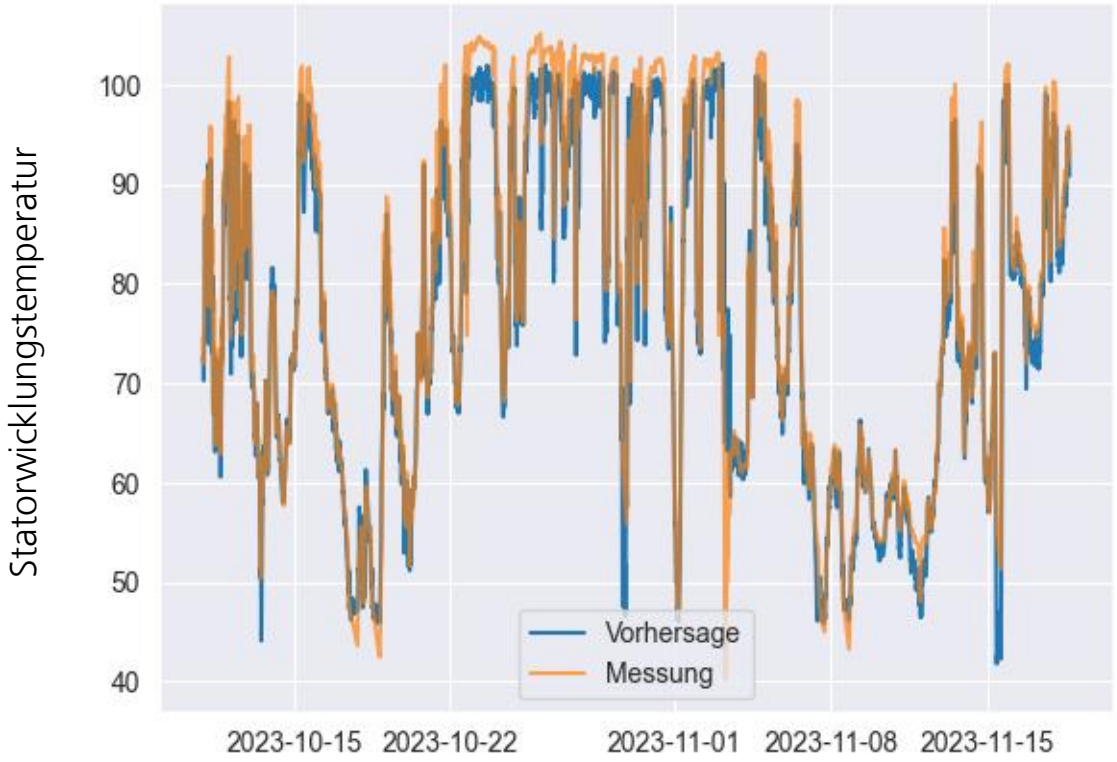

- **Beurteilung der Modelle anhand des MAE (Mean Absolute Error), da dieser in der Einheit °C interpretiert werden kann. PINN erreicht eine signifikant höhere Genauigkeit.**

 © Fraunhofer IEE

Fraunhofer IEE

Experimente und Ergebnisse

Weitere Experimente

Generalisierung: Wie verhalten sich die Modelle bei Extrapolationen hinsichtlich der Ziel- und Eingangsgrößen?

- Gut generalisierende PINNs können potenziell auch außerhalb des erlernten Verhaltens brauchbare Vorhersagen machen.

Datenreduktion: Wie beeinflusst die Größe des Trainingsdatensatzes die Modellperformanz?

- Eventuell können PINNs mit kleineren Trainingsdatensätzen eine vergleichbar hohe Genauigkeit erzielen.

 © Fraunhofer IEE

Fraunhofer IEE

Experimente und Ergebnisse

Generalisierung I: Zielgröße

- **Szenario**: Surrogate-Modell wird auf Daten trainiert, welche nicht das volle Temperaturspektrum enthalten.
  - Entferne alle Trainingspunkte mit hohen Temperaturen.
  - Teste die Modellvorhersage auf vollständigem Temperaturspektrum

Beispiel: Alle Temperaturen über 90°C wurden entfernt

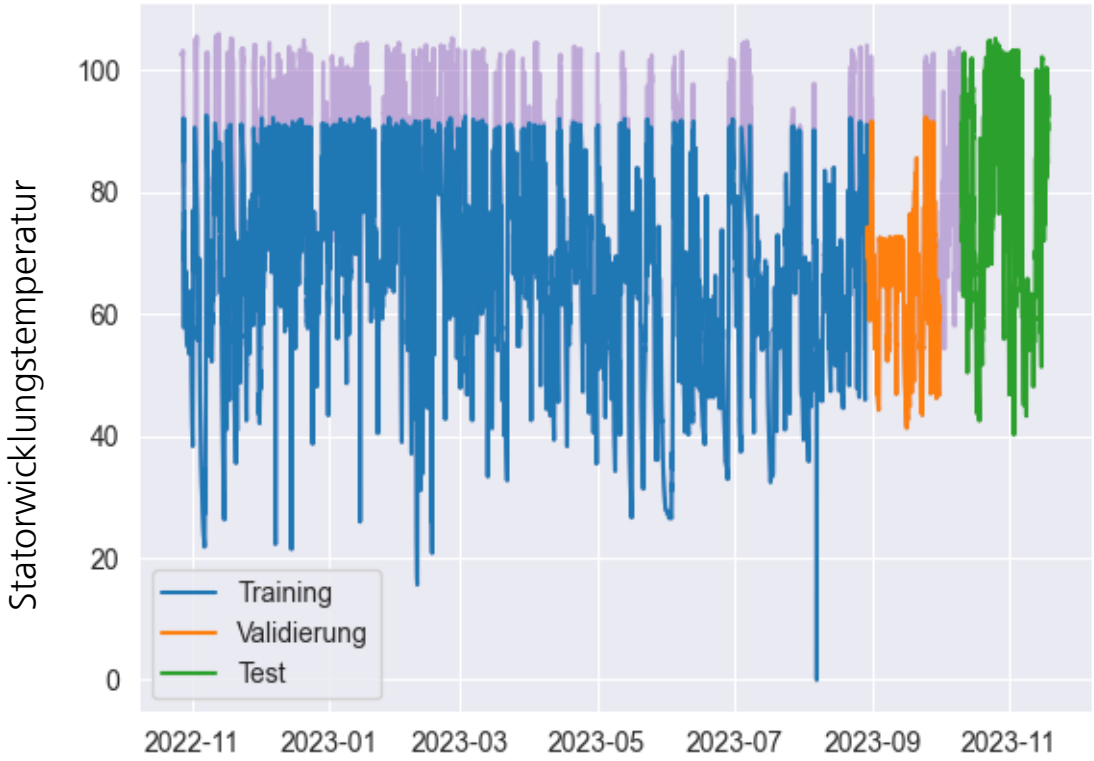

 © Fraunhofer IEE

Fraunhofer IEE

Experimente und Ergebnisse

Generalisierung I: Zielgröße

PINN

MAE: 3,85°C | MAE>90°C: 7,84°C

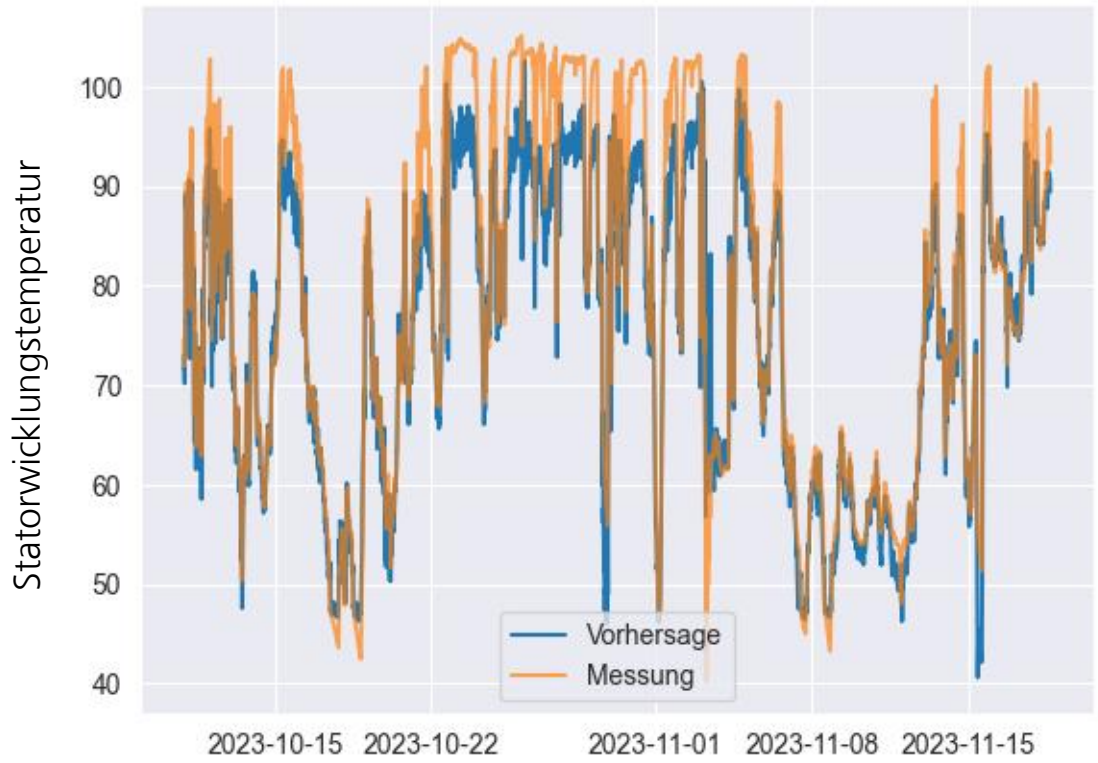

Standard CNN

MAE: 4,99°C | MAE>90°C: 10,77°C

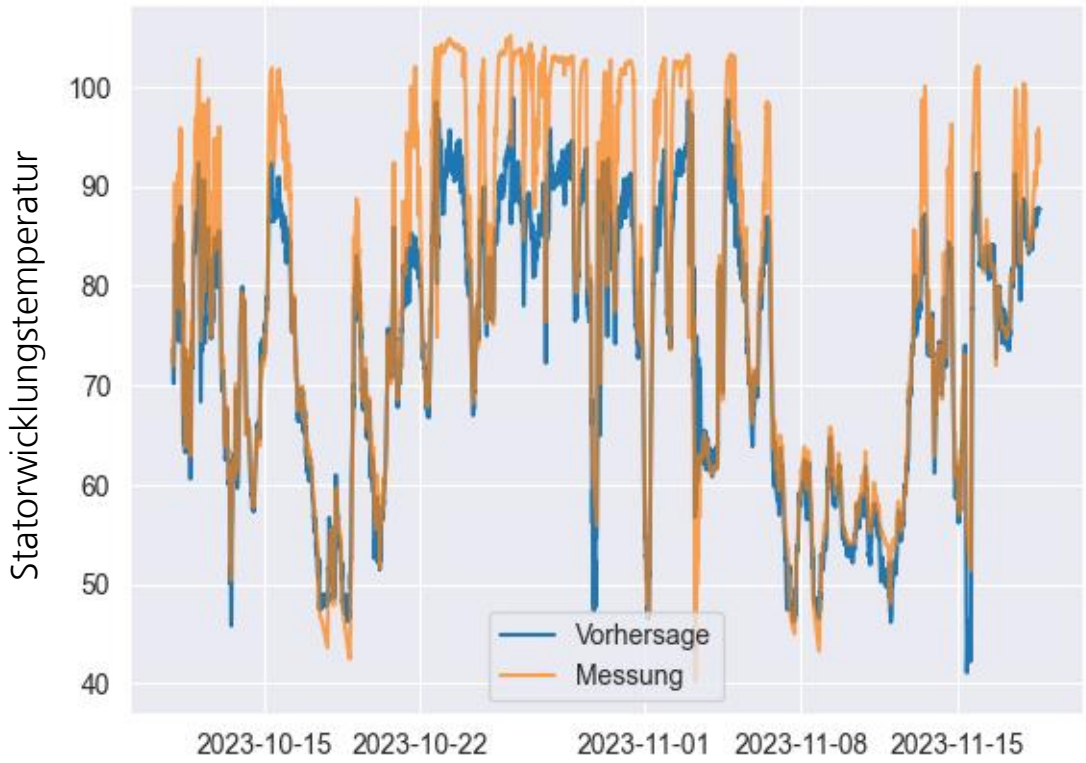

➢ **Das PINN bestätigt den Genauigkeitsvorteil gegenüber dem rein datengetriebenen Modell.**

 © Fraunhofer IEE

Fraunhofer IEE

Experimente und Ergebnisse

Generalisierung I: Zielgröße

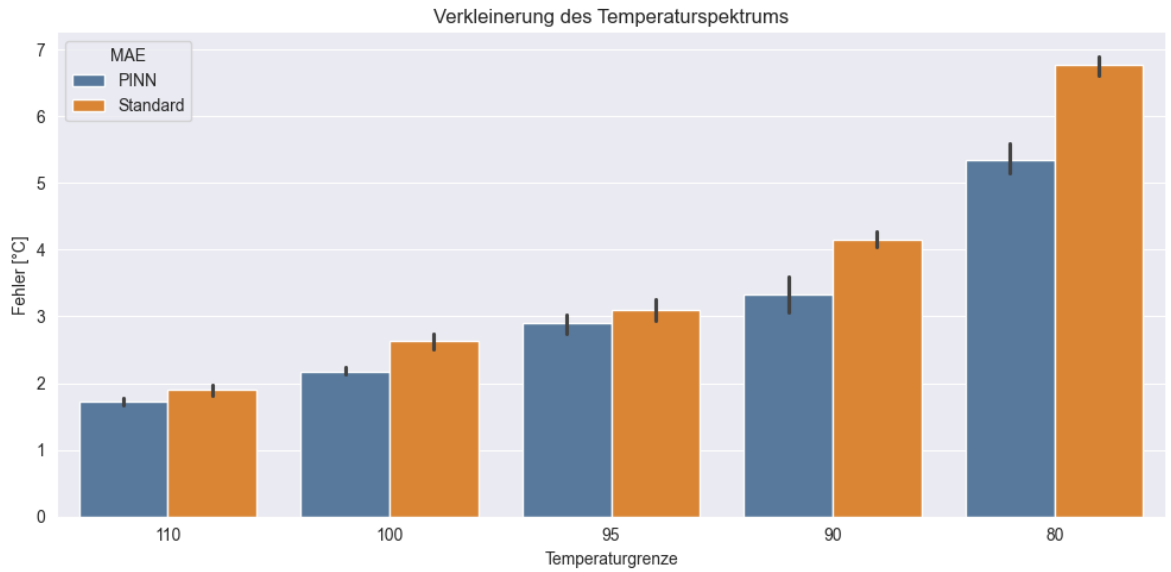

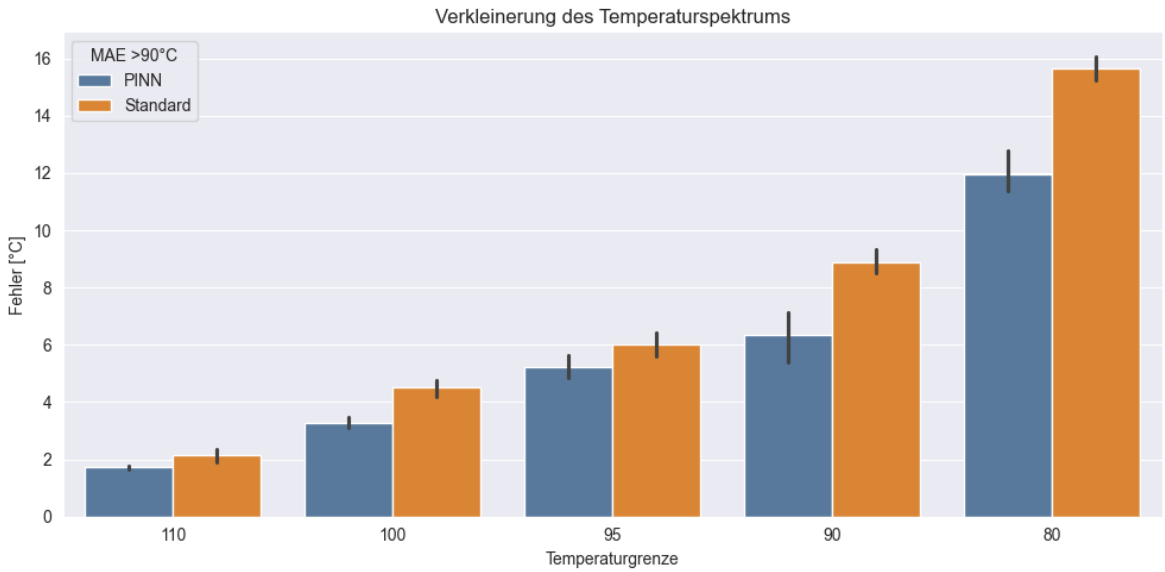

➢ **Es zeigt sich ein zunehmender Genauigkeitsvorteil für das PINN je kleiner das Temperaturspektrum im Training ist.**

 © Fraunhofer IEE

Fraunhofer IEE

Experimente und Ergebnisse

Generalisierung II: Eingangsdaten - Abregelungsgrade

- **Szenario:** Surrogate-Modell wird auf Daten trainiert, welche nur wenige Ausprägungen für bestimmte Abregelungsgrade enthalten.

- Reduziere die Anzahl von Abregelungsbeispielen zwischen 75% und 90%.

- Teste die Modellvorhersage auf Daten, in denen Abregelungsbeispiele vorhanden sind

- **Ergebnis:** Die Reduktion von Abregelungsbeispielen in den Daten hat keine relevanten Auswirkungen auf die Genauigkeit der Modelle.

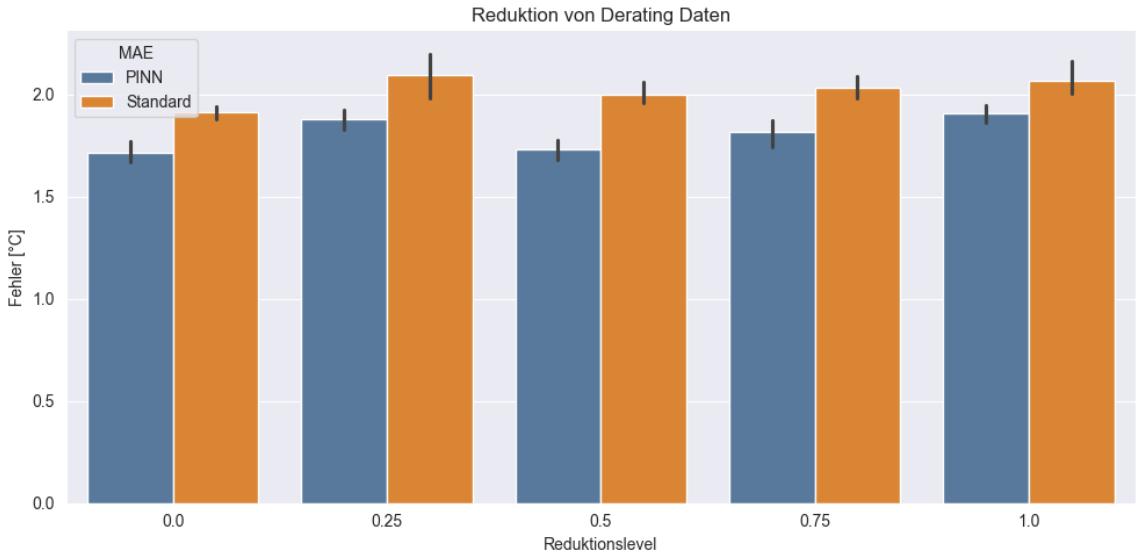

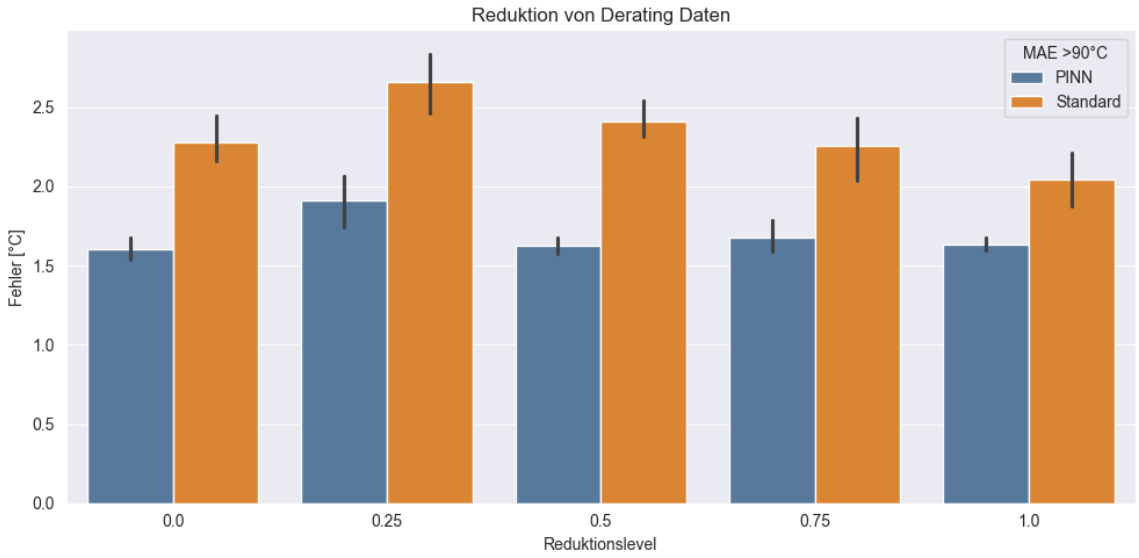

 © Fraunhofer IEE

Fraunhofer IEE

Experimente und Ergebnisse

Datenreduktion I

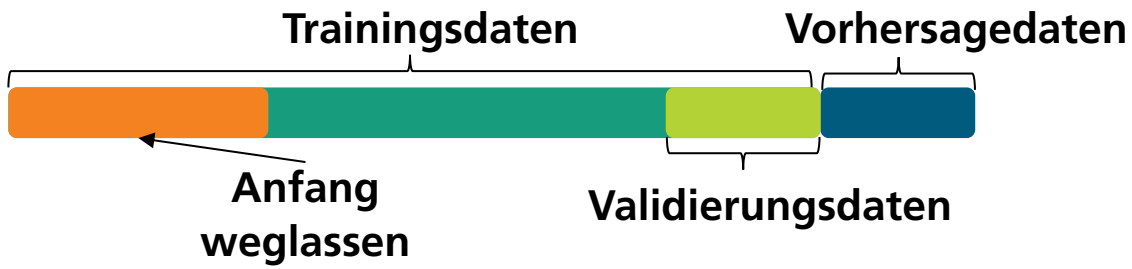

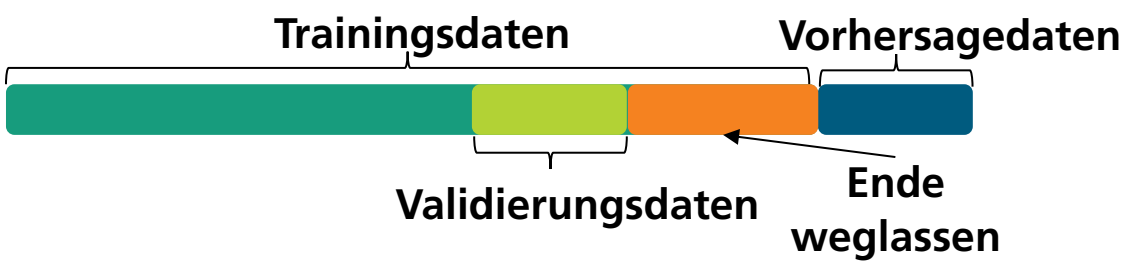

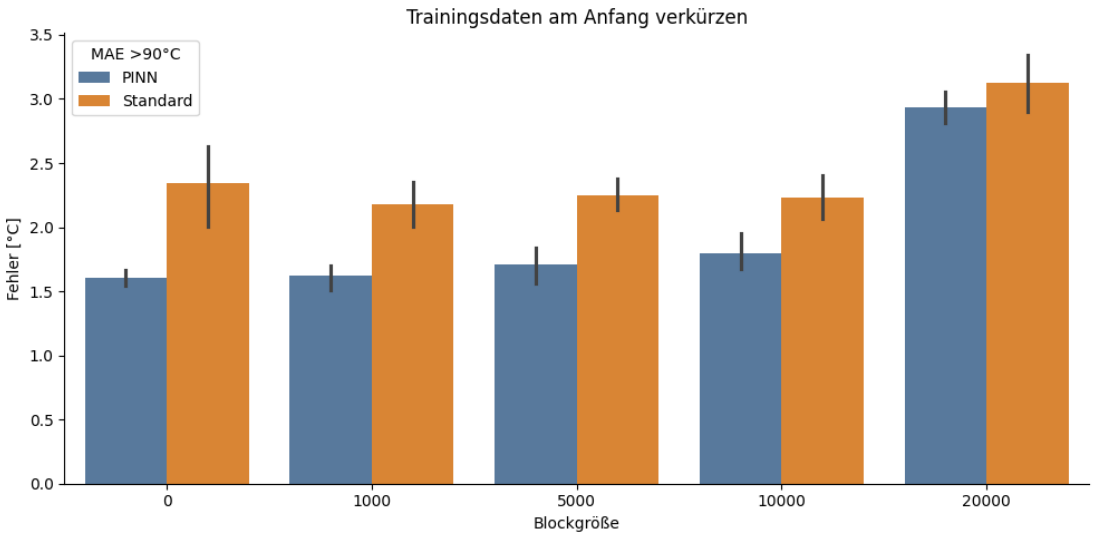

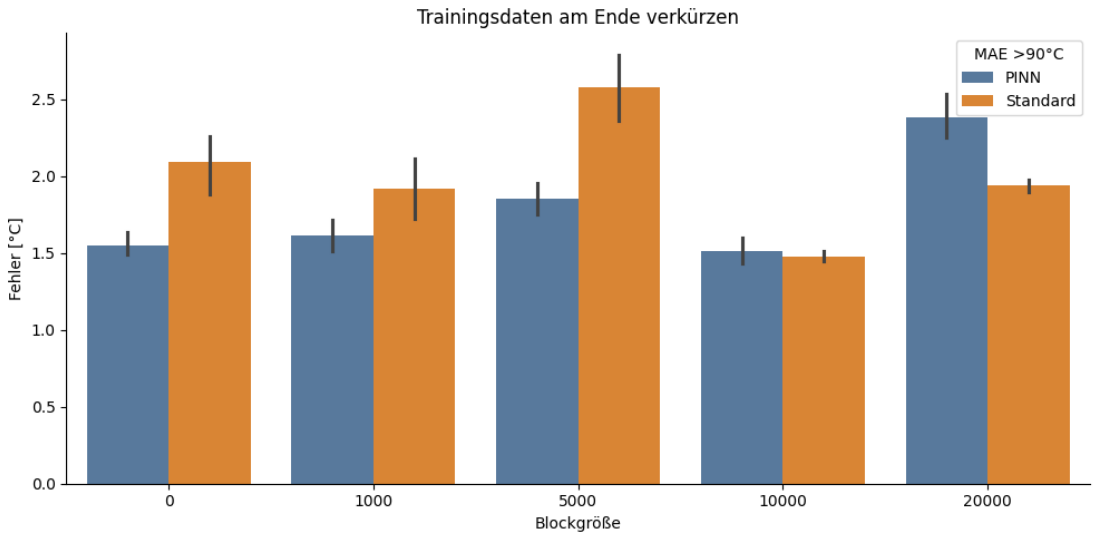

➢ **Eine Verkleinerung des Trainingsdatensatzes um bis zu 20% hat keine Auswirkungen auf die Genauigkeit. Eine Vergrößerung der Lücke zwischen Training und Test wirkt sich ab 10% aus.**

 © Fraunhofer IEE

Fraunhofer IEE

Experimente und Ergebnisse

Datenreduktion II

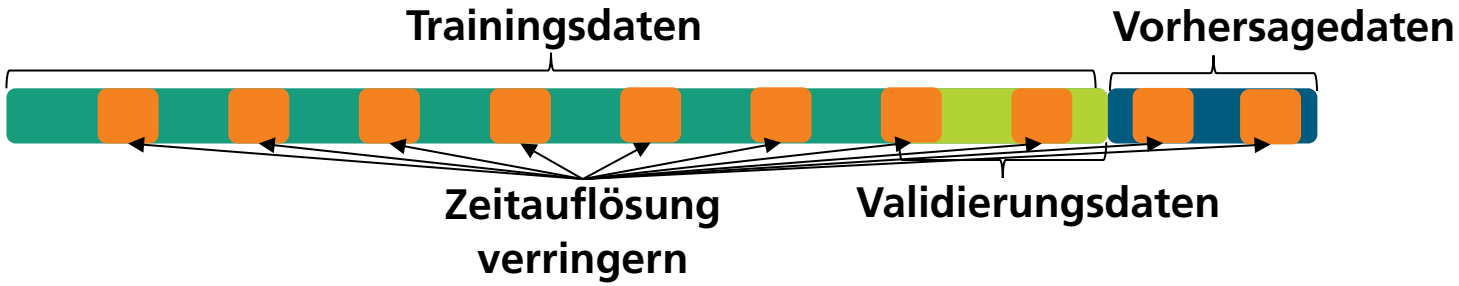

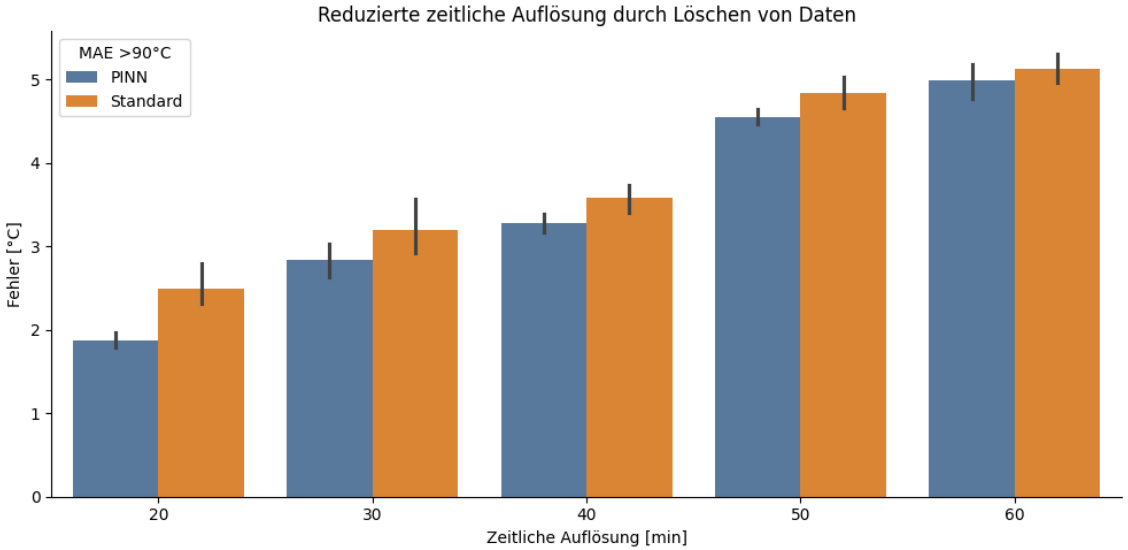

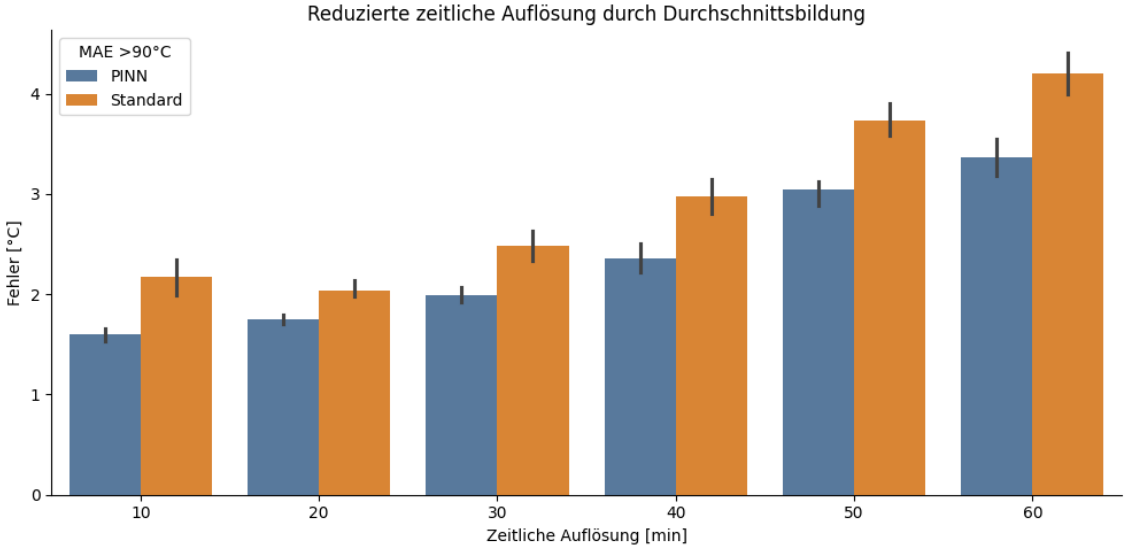

➢ **PINNs könne auch bei niedrigerer zeitlicher Auflösung einen (leichten) Genauigkeitsvorteil aufrechterhalten. Bei Durchschnittsbildung ist der Vorteil deutlicher.**

 © Fraunhofer IEE

Fraunhofer IEE

Zusammenfassung und Ausblick

Zusammenfassung und Ausblick

Zusammenfassung

Kriterium	Generator-modell	Surrogate-Modell (rein datengetrieben)	PINN
Genauigkeit	+	-	+
Generalisierungsfähigkeit	+	-	+
Benötigt großen Trainingsdatensatz	+	-	(+)
Auswertungszeit	-	+	+
Erstellungsaufwand	-	+	+
Metadaten	-	+	+
Übertragbarkeit des Konzepts	-	+	(+)

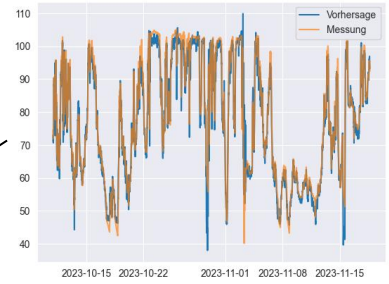

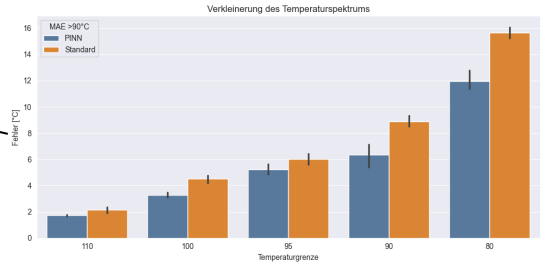

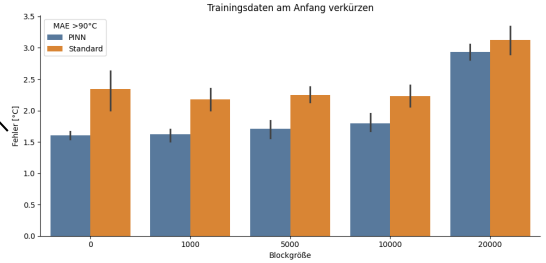

 © Fraunhofer IEE

Fraunhofer IEE

Zusammenfassung und Ausblick

Ausblick

Anschlusspunkte für Experimenten:

- **Validierung/Vergleich mit einem Generatormodell.**
- **Testen von verschiedenen NN-Architekturen + Hyperparameteroptimierung.**
- **Verwendung der Lastprognose in der Otello-Fahrplanoptimierung.**

 © Fraunhofer IEE

Fraunhofer IEE

Kontakt

Christian Gück
Automated Energy Fault Detection and Identification (AEFDI)
christian.gueck@iee.fraunhofer.de

Fraunhofer IEE
Straße Joseph-Beuys-Straße 8
34117 Kassel
https://www.iee.fraunhofer.de/

Kontakt

Florian Rehwald
Automated Energy Fault Detection and Identification (AEFDI)
Tel. +49 561 7294-448
florian.rehwald@iee.fraunhofer.de

Fraunhofer IEE
Straße Joseph-Beuys-Straße 8
34117 Kassel
https://www.iee.fraunhofer.de/