

LSTM

(Sequentiell)



Transformer

(Attention & Parallelität)



Residential Photovoltaic Generation Forecast via Long Short-Term Memory and Transformer



Agenda

- Motivation
- Datenauswahl und –Aufbereitung
- Modellauswahl und Training
- Ergebnisse
- Kritische Würdigung und Ausblick
- Zusammenfassung


Residential Photovoltaic Generation Forecast via Long Short-Term Memory and Transformer

Motivation

Individuelle Prognosen sind für lokale Optimierung notwendig


Überschusseinspeisung

Erzeugter PV-Strom der nicht direkt verbraucht wird, wird in das öffentliche Netz eingespeist.



Eigenstromoptimierung durch Flexibilisierung

Flexible Verbraucher (§14a) steuern um Nutzung von PV-Strom zu steigern.



Eigenverbrauch von günstigem PV-Strom wird erhöht, teurer Netzbezug minimiert.

Wie gut lässt sich die PV-Erzeugung auf Haushaltsebene prognostizieren?

Datenauswahl und -Aufbereitung

Auswahl und Aufbereitung der verwendeten, frei verfügbaren Daten

Fokus auf:

- Möglichst aktuelle Daten
- Möglichst lange Zeitreihen



Location	Gaithersburg (USA)	Melbourne	Istanbul	Hong Kong	Bielefeld (GER)
Quantity	1	3	1	1	2

Grober Datenaufbereitungsprozess

Herunterladen
und speichern in
Datenbank

Hinzufügen
ortsspezifischer
Wetterdaten

Datenanalyse
und
Aufbereitung

Normalisierung
auf die jeweilige
Peakleistung

Modellauswahl

Transformer und LSTM sind zwei vielversprechende Architekturen

Anforderungen an PV-Erzeugungsprognosen

- Stark nichtlineare Zeitreihen
- Ausgeprägte saisonale & tageszeitliche Muster
- Hohe Sensitivität gegenüber Wetterparametern
- Lokale Muster (Wolkendurchzüge) & Langzeitabhängigkeiten

State-of-the-Art Architekturen

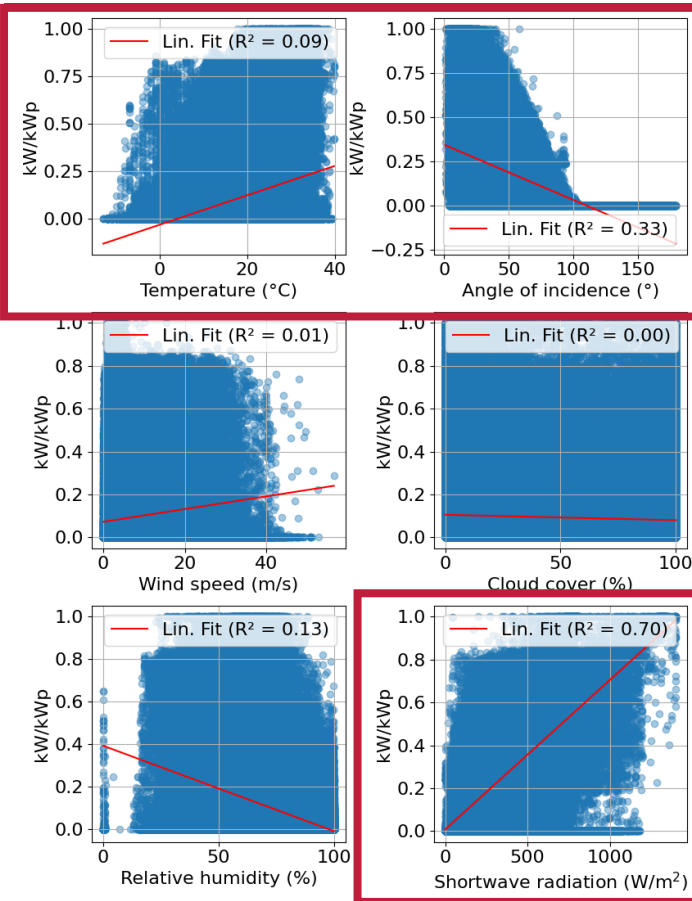
- Klassisch: ARIMA, SVR etc. werden zunehmend verdrängt
- LSTM dominiert die letzten Jahre (robuste Baseline)
- Transformer: Trend der letzten 2-3 Jahre
- Hybride: Kombination mehrerer Ansätze vielversprechend

Unter Berücksichtigung von Prognosegenauigkeit, Modellkomplexität sowie Trainingsdauer wurden LSTM und Transformer als Architekturen gewählt.

Modelltraining

Featureidentifikation durch Pearson-Korrelation und Scatterplots

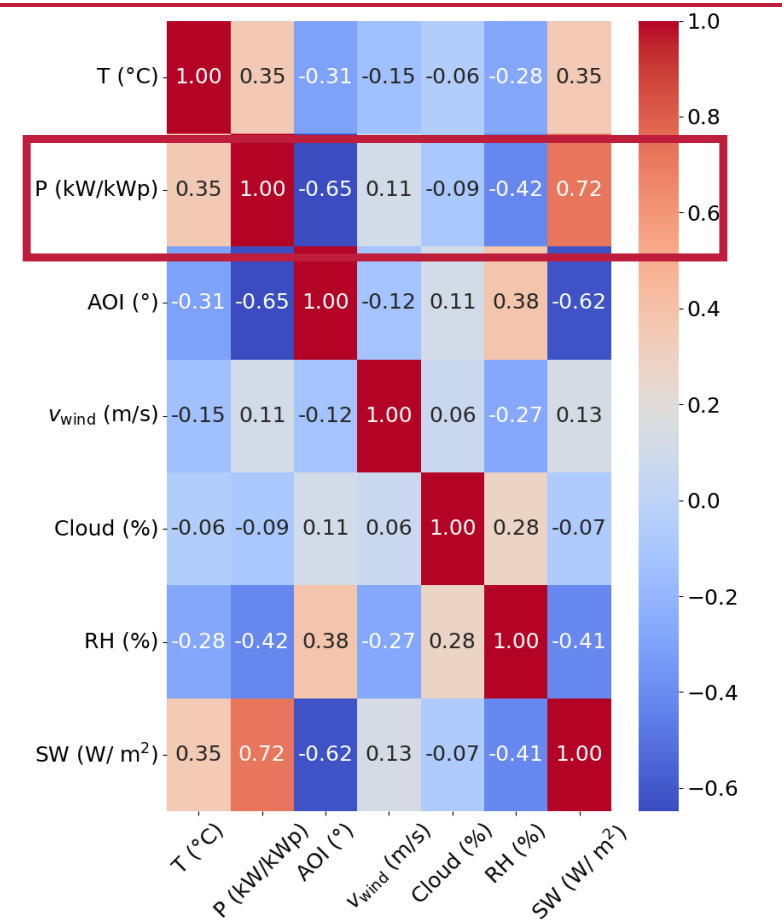
Scatterplot



Wetterparameter und Einfallswinkel höchste Korrelationen

Modelle mit unterschiedlichen Featuresätzen trainiert für Detailanalyse

Pearson-Korrelation



Ergebnisse

Auswirkung der Variation von Featuresätzen, Eingabetagen & Hyperparameteroptimierung auf die Prognosegüte

Einfluss Eingabetage (LSTM)

Input window (days)	MSE	MAE
1	0.0062	0.0378
2	0.0058	0.0365
3	0.0063	0.0382
4	0.0059	0.0365

Einfluss Hyperparameteroptimierung (LSTM)

Model type	MSE	MAE
Simplified LSTM	0.0058	0.0363
Complex LSTM	0.0055	0.0343

Einfluss Featureauswahl

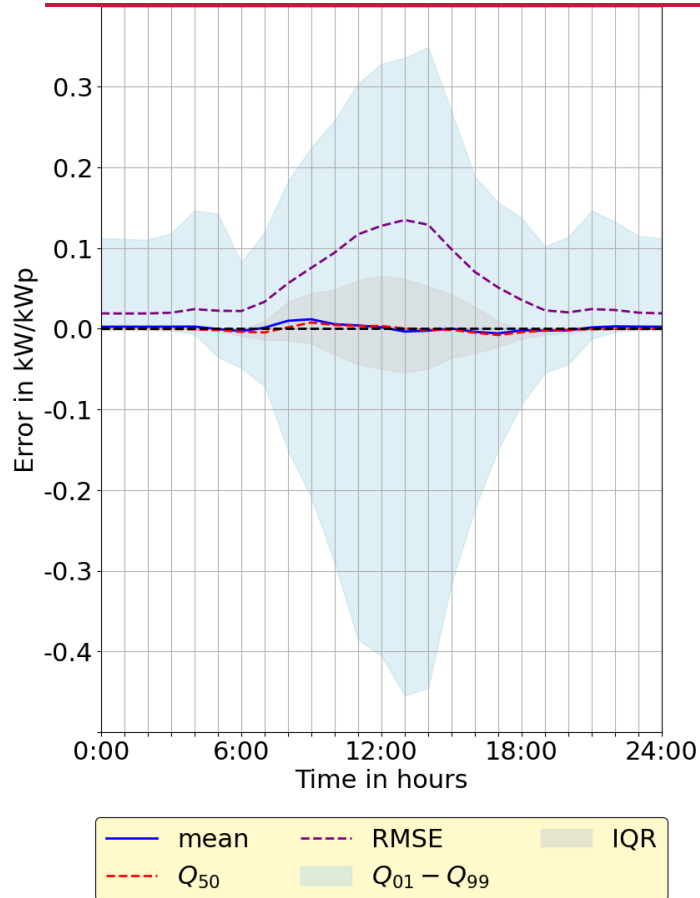
No.	Feature Selection	MSE	MAE
1	All features	0.0064	0.0383
2	All features except cloud coverage	0.0062	0.0378
3	All features except cloud coverage and wind speed	0.0063	0.0383
4	Shortwave radiation, temperature, angle of incidence	0.0065	0.0388
5	Shortwave radiation, angle of incidence	0.0067	0.0393

Ein Modell mit einem Eingabefenster von zwei Tagen mit allen Features außer der Bewölkung liefert nach Hyperparameteroptimierung das beste Ergebnis.

Ergebnisse

Die Fehlerverteilungen zeigen wie erwartet hohe Abweichungen in den Mittagsstunden


Fehlerverteilung LSTM



Insbesondere die
Mittagszeiten höhere
Prognosefehler

Hohe Fehler
möglicherweise durch
schlechte Abbildung von
Bewölkung verursacht


Fehlerverteilung Transfomer



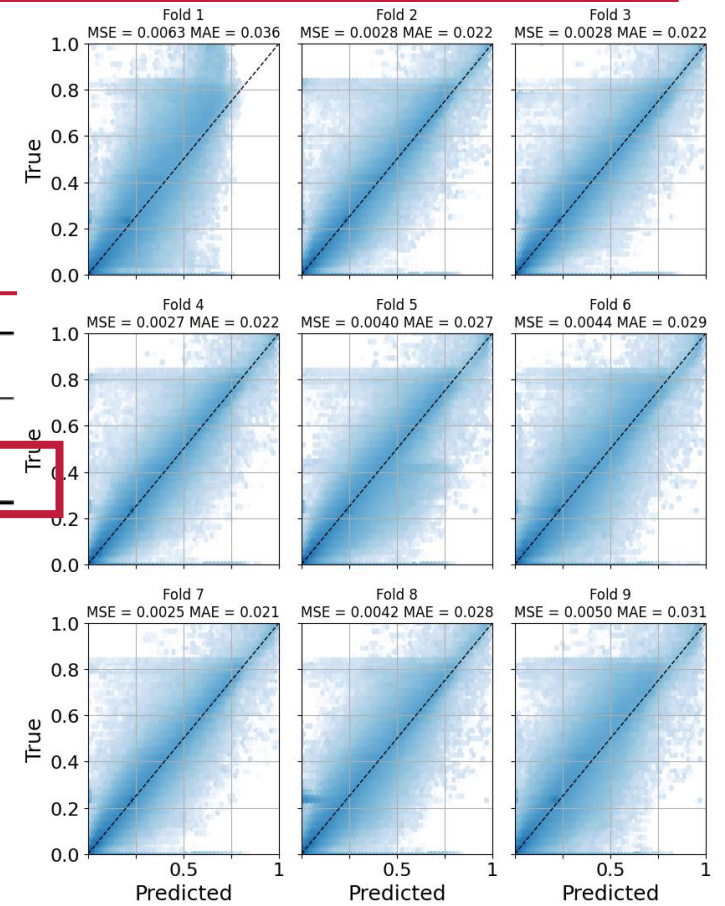
Ergebnisse

In den einzelnen Folds sind die Fehler unterschiedlich verteilt

Hexbin-Plot LSTM



Hexbin-Plot Transformer



Gesamtvergleich LSTM vs. Transformer

Model type	MSE	MAE
LSTM	0.0055	0.0343
Transformer	0.0038	0.0265

Kritische Würdigung



- Verwendung von realen Wetterdaten statt Wetterprognosen, wie es in realen Anwendungen der Fall ist



- Relativ kleine Anzahl an Trials während der Hyperparameteroptimierung



- Begrenzte Anzahl an Daten könnte sich negativ auf die Generalisierungsfähigkeit auswirken



- Genauere Angaben zum Wolkenzug könnte die Prognosegüte durch bessere Abbildung von Leistungsgradienten erhöhen



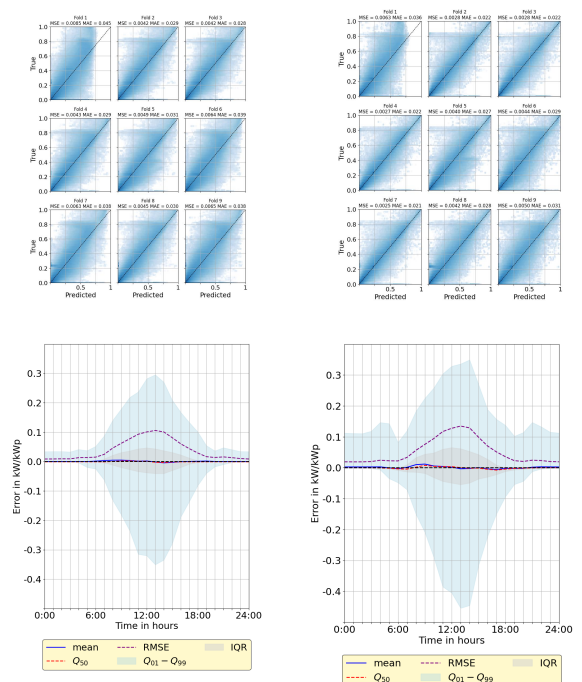
- Hybride Modelle sind in der Literatur in der Lage, die Prognosegüte um ein wenige Prozentpunkte zusätzlich zu verbessern

Zusammenfassung

PV-Erzeugungsprognose auf Haushaltsebene in 15min-Auflösung

- Detaillierte Betrachtungen ergaben, dass ein Input-Fenster von zwei Tagen sowie die Exkludierung der Bewölkung aus den Features die besten Ergebnisse lieferten
- Direkter Vergleich: Transformer besser als LSTM -> simultane Datenverarbeitung der Transformer liefert bessere Ergebnisse als das sequenziell arbeitenden LSTM
- Insbesondere zur Mittagszeit mit hohen Fehlern, wie erwartet niedrig in den Nachtstunden

No.	Feature Selection	MSE	MAE
1	All features	0.0064	0.0383
2	All features except cloud coverage	0.0062	0.0378
3	All features except cloud coverage and wind speed	0.0063	0.0383
4	Shortwave radiation, temperature, angle of incidence	0.0065	0.0388
5	Shortwave radiation, angle of incidence	0.0067	0.0393



Kontakt

Veröffentlichungen wurden im Rahmen der geförderten Projekte “MELANI- Mehrfach genutzte Energiespeicher im Mehrfamilienhaus nachhaltig integrieren” (FKZ: 03EI3012B/03EI3012C) und TEN.efzn (FKZ : ZN4462) angefertigt.



MARCEL LÜDECKE, M. SC.

Work Group Leader

Research Associate & PhD Student

Energiemanagement im Sektor
Wohnen

m.luedecke@tu-braunschweig.de



**BERND ENGEL,
PROF. DR.-ING.**



MICHEL MEINERT, M. SC.

Supported by:



on the basis of a decision
by the German Bundestag



**elenia Institut für Hochspannungstechnik u.
Energiesysteme**

Technische Universität Braunschweig

Schleinitzstraße 23
38106 Braunschweig
Germany



Anhang