



VS

Comparing Load-Forecasts of Residential Heatpumps with Transformer and XGB on Field Data

Agenda

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

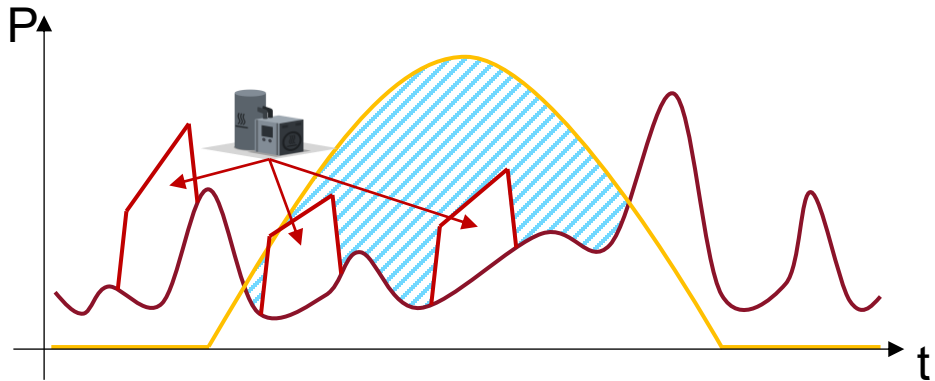
Comparing Load-Forecasts of Residential Heatpumps with Transformer and XGB on Field Data

Motivation

Individuelle Prognosen sind für lokale Optimierung notwendig

Eigenstromoptimierung


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



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

Flexibilisierung zur Nutzung dynamischer Tarife

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



Die Lastverschiebung bewirkt niedrigere Strombezugskosten.

Wie gut lassen sich die Leistungsbedarf von Wärmepumpen auf Haushaltsebene prognostizieren?

Datenauswahl und -Aufbereitung

Auswahl und Aufbereitung der verwendeten, frei verfügbaren Daten

Location



Quantity



Access



	Location	Quantity	Access
UK	UK	306 Profile	Open Source
Konstanz	Hildesheim	2 Profile	Open Source

Fokus auf:

- Luft-Wasser WP
- Möglichst aktuelle Daten
- Möglichst lange Zeitreihen

Grober Datenaufbereitungsprozess

Herunterladen
und speichern
in parquet-Datei

Hinzufügen
ortsspezifischer
Wetterdaten

Datenanalyse
und
Aufbereitung

Normalisierung
mittels Scaler

Modellauswahl

Transformer und XGB sind zwei vielversprechende Architekturen

Stand der Forschung

- **Nicht-Wohngebäude:** Labore, Büros, Universitäten – Fokus auf Steuerung & Effizienz
- **Aggregierte Lasten:** Mehrfamilienhäuser & Energiegemeinschaften (RF, XGB, LSTM, Transformer)
- **Einzelgeräte:** Kaum Forschung zu individuellen Wärmepumpen in Ein-/Zweifamilienhäusern

-> **Forschungslücke für Prognosen auf Haushaltsebene mit einer Auflösung von 15min**

Prognosemethoden

- **Klassisch:** LinReg, ARIMA
- **Machine Learning:** KNN, SVM, RF, XGB
- **Deep Learning:** ANN, LSTM, Transformer

-> **Unter Abwägung von Prognosegenauigkeit, Modellkomplexität sowie Trainingsdauer wurden eXtreme Gradient Boosting (XGB) und Transformer gewählt**

Modelltraining

Optimierung der Featureauswahl und Hyperparameter zur Verbesserung der Prognosegüte

Erstellen und Hinzufügen von Features

- Wetterdaten
- Vergangene Lastwerte
- Vergangene Temperaturwerte
- Zyklische Zeitwerte
- Tages- und Jahreslabel
- Belegungsdaten

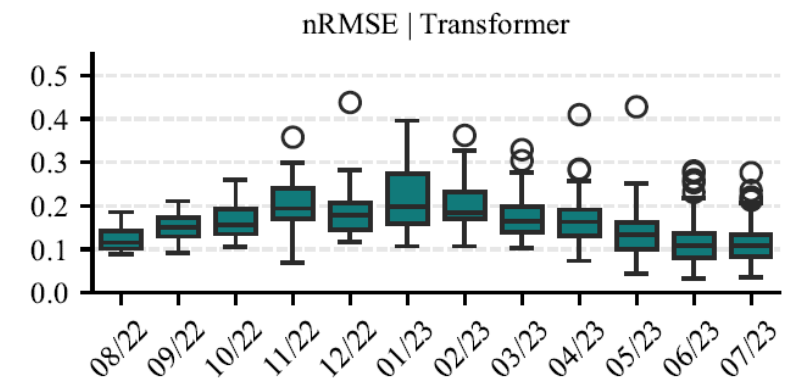
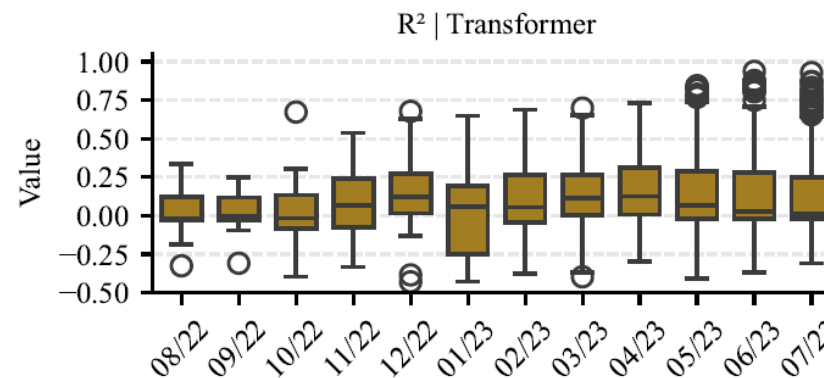

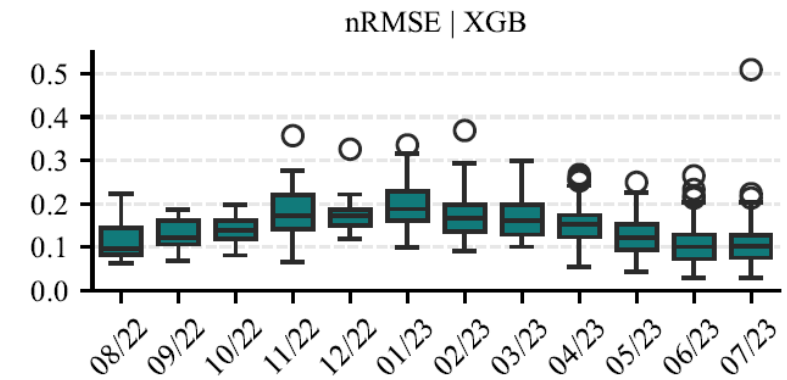
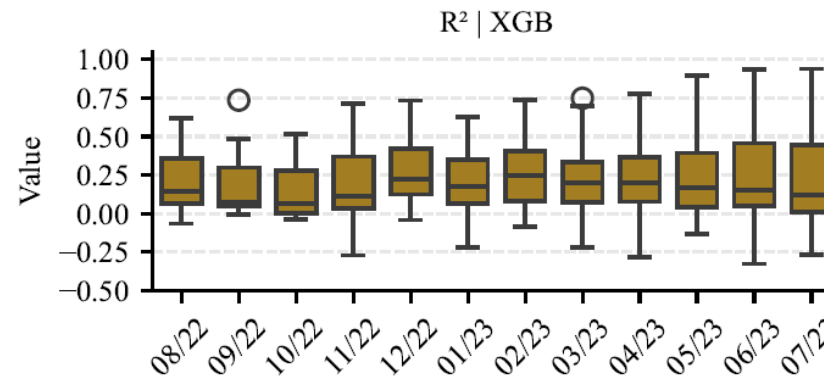
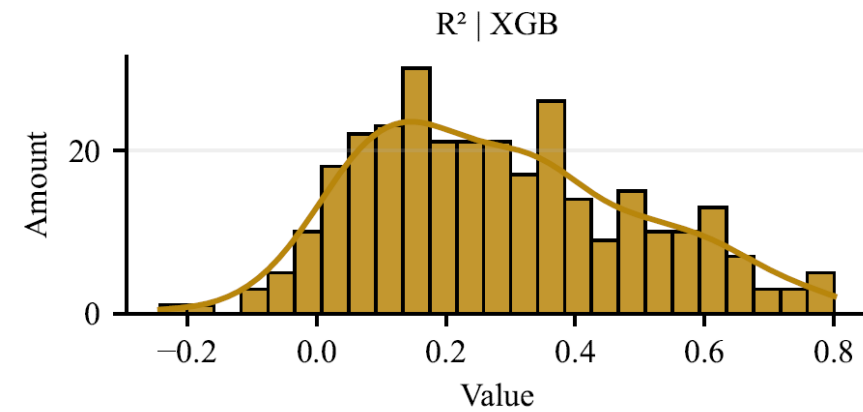
Analyse und Identifikation relevanter Features

- Spearman-Korrelation
- Random Forest Analyse

Finaler Feature-Satz

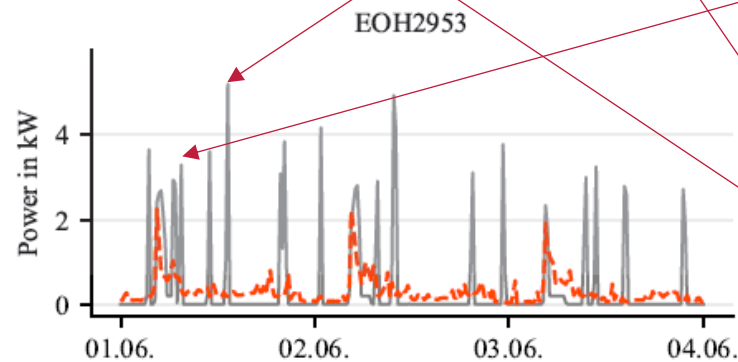
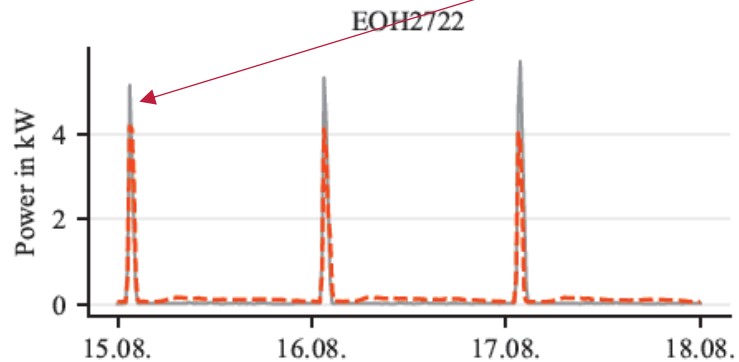
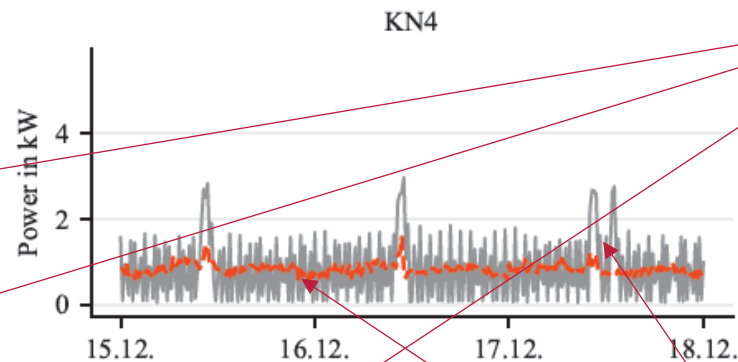
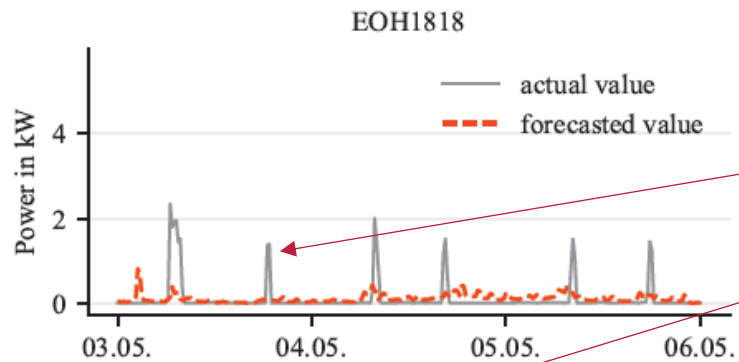
Ergebnisse

Es ergibt sich ein breites Spektrum an Prognosegüten



Ergebnisse

Die Muster im Leistungsverlauf unterscheiden sich stark




Regelmäßige Peaks

Unregelmäßige Peaks


Rauschen und zufällige Peaks

Ergebnisse




EOH2634
 $R^2 = 0,71$
 $nRMSE = 0.07$

Regelmäßig wiederkehrende Lastspitzen, wenige zufällige Peaks
 → Hoher R^2 , niedriger nRMSE
 → **Modell ist in der Lage, den Lastgang zu erfassen**



EOH0001
 $R^2 = 0.52$
 $nRMSE = 0.09$

Wenige regelmäßig wiederkehrende Lastspitzen, viele zufällige Peaks
 → Mittlerer R^2 , mittlerer nRMSE
 → **Modell ist nur teilweise in der Lage, den Lastgang zu erfassen**




EOH0789
 $R^2 = -0.09$
 $nRMSE = 0.14$

Keine regelmäßig wiederkehrende Lastspitzen, nur zufällige Peaks
 → Niedriger R^2 , hoher nRMSE
 → **Modell ist nicht in der Lage, den Lastgang zu erfassen**


→ **Prognose der elektrischen Last von Wärmepumpen ist abhängig von sich wiederholenden Mustern im Lastgang**

Ergebnisse

Die Modelle versuchen im Wesentlichen zyklische Muster nachzubilden



Transformer und XGB bilden teilweise ein mittleres Rauschen ab



Persistenz erzeugt Peaks wo keine sind

Lineare Regression liefert viele negative Werte

Ergebnisse

XGB und Transformer schlagen die Benchmarks, XGB liefert die besten Ergebnisse

Vergleich der Prognosen auf den Testdaten

Model	R^2	$nRMSE$	$Peak_E$
EOH1700			
Lin. Regression	0.74	0.075	798.16 kW
Transformer	0.80	0.066	713.90 kW
XGB	0.81	0.064	777.52 kW
Persistenz	0.55	0.099	917.87 kW
EOH2504			
Lin. Regression	0.408	0.078	358.10 kW
Transformer	0.775	0.048	293.25 kW
XGB	0.838	0.041	246.08 kW
Persistence	0.587	0.078	358.10 kW

Modellanwendung auf unbekanntem Daten

Metric	Transf.	XGB	LinReg	Persist.
R^2 Consist.	0.428	0.434	0.398	0.235
R^2 Inconsist.	0.038	0.164	0.213	0.235
$nRMSE$ Consist.	0.092	0.091	0.095	0.107
$nRMSE$ Inconsist.	0.119	0.111	0.108	0.107
$Peak_E$ Consist.	14,2k	11,4k	11,6k	10,4k
$Peak_E$ Inconsist.	12,2k	14,0k	13,0k	10,4k

Unit Peak-Error in MW (k = 1000)

Kritische Würdigung

Genauere, individuelle Prognosen sind so nicht erreichbar



- Keine technischen Detail-Parameter wie Innenraumtemperaturen oder Anwesenheit verwendet



- Daten aus ähnlichen klimatischen Zonen verwendet (Deutschland und UK)



- Nur Luft-Wasser Wärmepumpen betrachtet



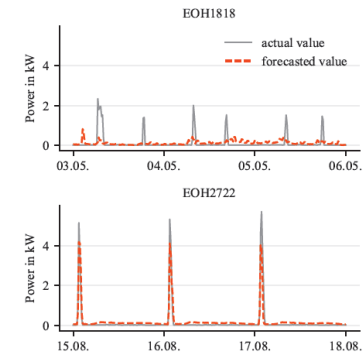
- Globales Modell für XGB vs. Lokale Modelle für Transformer machen den Vergleich unfair; Transformer zeigt auf aggregierten Daten auch bessere Prognosen

Zusammenfassung

Die Prognosegüte hängt maßgeblich vom Muster im Leistungsverlauf ab


Modellperformance

- **XGB übertrifft Transformer** (höheres R^2 , niedrigeres $nRMSE$)
- **Beide Modelle** schlagen LinReg & Persistenz bei stabilen Lastprofilen
- **Limitiert bei irregulären Profilen** – Modellklasse kann fehlende Vorhersagbarkeit nicht kompensieren



Feature-Relevanz

- **Vergangene Lastwerte** = wichtigster Treiber
- **Temperatur & zyklische Variablen** bieten nur inkrementelle Verbesserungen
- **Verhaltensinfo fehlt** – kann nicht durch Features kompensiert werden



Generalisierung

- Modelle erben Struktureigenschaften der Trainingsdaten

Metric	Transf.	XGB	LinReg	Persist.
R^2 Consist.	0.428	0.434	0.398	0.235
R^2 Inconsist.	0.038	0.164	0.213	0.235
$nRMSE$ Consist.	0.092	0.091	0.095	0.107
$nRMSE$ Inconsist.	0.119	0.111	0.108	0.107
$Peak_E$ Consist.	14,2k	11,4k	11,6k	10,4k
$Peak_E$ Inconsist.	12,2k	14,0k	13,0k	10,4k

Unit Peak-Error in MW (k = 1000)

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

Anhang

Monatlicher Verlauf der Metriken für den aggregierten Fall

