

Empirischer Methodenvergleich zur Steigerung der Prognosequalität

Bottom-Up Lastprognose im industriellen Kontext

L. Baur, C. Kaymakci, A. Sauer

In Zeiten volatiler und steigender Energiepreise gewinnt die Lastprognose als Entscheidungsgrundlage zunehmend an Bedeutung. Die fortschreitende Digitalisierung erlaubt zudem ein detailliertes Aufzeichnen von Verbrauchsdaten auf mehreren Abstraktionsebenen. In diesem Beitrag werden zwei Ansätze, die eine Messzählerlogik in die Prognose integrieren, mit dem Standardansatz auf Hauptzählerebene verglichen. Die Ergebnisse auf den Unternehmensdaten motivieren für einen flächendeckenden Einsatz.

STICHWÖRTER

Künstliche Intelligenz, Digitalisierung, Forschung

Bottom-up load forecasting in the industrial context

Increasingly volatile and rising energy prices make load forecasting increasingly important as a basis for decision-making. Moreover, the advancing digitalization allows a detailed recording of consumption data on several abstraction levels. This paper compares two approaches that integrate a metering topology into load forecasting with the standard approach at the main meter level. The results on enterprise data motivate widespread deployment.

1 Einleitung

Der zunehmende und zuletzt sprunghafte Anstieg der durchschnittlichen Preise auf den Energiemärkten und die steigende Volatilität des Energieangebots durch den höheren Anteil an erneuerbaren Energien im Energiesystem sind für die meisten produzierenden Unternehmen in Deutschland eine große Herausforderung [1]. Dabei bieten industrielle Verbraucher enormes Potenzial mittels industrieller Nachfrageflexibilität Schwankungen auszugleichen und zur Netzstabilität beizutragen [2]. Zusätzlich können durch die Flexibilisierung der Produktionsprozesse der Eigenverbrauch optimiert, Stunden mit negativen Preisen ausgenutzt und das Ziel der klimaneutralen Produktion erreicht werden [3].

Die grundsätzlichen Ziele für mehr Energieflexibilität in der produzierenden Industrie sind die Reduktion von Lastspitzen, die Optimierung des Verbrauchs von eigenerzeugter Energie, die Bereitstellung von Energieflexibilität auf den jeweiligen Märkten inklusive der flexiblen Energiebeschaffung auf den Spotmärkten [4, 5].

Für die optimale, dynamische Planung und den Betrieb von industriellen Energieversorgungssystemen kommen häufig Lastprognosen zum Einsatz, die anhand von historischen Energie-daten Vorhersagen über den zukünftigen Energieverbrauch treffen können. Diese Prognosen können wiederum für eine effektivere Planung des Energieverbrauchs und die Umsetzung der oben genannten Ziele genutzt werden [6]. Sowohl in der wissenschaftlichen Literatur als auch in der Praxis werden meistens

die Verbräuche am Hauptzähler auf Werksebene genutzt, da dies dem Standard in der Kommunikation mit dem Energieversorger entspricht [7].

Nichtsdestotrotz werden mit dem Aufkommen der Digitalisierung und der zunehmenden Vernetzung von Maschinen- und Stromdaten mittels hochauflösenden Energiezählern (Smart Meter) auf verschiedenen Ebenen feingranulare Daten erfasst. Ein Potenzial zu Prognoseverbesserung liegt in der Integration und Modellierung verschiedener Lastverbrauchsquellen auf unterschiedlichen Aggregationsebenen zur Berechnung der sogenannten Bottom-Up-Prognose, als Forschungsteilgebiet des Hierarchical Load Forecastings (HLF).

Dieser Beitrag untersucht das Potenzial zur Verbesserung der Prognosegüte mittels Bottom-Up-Ansatz. Dazu wird die Modellierung auf aggregierten Energieverbrauchsdaten dem Bottom-Up-Ansatz und einem kombinierten Modell gegenübergestellt. Es wird untersucht, ob sich der Prognosefehler unter Einbezug der Topologie verringern lässt und welchen Trainingsmehraufwand damit verbunden ist. Es soll die Tauglichkeit der Ansätze mit Realdaten von produzierenden Unternehmen analysiert werden. Als Einstieg wird die Bottom-Up-Prognose thematisch in das HLF-Framework eingebettet, dessen Vor- und Nachteile genannt sowie der Stand der Technik wiedergegeben (Kapitel 2), bevor in Kapitel 3 und 4 ein Vergleichsaufbau vorgestellt und auf Lastgangsdaten dreier deutscher Unternehmen aus dem Mittelstand evaluiert wird. Der letzte Abschnitt rundet den Beitrag mit der Diskussion der Ergebnisse und einem Ausblick thematisch ab.

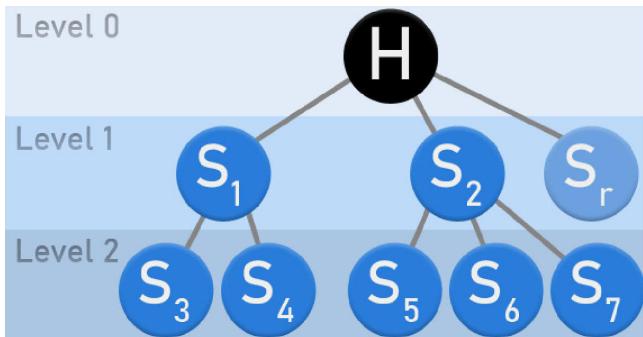


Bild 1. Hauptmesszähler mit zwei Kindern S_1 und S_2 sowie einem virtuellen Residual-Zähler S_r . *Grafik: Fraunhofer IPA*

1.1 Hierarchical Load Forecasting (HLF)

HLF zielt darauf ab, die Prognosen auf unterschiedlichen Ebenen zu modellieren [8, 9]. Es kann so beispielsweise, neben der Modellierung des Hauptzählers eines Unternehmens, die Topologie der Untermesszähler zur Prognosberechnung von einzelnen Werken, Hallen, Teilabschnitten, Maschinengruppen oder energieintensiven Einzelmaschinen genutzt werden [10].

In diesem Kontext besteht eine Topologie aus einem Hauptmesszähler und einer bestimmten Menge an Untermesszählern, die wiederum disjunkte Bereiche abbilden. Die Anzahl an Ebenen mit Untermesszählern ist dabei nicht auf eine Stufe begrenzt. Das heißt, Untermesszähler können auch Zähler von Untermesszählern auf einer höheren Ebene sein. Die Summe der elektrischen Lastgänge, der niedrigeren Ebene muss dabei stets mit der höheren Ebene übereinstimmen. Ist dies nicht der Fall, beispielsweise verursacht durch Bezugsverluste oder nicht gemessene Teilabschnitte in der Produktion, kann die Topologie durch Einfügen von (virtuellen) Residualzählern modelliert werden, die genau die Energiedifferenz ausgleicht. Eine beispielhafte Topologie ist in **Bild 1** dargestellt.

HLF unterscheidet zwischen drei Prognoseszenarien. Bei der Top-Down-Prognose werden Prognosen auf höheren Leveln berechnet, indem zuerst eine Prognose für den Hauptzähler erstellt wird, und die Lastverläufe der Unterzähler durch ein anteiliges Aufteilen der Hauptprognose entsteht. Bei der Bottom-Up-Prognose wird die Prognose des Hauptzählers durch die Aggregation von Prognosen von Untermesszählern höheren Levels bestimmt. Werden sowohl Prognosen für Messzähler höherer und niedrigerer Level aus Messzählern von dazwischenliegenden Leveln berechnet, spricht man von Middle-Out-Prognosen [8]. Für die Modellierung des Hauptzählerlastgangs werden Prognosen am Knoten der Topologie benötigt. Die Summation der Bottom-Up-Prognose approximiert diesen Knoten ebenfalls.

Tabelle 1. Chancen und Risiken.

Chancen	Herausforderungen
<ul style="list-style-type: none"> - Individuelle Einbindung von Features möglich - Zusammenfassen von Messzähler derselben Domäne zur besseren Prognose möglich 	<ul style="list-style-type: none"> - Höherer Trainingsaufwand und Datenaustausch - Aggregation von Prognosefehler möglich - Höheres Investment für Untermesszähler-Installation - Zunehmende Verringerung des Portfolio-Effekts

1.2 Bottom-Up-Prognose: Chancen und Herausforderungen

Die Integration der Messzähler-Topologie zur Prognose des Hauptzählerlastverlaufs bietet gegenüber der üblichen Hauptzähler-Modellierung entscheidende Vorteile. Die Trennung in mehrere Modelle erlaubt es, dass jedes mit anderen Features trainiert werden kann, sodass beispielsweise unterschiedliche Untermesszählermodelle spezifische Wettervariablen oder Produktionsplanungsdaten erhalten, angepasst an örtliche oder logistische Bereiche. Zudem können diese Modelle besser an die spezifischen Lasten angepasst werden [11, 12]. Im Unternehmenskontext weisen die Unternehmensbereiche, zusammengefasst durch je einen Zähler, typischerweise unterschiedliche Variablenabhängigkeiten auf. Im Falle eines Untermesszählers für ein Lagergebäude und ein weiterer für eine Halle mit Schmelzöfen sind folgende Abhängigkeiten denkbar: Während der Lagerhallen-Lastverlauf keine Wetterabhängigkeiten unterliegt, hängt der Lastbedarf für Schmelzöfen stark von Wetterverlauf, Außentemperatur und Jahreszeit ab.

Den Vorteilen gegenüber ist der Trainingsaufwand für mehrere Modelle signifikant höherer als der für einen einzelnen. Außerdem ist bei der Anschaffung, Installation, Wartung und Datenspeicherung der zusätzlich benötigten Submeter mit höheren Kosten zu rechnen. Hinzu kommt, dass stochastische Einflüsse auf Hauptzählerebene durch Aggregation gedämpft werden [13], was sich mit dem Portfolio-Effekt erklären lässt [14]. Da jedes Modell nur eine Approximation der Realität darstellt, treten bei jeder Instanz Modellierungsfehler auf. Es ist unklar, ob sich bei der Vielzahl der Modelle im Falle von Bottom-Up-Prognosefehler bei Aggregieren aufsummieren.

Tabelle 1 fasst die Chancen und Herausforderungen noch einmal übersichtlich zusammen.

2 Stand der Technik

Dieses Kapitel gibt einen kurzen Überblick über den Einsatzhorizont hierarchischer Lastprognosen, mit einem Fokus auf Bottom-Up-Methoden.

Einen wesentlichen Beitrag zur Forschung von hierarchischen Methoden wurde durch die Global Energy Forecasting Competitions 2012 und 2017 geleistet, in denen von mehreren Hundert Teilnehmern HLF-Algorithmen zur Lastprognose entwickelt wurden [5, 6].

Zheng et al. [15] verbessern die kurzfristige Lastprognose für Haushalte mithilfe eines Bottom-up-Ansatzes, indem Vorhersagen niedriger Granularität (Geräte-, Raum-, Haushaltsebene) integriert werden.

In [16] wird mittels eines Bottom-Up-Ansatzes die Verteilung von elektrischen Lasten des Hochspannungsbereichs aus Prognosen auf Substationen mit Mittelspannung prognostiziert.

In ihrer Dissertation [17] stellt *Walther* eine Architektur vor, die es erlaubt, historische Informationen und Informationen über

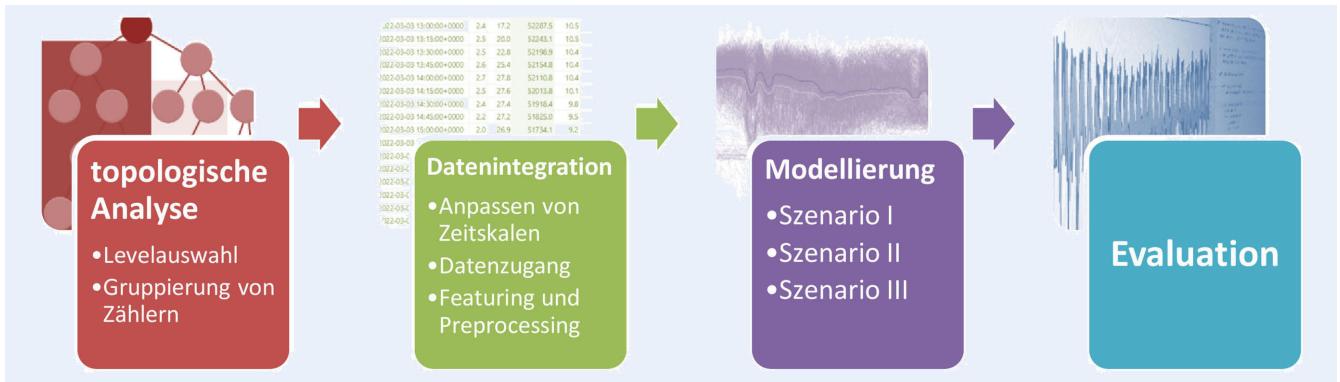


Bild 2. Methodisches Vorgehen des Modellvergleichs. Grafik: Fraunhofer IPA

den Prognosehorizont in den Modellierungsprozess zu integrieren. Hier führt die hierarchische Struktur zu einer Verbesserung der Prognose.

Zhao et al. [18] erweitern den HLF-Ansatz um probabilistische Prognosen, also die Berechnung von Vorhersagen als Lastintervallen statt Kurve, und erhalten durch Integration einer Topologie ein Verfahren mit höherer Vorhersagegenauigkeit.

3 Methode

In diesem Abschnitt wird das methodische Vorgehen für den systematischen Vergleich der Prognoseverfahren beschrieben. Das Ziel der hier betrachteten Prognose ist die Vorhersage des elektrischen Lastgangs für den folgenden Tag auf Hauptzähler-Ebene.

Im Falle von Bottom-Up wird die Prognose aus der Summe von Untermesszähler-Prognosen berechnet. Für die Wahl der Untermesszähler gibt es mehrere Möglichkeiten. Es kann je eine Prognose für die direkten Untermesszähler des Hauptmesszählers berechnet werden, oder je eine Prognose der Untermesszähler dieser Untermesszähler und so weiter. Ebenfalls ist eine Mischform denkbar, indem nur einzelne Unterzähler weiter aufgeteilt werden, andere jedoch keine Verfeinerung erfahren. Das Finden dieser Zähler-Teilmenge bildet den ersten Schritt, dem die Datenintegration, die Modellierung und die Evaluation folgt. Bild 2 zeigt das methodische Vorgehen im Überblick, das im Folgenden im Detail beschrieben wird.

3.1 Messtopologie Analyse

Typischerweise werden Messzähler an organisatorisch-logischen Verteilerstellen (etwa Hallen, Hallenabschnitte, Transformationsstationen oder Maschinen(gruppen) mit hohem Verbrauch) angebracht, da deren Nutzen so maximiert und der Energiefluss möglichst transparent wird. Zu Beginn wird die Zusammensetzung und Charakteristiken der Messzählertopologie untersucht, um eine Gruppierung der Untermesszähler zu extrahieren, die in die Modellierung miteinbezogen werden sollen.

Dazu wird im ersten Schritt ein Level festgelegt, auf dem Messzähler einbezogen werden, beispielsweise, falls verfügbar, Zählerdaten auf Transformatorm-, Werks-, Hallen-, Maschinengruppen- oder Einzelmaschinenebene. Die Wahl des Levels ist von der Tiefe und Granularität der Topologie abhängig und kann als Metaparameter aufgefasst werden, das experimentell und iterativ gefunden werden kann. Alternativ können, sofern die Granularität in einzelnen Zweigen signifikant voneinander

abweicht, Zähler unterschiedlicher Level zusammengefasst werden. Ein Zusammenfassen ist zu empfehlen, wenn die Messzeitreihen einzelner Unterzähler ähnliche Lastgänge aufzeigen oder nicht signifikant zur gesamten Last beitragen. Als ein Maß der Ähnlichkeit dient das errechnete Standardlastprofil und verwandte Distanzmetriken. Ein Beispiel zur Zusammenfassung findet sich in Bild 3, in dem Gruppen mit gleichem Verbrauchsmuster (hier: Maschinen mit gleicher Aufgabe und Verwaltungstrakte ähnlicher Arbeitsweisen) oder marginalen Beträgen (hier: Verbraucher mit geringen Einflüssen oder Grundrauschen) zusammengefasst werden.

Nach Abschluss der Analyse liegt eine Liste an Untermesszählergruppen vor, die zur weiteren Datenaufbereitung verwendet wird.

3.2 Datenintegration

Ziel der Datenintegration ist es, einen Datensatz für die anschließende Modellierung der zusammengefassten Topologie zu erzeugen. Dazu werden alle Messzählerdatenreihen geladen und, falls erforderlich, mittels zeitlichen Angleichens (resampling) oder Interpolation auf eine gemeinsame äquidistante Abtastrate gebracht. Anschließend werden die Datenreihen für jede Gruppe aggregiert und es entsteht für jede Gruppe (siehe Bild 3b) eine Zeitreihe. Zusätzlich wird eine Residualzeitreihe berechnet, die sich aus der Differenz der Hauptzählerzeitreihe mit der Summe aller Gruppendatenreihen bildet. Nach dem Hinzufügen von weiteren Features wie beispielsweise Wetter- und Kalenderinformationen werden die Zeitreihen für die Modellierung in Trainings- und Testdaten aufgeteilt.

3.3 Modellierung und Evaluation

Für einen systematischen Methodenvergleich werden drei Szenarien modelliert und validiert. Diese werden im Folgenden vorgestellt. Bild 4 zeigt sie schematisch.

In Szenario I wird als Referenz die Prognose nur auf Grundlage des Hauptmesszählers modelliert. Dazu wird im klassischen Sinne eine Prognose des Gesamtlastgangs berechnet. Dies entspricht der Sicht des Netzbetreibers ohne Einbezug der Messzählertopologie.

In Szenario II wird zu jedem der Untermesszählergruppen eine Prognose erstellt. Anschließend wird die Zielprognose auf Hauptzählerlevel durch Aggregation der einzelnen Prognosen der Untermesszähler berechnet.

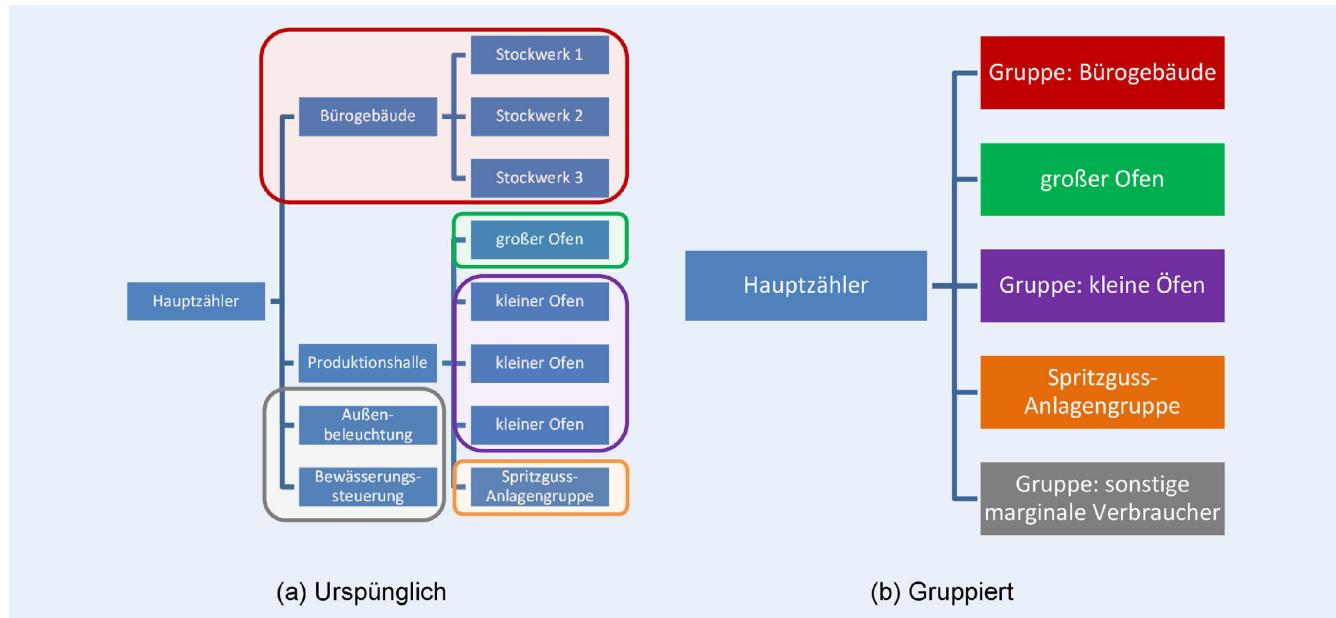


Bild 3. Gruppieren einer Topologie mit drei Leveln. Grafik: Fraunhofer IPA

Tabelle 2. Charakterisierung der Unternehmen.

Gewerbe	Datenzeiträume				zeitl. Auflösung	Last (kW)			Zusammengefasste Messzähler-Topologie		
	Training		Test			ø	min	max	# Zähler	Gruppiert nach	
	von	bis	von	bis							
A	Metallverarbeitung, Gehäusebau	03/2021	03/2022	08/2022	15 min	134	-149	340	1 + 6	Hallen, PV-Anlage, Prozessschritt	
B	Ventilator-/Lüfterräder- Herstellung	09/2020	03/2022	08/2022	15 min	241	0	569	1 + 9	Werk, Hallen, Maschinengruppe	
C	Präzisionsteile/Automobil- zulieferer	09/2020	03/2022	08/2022	15 min	6436	0	11779	1 + 3	Hallen	

In Szenario III wird nur ein Modell trainiert, das – analog zum ersten Fall – ebenfalls direkt die Hauptzählerprognose berechnet. Das Modell erhält die jedoch zusätzlich die Messreihen von Szenario II. Nach der Wahl einer geeigneten Metrik werden die Modelle der drei Szenarien mit den Trainingsdaten trainiert und auf den Testdaten evaluiert.

4 Validierung

4.1 Unternehmensbeschreibung und Parameter

Die in Kapitel 3 vorgeschlagene Methodik wurde mit Daten von drei deutschen Unternehmen (KMU) aus dem produzierenden Gewerbe evaluiert. Eine Beschreibung der Unternehmen sowie deren Topologie und Gruppierung lässt sich der Tabelle 2 entnehmen.

Zur Validierung der Methode wurden in der Literatur etablierte Modelle verwendet: Lineare Regression und Lasso-Regression, Random Forest, Decision Tree Regressor, Mutilayer Perceptron und Support Vector Regressor [19]. Zum Trainieren und Finden des jeweils besten Modells pro Modellklasse wurde das Hyperparametertuning mittels Grid Search und 5-Fold Cross Validation [20] durchgeführt. Der Mean Absolute Error (MAE) wurde als Evaluationsmetrik gewählt, da er gut interpretierbar

und im Kontext der Lastprognoseforschung weit verbreitet ist [21]. Für die zwei Vektoren Referenz-Testdaten y und Prognose \hat{y} ist diese wie folgt definiert:

$$MAE(y, \hat{y}) = \frac{1}{|y|} \sum_{i=1}^{|y|} |y_i - \hat{y}_i|.$$

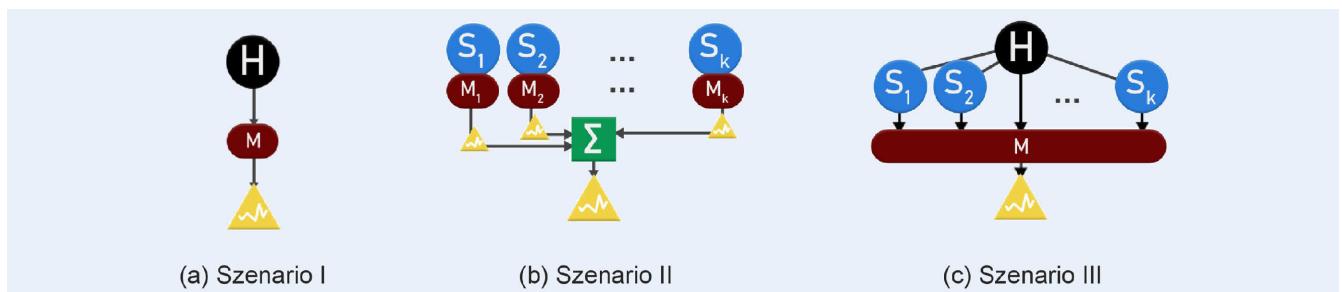
Die beliebte relative Metrik MAPE [21] konnte nicht berechnet werden, da einzelne Referenzwerte null sind, was eine Division unmöglich macht. Als Features wurden neben Kalenderinformationen und Wetterdaten Lasten mit Zeitrückstand (*lags* [22]) des Vortrags und der Vorwoche angefügt.

4.2 Ergebnisse

Die Ergebnisse der Experimente in den drei im vorangegangenen Kapitel beschriebenen Unternehmen sind Tabelle 3 zu entnehmen: Jeweils in grün hervorgehoben sind jene Szenarien, die für das jeweilige Modell je Unternehmen den geringsten Fehler aufwiesen. Zusätzlich fett markiert sind die Modelle, die über alle Szenarien hinweg für jedes Unternehmen das beste Ergebnis lieferten. Die schlechtesten Werte pro Unternehmen sind unterstrichen.

Tabelle 3. Prognosefehler (MAE) in kW für jedes Modell, und Trainingszeiten in Stunden für jedes der drei Unternehmen.

	Unternehmen A			Unternehmen B			Unternehmen C		
	Szenario I	Szenario II	Szenario III	Szenario I	Szenario II	Szenario III	Szenario I	Szenario II	Szenario III
LR	34,7	33,7	32,3	50,0	51,2	48,3	1390,1	1404,8	1374,9
Lasso	30,3	27,7	27,1	49,9	50,5	48,1	1339,2	1362,2	1329,3
Random Forest	24,0	23,3	23,2	37,9	35,1	39,7	1045,5	974,1	974,4
Decision Tree	28,7	24,3	27,3	39,3	36,3	41,7	1099,3	1000,6	1065,0
MLP	34,5	34,6	34,1	66,4	67,2	55,7	1247,6	1214,6	1161,1
SVR	28,5	26,2	25,9	48,8	48,5	43,2	1786,3	1568,0	1223,2
Trainingszeit	0:21h	4:52h	0:27h	00:49h	15:23h	1:33h	0:34h	1:54h	0:42h

**Bild 4.** Schematische Darstellung der untersuchten Szenarien (Hauptmeter in schwarz, Submeter blau, Modelle rot, Aggregator grün, Prognose gelb).
Grafik: Fraunhofer IPA

Szenario I (ohne Einbezug der Topologie) lieferte in allen 18 Durchgängen (drei Unternehmen, sechs Modelle) einen höheren Prognosefehler als das jeweils bessere Modell der Szenarien 2 oder 3 (mit Einbezug der Topologie). In zwölf von 18 Fällen für Szenario II und in 16 von 18 Fällen für Szenario III lieferte Szenario I eine schlechtere Prognose. Die Fehlerreduktion des jeweils besten Modells aus Szenario II und III gegenüber dem besten Modell aus Szenario I beträgt bei A 3,2 %, bei B 7,3 % und bei C 6,8 %.

In allen drei Unternehmen konnte der insgesamt beste Wert mit dem Modell *Random Forest* erreicht werden, davon einmal in Szenario II und zweimal in Szenario III.

Die Trainingszeiten liegen zwischen 21 Minuten und 923 Minuten, abhängig von Trainingsdatensatzgröße, Unternehmen und Anzahl einbezogener Untermesszähler. In allen Unternehmen war die Trainingszeit für Szenario I am kürzesten und Szenario II am längsten. Dies lässt sich durch die Datensatzgröße und die Anzahl der zu trainierenden Modelle erklären. Die Trainingszeiten von Szenarien III liegen für Unternehmen A um Faktor 1,3 für B um 1,9 beziehungsweise für C um 1,2 über denen von Szenario I.

5 Zusammenfassung und Ausblick

Die Lastprognose ist eine zentrale Komponente der unternehmensstrategischen Planung und Entscheidungsfindung. Durch die Reduktion des Prognosefehlers und die damit verbundene nachhaltige Verringerung von Fehlentscheidungen entsteht ein Wettbewerbsvorteil für Unternehmen.

Eine Möglichkeit der Lastprognoseverbesserung ist das Integrieren von Daten einer Messzählerarchitektur, wie es in den Methoden des Hierarchical Load Forecasting und damit insbesondere bei Bottom-Up-Prognosen Einsatz findet.

In diesem Beitrag wurde der Hauptzählerprognoseansatz (Szenario I) mit zwei Ansätzen mit Integration zusätzlicher Messzählerreihen verglichen. Dazu wurden zusätzlich ein einfacher Bottom-Up-Ansatz (Szenario II) und ein weiteres Modell implementiert, das – im Gegensatz zu Szenario II – lediglich eine Prognose berechnet, als Input aber ebenfalls die historischen Messzählerdaten erhält (Szenario III). Validiert wurde das Vorgehen auf realen Verbrauchsdaten dreier mittelständischer industrieller Unternehmen.

Basierend auf den gemessenen Ergebnissen lässt sich festhalten, dass sich das Einbeziehen der Messzählerarchitektur in allen 18 Fällen gelohnt hat. In 12 beziehungsweise 16 von 18 Fällen war der Fehler geringer durch Einsatz der Architektur aus Szenarien II beziehungsweise III gegenüber der Hauptzählermodellierung. Es konnte eine durchschnittliche Fehlerreduktion zwischen 3,2 % und 7,3 % gegenüber der Szenario I-Modellierung bei den drei Unternehmen gemessen werden. Mit Ausnahme von fünf der 18 Fälle war es ausreichend, das Modell aus Szenario III gegenüber dem Multi-Modell-Aufbau (Szenario II), das deutlich höhere Trainingsaufwand voraussetzt, zu verwenden. Die Trainingszeiten von Szenario I und III unterscheiden sich um Faktor 1,2 bis 1,9, die Trainingszeiten von Szenario II skalieren in etwa linear in der Anzahl der verwendeten Untermesszähler.

Die Arbeiten mit den Daten der Unternehmen haben weitere Fragen aufgeworfen, die es lohnt, in weitergehenden Arbeiten zu untersuchen. Es ist unklar, wie viele Untermesszähler zur Modellierung herangezogen werden sollen und wie die Wahl der Zählerzusammenfassung aus Abschnitt 3 sich auf den Prognosefehler auswirken. Zudem könnte eine statistische Analyse der Prognosen im Falle der Bottom-Up-Prognose interessante Erkenntnisse für die Unternehmen liefern, welche Untermesszähler einen positiven beziehungsweise negativen Beitrag zur Prognosefehlerreduktion liefern.

FÖRDERHINWEIS

Diese Arbeit wird vom Bundesministerium für Wirtschaft und Energie im Rahmen des Projekts „GalN-Gewinnbringende Partizipation der mittelständischen Industrie am Energiemarkt der Zukunft“ gefördert. Wir danken dem Projektpartner für das Bereitstellen der Daten.

L iteratur

- [1] BDEW Bundesverband der Energie- und Wasserwirtschaft e.V.: Konjunktur und Energieverbrauch. Internet: <https://www.bdew.de>. Zugriff am 06.10.2022
- [2] Roesch, M.; Bauer, D.; Haupt, L. et al.: Harnessing the Full Potential of Industrial Demand-Side Flexibility: An End-to-End Approach Connecting Machines with Markets through Service-Oriented IT Platforms. *Applied Sciences* 9 (2019) 18, S. 3796
- [3] Sauer, A.; Abele, E.; Buhl, H. U. (Hrsg.): Energieflexibilität in der deutschen Industrie. Ergebnisse aus dem Kopernikus-Projekt – Synchronisierte und energieadaptive Produktionstechnik zur flexiblen Ausrichtung von Industrieprozessen auf eine fluktuierende Energieversorgung (SynErgie). Stuttgart: Fraunhofer Verlag 2019
- [4] Tristán, A.; Heuberger, F.; Sauer, A.: A Methodology to Systematically Identify and Characterize Energy Flexibility Measures in Industrial Systems. *Energies* 13 (2020) 22, pp. 5887
- [5] Verein Deutscher Ingenieure e.V.: 5207. VDI 5207 Blatt 1 – Energieflexible Fabrik. Berlin: Beuth 2020–07
- [6] Rikin Patel; Mihir R Patel; Ravi V Patel: A Review: Introduction and Understanding of Load Forecasting. *Journal of Applied Science and Computations* (2019) 4
- [7] Walser, T.; Sauer, A.: Typical load profile-supported convolutional neural network for short-term load forecasting in the industrial sector. *Energy and AI* 5 (2021), pp. 100–104
- [8] Zhang, C.; Li, R.: A Novel Closed-Loop Clustering Algorithm for Hierarchical Load Forecasting. *IEEE Transactions on Smart Grid* 12 (2021) 1, pp. 432–441
- [9] Hong, T.; Fan, S.: Probabilistic electric load forecasting: A tutorial review. *International Journal of Forecasting* 32 (2016) 3, S. 914–938
- [10] Hong, T.; Xie, J.; Black, J.: Global energy forecasting competition 2017: Hierarchical probabilistic load forecasting. *International Journal of Forecasting* 35 (2019) 4, pp. 1389–1399
- [11] Wang, S.; Deng, X.; Chen, H. et al.: A bottom-up short-term residential load forecasting approach based on appliance characteristic analysis and multi-task learning. *Electric Power Systems Research* 196 (2021), pp. 107233
- [12] Böhner, J.; Scholz, M.; Franke, J. et al.: Integrating digitization technologies into resource efficiency driven industrial learning environments. *Procedia Manufacturing* 23 (2018), pp. 39–44
- [13] Peng, Y.; Wang, Y.; Lu, X. et al.: Short-term Load Forecasting at Different Aggregation Levels with Predictability Analysis. *2019 IEEE Innovative Smart Grid Technologies – Asia (ISGT Asia)*, Chengdu, China, 2019, pp. 3385–3390
- [14] Autoren von enargus.de: Portfolioeffekt. Internet: https://www.enargus.de/pub/bscw.cgi/d8808-2/*/*/Portfolioeffekt.html?op=Wiki.getwiki. Zugriff am 31.08.2022
- [15] Zheng, Z.; Chen, H.; Luo, X.: A Kalman filter-based bottom-up approach for household short-term load forecast. *Applied Energy* 250 (2019), pp. 882–894
- [16] Jiang, Z.; Wu, H.; Zhu, B. et al.: A Bottom-up Method for Probabilistic Short-Term Load Forecasting Based on Medium Voltage Load Patterns. *IEEE Access* 9 (2021), pp. 76551–76563
- [17] Walther, J.: Hierarchical Electrical Load Forecasting of Industrial Production Systems in the Manufacturing Industry based on Deep Learning, UNSPECIFIED, 2022
- [18] Zhao, T.; Wang, J.; Zhang, Y.: Day-Ahead Hierarchical Probabilistic Load Forecasting With Linear Quantile Regression and Empirical Copulas. *IEEE Access* 7 (2019), S. 80969–80979
- [19] Walser, T.; Reisinger, M.; Hartmann, N.; Dierolf, C.; Sauer, A.: Readiness of Short-term Load Forecasting Methods for their Deployment on Company Level. *Proceedings of GSM 2020* (2020), pp. 89–103
- [20] Fushiki, T.: Estimation of prediction error by using K-fold cross-validation. *Statistics and Computing* 21 (2011) 2, pp. 137–146
- [21] vom Scheidt, F.; Medinová, H.; Ludwig, N. et al.: Data analytics in the electricity sector – A quantitative and qualitative literature review. *Energy and AI* 1 (2020), S. 100009
- [22] Kaymakci, C.; Walser, T.; Sauer, A.: Benchmark von Lastprognosemethoden. *wt Werkstattstechnik online* 112 (2022) 1–2, Düsseldorf: Springer Fachmedien, S. 2–8, Internet: www.werkstattstechnik.de



L u k a s B a u r , M. Sc.
Foto: Fraunhofer IPA, Rainzer Bez

C a n K a y m a k c i, M. Sc.

Prof. Dr.-Ing. Dipl.-Kfm. **A l e x a n d e r S a u e r**

Fraunhofer-Institut für Produktionstechnik
und Automatisierung IPA
Institut für Energieeffizienz in der Produktion (EEP)
der Universität Stuttgart
Nobelstr. 12, 70569 Stuttgart
Tel. +49 711 / 970-1479
lukas.baur@ipa.fraunhofer.de
www.ipa.fraunhofer.de

L I Z E N Z



Dieser Fachaufsatzz steht unter der Lizenz Creative Commons
Namensnennung 4.0 International (CC BY 4.0)