

VALIDIERUNG VON HEURISTISCHEN UND KI-BASIERTEN ANSÄTZEN ZUR PROGNOSÉ VON LASTVERLÄUFEN ANHAND VON INDUSTRIEUNTERNEHMEN

Malte Schneidewind¹, Julian Hoevelmann², Jens Haubrock³

Abstract 1

Stationäre Batteriespeicher können in verschiedensten Betriebsführungsstrategien betrieben werden. Um das Speichersystem möglichst effizient mit dem höchsten wirtschaftlichen Output zu betreiben, werden mehrere Strategien parallel verfolgt. Damit zu jedem Zeitpunkt die Strategie mit dem höchsten Potential bedient werden kann, bedarf es Vorhersagen der für die Betriebsführung relevanten Zustände. Bei dem Betrieb von Speichersystemen an Co-Location Standorten Behind-the-meter [1], ist die Lastprognose neben der Prognose der Erzeugungsanlagen essenziell für die Parametrierung des Systems. Dafür werden verschiedene Vorgehen zur Lastprognose an einem Pool von Industrielastgängen getestet. Es handelt sich dabei um verschiedene Unternehmen des produzierenden Gewerbes, die in ihrer Größe und damit auch der Bezugsleistung variieren.

Verglichen werden im Rahmen dieser Forschung heuristische und ki-basierte Ansätze. Die Überlegungen der heuristischen Ansätze basieren auf den wiederkehrenden Verläufen der Lastgänge. Die Wochenmusterprognose stellt den ersten und einfachsten Ansatz dar. In diesem Fall entspricht der aktuelle Wochentag dem Wochentag der vorherigen Woche.

$$D_{d,t} = \widehat{D_{d,t}}$$

Weil sich die Wochentage maßgeblich in ihrer Charakteristik unterscheiden, unterscheidet auch die Wochenmusterprognose zwischen den Tagen. Vor allem Wochenenden und Feiertage weichen signifikant von Werktagen ab.

Aufgrund der direkten Abhängigkeit von der Charakteristik des Tages der vorherigen Woche, ist dieser Ansatz nur bedingt für die Vorhersage geeignet. Der nächste Ansatz basiert auf der Wochenmusterprognose. Beim Mean-Forecast wird der Mittelwert aus allen historischen Wochentagen gebildet, die für diesen Tag in dem vergangenen Profil bereits existieren.

$$D_{d,t} = \frac{1}{n_{d,t}} \sum_{i=1}^{n_{d,t}} U_{i,d,t}$$

Die Bildung des Mittelwertes über alle vorhandenen Wochentage des historischen Lastgangs hat zur Folge, dass saisonale Änderungen des Profils geglättet werden. Genauso werden Änderungen der grundsätzlichen Charakteristik des Profils nur anteilig in die Vorhersage aufgenommen. Für einen Industrielastgang könnte dies beispielsweise eine Änderung im Produktionsverhalten aufgrund der Auftragslage oder die Anschaffung einer neuen Maschine bzw.

¹ Denios SE, Dehmer Straße 54-66 32549 Bad Oeynhausen, malte.schneidewind@hsbi.de

² Hochschule Bielefeld, Interaktion 1 33619 Bielefeld, julian.hoevelmann@hsbi.de

³ Hochschule Bielefeld, Interaktion 1 33619 Bielefeld, jens.haubrock@hsbi.de

Erweiterung der Produktion darstellen. Auf dieser Überlegung basiert die dritte Ausbaustufe der Wochenmusterprognose.

Die gewichtete Wochenmusterprognose stellt den dritten Ansatz der Heuristik dar. Dabei wird ebenfalls ein Mittelwert aus den historischen Wochentagen gebildet. Allerdings werden die Tage absteigend vom aktuellen Zeitraum gewichtet.

$$w_i = \begin{cases} 1 + 0.15 \left(6 - \frac{\Delta_i}{7} \right), & \text{für } \Delta_i \leq 42 \text{ Tage (letzte 6 Wochen),} \\ 1, & \text{für } \Delta_i > 42 \text{ Tage (ältere Daten).} \end{cases}$$

Der Gewichtungsfaktor, wie in 3 dargestellt, gewichtet die vergangenen Wochen maximal mit dem Faktor 1,9. Von da fällt der Faktor bis zur sechsten Woche linear bis auf 1,15 ab. Ab der siebten Woche werden alle weiteren Wochen mit dem Faktor 1 gleich gewichtet.

Den heuristischen Ansätzen steht ein Ansatz, der sich dem maschinellen Lernen bedient, gegenüber. Zum Einsatz kommt in diesem Fall Catboost. Der Algorithmus nutzt ein Konstrukt aus vielen kleinen Entscheidungsbäumen. Als Trainingsdaten kann dem Algorithmus alles zur Verfügung gestellt werden, was einen Einfluss auf das Ergebnis haben könnte. Innerhalb des Trainings werden kleinste Abhängigkeiten erkannt und in den einzelnen Entscheidungsbäumen für die Lösung berücksichtigt [2]. Neben den Lastgängen wird der Algorithmus mit Wetterdaten gefüttert. Dabei werden nicht nur Temperatur und Einstrahlung, sondern auch Daten wie Luftfeuchtigkeit berücksichtigt [3, 4].

Tabelle 1: Genauigkeit $nRMSE_{peak}$

Modell	Januar	Juli	November	Mittelwert
Wochenmusterprognose	0,0980	0,1287	0,1207	0,1158
Mean Forecast	0,1336	0,1218	0,1152	0,1235
Gewichtete Prognose	0,0924	0,1190	0,1060	0,1058
CatBoost	0,0984	0,1068	0,1044	0,1032

Tabelle 1 zeigt die Genauigkeit der verschiedenen Ansätze bezogen auf die Vorhersage der Lastgänge. Dafür werden jeweils drei Wochen aus den Trainingsdaten entfernt, die entsprechend nicht dem Training zur Verfügung stehen und anschließend für die Validierung einer Vorhersage genutzt werden können. Catboost schneidet in der Gesamtbetrachtung am besten ab. Die gewichtete Wochenmusterprognose kommt sehr nah an den ki-basierten Ansatz heran. Im Januar schneidet sie sogar besser als der Catboost Algorithmus.

References

- [1] S. Englberger, H. Hesse, N. Hanselmann, and A. Jossen, "SimSES Multi-Use: A simulation tool for multiple storage system applications," pp. 1–5, doi: 10.1109/EEM.2019.8916568.
- [2] DataScientest, *CatBoost: Das Must-Have im Machine Learning*. [Online]. Available: <https://datascientest.com/de/catboost-das-must-have-im-machine-learning> (accessed: Jul. 2 2025).
- [3] L. Zhang and D. Jánošík, "Enhanced short-term load forecasting with hybrid machine learning models: CatBoost and XGBoost approaches," *Expert Systems with Applications*, vol. 241, p. 122686, 2024, doi: 10.1016/j.eswa.2023.122686.
- [4] L. Zhang, Y. Chen, and Z. Yan, "Predicting the short-term electricity demand based on the weather variables using a hybrid CatBoost-PPSO model," *Journal of Building Engineering*, vol. 71, p. 106432, 2023, doi: 10.1016/j.jobe.2023.106432.