

Forecast of electricity demand and load peaks in the distribution network with LSTM and Transformer architectures

Elena Giacomazzi

17. Januar 2023

Strombedarfsprognosen sind ein wesentlicher Bestandteil der Strom- und Energiewirtschaft und die Grundlage für die Planung und den Betrieb von Stromsystemen [Hong et al., 2020]. Sie tragen dazu bei, Stromsysteme effizient zu betreiben und diese anpassungsfähiger für die Nutzung von erneuerbaren Energien zu machen. Besonders wichtig sind sie geworden seit der aufkommenden Diskussion bezüglich der Sanktionen der Europäischen Union (EU) gegen Russland [Pfister, 2022]. Versorger und Unternehmen der Energiewirtschaft müssen ihre Entscheidungen über den Einkauf oder die Erzeugung von elektrischer Energie auf Prognosen stützen [Borkovski et al., 2019].

In dieser Arbeit werden die Vorhersagen eines neuronalen Netzes mit Langzeit-Kurzzeitgedächtnis (LSTM), eines ursprünglichen Transformer-Modells und des Temporal Fusion Transformer (TFT) auf einen stündlichen Day-Ahead- und Week-Ahead-Prognosehorizont bewertet. Die Arbeit leistet einen Beitrag zur aktuellen Literatur, indem sie Transformer-basierte Architekturen auf kurzfristige Lastprognosen anwendet, die in diesem Bereich relativ neu sind. Im Bereich der kurzfristigen Lastbedarfsprognose hat bisher nur Zhao et al. [2021] Transformers angewendet. Eine Forschungshypothese ist, dass die Prognosen der Transformer-basierenden Architekturen präziser sind als die des LSTMs. Diese Hypothese beruht darauf, dass Transformers mit einem Mechanismus namens Self-Attention arbeiten, der die zeitlichen Abhängigkeiten seiner Eingaben noch besser lernt als LSTMs [Vaswani et al., 2017].

Für das Tunen der Deep-Learning Modelle wurde eine aufwendige Hyperparametersuche mit Hilfe der Machine Learning Plattform *Weights and Biases* [Biewald, 2020] durchgeführt. Die Performanz der Vorhersagen der verschiedenen Modelle werden anhand verschiedener Accuracy Methoden, wie zum Beispiel dem mittleren absoluten prozentualen Fehler und der mittleren quadratischen Abweichung, verglichen und ausgewertet. Zusätzlich werden die Modelle auf ihre Genauigkeit bei der Vorhersage von Lastspitzen untersucht. Für die Definition von Lastspitzen wird das 95%-Perzentil, das über eine Woche berechnet wird, als Schwellenwert verwendet.

Die *Stadtwerke Haßfurt*¹, ein regionaler Stromversorger in Deutschland, stellt die zugrundeliegenden Daten zur Verfügung, die für diese Arbeit verwendet werden. Der Datensatz besteht aus stündlichen Smart-Meter-Lastdaten auf Haushaltsebene, welche für die Prognose auf die Ebene des Verteilungsnetzes aggregiert wurden. Sie umfassen den Zeitraum zwischen Januar 2019 und Oktober 2021. Für

¹<https://www.stwhas.de/>

eine bessere Prognose wurden die Daten mit Features wie der stündlichen Temperatur und Kalenderdaten, wie ob ein Wochentag, Wochenendtag oder Feiertag vorliegt, angereichert.

Diese Arbeit zeigt, dass die LSTM-Architektur für den Day-Ahead-Horizont mit MAPE = 6,09% am besten abschneidet, während die TFT-Architektur für die Wochenprognose mit MAPE = 6,46% am besten abschneidet. Die Leistungen der Modelle zeigt eine enttäuschende Leistung bei der Bewertung der Lastspitzen. Alle Modelle unterschätzen den Strombedarf während der Lastspitzenzeiten stark. Es wird deutlich, dass es wahrscheinlich hilfreich ist, ein Modell speziell für die Vorhersage von Lastspitzen zu trainieren, da die für eine genaue, generelle Vorhersage trainierten Modelle die kritischen Punkte der Lastspitzen nicht präzise abdecken.

Limitationen wie die fehlende Vergleichbarkeit der Datensätze, die Verwendung von skalenabhängigen Metriken, die Übereinstimmung von Datengranularität der Vorhersage und ihre Fenstergröße, machen es schwer die vorliegenden Ergebnisse mit anderen Arbeiten zu vergleichen. Hinzukommend schwankt der häusliche Energiebedarf im vorliegenden Datenset, da es den Zeitraum von der Covid-19 Pandemie und damit zusammenhängende Lockdowns enthält. Obwohl die Ergebnisse den Wert moderner Deep-Learning-Methoden für die Lastprognose demonstrieren, sind weitere Arbeiten notwendig, um die Methoden an anderen Datensätzen zu validieren.

Literatur

Biewald, L. (2020). Experiment tracking with weights and biases. Software available from wandb.com.

Borkovski, S., Petkoski, S., and Erkechova, M. (2019). Electricity consumption forecasting using recurrent neural network: Electrical trade market study. page 8.

Hong, T., Pinson, P., Wang, Y., Weron, R., Yang, D., and Zareipour, H. (2020). Energy Forecasting: A Review and Outlook. *IEEE Open Access Journal of Power and Energy*, 7.

Pfister, S. (2022). Energieversorgung in Europa - Was ein Ölembargo gegen Russland für Deutschland bedeutet.

Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, L., and Polosukhin, I. (2017). Attention Is All You Need. *arXiv:1706.03762 [cs]*. arXiv: 1706.03762.

Zhao, Z., Xia, C., Chi, L., Chang, X., Li, W., Yang, T., and Zomaya, A. Y. (2021). Short-Term Load Forecasting Based on the Transformer Model. *Information*, 12(12):516.