

Vergleich unterschiedlicher Methoden zur Strompreisvorhersage in Energiesystemmodellen

Energiesystem- und Klimamodellierung
Felix NITSCH^{1(*)}, Christoph SCHIMECZEK¹

⁽¹⁾ Deutsches Zentrum für Luft- und Raumfahrt,
Institut für Vernetzte Energiesysteme, Energiesystemanalyse,
Curiestr. 4, 70563 Stuttgart

Motivation und zentrale Fragestellung

Die agentenbasierte Modellierung (ABM) ist besonders für Untersuchungen der Energiemärkte geeignet: einerseits kann das Verhalten heterogener Akteure abgebildet werden und andererseits Emergenzen, welche durch das Zusammenspiel von Politikinstrumenten, Marktteilnehmenden und unterschiedlichen Zielfunktionen entstehen, analysiert werden [1, 2, 3]. Einzelentscheidungen haben Einfluss auf das Zusammenspiel der Akteure und erzeugen unter Umständen Rückkopplungen [4]. Damit Flexibilitätsanbieter wie z. B. Stromspeicher ihre Handelsentscheidungen im Modell treffen können, benötigen sie eine Preisvorhersage. Diese müssen modellendogen bestimmt werden und möglichst konsistent sein. Wir untersuchen daher unterschiedliche Methoden der Strompreisvorhersage zur Anwendung innerhalb von Strommarktsimulationen.

Methodische Vorgangsweise

Die Vorhersage von Zeitreihen ist ein intensiv untersuchtes Problem. Insbesondere Preiszeitreihen werden mehr und mehr betrachtet [5]. Neben der Qualität der Eingangsdaten ist die Wahl des entsprechenden Vorhersagemodells von großer Bedeutung. Wir untersuchen unterschiedliche Gruppen an Vorhersagemodellen. Das Ziel ist die Beurteilung deren Eignung zum Einsatz in einem ABM. Neben einem robusten Vorhersagefehler ist die Laufzeit des Vorhersagemodells eine zentrale Größe. Im Idealfall wirken sich die Laufzeiten des Prognosemodells nicht auf die Laufzeiten des Strommarktsimulationsmodells aus, liegen also im Bereich von unter einer Millisekunde pro Vorhersage, und weisen für eine Vielzahl simulierter Eingangsparameter ähnliche Fehlermaße auf.

Wir analysieren historische Preiszeitreihen der Jahre 2002 bis 2019 und vergleichen diese mit simulierten Preiszeitreihen, welche mit dem ABM AMIRIS [6] berechnet wurden. Mit unterschiedlichen Methoden werden Strompreise für die nachfolgenden 24 Stunden vorhergesagt. Zum Einsatz kommen naive Persistenzprognosen (z. B. t+1 und t+24 Vorhersagen), bewährte Methoden zur Zeitreihenvorhersage (z. B. Exponential Smoothing [7], LightGBM [8]), sowie aktuellste Machine-Learning (ML) Architekturen (z. B. DeepAR [9], N-Beats [10], Temporal Fusion Transformers [11]). Zum Schluss erfolgt eine Bewertung hinsichtlich der Einsatzmöglichkeiten in Strommarktmodellen bzw. Energiesystemmodellen im Allgemeinen.

Ergebnisse und Schlussfolgerungen

Die vorläufigen Ergebnisse werden mit verschiedenen Fehlermaßen, z. B. symmetric mean absolute percentage error (sMAPE), über die verstrichene Rechenzeit analysiert. Es zeigt sich, dass die Performance zwischen den eingesetzten Methoden stark variiert. Wenig überraschend sind naive Methoden am schnellsten zu berechnen, während das Training für ML Architekturen am rechenintensivsten ist. Hinsichtlich des Fehlermaßes zeigt die Berechnung mittels LightGBM vielversprechende Ergebnisse. Die Streuung der Fehler über die Zeit ist vor allem durch das typische Strompreismuster mit tendenziell höheren Preisen an Werktagen und niedrigeren Preisen an Wochenenden und Feiertagen zu erklären. Eine Auswertung für einzelne Wochentage und Tagesstunden bestätigt diese Vermutung. Die aktuellen Zwischenergebnisse werden noch ohne die Berücksichtigung von Kovariaten wie zum Beispiel (residuale) Last oder Kalenderinformation berechnet. Durch Berücksichtigung dieser Daten ist insbesondere für die umfangreicheren ML-Modelle eine signifikante Verbesserung der Ergebnisse zu erwarten. Wie in anderen Studien [12] zu ähnlichen Zeitreihenvorhersageproblemen demonstriert, könnten Verbesserungen durch den kombinierten Einsatz von Vorhersagemodellen (Ensembletechnik) erzielt werden. Vertiefte Untersuchung zu diesem Thema und die Anwendung der Ergebnisse in AMIRIS werden im aktuell laufenden Projekt FEAT (FKZ: 01IS22073B), welches vom deutschen Bundesministerium für Bildung und Forschung gefördert wird, behandelt.

¹ Kontakt: +49 711 6862- 8865, Felix.Nitsch@dlr.de, www.DLR.de

Literatur

- [1] Nitsch F, Deissenroth-Uhrig M, Schimeczek C, Bertsch V. Economic evaluation of battery storage systems bidding on day-ahead and automatic frequency restoration reserves markets. *Applied Energy* 2021;298:117267.
- [2] Ringler P, Keles D, Fichtner W. Agent-based modelling and simulation of smart electricity grids and markets – A literature review. *Renewable and Sustainable Energy Reviews* 2016;57:205–15.
- [3] Deissenroth-Uhrig M, Klein M, Nienhaus K, Reeg M. Assessing the Plurality of Actors and Policy Interactions: Agent-Based Modelling of Renewable Energy Market Integration. *Complexity* 2017;2017.
- [4] Frey UJ, Klein M, Nienhaus K, Schimeczek C. Self-Reinforcing Electricity Price Dynamics under the Variable Market Premium Scheme. *Energies* 2020;13(20).
- [5] Fraunholz C, Kraft E, Keles D, Fichtner W. Advanced price forecasting in agent-based electricity market simulation. *Applied Energy* 2021;290:116688.
- [6] Nienhaus K, Reeg M, Roloff N, Deissenroth-Uhrig M, Klein M, Schimeczek C et al. AMIRIS. Agent-based Market model for the Investigation of Renewable and Integrated energy Systems.: <https://gitlab.com/dlr-ve/esy/amiris/amiris>. GitLab 2021.
- [7] Gardner ES. Exponential smoothing: The state of the art. *J. Forecast.* 1985;4(1):1–28.
- [8] Ke, Guolin and Meng, Qi and Finley, Thomas and Wang, Taifeng and Chen, Wei and Ma, Weidong and Ye, Qiwei and Liu, Tie-Yan. LightGBM: A highly efficient gradient boosting decision tree. *Advances in Neural Information Processing Systems*;2017(30).
- [9] Salinas D, Flunkert V, Gasthaus J, Januschowski T. DeepAR: Probabilistic forecasting with autoregressive recurrent networks. *International Journal of Forecasting* 2020;36(3):1181–91.
- [10] Oreshkin BN, Carпов D, Chapados N, Bengio Y. N-BEATS: Neural basis expansion analysis for interpretable time series forecasting; 2019.
- [11] Lim B, Arık SÖ, Loeff N, Pfister T. Temporal fusion transformers for interpretable multi-horizon time series forecasting. *International Journal of Forecasting* 2021.
- [12] Galicia A, Talavera-Llames R, Troncoso A, Koprinska I, Martínez-Álvarez F. Multi-step forecasting for big data time series based on ensemble learning. *Knowledge-Based Systems* 2019;163:830–41.