

KI-gestützte Prognose von PV-Erzeugungsdaten für Erneuerbare Energiegemeinschaften

Karina Medwenitsch, Forschung Burgenland GmbH

Abstract. Zur Erreichung der österreichischen Klimaziele ist ein Übergang von fossilen Brennstoffen zu erneuerbaren Energiequellen notwendig. Erneuerbare Energiegemeinschaften (EEGs) bieten die Möglichkeit, selbst erzeugten Strom zu nutzen und zu handeln. Die volatile Natur erneuerbarer Energiequellen, insbesondere von Photovoltaikanlagen (PV), führt jedoch zu Netzüberlastungen und teurem Strombezug. Das Ziel dieser Arbeit ist die Entwicklung eines Prognosemodells für eine EEG, um PV-Erzeugungsdaten vorherzusagen und in weiterer Folge Lastspitzen zu verschieben. Eine Literaturanalyse zeigt, dass KI-gestützte Modelle wie LSTM-Netzwerke in der Prognose von PV-Erzeugungsdaten oft präzise Ergebnisse liefern. Lineare Regressionsmodelle, trainiert mit Machine Learning Algorithmen, finden diesbezüglich ebenfalls Einsatz in der Literatur. Es ist keine eindeutig beste Methode auszumachen, jedoch werden aufgrund ihrer Anpassungsfähigkeit LSTM-Netzwerke für derartige Prognosemodelle empfohlen. Zukünftige Arbeiten könnten sich auf die Implementierung von KI-gestützten Prognosemodellen konzentrieren, um die Flexibilität und Effizienz von EEGs zu verbessern und Netzüberlastung zu vermeiden.

Keywords: Prognosemodelle, EEG, Neuronale Netze, PV-Energie, LSTMs

1 EINLEITUNG

Zur Erreichung der von der österreichischen Bundesregierung vorgegebenen Klimaziele ist ein Umstieg von Energieproduktion aus fossilen Brennstoffen auf erneuerbare Energiequellen notwendig [1]. Neben dem „großen Ganzen“, auf dessen Klimastrategie einzelne Bürger:innen wenig Einfluss haben, kann auch auf Haushaltsebene erneuerbarer Strom produziert werden, z.B. in Form von Photovoltaik (PV)-Anlagen. Zusätzlich bietet das Betreiben von PV-Anlagen die Möglichkeit, den erzeugten Strom selbst zu verwenden und daraus einen wirtschaftlichen Nutzen zu ziehen. Um diesbezüglich nicht nur auf die eigene Produktion beschränkt zu sein, bieten sich Erneuerbare Energiegemeinschaften (EEGs) an. Dies sind lokale Zusammenschlüsse mehrerer Haushalte, Gemeinde- und/oder Industriebetriebe, die über erneuerbare Stromerzeugungsanlagen verfügen und den daraus generierten Strom innerhalb der EEG zu günstigen Preisen handeln können [2].

Da erneuerbare Energiequellen, darunter auch PV-Anlagen, jedoch eine volatile Charakteristik in der Stromerzeugung aufzeigen, ergeben sich folgende Problemstellungen: Einerseits kommt es an sonnigen Tagen zu einer Überlastung der Netzstruktur, wenn alle PV-Anlagen innerhalb der EEG gleichzeitig Strom produzieren und ins lokale Netz einspeisen, andererseits winken in Zeiten der Unterdeckung hohe Stromkosten, wenn Strom vom Netzbetreiber bezogen werden muss, um den Energiebedarf zu decken [3].

Aus dieser Problematik ergibt sich die Notwendigkeit, die Spitzenlasten in der PV-Produktion zu verschieben, um sowohl der Überlastung des Stromnetzes als auch dem teuren Strombezug entgegenzuwirken. Während mithilfe von Home Energy Management Systems (HEMS) PV-Produktionsdaten in Echtzeit übermittelt und infolgedessen beispielweise einer gleichzeitigen Einspeisung aller PV-Anlagen an einem sonnigen Tag entgegenwirken können, stehen ohne diese Systeme die Produktionsdaten der jeweiligen PV-Anlage meist erst am nächsten Tag zur Verfügung. Um dennoch die Flexibilität innerhalb der EEG nutzen zu können, können auf Basis von historischen Daten Prognosemodelle entwickelt werden, die die Energieerzeugungscharakteristik für den kommenden Tag vorhersehen können. Mithilfe dieser Lastprofile können auch ohne HEMS vorab Maßnahmen getroffen werden, um eine Spitzenverschiebung der Energieproduktion aus den Solaranlagen der EEG zu erzielen.

Ziel der Arbeit ist es, ein Prognosemodell für eine EEG zu entwickeln, das eine Prognose der PV-Erzeugungsdaten für den darauffolgenden Tag liefert. Anhand der erhaltenen Lastprofile können mithilfe bewusst gesetzter Maßnahmen seitens der Mitglieder der EEG, wie z.B. Ein- bzw. Ausschalten der PV-Anlage oder gezielte Nutzung des aktuell produzierten Stroms, Spitzenlasten verschoben werden. Dies trägt zur Stabilisierung des Netzes bei und bietet durch die Reduktion von bezogenem Strom vom Netzbetreiber einen wirtschaftlichen Vorteil für die Mitglieder der EEG.

Aus der geschilderten Problematik sowie Zielsetzung ergeben sich die folgenden Forschungsfragen, die im Rahmen dieser Arbeit beantwortet werden sollen:

F1: Welche Methoden eignen sich für Prognosen von Energieerzeugungsdaten der PV-Anlagen einer Erneuerbaren Energiegemeinschaft?

F2: Welche Metriken eignen sich zur Beurteilung der Prognosegenauigkeit dieser Methoden?

2 METHODIK

Diese Arbeit soll auf Basis einer Literaturrecherche aufzeigen, welche Methoden sich für die Prognose von Energieerzeugungsdaten von PV-Anlagen eignen, welche Modelle in dieser Hinsicht bereits entwickelt und implementiert wurden sowie die Möglichkeiten zur Beurteilung der Prognosegenauigkeit dieser Modelle.

Im Rahmen zukünftiger Arbeiten besteht die Bestrebung, diesbezüglich eine Case Study durchzuführen. Auf Basis dieser Rechercharbeit soll folglich ein Modell für eine konkrete EEG ausgewählt sowie umgesetzt werden. Dieses Prognosemodell soll die bereits vorhandenen PV-Produktionsdaten der EEG als Basis verwenden und die Lastprofile für den darauffolgenden Tag prognostizieren. Daraufhin sollen die prognostizierten Werte mit den Realwerten verglichen sowie die Prognosegenauigkeit des Modells mithilfe der vorab festgelegten Validierungskriterien ermittelt werden.

3 ERGEBNISSE

KI-basierte Methoden für Prognosemodelle von Zeitreihendaten wie PV-Erzeugungsdaten sind vor allem in der Literatur der letzten Jahre allgegenwärtig und erzielen in den meisten Fällen weitaus genauere Prognoseergebnisse im Vergleich zu rein statistischen Methoden. Unter den in diesem Zusammenhang verwendeten Methoden wurden unter anderem KI-gestützte lineare Regressionsmodelle eingesetzt. Neben der Verwendung einer reinen linearen Regression wurden auch autoregressive Modelle eingesetzt [7] sowie alle diese Modelle zusätzlich mit diversen Lernalgorithmen trainiert. Beispielsweise wurden Entscheidungsbäume, sogenannte Decision Trees [4], [5], [6], wie auch der Random Forest Algorithmus [6], [7], eine Weiterentwicklung der Decision Tree Methodik, mit einem linearen Regressionsmodell kombiniert. Darüber hinaus kamen unter anderem auch Gradient Boosting bzw. XGBoost und Support Vector Machine [5], [6], eine Gaußprozess-Regression [4] sowie ein Grey Wolf Optimizer Modell [5] zum Einsatz.

Im Zuge der Literaturrecherche kristallisierte sich heraus, dass bei der Prognose von Zeitreihendaten neben KI-gestützten linearen Regressionsmodellen großteils künstliche neuronale Netze (ANNs) zum Einsatz kommen. Die am meisten verwendeten ANNs darunter sind Multi Layer Perceptrons (MLPs), Feed Forward Neural Networks (FFNNs), Radial Basis Function Neural Networks (RBFNNs), Back Propagation Neural Networks (BPNNs) und Long Short-Term Memories (LSTMs) [8].

FFNNs bezeichnet ANNs, in denen sich die Informationen nur in eine Richtung, nämlich von der Eingabe- zur Ausgabeschicht bewegen, da keine zyklische Verarbeitung der Informationen notwendig ist. FFNNs wurden bereits mehrmals für Prognosen von

Zeitreihendaten im Energiebereich herangezogen [5] [6]. MLPs gehören zu den FFNNs und bezeichnen vorwärtsgerichtete ANNs, die aus einer Eingabeschicht, einer oder mehreren „versteckten“ informationsverarbeitenden Schichten, sogenannten Hidden Layers, und einer Ausgabeschicht bestehen [8]. Im Kontext der Prognose von Energieproduktionsdaten konnte der Einsatz von einem Modell basierend auf einem MLP mit einer Hidden Layer [11] sowie ein MLP kombiniert mit Support Vector Machine und Particle Swarm Optimization [12] verzeichnet werden. RBFNNs werden unter anderem für die Prognose von Sonneneinstrahlung verwendet und eignen sich ebenfalls zur PV-Produktionsprognose, da sie über eine einfache Struktur verfügen [7] [8]. Des Weiteren geht aus der Literatur hervor, dass RBFNNs verglichen mit FFNNs über eine geringere Fehleranfälligkeit verfügen [13]. BPNNs sind aufgrund der nicht-linearen Abbildungsfunktion ebenfalls geeignet für den Einsatz als Lösung komplexer Regressionsmodelle, wie beispielweise der Prognose von Zeitreihendaten [15], [16].

LSTMs sind eine Art rekurrenter neuronaler Netzwerke (RNNs), bei denen im Gegensatz zu FFNNs die Informationen nicht nur in eine Richtung verarbeitet, sondern auch Ergebnisse aus vorherigen Verarbeitungsschritten miteinbezogen werden. LSTMs wurden erstmals von Hochreiter und Schmidhuber beschrieben [17]. Sie verfügen über sogenannte „Gates“, die die Informationen ihrer Bedeutung nach klassifizieren und dafür sorgen, dass sie entweder beibehalten oder vergessen werden. Demnach bestimmt das Forget Gate, welche Informationen aus dem Zellzustand entfernt werden, das Input Gate entscheidet über das Hinzufügen neuer Informationen und das Output Gate sorgt für die Auswahl der für die Ausgabe verwendeten Informationen. LSTMs wurden in zahlreichen Arbeiten zur Prognose von Energieerzeugungs- und Temperaturdaten eingesetzt und schnitten im Vergleich zu anderen Methoden oft besser ab [6], [8], [18], [19], [20].

Gütekriterium	Häufigkeit
MAE	7
RMSE	6
MSE	6
MAPE	6
nRMSE	5

Tabelle 1: Übersicht über am häufigsten eingesetzte Gütekriterien in der untersuchten Literatur inkl. deren absoluter Häufigkeit

In Bezug auf die Validierungskriterien für die Prognoseergebnisse der diversen Modelle wurden in allen Fällen Metriken verwendet, die eine Art Berechnung unter Einbeziehung der prognostizierten und der zugehörigen realen Energiedatenwerte abbilden. Die in dieser Hinsicht am häufigsten in der untersuchten Literatur vertretenen Gütekriterien sind die Metriken des mittleren absoluten Fehlers (Mean Absolute Error - MAE), der Wurzel des mittleren quadrierten Fehlers (Root Mean Squared Error - RMSE), des mittleren quadrierten Fehlers (Mean Squared Error - MSE), des mittleren absoluten prozentualen Fehlers (Mean Absolute Percentage Error - MAPE) sowie des normalisierten RMSE (nRMSE). Ein Auszug der diesbezüglich erhobenen Daten inklusive der absoluten Häufigkeit der eingesetzten Metriken in der untersuchten Literatur ist in Tabelle 1

dargestellt.

Zur Einordnung der Modellgüte der in der Literatur verwendeten KI-basierten Prognosemodelle wurden deren Bewertungen anhand der Gütekriterien RMSE, MAPE sowie nRMSE herangezogen, da sämtliche Modelle zumindest über eine dieser Metriken validiert wurden. Tabelle 2 bietet eine Übersicht über die Evaluierung der untersuchten Modelle.

Basis Lineare Regressionsmodelle				
Quelle	Modellmethode	RMSE	MAPE	nRMSE
Khandakar et al. [4]	Gaußprozess-Regression	12,7144	-	-
Houben et al. [7]	autoregressives Modell mit XGBoost	-	0,138	0,0187
Abu-Salih et al. [6]	Gradient Boost Tree	8,275	-	-
ANNs				
Quelle	Modellmethode	RMSE	MAPE	nRMSE
Khandakar et al. [4]	ANN	2,1436	-	-
Abu-Salih et al. [6]	LSTM	-	-	0,5654
Liu et al. [8]	LSTM	-	-	0,497
Alam et al. [20]	LSTM	-	0,21784	-
Tomar et al. [21]	FCNN	-	0,108595 (Winter), 0,134669 (Sommer)	-
Boum et al. [12]	MLP + SVM + PSO	3,8693	0,0332	-
Tavares et al. [11]	MLP (1 Hidden Layer)	-	-	0,06213
Theocharides et al. [22]	ANN + Post-Processing	-	0,047	0,0611

Tabelle 2: Übersicht über untersuchte Prognosemodelle inkl. zugehöriger Bewertung der Prognoseergebnisse

Wie den Ergebnissen zu entnehmen ist, variieren die berechneten Werte für MSE, RMSE und nRMSE stark. Dadurch gestaltet sich der Vergleich der dargelegten Ergebnisse schwierig, da für jede Modellentwicklung unterschiedliche Algorithmen verwendet wurden, und selbst bei Einsatz derselben Methode bestehen Unterschiede zwischen den

verwendeten Parametern und Inputdaten der Modelle. Jedenfalls ist anzumerken, dass die in Tabelle 2 dargestellten Modelle jeweils die am besten bewerteten Modelle in den Kategorien lineare Regressionsmodelle und ANNs der jeweiligen Autor:innen sind, falls diese mehrere Methoden zur Prognose der Energieerzeugungsdaten einsetzten.

4 SCHLUSSFOLGERUNGEN UND AUSBLICK

Schlussfolgernd kann gesagt werden, dass keine eindeutige Aussage über ein generelles bestes Prognosemodell bzw. eine beste Methode zur Prognose von Energieerzeugungsdaten in Energiegemeinschaften getroffen werden kann. Dennoch sollten aufgrund ihrer Häufigkeit in der Literatur der letzten Jahre sowie ihrer hohen Anpassungsfähigkeit LSTMs bei der Modellierung von Prognosemodellen für PV-Erzeugungsdaten in Betracht gezogen werden. Da jedoch auch andere Methoden, wie beispielweise jene basierend auf linearen Regressionsmodellen und erweitert durch Machine Learning Techniken, nicht als optimale Algorithmen ausgeschlossen werden können, empfiehlt sich bei der Modellierung derartiger Prognosemodelle für konkrete EEGs eine Entscheidung anhand der Charakteristiken der jeweiligen EEG.

Aufbauend auf diese Arbeit soll ein Konzept für die Umsetzung eines KI-gestützten Prognosemodells für eine konkrete EEG entwickelt werden. Mithilfe dieses Prognosemodells sollen in weiterer Folge die Erzeugungsleistung der PV-Anlagen innerhalb der EEG prognostiziert werden. Dies soll maßgeblich dazu beitragen, die Flexibilitäten innerhalb der Energiegemeinschaft besser zu nutzen sowie einer Überlastung des Netzes und dem Bezug teuren Stroms vom Netzbetreiber entgegenzuwirken.

5 REFERENZEN

- [1] „Nachhaltige Klimaschutz-Maßnahmen“. Zugegriffen: 19. Januar 2024. [Online]. Verfügbar unter: https://www.bmk.gv.at/themen/klima_umwelt/agenda2030/bericht-2020/nachhaltigkeit.html
- [2] „Erneuerbare-Energie-Gemeinschaften (EEG) – Energiegemeinschaften“. Zugegriffen: 19. Januar 2024. [Online]. Verfügbar unter: <https://energiegemeinschaften.gv.at/erneuerbare-energie-gemeinschaften-eeg/>
- [3] B. Wimmer, „Wie zu viel Solarstrom Österreichs Netze belastet“. Zugegriffen: 19. Januar 2024. [Online]. Verfügbar unter: <https://futurezone.at/digital-life/strom-evn-netzbetreiber-apg-noe-erneuerbare-energien-stau-verstopfung-solarstrom-photovoltaik/402601493>
- [4] A. Khandakar u. a., „Machine Learning Based Photovoltaics (PV) Power Prediction Using Different Environmental Parameters of Qatar“, *Energies*, Bd. 12, Nr. 14, S. 2782, 2019, doi: 10.3390/en12142782.
- [5] M. Alaraj, A. Kumar, I. Alsaidan, M. Rizwan, und M. Jamil, „Energy Production Forecasting From Solar Photovoltaic Plants Based on Meteorological Parameters for Qassim Region, Saudi Arabia“, *IEEE Access*, Bd. 9, S. 83241–83251, 2021, doi: 10.1109/access.2021.3087345.
- [6] B. Abu-Salih, P. Wongthongtham, G. Morrison, K. Coutinho, M. Al-Okaily, und A. Huneiti, „Short-term renewable energy consumption and generation forecasting: A case study of Western Australia“, *Heliyon*, Bd. 8, Nr. 3, S. e09152, März 2022, doi: 10.1016/j.heliyon.2022.e09152.
- [7] N. Houben u. a., „Optimal dispatch of a multi-energy system microgrid under uncertainty: A renewable energy community in Austria“, *Appl. Energy*, Bd. 337, S. 1–23, Mai 2023, doi: 10.1016/j.apenergy.2023.120913.
- [8] C.-H. Liu, J.-C. Gu, und M.-T. Yang, „A Simplified LSTM Neural Networks for One Day-Ahead Solar Power Forecasting“, *IEEE Access*, Bd. 9, S. 17174–17195, 2021, doi: 10.1109/ACCESS.2021.3053638.
- [9] A. Elamim, B. Hartiti, A. Barhdadi, A. Haibaoui, L. Abderrazak, und P. Thevenin, „Photovoltaic output power forecast using artificial neural networks“, *J. Theor. Appl. Inf. Technol.*, Bd. 96, S. 5116–5126, Aug. 2018.
- [10] S. P. Durrani, S. Balluff, L. Wurzer, und S. Krauter, „Photovoltaic yield prediction using an irradiance forecast model based on multiple neural networks“, *J. Mod. Power Syst. Clean Energy*, Bd. 6, Nr. 2, S. 255–267, März 2018, doi: 10.1007/s40565-018-0393-5.
- [11] I. Tavares u. a., „Comparison of PV Power Generation Forecasting in a Residential Building using ANN and DNN“, *IFAC-Pap.*, Bd. 55, Nr. 9, S. 291–296, 2022, doi: 10.1016/j.ifacol.2022.07.051.
- [12] A. T. Boum, V. J. Foba Kakeu, C. F. Mbey, und F. G. Yem Souhe, „Photovoltaic Power Generation Forecasting Using a Novel Hybrid Intelligent Model in Smart Grid“, *Comput. Intell. Neurosci.*, Bd. 2022, S. 1–13, Okt. 2022, doi: 10.1155/2022/7495548.
- [13] A. Yona, T. Senjyu, und T. Funabashi, „Application of Recurrent Neural Network to Short-Term-Ahead Generating Power Forecasting for Photovoltaic System“, in *2007 IEEE Power Engineering Society General Meeting*, Juni 2007, S. 1–6. doi: 10.1109/PES.2007.386072.
- [14] M. Benghanem und A. Mellit, „Radial Basis Function Network-based prediction of global solar radiation data: Application for sizing of a stand-alone photovoltaic system at Al-Madinah, Saudi Arabia“, *Energy*, Bd. 35, Nr. 9, S. 3751–3762, Sep. 2010, doi: 10.1016/j.energy.2010.05.024.
- [15] A. S. und Y. Zhang, „A Review on Back-Propagation Neural Networks in the Application of Remote Sensing Image Classification“, *J. Earth Sci. Eng.*, Bd. 5, Jan. 2015, doi: 10.17265/2159-581X/2015.01.004.
- [16] R. Srivastava, A. Tiwari, und V. Giri, „Forecasting of Solar Radiation in India Using Various ANN Models“, Nov. 2018, S. 1–6. doi: 10.1109/UPCON.2018.8597170.

- [17] S. Hochreiter und J. Schmidhuber, „Long Short-Term Memory“, *Neural Comput.*, Bd. 9, Nr. 8, S. 1735–1780, Nov. 1997, doi: 10.1162/neco.1997.9.8.1735.
- [18] M. Gao, J. Li, F. Hong, und D. Long, „Day-ahead power forecasting in a large-scale photovoltaic plant based on weather classification using LSTM“, *Energy*, Bd. 187, Nr. C, 2019, Zugegriffen: 22. Januar 2024. [Online]. Verfügbar unter:
<https://ideas.repec.org//a/eee/energy/v187y2019ics0360544219315105.html>
- [19] S. Srivastava und S. Lessmann, „A comparative study of LSTM neural networks in forecasting day-ahead global horizontal irradiance with satellite data“, *Sol. Energy*, Bd. 162, S. 232–247, März 2018, doi: 10.1016/j.solener.2018.01.005.
- [20] Md. M. Alam, Md. H. Rahman, Md. F. Ahmed, M. Z. Chowdhury, und Y. M. Jang, „Deep learning based optimal energy management for photovoltaic and battery energy storage integrated home micro-grid system“, *Sci. Rep.*, Bd. 12, Nr. 1, S. 15133, Sep. 2022, doi: 10.1038/s41598-022-19147-y.
- [21] A. Tomar, D. S. Shafiullah, P. H. Nguyen, und M. Eijgelaar, „An integrated flexibility optimizer for economic gains of local energy communities—A case study for a University campus“, *Sustain. Energy Grids Netw.*, Bd. 27, S. 100518, 2021.
- [22] S. Theocharides, G. Makrides, A. Livera, M. Theristis, P. Kaimakis, und G. E. Georghiou, „Day-ahead photovoltaic power production forecasting methodology based on machine learning and statistical post-processing“, *Appl. Energy*, Bd. 268, S. 115023, Juni 2020, doi: 10.1016/j.apenergy.2020.115023.