

PROGNOSEMODELL EINER PV-ANLAGE BASIEREND AUF EINEM KURZZEITMESSSYSTEM, WETTERDATEN UND MACHINE-LEARNING VERFAHREN

Marta Sophia POTYKA¹, Hannes SEEFLUTH¹, Prof. Peter SCHEGNER¹

Inhalt

Aufgrund des steigenden Umweltbewusstseins der Bevölkerung werden vermehrt dezentrale und zumeist regenerative Energieerzeugungsanlagen errichtet. Um eine hohe Versorgungszuverlässigkeit weiterhin gewährleisten zu können, ist es unerlässlich, volatile Erzeuger so genau wie möglich zu prognostizieren. Ebenso kann der Betreiber dieser die Prognosen für sein Energiemanagement und die bestmögliche ökonomische Verwertung nutzen. Hierfür wird ein Prognosemodell für PV-Anlagen erstellt, dessen Eingangsparameter sich aus wenigen Wochen Messdaten der erzeugten, elektrischen Leistung und Wetterdaten zusammensetzen. Gängige physikalische Modelle bilden meist nur lineare Zusammenhänge ab, wohingegen Machine-Learning-Verfahren auch nichtlineare Verhältnisse erlernen können. Daher werden verschiedene Arten dieser auf ihre Eignung für die genannte Problemstellung untersucht.

Methodik

Im Paper werden zunächst potenzielle Eingangsparameter identifiziert. Das Prognosemodell soll nur diejenigen Wetterdaten heranziehen, zu denen ein physikalischer Zusammenhang besteht. Beispielsweise setzt sich die elektrische Leistung der PV-Module $P_{PV\ DC}$ aus dem Produkt von dem Strom $I_{PV\ DC}$ und der Spannung $U_{PV\ DC}$ zusammen. Dieser Strom ist maßgeblich abhängig von dem photogenerierten Strom I_{photo} (siehe Gleichung (1)) und dem Diodenstrom I_{Diode} (siehe Gleichung (2)). G steht dabei für die Bestrahlungsstärke, α für den Temperaturkoeffizienten, T_Z die Zelltemperatur, I_{T0} den temperaturabhängigen Sperrstrom, e die Elementarladung, n den Idealitätsfaktor und k_B die Boltzmann-Konstante. Der Index STC kennzeichnet die Standard-Testbedingungen und K den Kurzschluss. Ausgehend von diesen Gleichungen werden die Wetterparameter Globalstrahlung, Umgebungstemperatur und die Windgeschwindigkeit als potentielle Einflussparameter für die Prognose herangezogen. Die Umgebungstemperatur und die Windgeschwindigkeit beeinflussen dabei die Zelltemperatur.

$$I_{photo} = \frac{G}{G_{STC}} \cdot (I_{K\ STC} + \alpha_{K\ STC} \cdot (T_Z - T_{Z\ STC})) \quad (1) [1]$$

$$I_{Diode} = I_{T0} \cdot \left(\exp\left(\frac{e \cdot U_{Diode}}{n \cdot k_B \cdot T_Z}\right) - 1 \right) \quad (2) [1]$$

Als nächstes werden geeignete Machine-Learning-Verfahren untersucht. Jedes dieser Verfahren wird mit der Potenzmenge der möglichen Eingangsparameter trainiert und getestet.

Ergebnisse

Nach eingehender Analyse wurden die multiple lineare Regression, polynomiale Regression, Support-Vector-Regression und k-nächste Nachbarn als Verfahren ausgewählt. Die Prognoseergebnisse werden mittels des auf die Maximalleistung bezogenen MAE miteinander verglichen. Das beste Modell wird an einem Prognosedatensatz evaluiert und adaptierbar für andere PV-Anlagen gestaltet.

Die Langfassung des Papers wird die entwickelten Modelle detaillierter vorstellen und die resultierenden Prognoseergebnisse bewerten.

¹ TU Dresden, Mommsenstraße 10 01069 Dresden, +49 351 463-43203, marta_sophia.potyka@tu-dresden.de, <https://tu-dresden.de/ing/elektrotechnik/ieeh/ev/die-professur>

Referenzen

- [1] N. Kaushika, A. Mishra, und A. K. Rai, "Solar Photovoltaics Technology, System Design, Reliability and Viability," Springer Verlag, 2018, <https://katalog.slub-dresden.de/id/0-1654952753> (Aufgerufen 08. November 2021)