

MENSCHLICHES WISSEN UND KÜNSTLICHE INTELLIGENZ IN EINEM PROGNOSEMODELL FÜR ERNEUERBARE ENERGIEN

Alexander WALLIS¹, Alfons HABER², Sascha HAUKE³

Einleitung

Ein aktives Mitwirken an den Klimazielen ist ein wichtiger Beitrag, es geht darum, hier mit dem Tun die erforderlichen Schritte zu setzen. So baut das „*Clean Energy for all Europeans Package*“ der Europäischen Kommission auf einen unverzüglichen Ausbau von erneuerbaren Energiequellen [1]. Die Rahmenbedingungen in Deutschland und auch in Europa führen zu einem Paradigmenwechsel in der Integration von Erzeugungs- und Speicheranlagen in das Stromnetz. Die Aggregation und Steuerung der jeweiligen Teilnehmer führt zu einem Komplexitätsanstieg innerhalb des Netzes, den es über Expertenwissen, sprich menschlicher Intelligenz zu lösen gilt. Verschiedene Ansätze befassen sich mit strenger Überwachung und schneller Steuerung, um einen stabilen Betrieb zu gewährleisten [2]. Insbesondere die Integration von unterschiedlichen erneuerbaren, volatilen Energiequellen baut auf eine solide Produktionsvorhersage, um die einhergehenden Fluktuationen zu bewältigen. Auf Basis einer soliden Vorhersage können im Folgenden z.B. Betriebsstrategien für ein Heimspeichersystem anhand dynamischer Randbedingungen optimiert werden [3]. Im Rahmen dieser Arbeit wird ein datengetriebener Ansatz mit Hilfe von Methoden des *maschinellen Lernens*, einem Teilgebiet der *Künstlichen Intelligenz* (KI), für die Vorhersage des Stromverbrauchs einer Forschungseinrichtung sowohl vorgestellt als auch untersucht und anschließend mit state-of-the-art Methoden verglichen.

Methodik

Bisherige Forschungsarbeiten im Bereich Verbrauchsvorhersage können grob in die folgenden zwei Kategorien unterteilt werden: *konventionelle Methoden* und auf *Künstliche Intelligenz basierende Methoden* (KI) [4]. Zudem erfolgt eine weitere Aufteilung in Abhängigkeit des Vorhersagehorizonts. Das Ziel dieser Arbeit ist es, eine Vorhersage für den nächsten Tag zu treffen (engl. *day-ahead forecast*), die mit dem Begriff *short-term load forecasting* (STLF) beschrieben werden. Während die bisherigen konventionellen Methoden in der Regel mit punktuellen Referenzwerten oder mit Hilfe von Standard Nutzer- und Lastprofilen arbeiten, bauen KI-Methoden auf bestehende bzw. eigens aufgezeichnete Daten, um präziser individuelles Verhalten und plötzliche Schwankungen abzubilden.

Die im Rahmen dieser Arbeit entwickelten Prognosemodelle basieren auf umfassenden und detaillierten Datensätzen von sowohl Stromverbrauch als auch Erzeugung durch erneuerbaren Energiequellen. Hierzu können auf Messdaten mit einem Aufzeichnungsintervall von sekundengenauen Werten für Erzeugungsanlagen, z.B. PV-Anlagen, mit zugehörigen Verbrauchsdaten über einen Zeitraum von zwei Jahren zurückgegriffen werden. Diese Messdaten wurde am *Technologiezentrum Energie* (TZE) in Ruhstorf an der Rott, eine Forschungseinrichtung der Hochschule Landshut, aufgezeichnet und für anschließende Auswertungen zur Verfügung gestellt.

Die relevanten Daten für das Prognosemodell umfassen somit insbesondere:

- Leistungsdaten von PV-Anlagen (Sekunden- und Minutendaten)
- Leistungsdaten von Verbrauchern (Sekunden- und Minutendaten)
- Energieflussrichtungen
- Leistungsfaktoren

¹ Hochschule Landshut, Am Lurzenhof 1, D-84036 Landshut, Tel. +49 (0)871 506 690, alexander.wallis@haw-landshut.de, www.haw-landshut.de

² Hochschule Landshut, Am Lurzenhof 1, D-84036 Landshut, Tel. +49 (0)871 506 230, alfons.haber@haw-landshut.de, www.haw-landshut.de

³ Hochschule Landshut, Am Lurzenhof 1, D-84036 Landshut, Tel. +49 (0)871 506 778, sascha.hauke@haw-landshut.de, www.haw-landshut.de

Diese historischen Daten gilt es einer Aufbereitung und Bereinigung von fehlerhaften und fehlenden Daten zu unterziehen, um so relevante Eingangsdaten zu generieren. Im Anschluss werden diese vorverarbeiteten Daten, unter Berücksichtigung tages- und wochenzeitlichen Änderungen, einer statistischen Analyse unterzogen. Hieraus sollen mögliche Korrelationen für die Vorhersagewerte über längere Zeiträume, für einen und mehrere Tage, analysiert werden. Anhand der statistischen Analyse der Eingangsdaten werden mit Verfahren des *überwachten Lernens* Modelle zur Vorhersage des Stromverbrauchs entwickelt. Dabei steht in dieser Arbeit ein Vorhersagehorizont von einem Tag im Vordergrund. Über statistische Abgleiche mit dem entwickelten Modell wird eine Möglichkeit der Prognose untersucht und mit den Werten vom Folgetag (t+1) tageszeitlich (über ein Lastprofil und Erzeugungsprofil unter Berücksichtigung der Wochentage) gegenübergestellt. Auf Basis dieser Werte wird ebenfalls eine Form der künstlichen Intelligenz zum Lernen der Prognose erstellt.

Neben den zuvor erwähnten Leistungsdaten werden zudem lokale Wetterdaten über eine hauseigene Wetterstation aufgezeichnet, die ebenfalls für die Entwicklung der Prognosemodelle berücksichtigt werden. Diese externen Daten spiegeln ebenfalls eine gewisse Form von Expertenwissen wider, wie etwa kalendarische Faktoren, z.B. Ferien, Feiertage, Vorlesungszeiten oder im Vorhinein angekündigte Events, das nur durch menschliches Hinzutun von zusätzliche Informationen Verfügbar ist. Über diese zusätzliche Datenbasis lassen sich in einer abschließenden Auswertung der Vorhersagegenauigkeit Rückschlüsse auf einflussreiche Faktoren ziehen, die in weiterführenden Arbeiten Ansatzpunkte für eine Verbesserung der Prognosegüte berücksichtigt werden können.

Ergebnisse

Die Prognosen der unterschiedlichen Vorhersagehorizonte (z.B. Werktags und komplette Woche) erfolgen auf Basis von Metriken der statistischen Vergleichswerte. Somit können Vergleichsmodelle von prognostizierten Werten mit tatsächlichen Werten der Erzeugung und des Verbrauchs, bezogen auf einen Netzknoten, gegenübergestellt und bewertet werden. Die Güte des Prognosemodells mit den beschriebenen Annahmen und Eingangsgrößen wird dargestellt. Anhand dieser Gegenüberstellung werden Rückschlüsse auf relevante Faktoren getroffen, welche die Genauigkeit weiter verbessern können. Des Weiteren wird gezeigt, ob und in welchen Fällen konventionelle Methoden präzisere Ergebnisse liefern als Methoden des maschinellen Lernens. Alle diese Abwägungen basieren auf einheitlichen statistischen Metriken, um eine Vergleichbarkeit zu gewährleisten. Abschließend werden Potentiale für weiterführende Arbeiten aufgezeigt.

Referenzen

- [1] European Commission, „Clean energy for all Europeans“, 2019.
- [2] S. Kakran und S. Chanana, „Smart operations of smart grids integrated with distributed generation: A review“, *Renewable and Sustainable Energy Reviews*, pp. 524-535, Januar 2018.
- [3] O. Greil, J. Kainz, M. Kain und A. Haber, „Optimierungsmodell für unterschiedliche Lade- und Entladestrategien von PV-Speichersystemen“, 11. *Internationale Energiewirtschaftstagung*, Wien, 2019.
- [4] M. Raza und A. Khosravi, „A review on artificial intelligence based load demand forecasting techniques for smart grid and buildings“, *Renewable and Sustainable Energy*, pp. 1352-1372, 2015.