

# ERSTELLUNG VON LANGZEITPROGNOSEMODELLEN INDUSTRIELLER, ELEKTRISCHER LASTGÄNGE MITTELS KURZZEITMESSUNG UND GAUSS'SCHER PROZESSE

Marta Sophia POTYKA<sup>1</sup>, Prof. Peter SCHEGNER<sup>1</sup>

## Inhalt

Die Anforderungen an industrielle Unternehmen bezogen auf einen effizienten Umgang mit beispielweise elektrischer Energie steigen stetig. Deren Umsetzung kann ein Energiemanagement nach DIN EN ISO 50001 [1] erleichtern. Dafür ist es vorteilhaft, sich auf elektrische Messwerte des gesamten Lastganges und einzelner technischer Anlagen über mindestens ein Jahr zu stützen. Somit können auch saisonale Komponenten berücksichtigt werden. Doch zumeist existiert eine solche Datengrundlage nicht, da sie gemäß DIN EN ISO 50001 nicht zwingend erforderlich ist und die wenigsten Unternehmen diese zeit- und kostenaufwendige Messung freiwillig durchführen lassen. Daher wird ein Langzeitprognosemodell elektrischer Lastgänge über ein Jahr erstellt, das als Trainingsdatensatz nur eine Messung von vier Wochen benötigt. Weil künstliche neuronale Netze erst mit steigender Anzahl an Trainingsdaten immer genauer werden und auch Regressionsmethoden mit der Randbedingung einer Kurzzeitmessung keine adäquaten Prognosegüten erreichen, soll das Modell mittels Gauß'scher Prozesse (GP) als eine stochastische Methode aufgebaut werden.

## Methodik

Im Paper werden zunächst frei verfügbare Wetterparameter und aus dem Zeitstempel generierte Zeitparameter als potentielle Eingangsparameter untersucht. Danach werden die Daten vorverarbeitet und mittels einer Lastklassifikation unterteilt. Mit letzterer kann der Datensatz in charakteristische Leistungszeitbereiche geordnet werden, um diese einzeln und damit genauer modellieren zu können. Für die Teildatensätze wird je ein eigenes GP-Modell aufgestellt und am Ende alle prognostizierten Daten zu einem Datensatz zusammengefügt. GPs zeichnen sich durch die Wahl ihres Kernels aus [2]. Daher werden verschiedene Kernel sowie Kombinationen von ihnen untersucht. Des Weiteren optimiert der erstellte Algorithmus die Hyperparameter des Modells. Für eine bessere Vergleichbarkeit zu anderen Veröffentlichungen werden zur Evaluation der Ergebnisse vier Kriterien für die Prognosegüte herangezogen: MAPE, nMAE, nRMSE und  $r_E$ . Die zugehörigen Definitionen finden sich in Gl. (1) – (4) wieder.  $P_{\text{progn } t}$  steht dabei für die prognostizierte Leistung zum Zeitschritt  $t$ ,  $P_{\text{wahr } t}$  für die wirklich eingetretene Leistung zum Zeitschritt  $t$ ,  $P_{\text{max}}$  für die maximale Leistung des Datensatzes,  $P_{\text{mittel}}$  für die durchschnittliche Leistung des Datensatzes,  $E_{\text{progn}}$  für die prognostizierte Energie und  $E_{\text{wahr}}$  für die wirklich eingetretene Energie über ein Jahr.  $n$  ist die Gesamtanzahl von Zeitschritten. Jedes Gütekriterium weist einen anderen Normierungswert auf. So bezieht sich der MAPE auf die aktuelle, der nMAE auf die maximale und der nRMSE auf die durchschnittliche Leistung. Das letzte Gütekriterium,  $r_E$ , bewertet nicht die Leistung, sondern den relativen Fehler der prognostizierten Energie. Damit das Modell nicht nur anhand eines Datensatzes aufgestellt und evaluiert wird, werden drei verschiedene mittelständige Unternehmenstypen untersucht.

$$\text{MAPE} = \frac{1}{n} \sum_{t=1}^n \left| \frac{P_{\text{progn } t} - P_{\text{wahr } t}}{P_{\text{wahr } t}} \right| \cdot 100 \% \quad (1)$$

$$\text{nMAE} = \frac{\frac{1}{n} \sum_{t=1}^n |P_{\text{progn } t} - P_{\text{wahr } t}|}{P_{\text{max}}} \cdot 100 \% \quad (2)$$

---

<sup>1</sup> 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>

$$\text{nRMSE} = \frac{\sqrt{\frac{1}{n} \sum_{t=1}^n (P_{\text{progn } t} - P_{\text{wahr } t})^2}}{P_{\text{mittel}}} \cdot 100 \% \quad (3)$$

$$r_E = 100 \% \cdot \left( \frac{E_{\text{progn}}}{E_{\text{wahr}}} - 1 \right) \quad (4)$$

## Ergebnisse

Als geeignetste Eingangsparameter stellten sich überwiegend Zeitparameter heraus, wie beispielsweise die Stunde des Tages und der Wochentag. Für jedes untersuchte Unternehmen fanden sich zudem verschiedene charakteristische Leistungszeitbereiche. Die Ergebnisse der jeweiligen Prognosemodellvarianten wurden mittels der vier Gütekriterien miteinander verglichen und die jeweils am genauesten prognostizierende Modellvariante für jeden charakteristischen Leistungszeitbereich ausgewählt. Die höchsten Prognosegüten ergaben sich bei Addition mehrerer Kernel.

Abbildung 1 dient als Beispiel für das Unternehmen 1. Es ist die prognostizierte und die tatsächlich eingetretene elektrische Wirkleistung  $P$  über die Zeit  $t$  dargestellt. Die Vorhersage wurde für ein Jahr durchgeführt, auch wenn der Übersicht wegen nur eine Woche abgebildet ist. Die Abweichung der beiden Kurven ist für die anspruchsvolle Randbedingung eines geringen Trainingsdatensatzes über vier Wochen sehr gering. Diese umfassen zwei Wochen aus dem Sommer und zwei aus dem Winter.

Im Paper werden die entwickelten Modelle detaillierter vorgestellt und die resultierenden Prognoseergebnisse bewertet.




Abbildung 1: Lastgang von Unternehmen 1 über eine Woche mit prognostiziertem und tatsächlichem Leistungsverlauf.

## Referenzen

- [1] DIN EN ISO 50001: "Energiemanagementsysteme - Anforderungen mit Anleitung zur Anwendung", 2018.
- [2] C. E. Rasmussen und C. K. I. Williams, "Gaussian Processes for Machine Learning", the MIT Press, 2006.