

1. Motivation

Durch die Digitalisierung der Stromnetze entstehen neue Möglichkeiten für einen sichereren und effizienteren Betrieb, insbesondere in Niederspannungsnetzen, wo der Bedarf an einer effizienteren Verwaltung dezentraler Energieversorgungsflexibilitäten immer größer wird. Day-Ahead Lastprognosen werden beispielsweise in fahrplanbasierten Energiemanagementsystemen verwendet und ihre Genauigkeit spielt deswegen eine wichtige Rolle bei der täglichen Flexibilitätsplanung und Betriebsentscheidungen in Smart Grids. Da die Lastzeitreihen mit einem hohen Maß an Unsicherheiten behaftet sind, was die Erstellung genauer kurzfristiger Lastprognosen erschwert, ist es zu empfehlen, die theoretischen Modelle anhand eines realen Anwendungsfalls zu validieren, um ihre Zuverlässigkeit und Funktionalität zu überprüfen und somit eine adaptive Optimierung der Versorgungsfahrpläne zu ermöglichen.




Abb. 1: Anwendung der elektrischen Lastprognose bei der Optimierung der Energieversorgung

2. Anwendungsfall

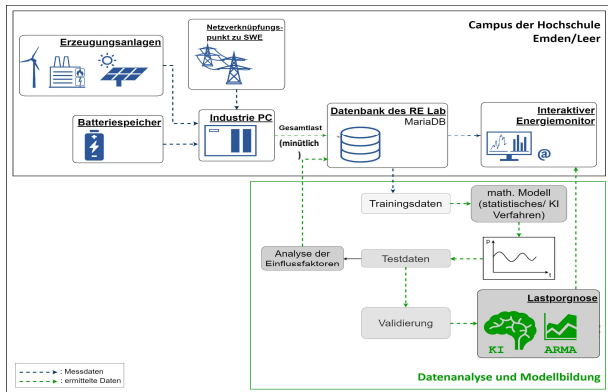


Abb. 2: Erfassung und Auswertung von Energiedaten der Hochschule Emden/Leer am Emden Campus

Rahmenbedingungen

- **Datensatz:** gemessener Lastprofil, zeitliche Auflösung: 1h
- **Trainingszeitraum:** 67 Tage
- **Prognosehorizont:** 24 h
- **Spezialfälle:** Übergang zu den Feiertagen, Messausfall, Semesterferien


3. Methoden

- **Last-Prognosemodell 1: ARMA(p, q)**¹

$$X_t + \sum_{v=1}^p a_v X_{t-v} = \sum_{\mu=1}^q b_{\mu} e_{t-\mu} + e_t, \quad \forall t \in \mathbb{Z} \quad [1]$$

Für eine Zeitreihe mit den Ordnungen $p, q \in \mathbb{N}$ und Koeffizienten a_1, \dots, a_p und b_1, \dots, b_q mit $a_p \neq 0$ und $b_q \neq 0$, falls für ein weißes Rauschen $e = (e_t : t \in \mathbb{Z})$

- **Last-Prognosemodell 2: KNN** (Künstliches neuronales Netz)



- **Persistenz-Prognosemodell**

$$P_{load,f}(d)_t = P_{load}(d-7)_t \quad [2]$$

$P_{load,f}(d)$: Zeitreihe des zu prognostizierenden Tages, $P_{load}(d-7)$: gemessene Zeitreihe des gleichen Tages der vergangenen Woche, t : Tagesstunde

- **Fehlerrechnung: RMSE**

$$RMSE = \sqrt{\frac{\sum_i (M_i - P_i)^2}{n}} \quad [3]$$

P_i : vorhergesagte Wert, M_i : beobachtete Wert für die i -te Beobachtung, n : Stichprobengröße

4. Ergebnisse und Auswertung




Abb. 3: Gemessener Lastverlauf vom 01.10. bis 15.10.2021 (grün)
Lastprognose mit ARMA Prozess (gelb), mit KNN (blau)

Spezialfälle: Modellvergleich mittels 7-Tages-RMSE




Abb. 4: 7-Tages-RMSE vom 13.12.2021 bis 01.06.2022 Spezialfall: **Übergang zu den Feiertagen**




Abb. 5: 7-Tages-RMSE. Spezialfall: nach einem **Messausfall** von 24. bis 28.02.2022




Abb. 6: 7-Tages-RMSE vom 01. bis 31.08.2021
Spezialfall: **Semesterferien**

Modellreaktionen auf Störungen:

Übergang zu den Feiertagen: KNN Modell reagiert am zuverlässigsten.

Messausfall: Auswirkung ist über eine Woche sichtbar, ARMA und KNN Modelle reagieren deutlich schneller

Semesterferien: Spezialfall wurde nicht speziell trainiert. Persistenz-Modell reagiert meistens zuverlässiger als KNN und ARMA.

5. Fazit und Ausblick

- Ein Vergleich verschiedener Prognosemodelle bei Störungen ist hilfreich, um die Lastprognose adaptiv zu optimieren.
- Persistenz-Modell: Tages-/ Wochenrhythmen berücksichtigt, was die Prognosequalität bei störungsfreier Lastgänge erhöht.
- Statistische und KI Ansätze: reagieren schneller auf Lastgangsstörungen. Beim Übergang zu den Feiertagen war das KI Modell am zuverlässigsten.
- Weitere Eingangsdaten (Einflussfaktoren) und ein regelmäßiges Nachtraining sind nötig um das KI Modell zu optimieren.
- Ein 7-Tages-RMSE kann als Entscheidungsgröße für die Zuverlässigkeit und das Nachtrainieren der Modelle dienen.

Quellen

1) J.-P. Kreiß und G. Neuhaus, Einführung in die Zeitreihenanalyse: mit 8 Tabellen. Berlin Heidelberg: Springer, 2006..