



## KI-gestützte Verbrauchsprognosen auf Basis von Smart-Meter-Daten

J. Koch, D. Beinert, D. Jost

Kontakt: Dominik Jost | +49 561 7294 467 | dominik.jost@iee.fraunhofer.de

### Verändertes Verbrauchsverhalten und Verfügbarkeit neuer Daten

- Standardlastprofile für Verbraucher bis 100.000 kWh/Jahr bilden Verbrauchsverhalten nicht mehr ausreichend genau ab
- Verändertes Verbrauchsverhalten durch Lock-Downs, Homeoffice,... (Abb. 1)
- Neue Verbraucher wie E-Kfz und Wärmepumpen bringen Verteilnetze zunehmend an ihre Grenzen
- Digitalisierung (z. B. Smart-Meter) sorgt für die Verfügbarkeit von Verbrauchsmessungen und ermöglicht datengetriebene Ansätze zur Prognose des Verbrauchs




Abb. 1: Beispiel für verändertes Verbrauchsverhalten eines Haushalts durch COVID-19 Pandemie und Homeoffice

### Data4Grid-Challenge »KI gestützte Verbrauchsprognosen auf Basis von Smart-Meter-Daten«

- Betreuende VNB: Stromnetz Hamburg, Enercity, Rheinische Netzgesellschaft
- 3 Teams: ifesca, NaecoBlue, Fraunhofer IEE
- Aufgabenstellung:
  - Datenanalyse
  - Clustering von Verbrauchern
  - Erzeugung von Day-Ahead-Prognosen für Einzelverbraucher und Portfolios mit möglichst geringem RMSE

#### Einfluss auf Prognosegüte

- Hoher Einfluss:
  - Tageszeit und Kalenderinformationen (Wochentag, Feiertag, etc.)
  - Historische Messwerte (z.B. t-1d, t-7d)
- Geringer Einfluss:
  - Wetterprognosen (bei untersuchten Verbrauchern; wird teilweise bereits über historische Messwerte als Eingangsgröße abgebildet)

#### Modellauswahl

- Baseline-Modell:
  - Persistenz (7-d)
- Machine-Learning-Modelle:
  - Extreme Learning Machine (ELM)
  - Gradient Boosted Regressions Trees (GBRT)
  - Multi Task Learning based on ANN (MTL)




Abb. 2: Vergleich der Prognosegüte der verschiedenen Machine Learning Modelle. Das Multi Task Learning erreicht den im Median geringsten RMSE.

### Ergebnisse und Fazit

- Prognose von Portfolios von vielen Verbrauchern (Abb. 3):
  - relativ hohe Genauigkeit
- Prognose des Bedarfs von einzelnen Verbrauchern (Abb. 4):
  - RMSE-Optimierung führt zu „Durchschnittsprognose“, Peaks werden nur bei hoher Wahrscheinlichkeit und nicht in voller Höhe prognostiziert
  - Persistenz-Prognose bildet die Verteilung der Verbräuche besser ab, führt jedoch zu einem höherem RMSE




Abb. 3: Beispiel für die Prognose des Verbrauchs eines Clusters aus ca. 100 Verbrauchern mit MTL




Abb. 4: Beispiel für die Prognose eines einzelnen Verbrauchers mit MTL

Gefördert durch: