

EV Load Forecasting for Grid Operation


D. Beinert, J. Koch, G. Good, D. Jost

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

Ausgangssituation

- Elektromobilität erfährt starkes Wachstum.
- Laden der Elektroautos erzeugt hohe Leistungsbedarfe in Verteilnetzen.
- Verteilnetzbetreiber verfügen kaum über aktuelle Messwerte des Verbrauchs, weil Rollout von Smart-Metern stockt.
- Für Netzbetrieb werden zukünftig Prognosen des Verbrauchs in den Verteilnetzen benötigt (z.B. um Gebrauch von steuerbaren Verbrauchseinrichtungen §14a zu machen).

Abb. 1: Übersicht über Erzeuger und Verbraucher in den verschiedenen Erzeugungsebenen



Projektziele

- Erbringung des Proof-of-Concept, dass die Prognose der Ladeleistung für die nächsten Stunden auf Basis von Fahrzeugdaten möglich ist.
- Untersuchung des Mehrwerts von zusätzlichen GIS-Daten wie Ladesäulenstandorte, Straßenverläufe, Verkehrsflusszahlen.
- Bewertung der Nutzbarkeit der erzeugten Prognosen für den Netzbetrieb.

Stand der Wissenschaft und Technik

- Die Prognose der Ladeleistung an Ladestationen bzw. ortsfesten Stationen wird in zahlreichen Papern beschrieben (z. B. [1]).
- Fahrzeugdaten werden bisher vor allem verwendet, um Ladeprofile zu modellieren und den Netzausbau zu optimieren wie in [2] und [3].
- Eine Prognose der Ladeleistung auf Basis von Fahrzeugdaten ist nicht bekannt.

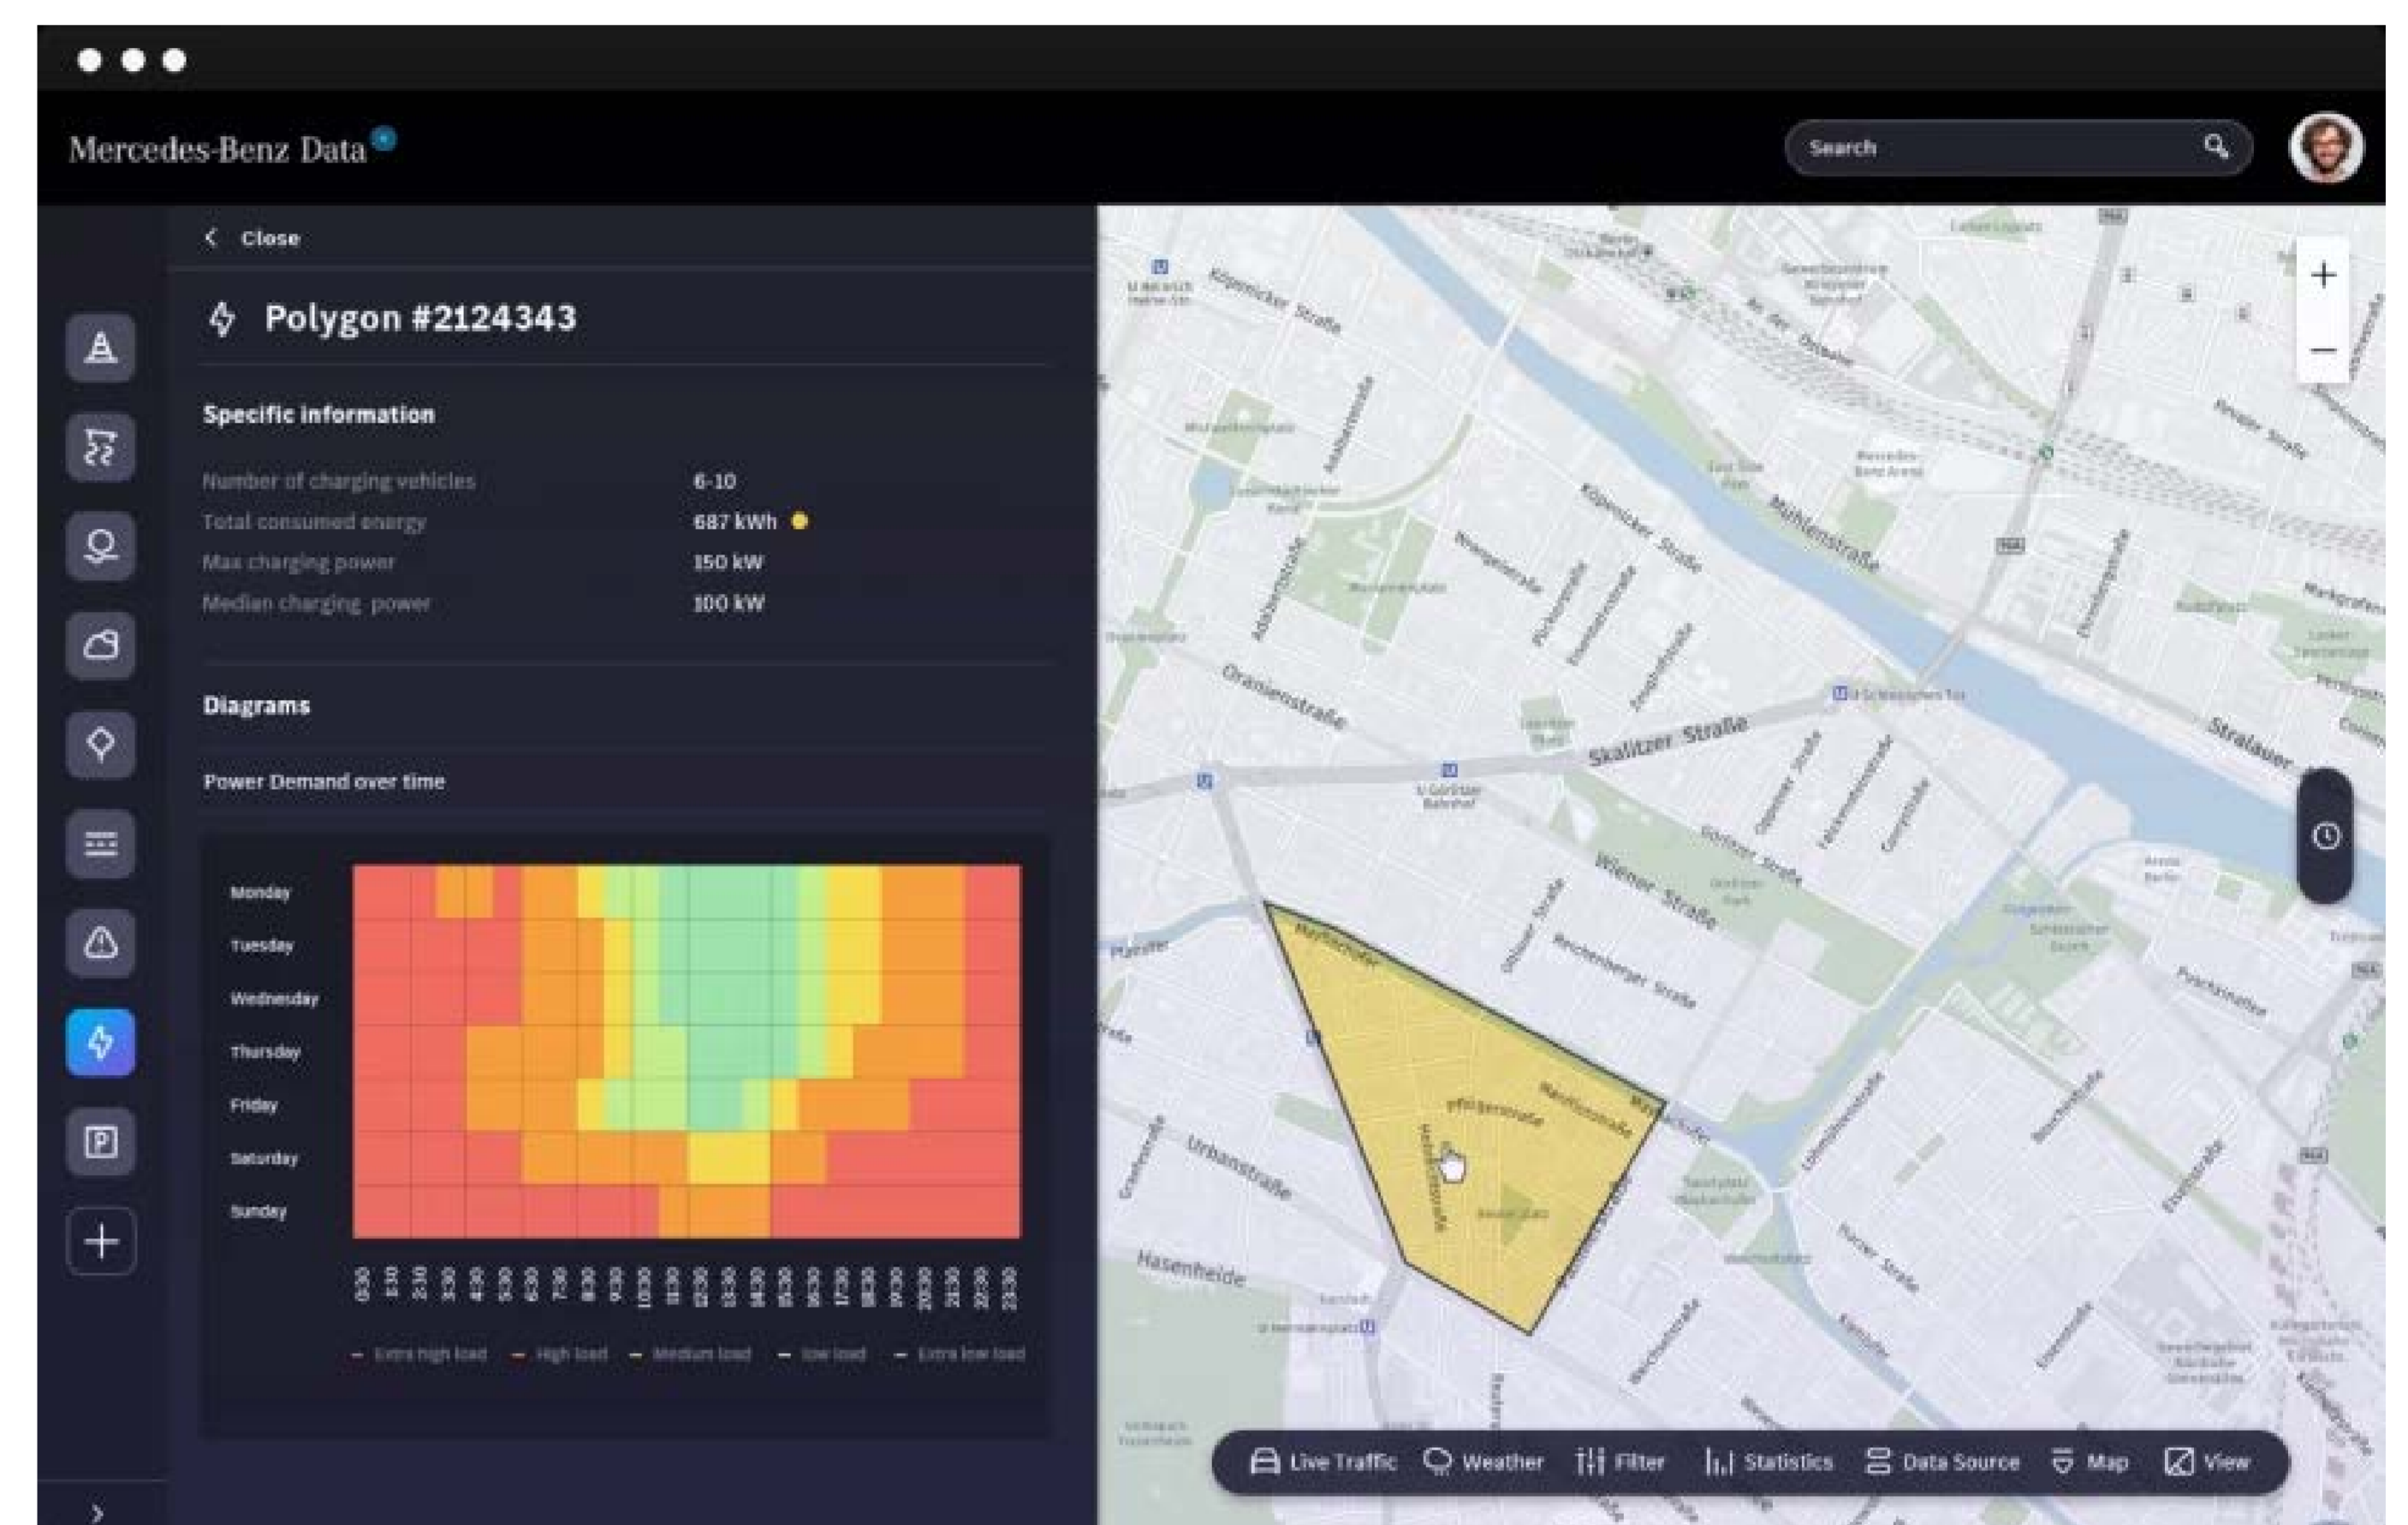


Abb. 2: Grafische Darstellung der »Energy Data« für ein Polygon (Quelle: Mercedes Benz AG)

Datengrundlage

- Fahrzeughersteller verfügen über eine breite Palette an Live-Daten aus ihren Fahrzeugflotten.
- Mercedes Benz als Projektpartner bietet unterschiedliche Datenprodukte an.
- Das Produkt »Energy Data« umfasst in anonymisierter Form pro Polygon:
 - Anzahl der Fahrzeuge
 - Maximale Ladeleistung
 - Durchschnittliche Ladeleistung
 - Gesamt geladene Energie
 - Gesamt geparkte Batteriekapazität

Methodik

- Problem aus Machine-Learning-Perspektive: Räumlich-zeitliche Sequenz-Prognose [4] gibt einen umfassenden Überblick von klassischen Methoden bis hin zu Deep-Learning-Verfahren zur Lösung dieses Problems.
- Geplant: Test verschiedener state of the Art Machine-Learning-Methoden wie
 - Generative Adversarial Networks (GAN)
 - pix2pix
 - Convolutional Neural Networks (CNN) kombiniert mit Long-Short-Term-Memory (LSTM)

1 Li, Y.; Huang, Y.; Zhang, M. Short-Term Load Forecasting for Electric Vehicle Charging Station Based on Niche Immunity Lion Algorithm and Convolutional Neural Network. Energies 2018, 11, 1253, doi: 10.3390/en11051253

2 Ashtari, E. Bibeau, S. Shahidinejad and T. Molinski, "PEV Charging Profile Prediction and Analysis Based on Vehicle Usage Data," in IEEE Transactions on Smart Grid, vol. 3, no. 1, pp. 341-350, March 2012, doi: 10.1109/TSG.2011.2162009.

3 C. Corchero, S. González-Villafranca and M. Sanmarti, "European electric vehicle fleet: driving and charging data analysis," 2014 IEEE International Electric Vehicle Conference (IEVC), 2014, pp. 1-6, doi: 10.1109/IEVC.2014.7056144.

4 Xingjian Shi, Dit-Yan Yeung, „Machine Learning for Spatiotemporal Sequence Forecasting: A Survey“, 2018, arXiv:1808.06865 [cs.LG]

5 Peng Xie, Tianrui Li, Jia Liu, Shengdong Du, Xin Yang, Junbo Zhang, Urban flow prediction from spatiotemporal data using machine learning: A survey, Information Fusion, Volume 59, 2020, Pages 1-12, ISSN 1566-2535, https://doi.org/10.1016/j.inffus.2020.01.002.

Gefördert durch: