

# NETZLASTMANAGEMENT VIA LADESÄULEN AUF BASIS VON DEEP REINFORCEMENT LEARNING UNTER BETRACHTUNG VERSCHIEDENER BEOBACHTUNGSRÄUME

Dennis Salvador Versen<sup>1</sup>

## Einleitung

Die ansteigende Last in elektrischen Energienetzen kann aufgrund der Elektrifizierung von immer mehr Verbrauchern zur Senkung der Treibhausgasemissionen zu Problemen an Betriebsmitteln im Netz führen. Die Elektrifizierung eines Großteils des Verkehrssektors sowie des Wärmesektors kann zu hohen Lastspitzen an Kabeln und Transformatoren führen. Diese zum Teil sehr alten Betriebsmittel sind häufig nicht für die bevorstehenden Lasten ausgelegt. Die Folge können Schäden an besagten Betriebsmitteln und damit einhergehende Stromausfälle sein.

Eine mögliche Lösung wäre der flächendeckende Netzausbau. Dieser würde allerdings viel Zeit und finanzielle Mittel kosten. Mit Blick auf die Fristen des Pariser Klimaabkommens und des Verbrennerverbots [1] [2] bis 2035 ist dies ein schwer umsetzbares Vorhaben. Zumal die Netzkapazität nicht das Problem darstellt, sondern nur die zeitweiligen Lastspitzen, die auch über intelligente Verfahren in kapazitivere Zeiten verschoben werden könnten. Um dies zu ermöglichen, müssen Verbraucher mit einer Leistung von über 4,2 kW beim Netzbetreiber gemeldet sein. Bei drohender Netzüberlastung kann der Netzbetreiber die Leistungsaufnahme solcher steuerbaren Verbraucher temporär drosseln. Darunter fallen folgende Verbraucher: Wallbox, Wärmepumpen, Batteriespeicher, Klimaanlagen [3]. Den Verbrauchern steht im Gegenzug ein reduziertes Netzentgelt zu, wenn ihre Geräte unter diese Steuerung fallen. Der Netzbetreiber hat daher das Ziel, die Regelung so effektiv und diskriminierungsfrei wie möglich zu gestalten. Das heißt, unter Einhaltung des Energiebedarfs der Verbraucher soll Netzstabilität gewährleistet werden. Von den genannten Verbrauchern eignen sich diejenigen am meisten zur Regelung, die eine hohe Flexibilität mit sich bringen. Das bedeutet, Verbraucher, die ihre Leistungsaufnahme zeitlich verlagern können bei gleicher Energieaufnahme, haben eine Flexibilität. Hierbei eignen sich insbesondere Batterien und E-Autos (EVs). Viele der privaten Kunden laden ihre Autos zu Hause in den Abendstunden [4]. Häufig sind diese schon nach kurzer Zeit vollgeladen und stehen dann über Nacht. Ein Regelsystem sollte diese Flexibilität möglichst energieeffizient ausnutzen und Überlast vermeiden. Eine Regelung im klassischen Sinne, z. B. mit Beschreibung der Physik in einem mathematischen Modell, ist hier nicht möglich, da das System viele äußere Einflüsse, Störgrößen und schwer vorhersagbare Wechselwirkungen besitzt. Ein weiteres Problem sind die Informationen, die vom Verbraucher bereitgestellt werden können. Dies ist aufgrund geringer Digitalisierung, aber vor allem aus Datenschutzgründen, nicht möglich. Viele Daten werden nur alle 15 Min. erhoben und machen es schwer auf aktuelle Ereignisse zu reagieren. Hier können Ansätze des selbstbestärkenden Lernens durch KI eine vielversprechende Lösung sein.

Diese Arbeit möchte unterschiedliche modellfreie Ansätze basierend auf KI und selbstlernenden Agenten (Reinforcement Learning) zur Echtzeit-Regelung eines Niederspannungsnetzes (NSN) evaluieren. Obwohl vorangegangene Arbeiten [7] [8] schon vielversprechende Ergebnisse gezeigt haben, so basierten die Lastprofile aus z.T. künstlich hergestellten repetitiven Daten. Die Gefahr bei künstlich generierten Daten und der Verwendung von KI ist immer, dass die KI lernt, wie diese erzeugt wurden, anstatt die Dynamik und Wahrscheinlichkeiten der Umgebung zu lernen. Die Forschungsfrage, die hier beantwortet werden soll ist: Kann ein prädiktives Echtzeit-Lastmanagement mit Reinforcement Learning in einer hoch komplexen stochastischen dynamischen Umgebung mit realen Messdaten zur Netzstabilität beitragen, und welche Informationen sind hierzu relevant?

---

<sup>1</sup> Helmut-Schmidt Universität Hamburg, Holstenhofweg 85, +49-40 6541-0,  
PressestelleHSU{at}bundeswehr.org, <https://www.hsu-hh.de>

## Daten

Für die Umsetzung der verschiedenen Szenarien wird eine NSN-Simulation mit pandapower [6] aufgebaut. Diese Arbeit nutzt für die Profile der Haushalte sowie die der EV-Daten die Forschungsdaten aus der Pecan Street Datenbank [9]. Diese sind real zusammengetragene Daten aus Haushalten in Kombination mit privatem EV-Gebrauch. Für die Analyse und Lastflussberechnungen wird das Python-Open-Source-Tool zur Modellierung von Stromversorgungssystemen pandapower genutzt.

## Methoden

Für die Umsetzung des Lastmanagements über die Ladesäulen werden verschiedene Reinforcement-Learning-(RL-)Algorithmen herangezogen. RL eignet sich insbesondere zur Lösung von markovschen Entscheidungsproblemen (MDP). Diese sind insbesondere gekennzeichnet durch eine stochastische Umgebung mit unsicheren Ergebnissen. MDPs können durch das Markow'sche Tupel beschrieben werden:

$$\{S, A, P, R\}$$

Es beschreibt eine Zustandsmenge S, eine Aktionsmenge A, eine Wahrscheinlichkeit der Zustandstransition P und eine Belohnungsfunktion R die den Zustandsübergang bewertet. Bezogen auf das NSN kann ein Zustand aus den abrufbaren Messdaten bestehen, wie z. B. *Transformator-Auslastung, Auslastung Kabel, Haushaltslast, Ladesäulenlasten, etc.*. Die Aktionen werden hier durch einen globalen diskriminierungsfreien Dimmfaktor beschrieben, der pro Zeitschritt (15 min) die Last an den Ladesäulen (LS) reguliert. Die Wahrscheinlichkeiten, der Zustandsübergänge ist durch die zukünftigen Ungewissheiten (Autos kommen/ Autos fahren weg) gegeben.

Zur Lösung dieses Problems wird ein RL-Agent eingesetzt, der Zustände s aus der Umgebung beobachtet und durch Interaktion a eine Belohnung r erhält, die ihm hilft eine Strategie zu erlernen.

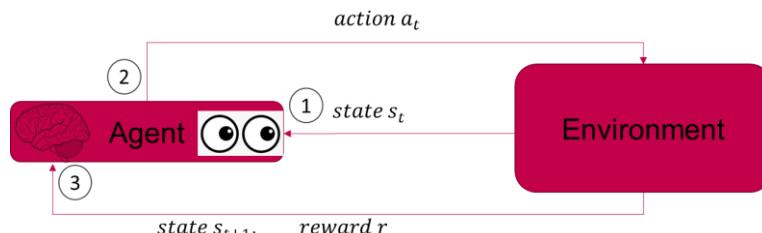


Abbildung 1: Schema des RL-Algorithmus

Hierzu eignen sich verschiedene RL-Algorithmen. Diese Arbeit evaluiert Deep RL Algorithmen die Neuronale Netze benutzen um ihre Entscheidungen zu treffen und zu bewerten.

Neben dem Vergleich unterschiedlicher RL-Algorithmen werden unterschiedliche Szenarien formuliert. Diese unterscheiden sich hauptsächlich in der Dichte der Informationsübertragung. Welche Daten braucht der Agent wirklich um eine Policy zu finden, die den Score erhöht?

In einem perfekten Szenario würden diese und andere Informationen abrufbar sein. Für diese Arbeit werden nur Teile dieses Zustandsraumes verwendet oder kumuliert übermittelt, um eine gewisse Realität und Datenschutz zu gewährleisten.

## Evaluation

Zur Auswertung wird die durchschnittliche Belohnung und der Episodenscore verglichen. Außerdem wird sich die Erfolgsquote beim Einhalten des Grenzwertes, sowie die der geladenen Energie angeschaut. Weitere Auswertungsmethoden müssen noch evaluiert werden.

## References

- [1] „Umwelt Bundesamt,“ 15 04 2025. [Online]. Available: <https://www.umweltbundesamt.de/themen/klima-energie/internationale->

- klimapolitik/uebereinkommen-von-paris/das-15-grad-ziel-nach-dem-uebereinkommen-von-paris?utm\_source=chatgpt.com#undefined.
- [2] „European Parliament,“ 08 08 2023. [Online]. Available: <https://www.europarl.europa.eu/topics/en/article/20180920STO14027/reducing-car-emissions-new-co2-targets-for-cars-and-vans-explained>.
  - [3] „Bundesnetzagentur,“ [Online]. Available: <https://www.bundesnetzagentur.de/DE/Vportal/Energie/SteuerbareVBE/artikel.html>.
  - [4] N. Andrenacci und M. P. Valentini, „A Literature Review on the Charging Behaviour of Private Electric Vehicles,“ *MDPI*, p. 29, 2023.
  - [5] Verbraucherzentrale, „www.verbraucherzentrale.de,“ 25 06 2025. [Online]. Available: [https://www.verbraucherzentrale.de/wissen/energie/preise-tarife-anbieterwechsel/smart-meter-was-sie ueber-die-stromzaehler-wissen-muessen-13275?utm\\_source=chatgpt.com](https://www.verbraucherzentrale.de/wissen/energie/preise-tarife-anbieterwechsel/smart-meter-was-sie ueber-die-stromzaehler-wissen-muessen-13275?utm_source=chatgpt.com).
  - [6] pandapower, „pandapower.readthedocs.io,“ 2016-2024 . [Online]. Available: <https://pandapower.readthedocs.io/en/latest/>. [Zugriff am 2024].
  - [7] Y. Fu und D. Versen, „Electric Vehicle Charging Management for Avoiding Transformer Congestion Using Policy-based Reinforcement Learning,“ in *IEEE*, 2023.
  - [8] D. Versen, „Entwicklung eines netzseitigen Lastmanagements auf Basis intelligenter nichtlinearer Systemidentifikation zur Vermeidung von Transformator-Lastspitzen in einem Niederspannungsnetz,“ in *TKB*, 2025.
  - [9] „PECAN STREET,“ [Online]. Available: <https://www.pecanstreet.org/dataport/>.
  - [10] Simbench, „simbench.de,“ 2016. [Online]. Available: <https://simbench.de/de/datensaetze/>. [Zugriff am 2024].