

A. Dreher, L. Martmann, M. Lehna, C. Roelofs, S. Liebehentze, R. Brandl, J. Dobschinski, J. Koch, L. Pauscher, S. Wende-von-Berg

Kontakt: M.Sc. Alexander Dreher | 0561-7294-1750 | alexander.dreher@iee.fraunhofer.de

Im Projekt **SmartChargingPilot** wurde die Funktionsfähigkeit von Algorithmen des maschinellen Lernens für das Lademanagement von Elektrofahrzeugen (E-Kfz) erprobt. Für zwei unterschiedliche Anwendungsfälle im Heimenergiemanagement und Fuhrparkmanagement wurden innovative selbstlernende Algorithmen entwickelt, die Flexibilitätspotenziale im Lademanagement nutzen, um Ladevorgänge intelligent zu steuern.

### Problemstellung

Das intelligente Lademanagement (*Smart Charging*) ist eine Klasse von Energiemanagement-Problemen, die sich mit dem optimalen Laden von E-Kfz beschäftigt. In dem Spotlight-Projekt SmartChargingPilot wurden dabei zwei Anwendungsfälle betrachtet. Im ersten Schritt wurden eine Simulationsumgebung und Algorithmen für ein Heim-Energiemanagement-System (HEMS) entwickelt, welches neben typischen Endkundeneinrichtungen auch eine steuerbare Ladestation berücksichtigt. Im zweiten Schritt wurden Algorithmen für das Management mehrerer Ladestationen für einen Unternehmensstandort entwickelt.



Abbildung 1: Untersuchte Anwendungsfälle des Smart Charging

### Methodik: Reinforcement Learning

Ein innovativer Ansatz das Smart Charging Problem zu lösen, ist die Anwendung von Deep Reinforcement Learning (DRL). Dabei werden Methoden des Reinforcement Learning (RL) mit tiefen neuronalen Netzen kombiniert. Beim RL lernt ein Agent durch Interaktion mit seiner Umgebung. Jedes Mal wenn der Agent eine gewählte Aktion durchführt, verändert sich seine Umgebung und gibt ihm ein numerisches Belohnungssignal (siehe Abbildung 2). Über dieses Signal optimiert der Agent im Training schrittweise seine Strategie. Da DRL ein datenbasierter Ansatz ist, wird kein exaktes Modell der Umgebung benötigt.

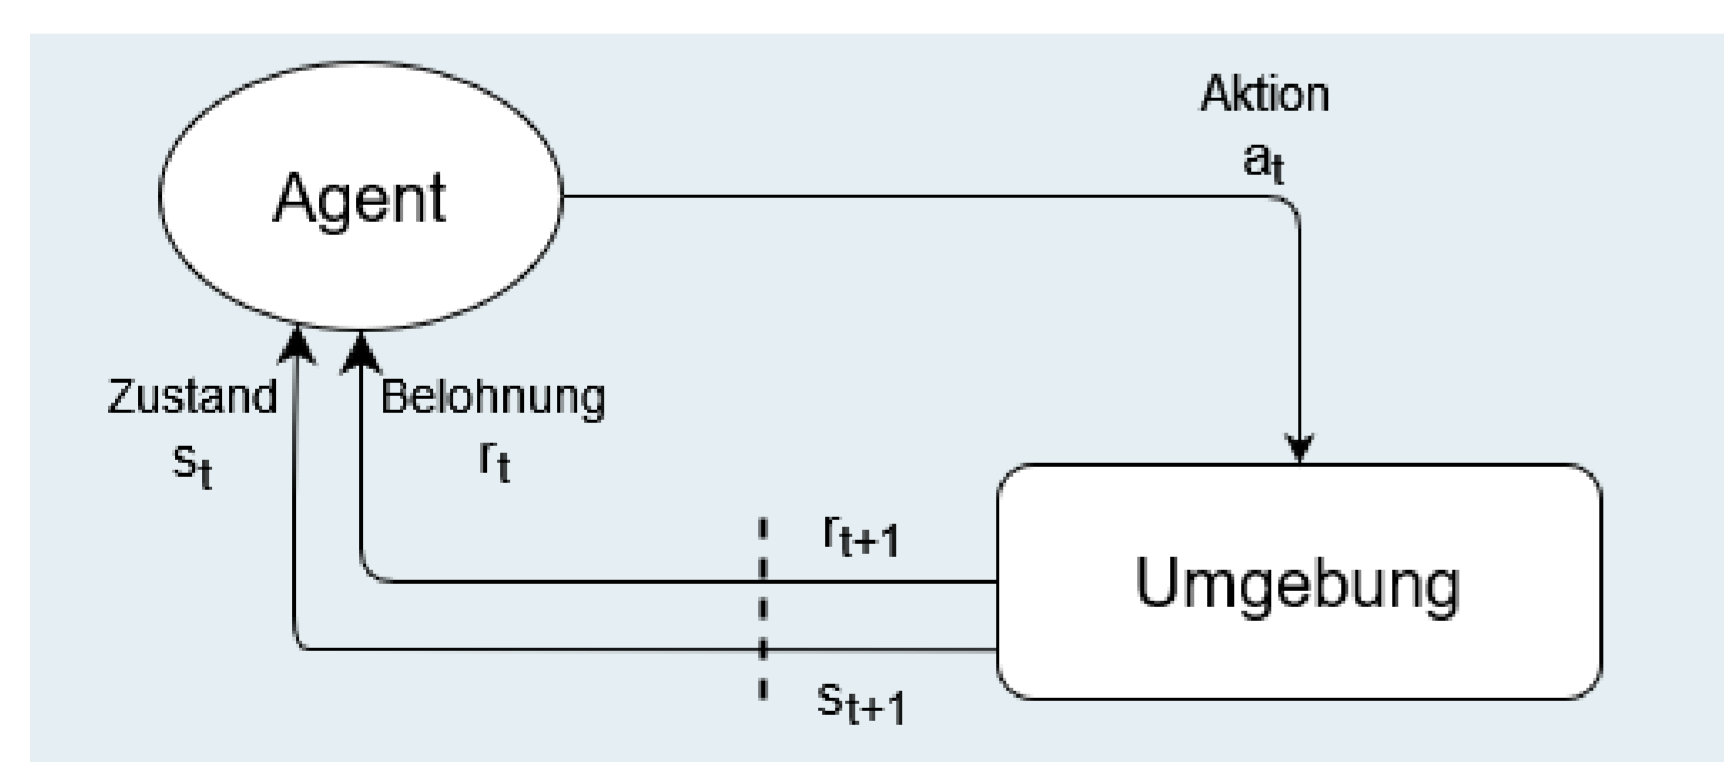


Abbildung 2: Interaktion eines Reinforcement Learning Agenten mit seiner Umgebung

### Modellierung

Für das Heim-Energiemanagement wurde ein Einfamilienhaus mit PV-Anlage, Batteriespeicher, Wärmepumpe und einem E-Kfz und deren Erzeugung / Verbräuche modelliert. Ziel des RL-Agenten war es, die Leistungsauf-/entnahme der Wärmepumpe, des Batteriespeichers und des E-Kfz optimal zu steuern, um die Energiekosten zu senken. Anschließend wurde für weitere Untersuchungen ein Ladeszenario für Unternehmensstandorte modelliert.

Die Modellierung bestand aus der Abbildung von 6 Ladesäulen, die an den Werktagen von verschiedenen E-Kfz besucht werden konnten. In Anlehnung an die Ergebnisse des Leuchtturms MobiCast wurden verschiedene Benutzerverhalten simuliert, die sich u.a. in An-/Abfahrtszeiten, gefahrener Strecke und präferierter Ladesäule unterschieden.

### Ergebnisse

Abbildung 3 zeigt Resultate eines trainierten RL-Agenten, welcher das Lademanagement für ein Elektrofahrzeug, das Speichermanagement eines Heimspeichersystems sowie die Steuerung einer Wärmepumpe erlernt hat.




Abbildung 3: Beispiel der Ergebnisse des RL-Algorithmus für das intelligente Lade- und Energiemanagement eines Haushalts

Gut zu erkennen ist, dass der Agent die Haushaltslasten, einschließlich des Batteriespeichers, so koordiniert, dass sie den durch die PV-Anlage eigenerzeugten Strom optimal aufnehmen. Weiterhin wird der Batteriespeicher koordiniert entladen, um die Last zu bedienen, welche durch die Wärmepumpe in Stunden entsteht, in denen kein PV-Strom erzeugt wird. Schließlich wird auch ersichtlich, dass der RL-Agent hohe Preisspitzen vermeidet, indem erforderliche Netzbezüge in Strompreistälern bedient werden<sup>1</sup>.

Während der Agent im Unternehmensstandort-Szenario ebenfalls Fortschritte im Training zeigte, waren die Ergebnisse beim Test auf ungesehenen Daten nicht eindeutig. Hier zeigt sich der Blackbox-Charakter der RL-Methodik, der in Folgeaktivitäten adressiert werden soll.

### Fazit und Ausblick

Das Spotlight-Projekt zeigt das hohe Potenzial der DRL-Algorithmen für eine dezentrale, ressourcengünstige und datenbasierte Lösung auf. Gleichzeitig wurden Herausforderungen identifiziert, wie die Ausgestaltung geeigneter Anreize bei mehreren konkurrierenden Zielen sowie die Ergebnisunsicherheit, welche durch den Blackbox-Charakter von RL entsteht. Auf Basis der Erkenntnisse wird nun ein Best-Practice-Factsheet für den DRL-Einsatz in energiewirtschaftlichen Anwendungsfällen entwickelt. Weiterhin wird ein von konkreten Anwendungsfällen abstrahierender Ansatz für eine optimale Evaluierungsstrategie abgeleitet, um dem RL-Blackbox-Problem zu begegnen.

<sup>1</sup> AI agents assessing flexibility: the value of demand side management in times of high energy prices <https://doi.org/10.1109/EEM54602.2022.9920982>