



Selbst-Adaptives Lademanagement für Ladeinfrastruktur

Bildnachweis

Cover: Stecker: © www.freepik.com, Foto: © [yuliachupina - stock.adobe.com](https://www.adobe.com/stock/yuliachupina)



VORWORT

Das vom BMBF geförderte Projekt „Selbst-Adaptives Lademanagement für Ladeinfrastruktur“ kurz „SALM“ zeigt wie in der Zusammenarbeit zwischen einem KMU (Flavia IT) und der Forschung (Universität Kassel) ein konkretes Optimierungsproblem im Kontext der Energiewende aufgenommen und innovative Lösungen erarbeitet werden konnten.

Vor dem Hintergrund der Energiewende stellt der Ausbau der Elektromobilität und die daraus resultierende Netzbelastung für die Beladung der Fahrzeugbatterien eine zusätzliche Anforderung für die Energieversorger dar. Letztendlich treffen an den Ladestationen die, durch den Einsatz der erneuerbaren Energien verstärkten, Schwankungen der Energieversorgung auf die Lastschwankungen, die aus ungesteuerten Ladevorgängen der Elektrofahrzeuge resultieren.

Die klassischen Lösungsansätze in Gestalt eines kalkulatorischen Vollausbau (Gleichzeitigkeitsfaktor) der Versorgungskapazitäten und der Verteilnetze stoßen

damit an physikalische und finanzielle Grenzen. Eine Vermeidung von Leistungsspitzen durch zeitgleiches Laden mittels einer intelligenten Steuerung der Ladevorgänge kann in gewissem Maße einem notwendigen Ausbau der Verteilnetze entgegenwirken. Das durch die Flavia IT im Projekt E-Mobility-LAB Hessen* umgesetzte cloud-basierte Lastmanagement eröffnete aufgrund der softwarebasierten Architektur grundlegende Möglichkeiten die Charakteristika der „Nutzer“ (d.h. der Fahrzeuge) in die Berechnung der Algorithmen für die Verteillogik zu integrieren. Allerdings zeigte sich auch, dass auf die sich ändernden Rahmenparameter (Anzahl der Fahrzeuge, Batteriekapazitäten, Lade- (Fahr-) verhalten der Fahrzeugführer, etc..) nur sehr schwer mit Anpassungen der Software reagiert werden kann.

* *weitere Infos zum Projekt E-Mobility-LAB Hessen*



Das Projekt SALM widmet sich der automatischen Anpassung der Verteilalgorithmen. Als Grundlage hierzu wurde eine umfangreiche technische Simulation durchgeführt, um das Verhalten von Ladevorgängen mithilfe von Digitalen Zwillingen realitätsgetreu nachzubilden. Durch die genaue Festlegung von Zielparametern konnten die Anforderungen und Bedürfnisse der einzelnen Standorte präzise berücksichtigt werden. Die Festlegung individueller Kennzahlen wiederum ermöglichten eine quantitative Bewertung der Ergebnisse des Lademanagements und dienten als Grundlage für die fachliche Beurteilung der Verteilalgorithmen. Insgesamt stellte die individuelle Ausarbeitung von Zielparametern und Kennzahlen einen entscheidenden Schritt zur erfolgreichen Umsetzung des Projekts dar.

Auf die Visualisierung der definierten Kennzahlen wurde in der praktischen Umsetzung ein großes Augenmerk gelegt. Aufbauend darauf wurden in der wissenschaftlichen Forschung Methoden für ein selbst-adaptives Lastmanagement entwickelt.



PROJEKTVORSTELLUNG

Im Rahmen des Projekts wurde eine Software-basierte Steuerung der Energieverteilung für Elektrofahrzeug-Ladeinfrastrukturen unter Einsatz von KI-Methoden weiterentwickelt. Digitale Zwillinge bilden dabei das Verhalten der Ladestationen nach und ermöglichen eine Optimierung der Steuerung. Ziel ist es, ein selbst-adaptives lernendes System nach dem Prinzip der LCS zu entwickeln, das sich zur Laufzeit weitgehend autonom an neue Situationen anpassen kann und gezielt Wissen über die Lastverläufe an den realen Ladestationen mit wählbaren Zielparametern kombiniert. Dabei können die Qualitätsziele individuell auf die Bedürfnisse des jeweiligen Betreibers angepasst werden. Ein neues evolutionäres Verfahren für Mehrzieloptimierung unter Nutzung von Prinzipien des verstärkenden Lernens und unter Einbeziehung von Simulationssystemen wird hierbei angewendet. Die Ergebnisse des Lademanagements werden anhand von Qualitätskennzahlen bewertet, um eine Selbstoptimierung durch Einsatz von KI-Verfahren zu erforschen.

"Im Projekt SALM werden reale Situationen simuliert, um so effektiv und effizient die Optimierung von Ladestrategien zu untersuchen. Die Ladeinfrastruktur mit künstlicher Intelligenz zu optimieren, ist ein wichtiger Beitrag hin zu klimaschonender Mobilität."

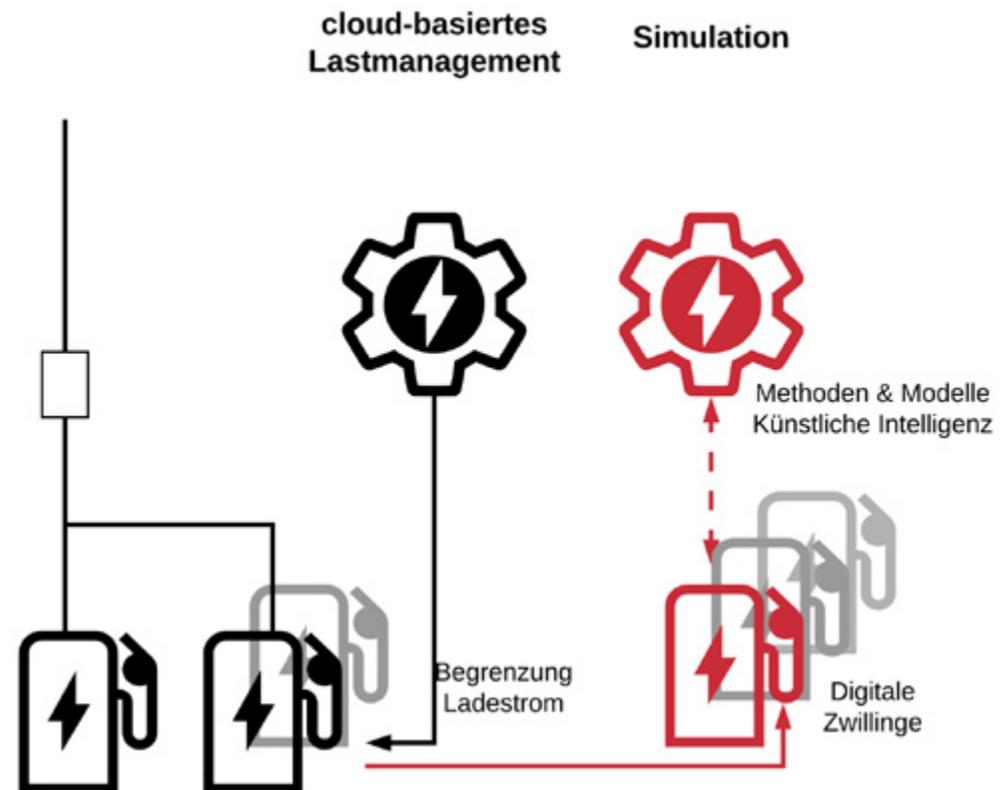
Prof. Dr. Sick, Leiter des Fachgebiets Intelligente Eingebettete Systeme an der Universität Kassel

Der Aufbau und Betrieb der Simulationsumgebung, in der Digitale Zwillinge das Verhalten von Ladestationen nachbilden, ist der technische Ankerpunkt des Projektes, der die Datenbereitstellung für die gesamte Projektlaufzeit sicherstellte.

Die Nachvollziehbarkeit der Entscheidungsfindung wurde ergänzend zu der wissenschaftlichen Aufarbeitung immer wieder im Austausch mit Betreibern von Ladeinfrastruktur an die realen betrieblichen Anforderungen gekoppelt.

Die Projektlaufzeit betrug 30 Monate.

Das Projektvolumen betrug ca. 1,9 Millionen EUR.





DIE PROJEKTPARTNER

FLAVIA IT



Die FLAVIA IT ist ein inhabergeführtes Technologieunternehmen, das bundesweit anspruchsvolle IT-Projekte im Kundenauftrag realisiert. Seit der Gründung im Jahr 2001 hat das Unternehmen ein stetiges Wachstum erfahren, sodass Kunden der FLAVIA IT auf das breit aufgestellte IT Know How von über 80 Mitarbeiter zählen können. Seit 2017 gehört die FLAVIA IT zu den 500 wachstumsstärksten Unternehmen Deutschlands.

Die FLAVIA IT hat als Kooperationspartner die Opel Automobile GmbH im Projekt E-Mobility-LAB darin unterstützt, für eine große Flotte an E-Fahrzeugen mit hoher Ladedichte in einem abgegrenzten Gebiet mit (durch die Netzinfrastruktur gegebenen) Netzengpässen und einer fluktuierenden Energieerzeugung die erforderliche Ladeinfrastruktur bereitzustellen. Hierbei haben bis Ende 2020 bis zu 1.000 E-Fahrzeuge an 500 Ladepunkten (20 Standorten) bis zu 7 MW tägliche Leistung abgerufen. Im Rahmen des Projektes wurde angestrebt,

die Investitionen in den Ausbau der vorhandenen elektrischen Netze auf ein Minimum zu reduzieren. So wurden die Investitionen in ein physisches Lastmanagement durch ein rein cloud-basiertes Lastmanagement substituiert. Die Begrenzung der Ladeströme erfolgt lediglich durch Vorgabe entsprechender Ladeprofile (charging profile) an die Controller der eingesetzten Ladestationen auf der Basis konfigurierter Algorithmen. Dieser Ansatz ist Startpunkt für SALM, um mit KI-Algorithmen des Betreiber- und Nutzerzentrierten Lastmanagements den Herausforderungen der kommenden Jahre – in denen technologischer Fortschritt, Veränderung der Fahrzeugflotten (Batteriekapazitäten) und wahrscheinlich auch Veränderung von Nutzungsgewohnheiten kontinuierlich die Rahmenbedingungen verschieben – durch selbstlernende bzw. selbst-adaptive (also "intelligente") Systeme zu begegnen.

UNIVERSITÄT KASSEL

U N I K A S S E L
V E R S I T Ä T

An der Universität Kassel fokussiert sich das Fachgebiet Intelligente Eingebettete Systeme (IES) unter Leitung von Prof. Sick auf Grundlagen- und Anwendungsforschung im Bereich der KI, speziell des maschinellen Lernens (ML). In Bereich ML wurden in den letzten Jahren insbesondere Arbeiten zum weitestgehend oder vollständig autonomen Lernen in intelligenten Systemen durchgeführt, insbesondere zum autonomen Erkennen von Änderungen in der Umgebung eines Systems (Emergenz, Anomalien, novelty, concept shift / drift), zum aktiven Lernen (ML with human in the loop; effizientes und effektives Einbeziehen von Menschen in ML), oder zum Transferlernen. Weitere relevante Arbeiten betreffen z.B. Modellierung von Unsicherheit und probabilistische Prognosen. Anwendungen wurden z.B. im Bereich der regenerativen Energien und zukünftigen Energiesysteme realisiert, wo IES in den Projekten Prophecy (BMBF), c/sells (BMW), Digital Twin

Solar (BMW) und Transfer (BMBF) mitgearbeitet hat. In den Projekten ging es z.B. um Wind- und PV-Prognosen, Netzzustände, Digitale Zwillinge und Regioflexmärkte.

Im Rahmen des Projekts SALM hat sich die Universität Kassel mit der Analyse von Daten, der Entwicklung von digitalen Zwillingen und dem Training von verschiedenen Methoden der künstlichen Intelligenz beschäftigt. Es wurden digitale Zwillinge für Ladeinfrastrukturen entwickelt und eine hochwertige Simulation integriert und betrieben, um plausible Lastmanagement-Szenarien zu generieren und Methoden des maschinellen Lernens optimal zu trainieren. Es wurden Kopplungsmechanismen in der Elektromobilität untersucht, indem verschiedene heterogene Datenquellen integriert wurden, um zugrunde liegende Korrelationen und Abhängigkeiten zu erörtern und das Verhalten realer Ladestationen möglichst realistisch abzubilden. Weiterhin wurden

wichtige Qualitätskriterien in die Entwicklung von Reinforcement Learning Modellen berücksichtigt. Die Konzeption, Entwicklung, Ausführung und Analyse von Reinforcement Learning Verfahren zeigte, dass diese geeignet sind, Ladevorgänge zu steuern. Des Weiteren wurden topologische Informationen und Graph-Neural-Networks für die Entscheidungsfindung genutzt um die Skalierbarkeit und Adaptivität der Methoden zu erhöhen. Transfer Learning wurde eingesetzt, um Wissen zwischen ähnlichen Standorten zu übertragen und die Vorhersagekraft von Modellen zur Lastprognose zu verbessern. Insgesamt ermöglichte das Projekt SALM eine optimale Planung und Optimierung von Lademanagement-Szenarien unter Berücksichtigung von Energiebedarf, Kosten, Effizienz und anderen Faktoren.



DIE PROJEKTERGEBNISSE

Im Rahmen des Projekts SALM wurde eine hochwertige Simulationsumgebung für Ladeinfrastrukturen konzipiert und betrieben. Die Simulationsumgebung ermöglicht es, durch den Einsatz digitaler Zwillinge, verschiedene Ladeinfrastrukturen abzubilden und plausible Lastmanagement-Szenarien zu generieren, die sowohl vielfältig als auch ausreichend zahlreich sind, um Methoden des maschinellen Lernens optimal zu trainieren. Darüber hinaus wurde die Synthese von realen Datensätzen und der Wissenstransfer zwischen verschiedenen Entitäten im Bereich der Elektromobilität untersucht. Dabei wurden Kopplungsmechanismen in der Elektromobilität untersucht, indem mehrere heterogene Datenquellen wie z.B. Daten von Ladestationen, Elektrofahrzeugen und Informationen von Fahrern miteinander integriert wurden. Durch die Integration dieser verschiedenen Informationen können zugrunde liegenden Korrelationen und Abhängigkeiten von Merkmalen erörtert werden. Ein Verständnis des Nutzungsprofils von E-Fahrern könnte uns beispielsweise in die Lage versetzen, den Energiebedarf an einem bestimmten Tag und zu einer bestimmten Uhrzeit an

einem bestimmten Ort und für eine bestimmte Bevölkerungsgruppe abzuschätzen. Diese Bedarfsprognose kann auch Energieversorgern und Netzbetreibern helfen, die Energieverteilungsnetze zu optimieren, um Kosten zu senken und die Effizienz zu steigern.

Des Weiteren wurden Ziele ausgearbeitet, die ein Lademanagement verfolgen sollte. Mögliche Ziele beinhalten die Maximierung der Nutzung der Ladeinfrastruktur wie z.B. die verbrauchte Energie in kWh und die Verbesserung der Ladequalität durch einen hohen Anteil vollständig geladener Fahrzeuge oder eine möglichst geringe Zahl der durchschnittlichen Leistungswechsel pro Ladevorgang, um Unruhen im System zu vermeiden. Weitere Ziele stellen die Minimierung der Ladekosten, der Ausgleich von Nachfrage und Angebot an elektrischer Energie und die Minimierung von Emissionen dar. Die spezifischen Ziele des Lademanagements hängen von den Anforderungen und Einschränkungen der Anwendung und des Kontextes ab und können eine Kombination dieser oder anderer Ziele beinhalten.

Die Simulationsumgebung kann in ihrer einfachsten Form historische Event-Daten wie Ladedaten und Lastverläufe wiedergeben und diese in sequenzieller Reihenfolge verschmelzen, um ein Kontrollsignal pro Zeitschritt zu erzeugen. Der Zeitraum und die Anzahl der Schritte sind dabei beliebig konfigurierbar, wodurch beispielsweise ein Simulationsdurchgang jeden Zeitraum tageweise oder wochenweise in Minutenschritten ausgeben kann. Zusätzlich können externe Daten wie Preisdaten oder Informationen über den erneuerbaren Energieanteil der Simulation integriert werden. Die Simulationsumgebung unterstützt zwei unterschiedliche reale Datensätze, die aus einer Ladeinfrastruktur auf einem Campus bzw. einen Mitarbeiterparkplatz stammen. Die Topologie der Simulation ist ebenfalls frei konfigurierbar und ermöglicht es, die Anzahl der Ladestationen, den Anschluss an die Infrastruktur und andere Merkmale wie die maximal mögliche Leistung festzulegen. **Zusammenfassend ist die Simulationsumgebung ein äußerst flexibles und leistungsfähiges Werkzeug zur optimalen Planung und Optimierung von Lademanagement-Szenarien.**

Da die Quantität von realen Daten oftmals nicht für das Training von tiefen neuronalen Netzen ausreicht, wurde in einem weiteren Arbeitsschritt die Simulation um Kopplungsmechanismen erweitert, die sicherstellen sollen, dass die simulierten Datenverläufe das Verhalten realer Ladestationen möglichst realistisch widerspiegeln. Zu diesem Zweck sind statistische und generative

Verfahren eingesetzt worden, die das Verhalten realer Ladeinfrastrukturen anhand von Daten erfassen und abbilden können. Eine Herausforderung besteht darin, die Zufälligkeit des realen Nutzungsverhaltens abzubilden. Eine Möglichkeit hierzu boten übliche Verfahren wie Histogramme und Gaußsche Mischmodelle aber auch komplexe generative Modelle wie Variationale

Autoencoder (VAE). Diese können Nutzungen und Ladekurven einschließlich einer realitätsnahen Zufälligkeit simulieren und können dem Ziel gerecht werden, dass die simulierten Datenverläufe dem Verhalten realer Ladestationen entsprechen und somit eine realitätsnahe Abbildung der realen Nutzungen ermöglichen. Dafür wurde eine empirische Untersuchung mit rea-

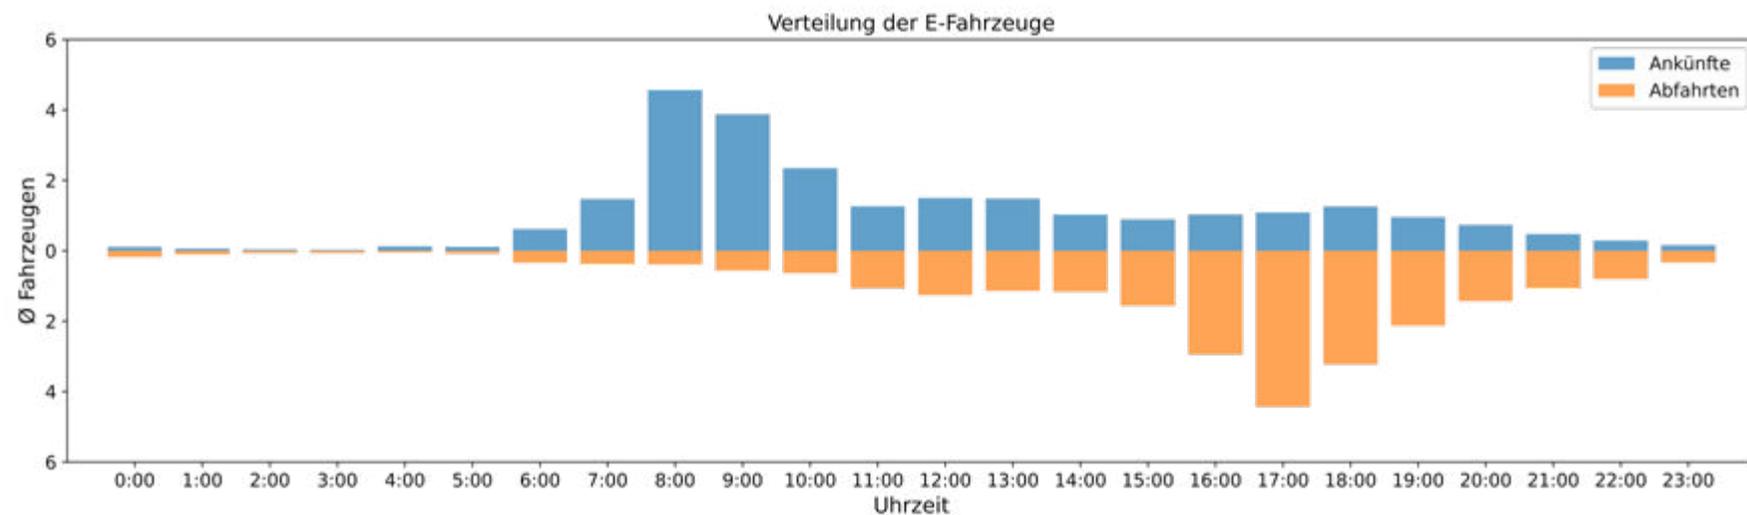


Abb.: Durchschnittlichen Abfahrten und Ankünfte von Fahrzeugen pro Tag; Datensatz: <https://ev.caltech.edu/dataset>

len Daten durchgeführt, welche Ladeprozessdaten, Nutzungsdaten und Infrastrukturinformationen von drei separat gelegenen Ladeinfrastrukturen umfassen. Mehrere Merkmale wie die Ankunftszeit, gelieferte Gesamtenergie, Stationskennungen, Lade- und Standzeit wurden berücksichtigt. Diese wurden als multivariate Zeitreihe angenommen und mit Hilfe von VAE-Modellen modelliert und folgend synthetisiert. **Um Einblicke in den Energiebedarf von Elektrofahrzeugen zu gewinnen, wurde eine große Anzahl von Nutzungsszenarien generiert. Diese synthetischen Daten enthalten Faktoren wie Energieverbrauch, Fahrzeugprofile, geschätzte Zeit und Standort, so dass reale Szenarien simuliert und der Energiebedarf genau vorhergesagt werden kann.** Durch die Verwendung synthetischer Daten können verborgene Faktoren, Korrelationen und Abhängigkeiten aufgedeckt werden, die für das Verständnis des Energiebedarfs von Elektrofahrzeugen entscheidend sind. Diese Faktoren sind aus realen Daten allein möglicherweise nicht sofort ersichtlich, was synthetische Daten zu einem wichtigen Instrument für ein besseres Verständnis macht. Ins-

gesamt kann durch die Nutzung synthetischer Daten der Energiebedarf besser vorhergesagt werden, was zu effizienteren und effektiveren Strategien für das Energiemanagement führt.

Die Analyse von Reinforcement Learning Verfahren hat ergeben, dass diese gut geeignet sind, um Ladevorgänge zu steuern da diese ein sequentielles Entscheidungsproblem darstellen. Beispielsweise können Single-Agent Methoden eine kleine Ladeinfrastruktur gut steuern und dabei Kosten minimieren, in dem in günstigen Zeiträumen priorisiert geladen wird. Eine weitere Erkenntnis liegt in der Nutzung der topologischen Informationen sowie der Beziehungen zwischen den Stationen für die Ladeentscheidungen. Die Ladeinfrastruktur ist natürlich in Form eines Graphen gegeben, in dem Ladestationen durch Knoten dargestellt werden, die mit Kanten verbunden sind, die ihre physischen Verbindungen darstellen. Generell scheinen die Verbindungen zwischen den Stationen einen großen Einfluss auf die Ladeentscheidungen zu haben. Da die Ladenetzwerke eine inhärente Graph-Struktur haben,

ist es intuitiv, die Topologie explizit zu nutzen, indem man Ladestationen als Knoten darstellt und sie mittels Kanten verbindet. Ein Graph-Neural-Network (GNN) kann dann als Policy-Netzwerk für die Entscheidungsfindung genutzt werden. Auf diese Weise kann die infrastrukturelle Semantik implizit kodiert werden. Da das Lademanagement an jeder Station von Natur aus ähnlich ist, ist es ratsam, gelerntes Wissen wiederzuverwenden und zwischen den Stationen auszutauschen und gleichzeitig ihre Unterschiede zu berücksichtigen. So werden beispielsweise an jeder Station die Laderaten reduziert, wenn ein Fahrzeug die angebotene Rate nicht ausschöpft, während sich die Statistiken über die Steh- und Ankunftszeiten der Nutzer unterscheiden können. Durch die Verwendung von GNN-Modellen erreicht man einen Wissenstransfer und eine Generalisierung über den Knotenpunkten. Darüber hinaus kann die Adaptivität zur Topologie-Veränderungen durch Ausblenden eines oder mehrerer Knoten verbessert werden, um das Hinzufügen, Löschen oder die Störung von Ladestationen zu simulieren.

In vielen realen Anwendungen kann die Sammlung ausreichender Daten für das Training eines tiefen neuronalen Netzes aufgrund von Ressourcenbeschränkungen wie Zeit und Rechenkosten eine Herausforderung darstellen. Die Übertragung von Wissen zwischen ähnlichen Einheiten kann jedoch eine Lösung für Fälle bieten, in denen einige Standorte nicht über genügend Daten verfügen, um effektive Prognosemodelle für mehrere Standorten zu erstellen. Transfer Learning ist eine leistungsstarke Technik, bei der ein Modell in einem Ausgangsbereich trainiert und dann an einen Zielbereich angepasst wird, um dieses Problem zu lösen. Um Transfer Learning zu nutzen, wurde ein für zeitliche Daten optimiertes Convolutional-Neural-Network (CNN) auf einer größeren Quelldomäne trainiert, die von zwei geografisch getrennten Ladestationen stammt. Anschließend wurde ein Fein-Tuning des CNN-Modells an einem kleineren Zieldatensatz hervorgehoben, der von einem anderen Standort stammte und dem Quellbereich ähnlich war. Trotz der begrenzten Trainingsdaten wurde zu einer verbesserten Leistung und Genauigkeit auf dem Zieldatensatz festgestellt. Somit

kann eine vorhandene Datenknappheit überwunden und die Vorhersagekraft von Modellen zur Lastprognose an Ladestationen verbessert werden.

"Mit dieser Lösung können sowohl die Betreiber privater Industrienetze als auch die öffentlichen Verteilnetzbetreiber ihre Kosten für den Ausbau der Netze durch effiziente Ausnutzung der Netzkapazitäten begrenzen."

Georg Schmitt, Vertreter des Konsortialführers Flavia-IT



FAZIT

Der entscheidende Faktor für den Erfolg des Projekts war die Umsetzung einer intuitiven und aussagekräftigen Visualisierung der erhobenen Daten. Diese erlaubte es die komplexen Zusammenhänge auf einen Blick zu erfassen und uns sowohl innerhalb des Projektes als auch im Austausch mit Betreibern von Ladeinfrastruktur im Gespräch zu gemeinsamen Schlussfolgerungen zu kommen. Im Ausblick liegt daher ein besonderer Fokus auf der Weiterentwicklung der Visualisierungsmöglichkeiten. Durch konsequente Weiterentwicklung der bisherigen Ansätze sollen in weiteren Entwicklungsschritten zukünftig im direkten Gespräch mit Entscheidungsfindern in einer Simulation präzise Prognosen und damit eine zielgerichtete Investition ermöglicht werden. Damit wird die Simulation zu einem unverzichtbaren Werkzeug für Unternehmen und Organisationen, die den Aufbau der Ladeinfrastruktur auf Basis von Daten und Analysen optimieren möchten.



KONTAKTDATEN

KONSORTIALFÜHRER

FLAVIA IT-Management GmbH

Jonas Kilian
Wilhelmshöher Allee 268
34131 Kassel

jonas.kilian@flavia-it.de
Tel. 0561 / 57439-23

PROJEKTPARTNER

Universität Kassel

Fachgebiet Intelligente Eingebettete Systeme, IES

Prof. Dr. Bernhard Sick
Mönchebergstr. 19
34109 Kassel

bsick@uni-kassel.de
Tel.: 0561 / 804-6020

House of Energy e.V. (Auftragnehmer)

Dr. Dorothee Walther
Universitätsplatz 12
34127 Kassel

d.walther@house-of-energy.org
Tel.: +49 (0)561 51 00 53 34



U N I K A S S E L
V E R S I T Ä T

House 
of **Energy**

