
Integration der Ladeinfrastruktur der Elektromobilität in ein Smart Home

Dipl. Inf. Wolfgang Schwedler



Technische Universität Clausthal
Prof. Dr. Andreas Rausch
Institute for Applied Software
Systems Engineering
Wallstraße 6
38640 Goslar

Gliederung

- Einführung mit Beispiel-Szenario
- Problembeschreibung
- Erster Lösungsansatz
- Ergebnis
- Ausblick
- Fragen und Diskussion

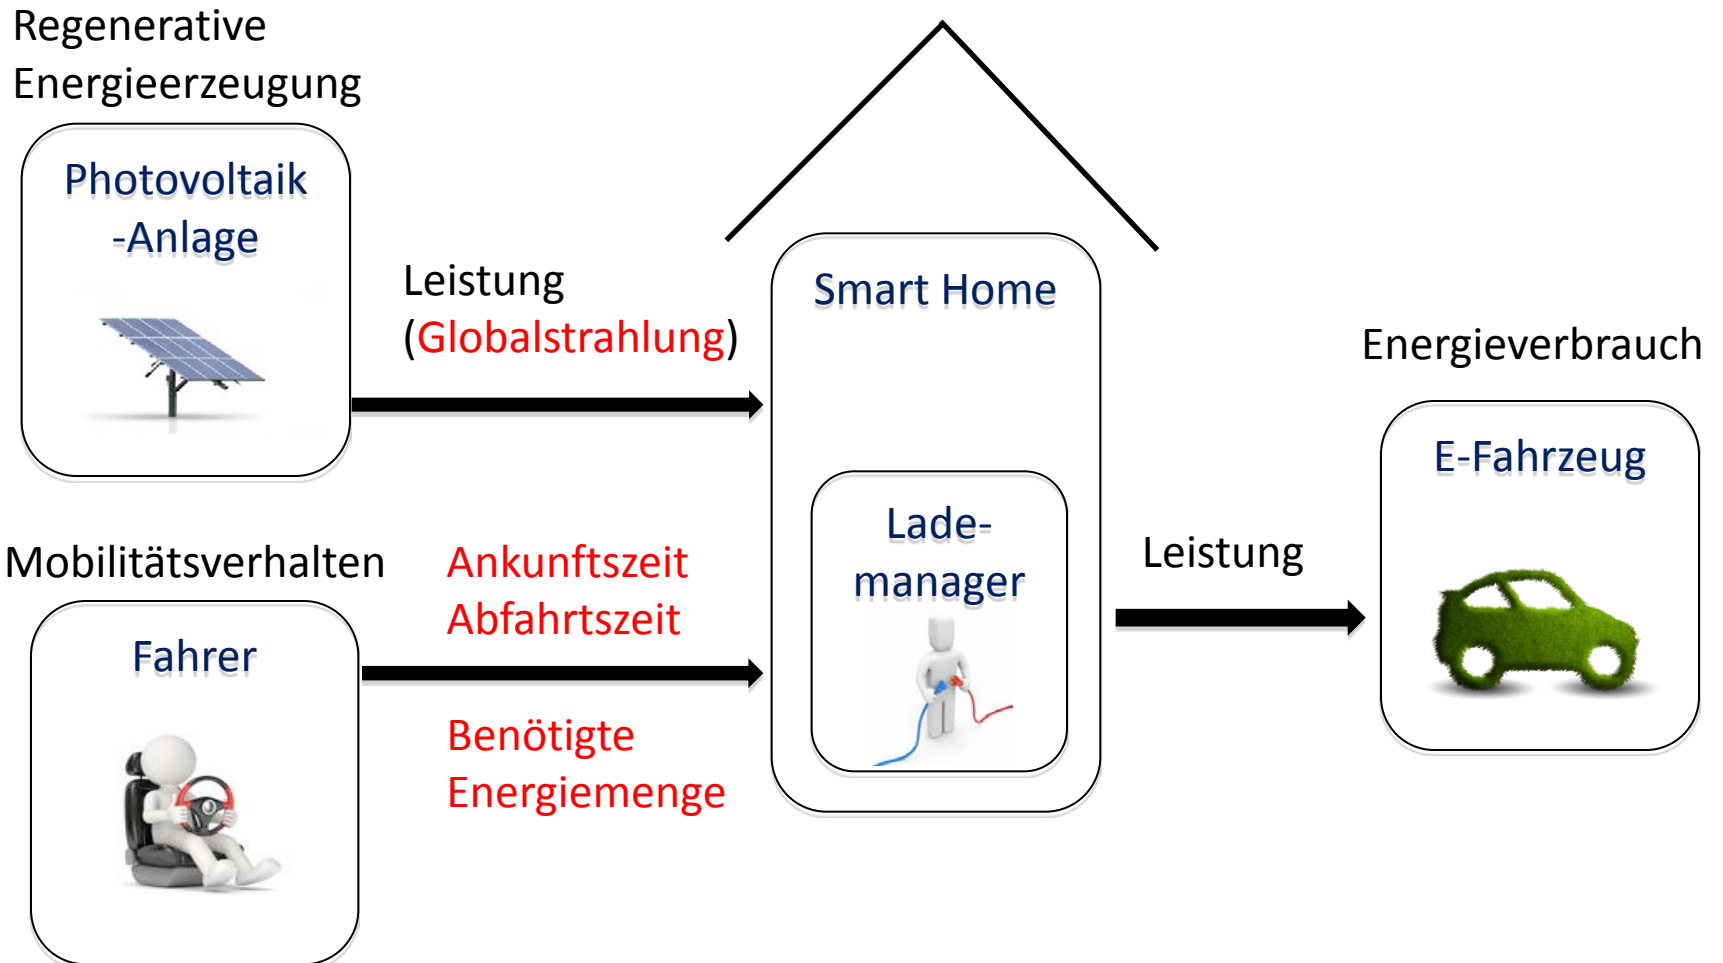
Beispiel-Szenario

Ein Pendler fährt täglich mit seinem Elektrofahrzeug von zu Hause aus in die Arbeit. Dort steckt er sein Ladekabel in die Ladesäule. Sein Fahrzeug wird während der Arbeit möglichst regenerativ mittels Photovoltaik-Strom geladen. Am Abend fährt er wieder heim.



Wie lässt sich Energieerzeugung und Mobilitätsverhalten in Einklang bringen?

Ausgewählte Einflussparameter beim Beladungsvorgang




Der Beladungsvorgang ist auch von **nichtdeterministischen** Eingangsparameters abhängig. Aber: Diese folgen womöglich stochastischem Verhalten

Wissenschaftliche Fragestellung

Der zu verwendende Algorithmus muss mitlernen und sich so kontinuierlich an das Mobilitätsverhalten sowie der regenerativen Energieerzeugung anpassen können und damit **nichtdeterministische** Einflussparameter berücksichtigen.

Forschungsfrage

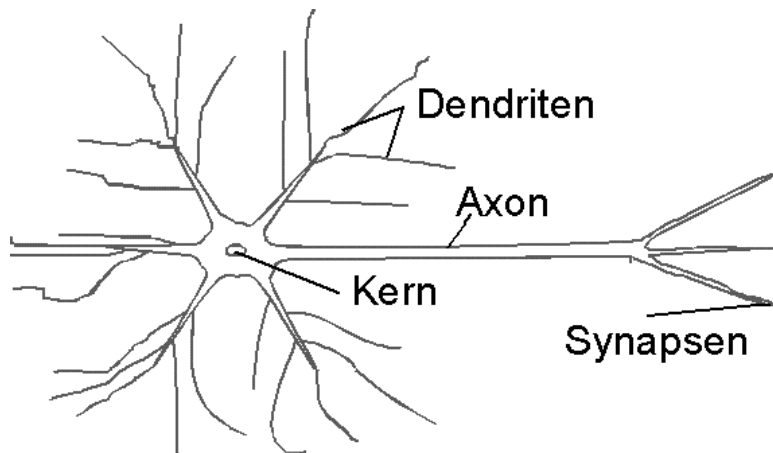
Wie sieht der **selbstlernende Optimierungsalgorithmus** dazu aus?




Erster Lösungsweg

Nichtdeterministische Einflussparameter sollen erlernt werden zukünftige Fahrten zu prognostizieren. Dabei soll sich die Prognose kontinuierlich anpassen und die Abweichung der Prognose zur Realität immer kleiner werden.

Einsatz von neuronalen Netzen:




(Künstliches) Neuronale Netz




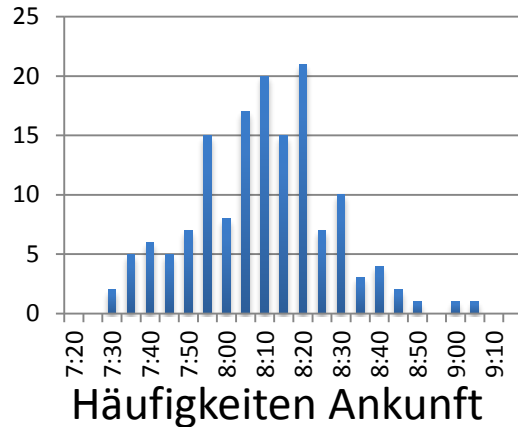
Selbstlernende Optimierung am Beispiel der Prognose der Abfahrtszeit (Überwachtes Lernen, Verdeckten Schichten, Backpropagation)

1. Trainingsphase: ([Ankunftszeit, ...], [**Abfahrtszeit**])ⁿ
2. Testphase: [Ankunftszeit, benötigte Energie] -> Prognose der **Abfahrtszeit**
3. Beladungsphase des E-Fahrzeuges
4. Tatsächliche **Abfahrt**: -> **Abfahrtszeit** bekannt

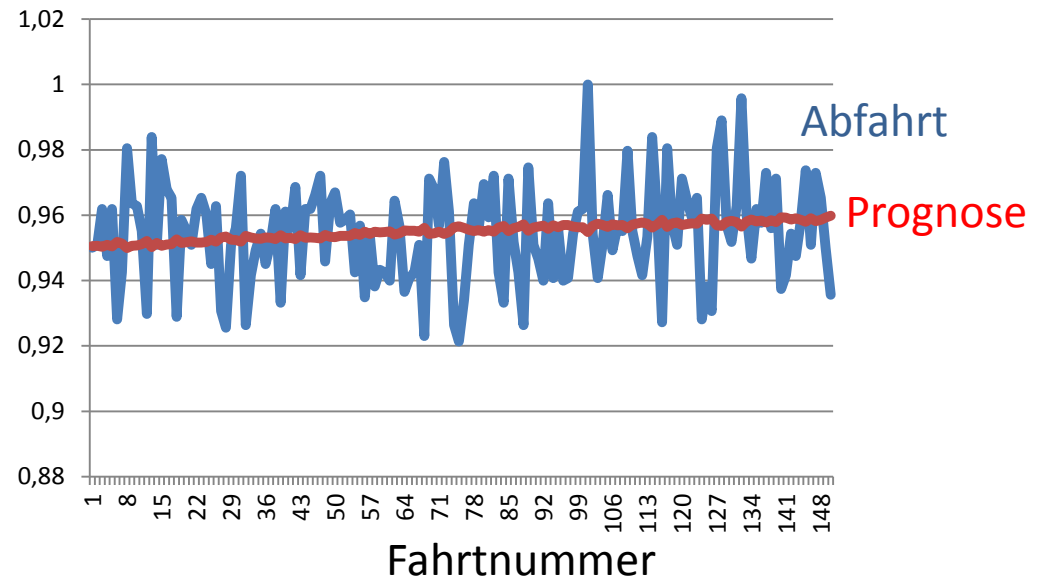
Beispiel Photovoltaik-E-Erzeugung



Ergebnis selbstlernender Optimierungsalgorithmus



Zeit normalisiert




Ergebnis

- Das neuronale Netz liefert bei diesem einfachen Beispiel akzeptable Prognosen
- Die Leistungsfähigkeit um Zusammenhänge zu identifizieren wird noch nicht ausgeschöpft
- Die Berechnung ist schnell
- Offline-Lösung zum Schutz der Privatsphäre
- Weder Sammlung noch statistische Auswertung basierend auf historischen Daten

Ausblick

Energieverbrauchprognose



Fahringsimulator-Anbindung



Realdatenmessung per CAN-Bus



Fragen und Diskussion

Danke für Ihre Aufmerksamkeit

Literatur und Quellenverzeichnis

- George F. Luger, Künstliche Intelligenz, 4. Auflage, 2002.
- Neuronale Netze, Eine Einführung, www.neuronalesnetz.de, letzter Aufruf 1.9.14
- Matthias Stifter, Stefan Übermasser, Dynamic simulation of power system interaction with large electric vehicle fleet activities
- Nicole Taheri, Robert Entriken, and Yinyu Ye , A Dynamic Algorithm for Facilitated Charging of Plug-In Electric Vehicles , 2013.
- Kevin Mets, Reinhilde D’hulst, and Chris Develder, Comparison of Intelligent Charging Algorithms for Electric Vehicles to Reduce Peak Load and Demand Variability in a Distribution Grid, 2002.
- Kathrin Büdenbender et al., Ladestrategien für Elektrofahrzeuge Charging Strategies for Electric Vehicles.
- Java, NEUROPH, <http://neuroph.sourceforge.net/>
- Bildnachweise:
 - <http://www.pressebox.de/pressemitteilung/vector-informatik-gmbh/Neue-Datenlogger-bieten-CAN-LIN-und-FlexRay-Kanaele/boxid/336686>
 - <http://blog.kiunke-coaching.de/liste-graue-3d-maennchen/3d-man-blue-trike-3/>
 - <http://de.fotolia.com/id/67198331>
 - http://www.gul-berlin.de/tl_files/gul/img/box_photovoltaik.png
 - http://www.dieeinsparinfos.de/fileadmin/_migrated/pics/Maennchen_trennt_STromkabel_02.jpg
 - GoogleMaps unter <https://www.google.de/maps/>
 - <http://www.lunaticpride.de/NEURONEN.HTM>