

Ansprechpartner:



Armin Giessler, M.Sc.
IRS, Raum 202
Tel.: 0721/608-43179
armin.giessler@kit.edu

Beginn: ab sofort

Dauer: 6 Monate

experimentell anwendungsorientiert theorieorientiert

Ihre Interessen:

Energiesysteme
 Reinforcement Learning

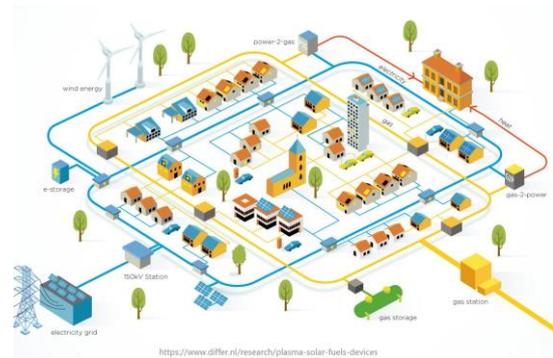


Bachelorarbeit

Reinforcement Learning für die Primärregler von DC Microgrids

Motivation:

Durch die Integration von immer mehr erneuerbaren Energien in das elektrische Netz, werden die konventionellen Kraftwerke durch eine Vielzahl an verteilten Erzeugern abgelöst. Die optimale Koordinierung der dezentralen Einspeiser ist eine große Herausforderung. Üblicherweise wird für die Koordinierung das Netz in kleinere Teilgebiete, z.B. Microgrids, unterteilt. In der Regel werden anschließend ökonomische optimale Sollwerte berechnet, welche von der primären Regelung eingeregelt werden.



Aufgabenstellung:

Ziel der Arbeit ist das Lernen von primären Reglern für die dezentralen Einspeiser mit Hilfe von Reinforcement Learning (RL). Es soll ein *grid-forming*, ein *grid-following* und ggf. ein „dämpfender“ Regler gelernt werden. Beim Lernen wird der Fehler der Hamilton-Jacobi-Bellmann Gleichung minimiert und die Value-Function und eventuell die Policy (Regelungsgesetz) werden mit Hilfe von neuronalen Netzen approximiert [1], [2]. Am Anfang der Arbeit findet eine Einarbeitung in die Modellierung von DC Microgrids und in das RL mit Fokus auf die Regelungstechnik statt. Anschließend soll ein geeignetes Framework für das Lernen entworfen und implementiert werden. Weiterhin soll untersucht werden, inwiefern Stellgrößen- und Zustandsbeschränkungen in den Lernvorgang eingebunden werden können. Am Ende sollen die gelernten Regler mittels einer Simulationsstudie demonstriert und plausibilisiert werden. Dabei sollen ausschließlich einzelne Knoten und kein komplettes Microgrid simuliert werden. Optional können die gelernten Regler gegen die bestehenden klassischen Regler in einer Simulation gebenchmarkt werden.

[1] [L. Buşoniu et al. „Reinforcement learning for control: Performance, stability, and deep approximators“. Annual Reviews in Control, 2018](#)
[2] [B. Recht „A Tour of Reinforcement Learning: The View from Continuous Control“, Annual Reviews of Control, Robotics, & Autonomous Systems, 2019](#)

