



Deep Reinforcement Learning als Methode zur autonomen Steuerung von Niederspannungsnetzen mit Fokus auf die Netzstabilität

Lars Quakernack, Michael Kelker, Ulrich Rückert, Jens Haubrock

Fachhochschule Bielefeld Fachbereich Ingenieurwissenschaften und Mathematik

Institut für Technische Energie-Systeme (ITES)

EnInnov2022

17. Symposium Energieinnovation | 16.02.–18.02.2022

Inhalt

1. Einleitung
2. Reinforcement Learning
3. Reinforcement Learning in der Energietechnik
4. Kritik
5. Fazit und Ausblick

Einleitung

- Pariser Klimaabkommen 1.5°C-Ziel <-> D ist Klimaneutral bis 2045
 - 7-10 Mio. Elektrofahrzeuge bis 2030 in D
 - Bis 2025 40-45 % erneuerbare Energien in D
- ⇒ Hohe Ladeleistungen mit volatilen Erzeugung durch dezentralen Energieanlagen belasten besonders das Niederspannungsnetz!

Lösungen:

⇒ Zulassungstop, Netzausbau oder **Steuerungssystem!**

Einleitung

Steuerungssysteme mittels KI bzw. RL im Vormarsch!

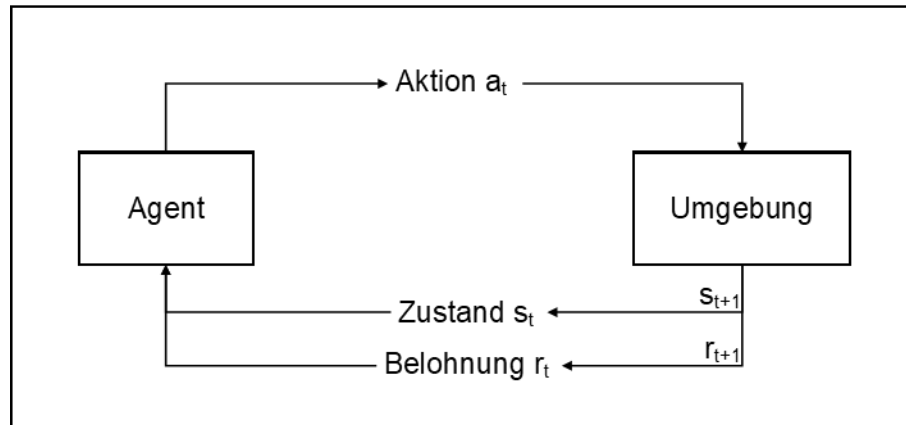
- (1) J. Duan, "Deep-Reinforcement-Learning- Based Autonomous Voltage Control for Power Grid Operations". In: IEEE Transactions on Power Systems 35.1, (2020).
- (2) D. Didden, "Sample efficient reinforcement learning with domain randomization for automated demand response in low-voltage grids". In: IEEE Journal of Emerging and Selected Topics in Industrial Electronics (2021).
- (3) M. Kelker, "Multi agent deep Q-reinforcement learning for autonomous low voltage grid control". In: IEEE PES Innovative Smart Grid Technologies Europe (ISGT Europe), (2021).
- (4) W. Bi, "Real-time Energy Management of Microgrid Using Reinforcement Learning," *2020 19th International Symposium on Distributed Computing and Applications for Business Engineering and Science (DCABES)*, (2020).
- (5) A. O. Erick, "Power Flow Management in Electric Vehicles Charging Station Using Reinforcement Learning," *2020 IEEE Congress on Evolutionary Computation (CEC)*, (2020).
- (6) ...

⇒ Aber was ist Reinforcement Learning?

⇒ Fokus auf Netzstabilität mit Paper (1),(2),(3)

Reinforcement Learning

RL ist eine der Methoden des maschinellen Lernens. RL verwendet positive oder negative Verstärkungen, um einen Agenten auf der Grundlage von Zuständen in einer Umgebung zu trainieren, die beste Aktion zu wählen, um ein definiertes Optimum zu erreichen.



Q-Learning

1. Zufällige Aktionen als Initalisierung
2. Setzen der Aktionen in der Umgebung
3. Berechnung der Belohnungsfunktion
4. Berechnung der Q-Werte
5. Höchster Q-Wert = neue Aktion
6. Wiederholung

	laden	entladen
t=0	$Q(s_0, a_0)$	$Q(s_0, a_1)$
t=1	$Q(s_1, a_0)$	$Q(s_1, a_1)$
t=2	$Q(s_2, a_0)$	$Q(s_2, a_1)$
...
t = 95	$Q(s_{95}, a_0)$	$Q(s_{95}, a_1)$

Bellmann-Gleichung:


$$Q_{\text{new}}(s_t, a_t) \leftarrow Q_{\text{old}}(s_t, a_t) + \alpha \times [r_t + \gamma \times \max(Q(s_{t+1}, a_t) - Q_{\text{old}}(s_t, a_t))]$$

- α = Learning Rate <-> Ausmaß in dem neue Erfahrungen alte Überlagern
- γ = Discountfactor <-> Bedeutung zukünftiger Belohnungen


Deep Q-Learning (DQN)

Anstatt: Q-Tables

	laden	entladen
t=0	$Q(s_0, a_0)$	$Q(s_0, a_1)$
t=1	$Q(s_1, a_0)$	$Q(s_1, a_1)$
t=2	$Q(s_2, a_0)$	$Q(s_2, a_1)$
...
t = 95	$Q(s_{95}, a_0)$	$Q(s_{95}, a_1)$

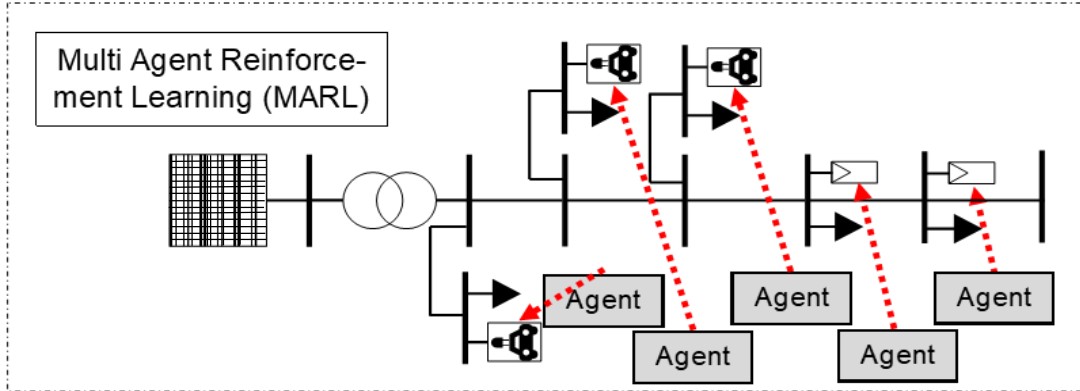
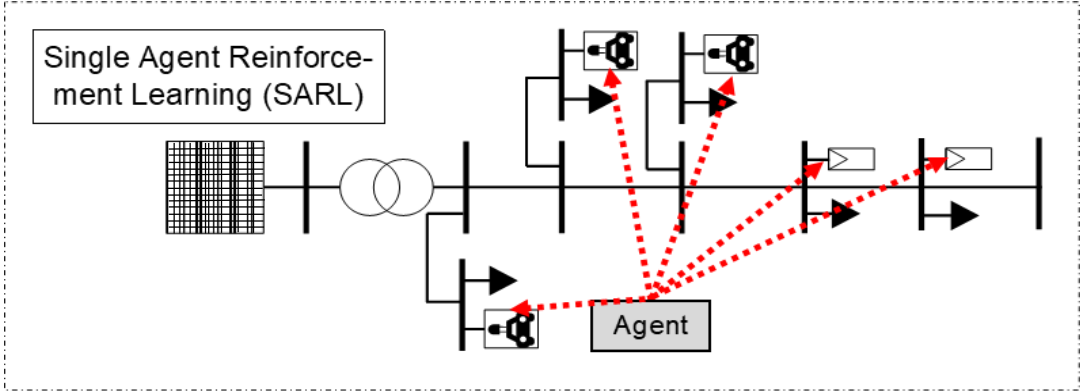


Deep Neural Networks

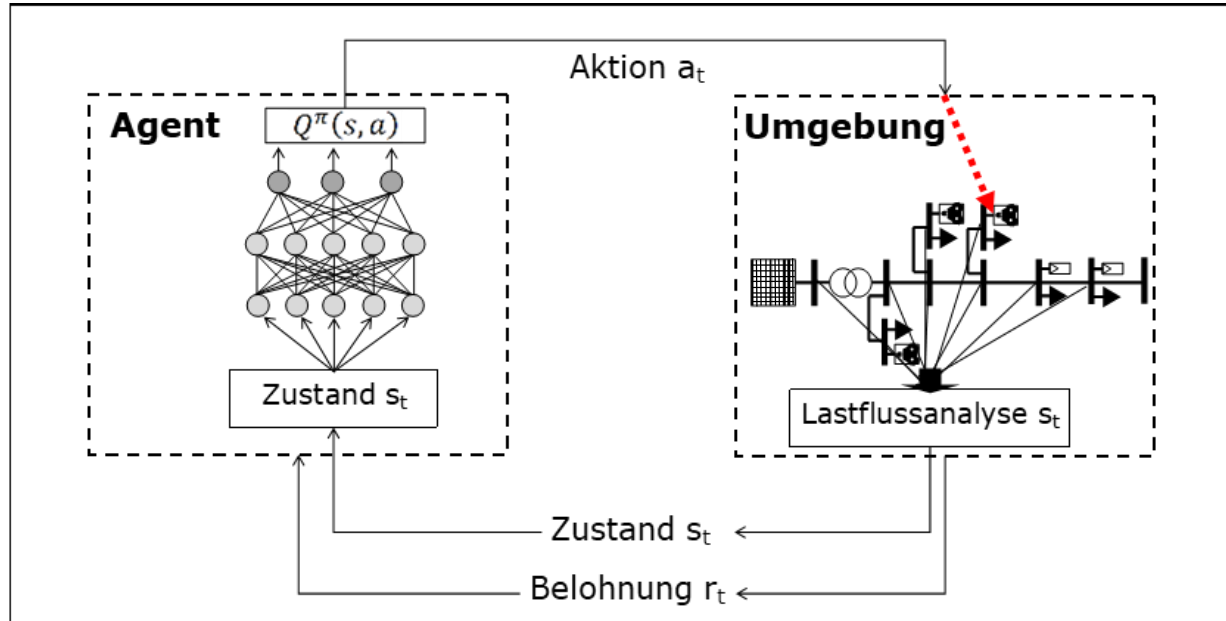


SARL vs MARL

In DQN:



RL in Niederspannungsnetzen



RL in Niederspannungsnetzen

Parameter	Stand der Technik		
	J. Duan (1)	D. Didden (2)	M. Kelker (3)
Methode	DDPG, DQN	DQN	DDQN, DQN
Umgebung	200 Knoten Netz	29 Knoten, PV, Wärmepumpen	12 Knoten, 2 Stränge, PV, Elektromobilität
Zustand	Spannungsdaten	Kalenderdaten, SoC Batterie, Nutzleistungsprognose	Strom- und Spannungsdaten, Zeit, alte Aktionen jedes Agenten
Reward	R_{voltage}	$R_{\text{voltage}}, R_{\text{line}}, R_{\text{trafo}}, R_{\text{losses}}$	$R_{\text{voltage}}, R_{\text{trafo}}$
Agent	SARL	SARL, MARL	MARL
Aktionen	Einstellwerte von Generatoren	Batterieleistung, Einschränkung der PV-Leistung	Ladeleistung, Batterieleistung

Ergebnisse

- Offline und online trainierte SARL-Agenten mit einer zentralen Steuerung für Batterien reichen nicht aus, um besser zu sein als normale Controller (2)
- Fortgeschrittenen RL-Agenten, können bessere Ergebnisse erzielen als die meisten der betrachteten Regler (2)
- Reduzierung der Transformatorleistung um 24.4 % (3)
- Erhöhung der Energie der dezentraler Energieanlagen um 10 % (3)
- Einhaltung des Spannungsgrenzen (1,2,3)

Kritik an RL

- Bisherige Ergebnisse basieren auf Simulationen
- Detailgrad der Simulation und Qualität der Eingabedaten bestimmen die Ergebnisse
- Homogenität der Lerndaten
- Große Mengen an Daten notwendig
- Deep Neural Networks sind Blackbox Modelle
- “reality gap” – RL Modell kann nicht im realen Netz trainiert werden

Fazit und Ausblick

- Vielversprechende Ergebnisse mit RL Steuerungsmethodik für die Netzstabilität im Niederspannungsnetz
- Viele und hohe Qualität an Daten von Nöten
- Probleme mit Deep Learning im Allgemeinen (Blackbox Model und „reality gap“)
- Validierung im Feld notwendig!



**Vielen Dank für
Ihre Aufmerksamkeit.**

Kontakt:

Lars Quakernack, B.Eng.
Fachhochschule Bielefeld
Arbeitsgruppe Netze und Energiesysteme

E-Mail: lars.quakernack@fh-bielefeld.de

Telefon: +49.521.106-70341

EnInnov2022

17. Symposium Energieinnovation | 16.02.–18.02.2022



Referenzen

- (1) J. Duan, "Deep-Reinforcement-Learning- Based Autonomous Voltage Control for Power Grid Operations". In: IEEE Transactions on Power Systems 35.1, (2020).
- (2) D. Didden, "Sample efficient reinforcement learning with domain randomization for automated demand response in low-voltage grids". In: IEEE Journal of Emerging and Selected Topics in Industrial Electronics (2021).
- (3) M. Kelker, "Multi agent deep Q-reinforcement learning for autonomous low voltage grid control". In: IEEE PES Innovative Smart Grid Technologies Europe (ISGT Europe), (2021).
- (4) Bundesregierung Klimaschutzprogramm 2030 [Online] <https://www.bundesregierung.de/bregde/themen/klimaschutz/klimaschutzprogramm-2030-1673578> [letzter Zugriff 06. Januar 2021]
- (5) Umweltbundesamt, Erneuerbare Energien in Zahlen [Online] <https://www.umweltbundesamt.de/themen/klima-energie/erneuerbare-energien/erneuerbare-energien-in-zahlen#strom> [letzter Zugriff: 09.02.2022]
- (6) Volodymyr Mnih, Koray Kavukcuoglu, David Silver, Andrei A. Rusu, Joel Veness, Marc G. Bellemare, Alex Graves, Martin Riedmiller, Andreas K. Fidjeland, Georg Ostrovski, Stig Petersen, Charles Beattie, Amir Sadik, Ioannis Antonoglou, Helen King, Dhharshan Kumaran, Daan Wierstra, Shane Legg, and Demis Hassabis. "Human-level control through deep reinforcement learning". In: Nature 518.7540 (Feb. 2015)
- (7) L. P. Kaelbling, M. L. Littman, and A. W. Moore. Reinforcement Learning: A Survey. 1996.