

# **Trainings-, Validierungs- und Benchmarkwerkzeuge zur Entwicklung datengetriebener Betriebs- und Regelungsverfahren für intelligente, lokale Energiesysteme (DARE)**

Das diesem Bericht zugrunde liegende Vorhaben wurde mit Mitteln des Bundesministeriums für Bildung und Forschung (Ausschreibung „Erzeugung von synthetischen Daten für Künstliche Intelligenz“) unter dem Förderkennzeichen 01IS21064 gefördert. Die Verantwortung für den Inhalt dieser Veröffentlichung liegt bei den Autoren

Laufzeit: 10/2021-09/2023

Antragsteller:

- **Universität Paderborn (UPB)**

Ausführende Stellen:

**Software Innovation Lab (SI-Lab)**

Involvierte Zentrale Wissenschaftliche Einrichtungen

- Kompetenzzentrum für nachhaltige Energietechnik (KET)
- Software Innovation Lab (SI-Lab)

Wissenschaftlicher Projektleiter:

Herr Dr.-Ing. Oliver Wallscheid (KET)  
Lehrstuhl: Regelungs- und Automatisierungstechnik  
Warburger Str. 100, D-33098 Paderborn  
E-Mail: [oliver.wallscheid@upb.de](mailto:oliver.wallscheid@upb.de)

Technische Projektleitung:

Herr Dr. Gunnar Schomaker  
Software Innovation Lab  
Zukunftsmeile 2, D- 33102 Paderborn  
Email: [schomaker@sicp.de](mailto:schomaker@sicp.de)

Wissenschaftlicher Partner:

Herr Jun.-Prof. Dr. Sebastian Peitz (SI-Lab)  
Lehrstuhl: Data Science for Engineering  
Warburger Str. 100, D-33098 Paderborn  
E-Mail: [sebastian.peitz@upb.de](mailto:sebastian.peitz@upb.de)

Assoziierte wirtschaftliche Partner:

WestfalenWIND GmbH  
Friedbert Agethen  
Johannes Lackmann  
Vattmannstraße 6, 33100 Paderborn

Externer wissenschaftlicher Partner:

Herr Prof. Dr. Eyke Hüllermeier (SI-Lab)  
Software Innovation Lab  
Zukunftsmeile 2, 33102 Paderborn  
E-mail: [eyke@sicp.de](mailto:eyke@sicp.de)

Westfalen Weser Netz GmbH  
Michael Wippermann  
Mike Süggeler  
Tegelweg 25, 33102 Paderborn

**Förderkennzeichen: 01IS20164**

# 1. Inhaltsverzeichnis

<b>1. Kurzbeschreibung des Forschungsvorhabens .....</b>	<b>3</b>
<b>2. Verfolgte Vorhabenziele .....</b>	<b>4</b>
2.1 <i>Motivation und Aufgabenstellung .....</i>	4
2.1.1 <i>Schwerpunkte und gemeinsame Ziele .....</i>	5
2.1.2 <i>Wissenschaftliche und technische Ziele .....</i>	5
<b>3. Wissenschaft und Technik .....</b>	<b>9</b>
3.1 <i>Stand der Technik .....</i>	9
3.2 <i>Stand der Wissenschaft .....</i>	10
3.3 <i>Abgrenzung des Vorhabens .....</i>	11
<b>4. Kompetenzprofile der Verbundpartner .....</b>	<b>14</b>
4.1 <i>Fachgruppe: Regelungs- und Automatisierungstechnik (RAT) .....</i>	14
4.2 <i>Fachgruppe: Data Science for Engineering (DSE) .....</i>	14
4.4 <i>Assoziierte wirtschaftliche Partner .....</i>	14
4.4.1 <i>WestfalenWIND GmbH .....</i>	14
4.4.2 <i>Westfalen Weser Netz GmbH .....</i>	15
<b>5. Durchgeführte Arbeiten im Vorhaben .....</b>	<b>16</b>
<i>Projektmanagement .....</i>	16
<i>Erstellung eines skalierbaren Simulationsframeworks .....</i>	16
<i>Modellcontainer für energietechnische Basiskomponenten .....</i>	17
<i>Automatisierung der Modellabstraktion .....</i>	17
<i>Visualisierungen und Konfigurierbarkeit .....</i>	18
<i>Die Anwendung von Reinforcement Learning .....</i>	18
<i>Sicherheitsvalidierung mittels Adversarial ML .....</i>	19
<i>Erstellung von standardisierten Benchmarks .....</i>	19
<i>Nutzer- und Code-Dokumentation .....</i>	19
<i>Wissenschaftliche Veröffentlichungen .....</i>	20
<b>6. Wesentliche Ergebnisse und Verwertung der Erkenntnisse .....</b>	<b>21</b>
6.1 <i>Wesentliche Ergebnisse .....</i>	21
6.2 <i>Wissenschaftlich-technische Verwertung .....</i>	22
6.3 <i>Wissenschaftliche und wirtschaftliche Anschlussfähigkeit .....</i>	22
6.4 <i>Nachhaltigkeit der Verwertung .....</i>	23
<b>7. Wichtigste Positionen des zahlenmäßigen Nachweises .....</b>	<b>24</b>
<b>10. Literaturverzeichnis .....</b>	<b>25</b>



## 1. Kurzbeschreibung des Forschungsvorhabens

Dieses Dokument ist der Abschlussbericht des Forschungsvorhabens DARE. Die wissenschaftliche Leitung im Vorhaben ist zum Zeitpunkt der Erstellung des Berichts nicht mehr an der Universität Paderborn angestellt. Bei jeglichen Fragen oder auch Anregungen bitte die technische Projektleitung des Vorhabens kontaktieren.

Dezentrale, elektrische Energienetze stellen besondere Herausforderungen an die Betriebs- und Regelungsverfahren zur Sicherstellung einer durchgängigen und effizienten Energieversorgung. Gegenüber den klassischen, zentralen Großnetzen (bspw. dem Europäischen Verbundsystem) verfügen dezentrale Energienetze i. d. R. über keine oder kaum Schwungmassen zur Stabilisierung der Netzfrequenz und -spannung. Stattdessen werden regenerative und volatile Kraftwerke (insb. Wind & Photovoltaik/PV) sowie (Batterie-)Speicher mittels leistungselektronischer Steller in die lokalen Netze eingebunden. In Kombinationen mit dem stochastischen Leistungsbedarf durch die angeschlossenen Lasten sowie typischerweise nur geringen Speicher- und Reservekapazitäten ist eine sichere Energieversorgung deutlich schwieriger aufrechtzuerhalten als in zentralen Netzen. Weiterhin gilt es beim Betrieb verschiedene Zeitskalen zu differenzieren, welche von der Komponentenregelung im Mikro- und Millisekundenbereich bis hin zum Energiemanagement mit Zeithorizonten von Stunden, Tagen oder sogar Wochen reichen. Dezentrale Energienetze sind zudem äußerst heterogen, da diese je nach Anwendungsgebiet vollständig anders ausgerichtet sind: industrielle, lokale Stromnetze sind typischerweise auf Kostenoptimierung ausgelegt und wurden durch Experten sorgfältig geplant und angelegt, während die Energieversorgung für abgelegene, ländliche Dörfer oder auch Farmen (bspw. in Sub-Sahara Afrika) typischerweise autonom und ohne Experteneingriffe funktionsfähig sein müssen.

Zum Betrieb und Regelung derart stochastischer, heterogener und volatiler Energienetze können die traditionellen Top-Down-Strategien zentraler Großnetze nicht übertragen werden. Stattdessen zeichnen sich datengetriebene und selbstlernende Verfahren, bspw. aus dem Bereich des Reinforcement Learning, als mögliche Lösungen ab. Aufgrund von Sicherheits- und Verfügbarkeitsaspekten können diese lernenden und neuartigen Regelungsverfahren aber nicht unmittelbar im Feld eingesetzt werden, sondern müssen zunächst auf Basis synthetischer Daten in einem geschlossenen Simulationszyklus verbessert und bewertet werden. Bisherige Lösungsansätze sind ebenfalls sehr heterogen und orientieren sich häufig an derart stark vereinfachten Modellumgebungen, sodass keinerlei Aussagen über einen zukünftigen Praxistransfer möglich sind. Zudem gibt es keinen etablierten Vergleichsstandard anhand dessen datengetriebene Regler objektiv und quantifizierbar bewertet werden könnten.

Ziel dieses Projekts war es daher ein Open-Source Simulations- und Benchmarkframework aufzubauen, welches den oben skizzierten Problemrahmen beim Betrieb dezentraler Energienetze abbilden kann. Durch leicht zugängliche, sowie standardisierte Trainings-, Validierungs- und Benchmarkwerkzeuge, soll die Erforschung datengetriebener Regler für die Energietechnik beschleunigt und vergleichbar gemacht

werden. Die Integration wirtschaftlicher Partner aus der energietechnischen Domäne hat hierbei einen großen Beitrag auf die Abbildung realistischer Bewertungsszenarien beigesteuert. Das zu erstellende Open-Source Framework wird daher auch nach dem Ende des Vorhabens einen wichtigen Beitrag zum bilateralen Transfer im Kontext datengetriebener Regler von der Simulation bis zum Feldeinsatz leisten.

## 2. Verfolgte Vorhabenziele

### 2.1 Motivation und Aufgabenstellung

Die Transformation unseres derzeitigen Energieversorgungssystems auf eine nachhaltige und durch erneuerbare Energien geprägte Struktur ist eine zentrale gesellschaftliche Herausforderung des 21. Jahrhunderts. Hierfür erfordert die inhärente Volatilität erneuerbarer Energiequellen eine Abkehr von konventionellen, hierarchisch strukturierten Top-Down-Energienetzen hin zu flexiblen, sektorübergreifenden und intelligenten Energiesystemen. Daher stellen im Zuge der Energiewende zellulare und dezentrale Energiesysteme, sog. Microgrids ( $\mu\text{G}$ ), eine wichtige Lösungskomponente dar, um auch zukünftig eine nachhaltige, effiziente und kostengünstige Energieversorgung zu gewährleisten. Als  $\mu\text{G}$  wird das Konzept eines lokalen Netzes bezeichnet, welches aus Energiequellen (z. B. Windkraftanlagen), -speichern (z. B. Batterien) und -verbrauchern verschiedener Sektoren (z. B. Elektrizität, Wärme, Mobilität) besteht (vgl. Abb. 1). Durch die lokale Integration regenerativer Energien mittels  $\mu\text{G}$ , z. B. innerhalb von Industrieunternehmen oder Wohnquartieren, wird Energie lokal erzeugt und genutzt. Die überregionalen Energienetze werden entlastet, womit der Bedarf für den Netzausbau sinkt. Der Anteil der regenerativen Energien erhöht sich, da der verlustbehaftete Transport über große Distanzen als auch unnötige Abschaltungen regenerativer Kraftwerke aufgrund von Netzengpässen (sog. Einspeisemanagement) vermieden werden. Ein  $\mu\text{G}$  kann hierbei sowohl netzgekoppelt als auch autonom im Inselbetrieb operieren, wobei Letzteres der typische Fall für abgelegene, netzferne Areale darstellt. Neben dem Beitrag zur Energiewende in Europa stellt das  $\mu\text{G}$  daher auch einen zentralen Baustein zur Herstellung der grundsätzlichen Energieversorgung in Schwellen- und Entwicklungsländern (insb. Sub-Sahara Afrika) dar, da dort der Aufbau einer zentralen Energieinfrastruktur im dünnbesiedelten, ländlichen Räumen auch langfristig nicht in Aussicht steht.

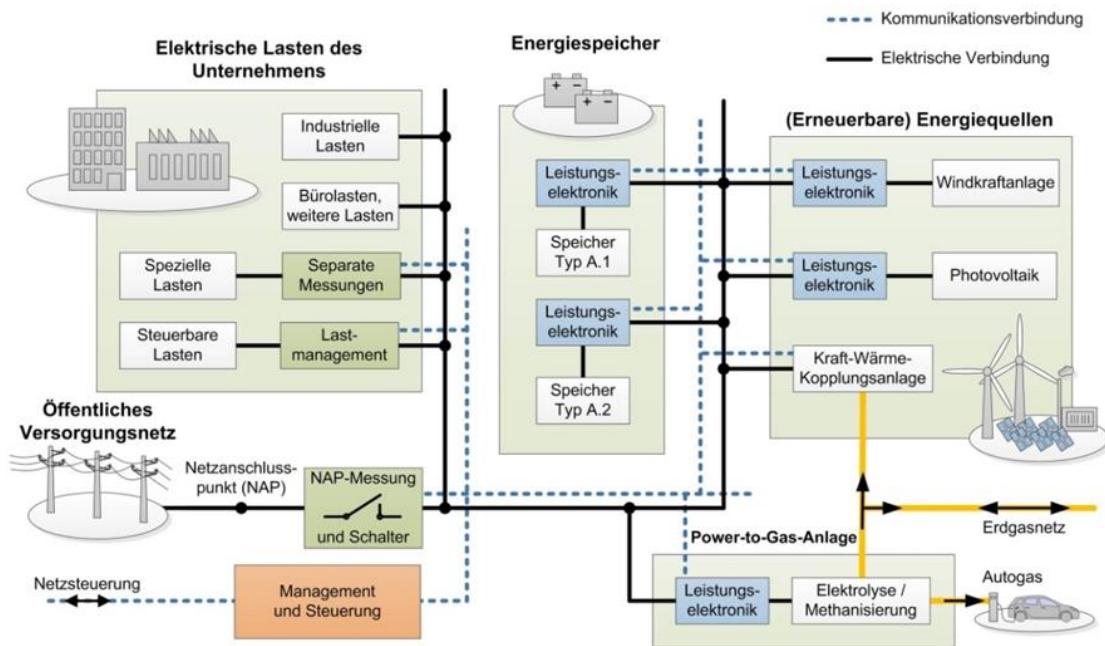


Abbildung 1: Beispielhafte µG-Struktur für einen industriellen Anwender

### 2.1.1 Schwerpunkte und gemeinsame Ziele


Eine zentrale Hürde zur Etablierung von µGs ist der sichere Betrieb bei gleichzeitig maximaler Ausnutzung der installierten Infrastruktur bzw. der verfügbaren Ressourcen (Zielkonflikt). Die Komponenten (z. B. Erzeuger, Verbraucher, Speicher) in µGs sind z. T. hochgradig heterogen und komplex im Eigenverhalten. Sie weisen im Betrieb eine signifikante stochastische Komponente auf, welche auf Erzeugungsseite häufig durch die Volatilität der regenerativen Kraftwerke (wetterabhängig) und auf Lastseite durch die nur bedingte Vorhersagbarkeit der angeschlossenen Verbraucher (bspw. manuell aktivierte Produktionsprozesse in Industrieunternehmen oder auch wetterabhängige Klimatisierungsbedarfe) bedingt sind. Auch gilt es zahlreiche Betriebsgrenzen, wie z. B. unterschiedliche Übertragungskapazitäten der Leitungsnetze oder auch die limitierte Leistungsfähigkeit der Energiespeicher (Entladetiefe, max. Leistungsaufnahme/-abgabe) einzuhalten, da deren Überschreitung sich sicherheitskritisch auswirkt. Auch erfordert der Betrieb von µGs eine Orchestrierung der Regelungsstrategien auf verschiedenen Zeitskalen. Auf der Ebene der Komponentenregelung (bspw. leistungselektronische Konverter) werden die Entscheidungen im Mikrosekundenbereich getroffen, während im Energiemanagement Entscheidungszeiträume eher im Bereich von Stunden oder sogar Tagen bis Wochen anzusiedeln sind. Klassische Methoden der Regelungstechnik werden zur Lösung dieses komplexen Problemgefüges als nicht optimal erachtet, da diese i. A. auf Heuristiken oder vereinfachende Annahmen mit großen Sicherheitsmargen zurückgreifen und zudem einen sehr hohen systemspezifischen Applikationsaufwand erfordern.

### 2.1.2 Wissenschaftliche und technische Ziele

Ein vielversprechender und gewählter Lösungsweg stellt das Reinforcement Learning (RL) als datengetriebenes, adaptives Regelungskonzept aus dem Bereich des maschinellen Lernens (ML) dar. Die Methodik wurde bereits bei ähnlich komplexen und stochastischen Problemen (Robotik, Börsen-

Trading, etc.) erfolgreich angewandt. Gegenüber den üblichen Experten basierten, individuell applizierten Regelungsstrategien liegen die Hauptvorteile in der Generalisierbarkeit, sowie im prinzipbedingten Optimierungsansatz für RL-basierte Ansätze. Die Erforschung  $\mu$ G-spezifischer RL-Strategien ist dennoch mit einem hohen Risiko behaftet, da die Sicherheit und Verfügbarkeit von Energienetzen höchsten Anforderungen genügen muss: bereits eine singuläre Fehlentscheidung kann zu partiellen Ausfällen durch Defekte oder zu einem vollständigen Systemversagen (Black-Out) führen. Mangels mathematisch beweisbarer Garantien ist der Einsatz datengetriebener Steuerungs- und Regelungsmethoden des ML, für die keine analytisch-geschlossenen regelungstechnischen Stabilitätsgarantien existieren, in diesem Zusammenhang äußerst herausfordernd.

Gegenüber dem (un-)überwachten ML erfordert das RL eine ad-hoc Datengenerierung. Die erforderlichen Daten zum Training, zur Validierung und Bewertung von RL-basierten Regelungsstrategien müssen online zur Laufzeit des ML-Verfahrens erzeugt werden (vgl. Regelkreis in Abb. 2), da die Entscheidungen eines gegebenen RL Algorithmus die zukünftigen Zustände des zu regelnden Systems unmittelbar beeinflussen. Die Erzeugung der Daten entspricht hierbei der Systemreaktion der behandelten dezentralen Netze inkl. der Nachbildung der angeschlossenen Sensorik im Kontext einer dynamischen Simulation. Eine asynchrone Datengenerierung gefolgt von einer zeitlich entkoppelten Datennutzung, wie im (un-)überwachten ML, ist nicht möglich. Wesentliches Teilergebnis dieses Vorhabens ist daher nicht die synthetische Generierung von statistischen Daten, sondern von dynamischen Simulationsumgebungen mit dessen Hilfe sich interessierter Nutzer Daten ad-hoc entsprechend des in Abb. 2 dargestellten Regelkreises selbst erzeugen können.



**Abbildung 2: Sequenzielle Entscheidungsfindung im Reinforcement Learning erfordert ad-hoc Datengenerierung**

Aufgrund höchster Sicherheitsanforderungen von energietechnischen Systemen sowie der geringen Verfügbarkeit von abgesicherten Reallaboren im Kontext lokaler Energienetze ist eine direkte, labortypische Erprobung von RL Methoden im besagten Anwendungsfeld äußerst schwierig. Darüber hinaus befinden sich die Forschungsaktivitäten zu Einsatz und Ertüchtigung von RL Methoden in  $\mu$ Gs

noch im Grundlagenstudium, sodass simulative Evaluierungen auf Basis synthetischer Daten angezeigt sind, bevor ein Praxistransfer auf realen Anlagen erfolgen sollte.

Zur Wahrung eines hohen Realitätsgrads der Simulationsumgebung stehen dem Projektkonsortium skalierte Prototypen von dezentralen Energienetzen in Labormaßstab zur Verfügung, sodass Simulationsergebnisse gegenüber echten Messungen validiert werden können (zunächst außerhalb geschlossener Regelschleifen). Zudem vernetzt sich das Projekt mit weiteren Initiativen im Anwendungskontext, wie z.B. das [Microgrid-Labor](#) der Universität Paderborn oder der [A:RT-D Grids](#) Initiative. Auch durch die Kooperationen mit den weiteren Partnern aus der industriellen Praxis wird so sichergestellt, dass die Simulationsumgebung und die mit dieser behandelten Fallstudie an realen Beispielproblemen ausgerichtet werden.

Zur Etablierung und Erforschung von RL-Methoden in  $\mu$ Gs können synthetische Daten wesentliche Beiträge in Form von Trainings-, Validierungs- und Benchmarkwerkzeugen liefern. Im Projekt wurden hierzu eine quelloffene Entwicklungstoolbox erarbeitet und dabei die folgenden Schwerpunkte berücksichtigt:

- **Simulationsmodelle:** Damit RL-Methoden trainiert und bewertet werden können sind skalierbare, dynamische Modelle zur Abbildung des Verhaltens der zu regelnde Systeme (hier  $\mu$ Gs) entsprechend Abb. 2 notwendig. Dies umfasst eine heterogene Landschaft unterschiedlicher energietechnischer Komponenten sowie die flexible Verschaltung dieser Komponenten hin zur Abbildung beliebiger Netzwerktopologien. Des Weiteren sind je nach Betrachtungshorizont (Komponentenregelung bis hin zum Energiemanagement) unterschiedliche Modellklassen mit veränderlichem Detailgrad vorzusehen, um sowohl sehr fein aufgelöste Simulationen im Mikrosekundenbereich bis hin zu stärker abstrahierten Modellen im Stunden- oder Tagesrhythmus ableiten zu können. Technisch musste dies durch die Entwicklung strukturveränderlicher, differenzial-algebraischer Gleichungssysteme mit flexibler Parametrierung, sowie einer automatischen Modellreduktion gelöst werden. Wobei die Modellreduktion letztendlich ob der überschaubaren Komplexität und der hohen Performance der Entwicklung nicht notwendig war.
- **Validierung (Sicherheit):** Aufgrund des Black-Box Charakters von RL-basierten Regelungsverfahren sowie durch die hohe Komplexität und Heterogenität von  $\mu$ Gs ist eine Bewertung der Betriebssicherheit nicht durch analytisch-geschlossene Methoden möglich. Stattdessen wurden im Projekt datengetriebene Verfahren aus dem Bereich des Adversarial MLs eingesetzt, um sicherheitskritische Betriebssituationen durch Manipulation der einstellbaren Simulationsparameter zu generieren.
- **Benchmarking:** Das RL ist ein äußerst dynamischer Wissenschaftszweig, der in kurzen Zeitintervallen neue Verfahren zur Regelung komplexer Systeme hervorgebracht hat und auch weiterhin regelmäßig neue Methoden einführt. Die Bewertung von RL in der

Anwendungsdomäne intelligenter, lokaler Energienetze sollte daher auch standardisierten Testfällen unterzogen werden, um eine objektive Vergleichbarkeit sicherzustellen. Durch die Einbindung wirtschaftlicher Partner aus der energietechnischen Praxis wurde hierbei großer Wert auf eine realistische Szenariendefinition gelegt, sodass die erarbeitete Toolbox auch einen wichtigen Beitrag hin zum bilateralen Erkenntnistransfer leisten konnte.

- **Lösungsdemonstration:** Die Erforschung von datengetriebenen, selbstlernenden Regelungsverfahren in sicherheitskritischen Anwendungen mit vielfältigen Zustands- und Aktionsbeschränkungen befindet sich nach wie vor im Grundlagenstadium. Wissenschaftlich ist es eine noch nicht final geklärte Fragestellung, wie lernende und explorierende Regler in (teilweise) unbekanntem Anwendungsumgebungen einen sicheren Betrieb, ohne die Verletzung von Systemgrenzen realisieren sollen. Der Einsatz und Nutzen der Toolbox konnte anhand RL-basierter Lösungsalgorithmen demonstriert werden, und das Problembewusstsein in der wissenschaftlichen Community schärfen. Insbesondere konnten im Kontext des Projekts einzelne Lösungsbeiträge auf diesem Gebiet publiziert werden.

Der aktuelle primäre Projektoutput ist eine quelloffene Softwaretoolbox zur Entwicklung datengetriebener Lösungen in der Energiesystemtechnik, welche kollaborativ und offen bzw. für die wissenschaftliche und industrielle Gemeinde nutzbar. Alle Projektergebnisse und Softwarebausteine wurden vollständig mittels Open-Source umgesetzt. Die Veröffentlichung des Quellcodes inkl. Anwendungsbeispielen und Dokumentation erfolgte über GitHub, sodass diese der interessierten Öffentlichkeit ohne Einschränkungen die Ergebnisse zur Verfügung stehen.

### 3. Wissenschaft und Technik

#### 3.1 Stand der Technik

Die Erforschung von Regelungs- und Betriebsstrategien für  $\mu$ Gs ist eine zentrale Herausforderung der Energietechnik und gewinnt als Baustein der Energiewende zunehmend an Bedeutung (VDE Verband der Elektrotechnik Elektronik Informationstechnik e.V., 2019). Die Aufgabe erfordert Regelungseingriffe auf verschiedenen Zeitskalen und es muss zwischen den Modi im netzgekoppelten Betrieb sowie Inselnetzbetrieb differenziert werden (vgl. Abb. 3, (Guerrero, Chandorkar, Lee, & Loh, 2013))

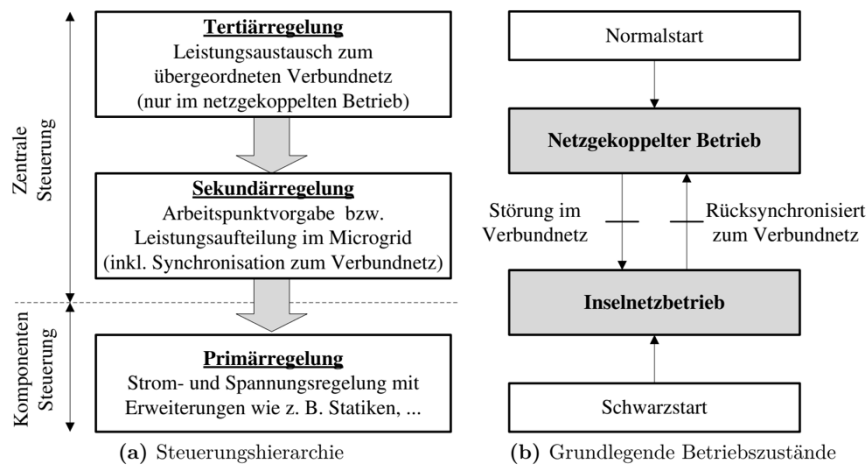


Abbildung 3: Steuerungshierarchie und Betriebszustände von  $\mu$ Gs

Darüber hinaus stellen  $\mu$ Gs verteilte Systeme dar, d. h., dass sowohl innerhalb eines  $\mu$ Gs mehrere Komponenten (Erzeuger, Lasten, Speicher) miteinander in Einklang gebracht werden müssen als auch dass lokal benachbarte  $\mu$ Gs im Sinne eines zellularen Ansatzes miteinander kooperieren (virtuelle Kraftwerke), um ihre jeweilige Systemstabilität bzw. Verfügbarkeit zu erhöhen oder um netzdienliche Leistungen für Verteil- und Übertragungsnetze zu erbringen. Für diese Koordinationsaufgabe sind verschiedene Regelungs- und Kommunikationstopologien denkbar (vgl. Abb. 4, (Meng, et al., 2017)).

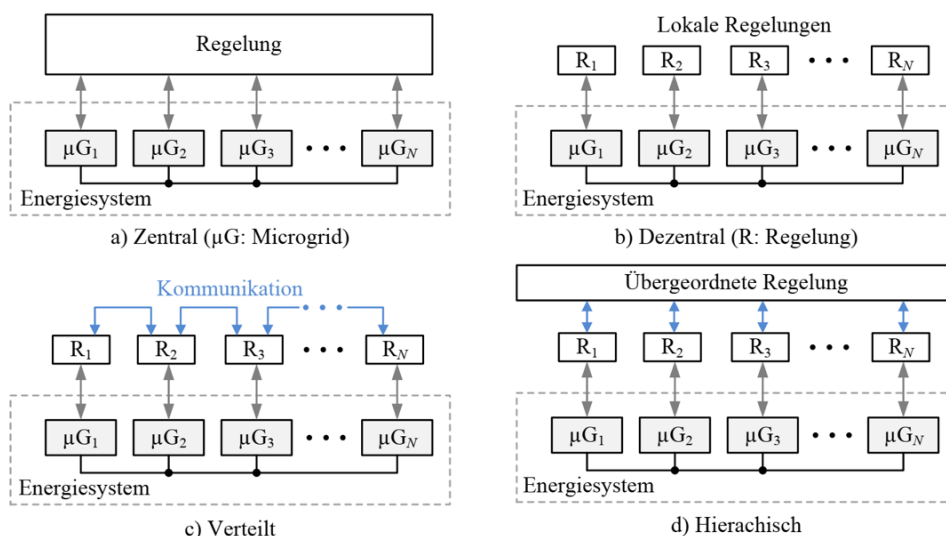


Abbildung 4: Konzepte zur Koordinierung mehrerer  $\mu$ Gs bzw. der Komponenten innerhalb eines  $\mu$ Gs

Die Erarbeitung von Regelungs- und Betriebsstrategien für  $\mu$ Gs steht somit einer enormen, nahezu nicht eingrenzbar Variantenvielfalt inklusive stochastischer Einflüsse auf Seite des zu regelnden Energiesystems gegenüber. Aufgrund dieser Komplexität konnten aus dem Bereich der klassischen, expertenbasierten Regelungsstrategien noch keine zielführenden, universell anwendbaren Lösungen gefunden werden. Stattdessen werden für konkrete Anwendungsfälle, also einzelne  $\mu$ Gs z. B. in Form eines Reallabors, vollständig individuelle Regelungskonzepte mit hohem Applikationsaufwand neuentwickelt und ausgerollt. Dieser Aufwand stellt ein zentrales Hemmnis zur Etablierung von  $\mu$ Gs dar, welcher zukünftig durch den Einsatz selbstlernender, datengetriebener Regelungsansätze aus dem Bereich des RLs reduziert werden soll (Generalisierbarkeit). Als Schnittstelle zu den gängigen RL-Toolboxen wie Keras-RL2 (Keras RL2, 2021) oder Stable Baselines3 (Raffin, et al., 2019) hat sich OpenAI Gym (Brockman, et al., 2016) als Stand der Technik etabliert (siehe Abbildung 5).




Abbildung 5: OpenAI Gym Schnittstelle zwischen zu regelndem System und Agenten

### 3.2 Stand der Wissenschaft

Der Einsatz von RL-Techniken in Bezug auf lokale Energienetze ist ein aktuelles Forschungsgebiet mit ersten, vielversprechenden Veröffentlichungen (Zhang, Zhang, & Qiu, 2020) (Yang, Zhao, Li, & Zomaya, 2020) (Huang, et al., 2019). Die Arbeiten hierbei konzentrieren sich allerdings nur auf ausgewählte Betriebsaspekte in  $\mu$ Gs, wie beispielsweise der ökonomische Energiehandel zwischen  $\mu$ Gs (Wang, Liao, Abu-Rub, & Chen, 2016) (Lu, et al., 2019), Demand Response (Li, Wan, & He, 2020) oder das Energiemanagement anhand von stark vereinfachten  $\mu$ G Systemmodellen (Mbuwir, Ruelens, Spiessens, & Deconinck, 2017) (Kuznetsova, et al., 2013) (Sogabe, et al., 2018) (Foruzan, Soh, & Asgarpoor, 2018) (Xi, et al., 2015) (Leo, Milton, & Sibi, 2014) (vgl. Abb. 3) mit teils nicht einsehbaren bzw. nachvollziehbaren Close-Source Lösungen. Arbeiten wie (Zhou, Zhou, Mao, & Xi, 2020) verdeutlichen den Mangel an vorhandenen Daten und suchen in Teilaspekten eines  $\mu$ Gs nach ersten

Lösungsansätzen, was den Bedarf an der Erzeugung adäquater synthetischer Daten verdeutlicht (Arwa & Folly, 2020) (A. Marot et al., 2021).

Demgegenüber werden bei den bisher vorgelegten Arbeiten die folgenden Aspekte vernachlässigt:

- **Vergleichbarkeit:** Jede Publikation baut auf eigenen, teils stark akademisch vereinfachten, beispielhaften  $\mu$ G Systemmodellen auf. Die Modelle sind i. d. R. zudem nicht öffentlich verfügbar und/oder bauen auf proprietär-geschlossener Software (häufig Matlab/Simulink, aber auch HOMER) auf. Ein quantifizierender Vergleich anhand statistischer Gütekriterien bezüglich der vorgeschlagenen RL-Lösungsansätze ist somit nicht möglich.
- **Skalierbarkeit:** Ebenso werden RL-Algorithmen bisher lediglich an vereinzelt und stationären  $\mu$ G Topologien erprobt. Eine Überprüfung, ob ein vorgeschlagener Lösungsweg auch für verschiedene  $\mu$ G Szenarien tragfähig ist, findet nicht statt. Auch wird i. A. lediglich eine Zeitskala bzw. Regelungsebene entsprechend Abb. 3 betrachtet, sodass das Zusammenspiel von RL-Ansätzen auf verschiedenen Zeitskalen bisher unerforscht ist.
- **Sicherheit / Verfügbarkeit:** Energietechnische Anlagen und Systeme unterliegen vielfältigen Beschränkungen hinsichtlich des erlaubten Zustandsraums. Werden diese Grenzen überschritten, fährt die Anlage in den Not-Aus, was die Verfügbarkeit der Energieversorgung in einem  $\mu$ G gefährdet. Soll ein RL-Algorithmus die Vorgänge in einem  $\mu$ G steuern ist sicherzustellen, dass die Energieversorgung maximal verfügbar bleibt, auch unter atypischen Nutzungsszenarien. Dies wird in bisherigen Publikationen nicht gewürdigt, da exogene Betriebsparameter, wie beispielsweise Lastgänge oder Wetterszenarien, nur durch statische Datenreihen und stationäre Zufallsprozesse abgebildet werden.

### 3.3 Abgrenzung des Vorhabens

Auch nach Abschluss des Vorhabens fehlt es an standardisierten, offenen sowie skalierbaren Werkzeugen zur Generierung synthetischer Daten für das Training, die Validierung und Benchmarks im RL, um die Entwicklung datengetriebener Betriebs- und Regelungsverfahren für lokale Energiesysteme voranzutreiben und somit wichtige Vorarbeiten für einen Transfer in die Anwendung zu leisten. Bereits verfügbare Open-Source Werkzeuge für Energiesysteme, insbesondere PyPSA (Brown, Hörsch, & Schlachtberger, 2018) und pandapower (Turner, et al., 2018), sind nach wie vor nicht geeignet, da diese nur stationäre Modelle ohne dynamische Systemeigenschaften verwenden und großskalige Energiesysteme auf Übertragungs- und Verteilnetzebene fokussieren. Weitere Open-Source Beispiele wie MATPOWER (Zimmerman, Murillo-Sanchez, & Thomas, 2011) oder PSAT (Milano, Vanfretti, & Morataya, 2008), ein Matlab-basiertes Projekt, besitzen ähnlich wie in den vorhergenannten, keine dynamische Modellierung und darüber hinaus oft spärliche bis überhaupt keine Dokumentation. Ebenso lassen die genannten Beispiele eine OpenAI Gym Schnittstelle, welche sich in den aktuellen RL-Bibliotheken als Standardschnittstelle für gängige Algorithmen etabliert hat, sowie Skalierbarkeit vermissen. Zwar sind Projekte vorhanden, die eine OpenAI Gym Schnittstelle liefern, wie GridAlive

(France, GridAlive, 2021) und auch erste Ansätze zur synthetischen Datengenerierung (Auflösung jedoch im Minutenbereich) wie Chronix2Grid (ChroniX2Grid, 2021), dennoch konzentrieren sich diese sowie die unterlagerten Tools wie zum Beispiel Grid2Op (France, Grid2Op, 2021) bzw. der Vorgänger Pypowernet (France R. a., 2021) (noch ohne OpenAI Gym Schnittstelle) auf stationäre Modelle auf sekundärer bzw. tertiärer Regelungsebene. Dies gilt ebenso für daraus entstandene Wettbewerbe (Antoine, et al., 2021) welche dazu gedacht sind Benchmarks zu etablieren. Dem sich anschließend genannt werden können weitere Open-Source Werkzeuge wie RLGC (Reinforcement Learning for Grid Control) (Huang, et al., 2019), pymgrid (Gonzague, Tanguy, Avishai, Reda, & Cordier, 2020) oder PowerModels.jl (Coffrin, Bent, Sundar, Ng, & Lubin, 2018), welche teils intern definierte Benchmarks mit Zeitauflösungen im Stundenbereich liefern, sich jedoch ebenso auf stationäre Modelle ausschließlich großskaliger Energiesysteme konzentrieren.

Darüber hinaus müssen im Kontext der dynamischen Simulation von Energienetzen die wichtigsten kommerziellen Werkzeuge wie Simscape (Mathworks, Simscape, 2020), LTspice, PLECS oder ngspice genannt werden. Ersteres kann für die abgezielten Zwecke verwendet werden, stellt aber eine Closed-Source Lösung dar und bietet darüber hinaus keine direkte Schnittstelle wie OpenAI Gym zu gängigen RL-Bibliotheken. Zwar kann diese wie in (Mathworks, MATLAB Engine API for Python, 2020) beschrieben nachträglich eingerichtet werden, ist aber mit einem erheblichen Mehraufwand an Berechnungszeit verbunden, was eine essenzielle Hürde in der in Abb. 2 beschriebenen ad-hoc Datengenerierung darstellt. Die SPICE-basierten Closed-Source Programme fokussieren darüber hinaus die detaillierte Simulation der leistungselektronischen Steller und Bauteile im Nanosekundenbereich, was sie für die abgezielten Zeitskalen nicht praktikabel einsetzbar macht. Zudem existieren bereits kommerzielle Beispiele wie HOMER (Energy, 2021), welche aber wie die oben genannten Open-Source Lösungen auf die Sekundär- bzw. Tertiärer Regelungsebene zur stationären Modellierung und insbesondere überschlägigen Auslegung von Energienetzen abzielen.

Die in der Literatur vorhandenen verschiedensten Benchmark-Definitionen wie (Syed A. & Jin) oder (Melike Selcen, Rasoul, & Vladimir, 2018) zielen wie die meisten oben genannten Simulationswerkzeuge auf stationäre Modelle großskaliger Energiesysteme ab. Ebenso genannt werden soll hier die *IEEE PES PGLib-OPF Task Force* welche unter anderem in (Babaeinejadsarookolae, et al., 2021), welche auf Leistungsfluss-Ebene eine mit dem kommerziellen Tool MATPOWER generierte Benchmark Bibliothek (PES Task Force on Benchmarks for Validation of Emerging Power System Algorithms, 2021) zur Verfügung stellt. Da diese Benchmarks nur bei stationären Modellen ohne dynamische Systemeigenschaften auf tertiärer bzw. sekundärer Regelungsebene Anwendung finden und eine Skalierbarkeit vermissen lassen, lässt sich damit nicht hinreichend eine Validierung eines RL-Reglers insbesondere in Hinblick auf die im vorherigen Kapitel genannten Aspekte der Sicherheit und Verfügbarkeit von Energienetzen gewährleisten.

Ansätze zur Validierung mit Fokus auf die Punkte Sicherheit und Verfügbarkeit finden sich bisher kaum in der Literatur. Erste Ansätze wie (Zhang, Dehghanpour, Wang, Qiu, & Zhao, 2020) zielen hierbei auf

höhere Regelungsebenen ab und lassen dabei ein akkurates Vergleichsmodell und einsehbare, nachvollziehbare Simulationen vermissen.

## **4 Kompetenzprofile der Verbundpartner**

### **4.1 Fachgruppe: Regelungs- und Automatisierungstechnik (RAT)**

Die Fachgruppe Regelungs- und Automatisierungstechnik, in der Umsetzungszeit geleitet durch Herrn Dr. Oliver Wallscheid, beschäftigte sich schwerpunktmäßig mit datengetriebenen Regelungs- sowie Identifikationsverfahren im Kontext intelligenter technischer Systeme. Herr Dr. Oliver Wallscheid hat die Universität Paderborn verlassen. Seine Arbeiten finden in der Schnittstelle zwischen klassischen ingenieurwissenschaftlichen Methoden unter Einsatz von reichhaltigem Experten- und Modellwissen sowie datengetriebenen Verfahren aus den Bereichen des überwachten maschinellen Lernens sowie des Reinforcement Learnings statt. Ziel ist es das Beste aus zwei Welten zu verbinden: Robustheit und Sicherheit durch ingenieurwissenschaftliches Expertenwissen sowie Effizienz und Adaptivität aus dem Bereich des maschinellen Lernens. Anwendungsschwerpunkte bilden die Energie- und Antriebstechnik sowie leistungselektronische Systeme. Bisherige Forschungsprojekte auf diesem Gebiet bilden das Spektrum von der DFG-geförderten Grundlagenforschung bis hin zum industriefinanzierten Transfer ab.

### **4.2 Fachgruppe: Data Science for Engineering (DSE)**

Die Arbeitsgruppe Data Science for Engineering, geleitet durch Jun.-Prof. Dr. Sebastian Peitz, befasst sich mit der Entwicklung von datenbasierten Methoden und maschinellen Lernverfahren im ingenieurwissenschaftlichen Kontext. Genauer geht es unter anderem um die Fragestellung, wie Daten aus verschiedenen Quellen in komplexen Systemen genutzt werden können, um diese zu analysieren, in Echtzeit zu steuern sowie zu optimieren. Letzteres kann auch bezüglich mehrerer, miteinander in Konflikt stehender Ziele erfolgen wie z.B. die Maximierung des Wirkungsgrades bei gleichzeitiger Minimierung des Ressourcenverbrauches.

Eine wichtige Komponente hierbei ist die Approximation des Systemverhaltens aus Daten, um effiziente und gleichzeitig verlässliche Vorhersagen treffen zu können. Je nachdem, ob ein mathematisches Modell vorliegt, können hierzu reale oder aus Computersimulationen generierte Daten sowie Mischformen verwendet werden. Im Gegensatz zu vielen anderen Anwendungsbereichen sind in technischen Systemen Verlässlichkeit und Sicherheit von entscheidender Bedeutung, da Fehlverhalten oder Systemversagen häufig fatale Folgen haben können. Der Verlässlichkeit datenbasierter Verfahren kommt dementsprechend eine hohe Bedeutung zu.

## **4.4 Assoziierte wirtschaftliche Partner**

### **4.4.1 WestfalenWIND GmbH**

Die WestfalenWIND GmbH hat sich die Erschließung und Nutzung regenerativer Energien zur Aufgabe gemacht. Es sind in den letzten Jahren in der Region Ostwestfalen Lippe und dem Kreis Paderborn Windparks, auch unter der breiten Beteiligung der heimischen Bevölkerung entstanden. Unter der Beteiligung versteht das Unternehmen, das die Bürger der Region als Kommanditisten, als „Wind-Genossen“ oder als Verpächter von dieser Entwicklung profitieren. Das Unternehmen liefert regional

erzeugten Strom an Haushalte, Gewerbe und Industrie – quasi „ab Werk“ – und erzeugt so einen nachhaltigen Vorteil aller Beteiligten. Eine große Herausforderung besteht dabei im weiteren Ausbau der Erzeugerstruktur und deren Systemintegration, bei gleichzeitiger Erfüllung der Bedarfe und Anforderungen der Areal- und Verteilnetze.

#### **4.4.2 Westfalen Weser Netz GmbH**

Das Unternehmen Westfalen Weser Netz GmbH (WWN) mit Sitz in Paderborn betreibt regionale Verteilnetze für Strom, Gas und Wasser. Die zentrale Aufgabe des Unternehmens ist die sichere, effiziente und diskriminierungsfreie Bereitstellung des Strom- und Gasnetzes für die Industrie, Gewerbe, die Landwirtschaft und Haushalte. Auch die WWN sieht eine große Herausforderung im weiteren Ausbau der Erzeugerstruktur und deren Systemintegration, bei gleichzeitiger Erfüllung der Bedarfe und Anforderungen der Areal- und Verteilnetze.

## 5 Durchgeführte Arbeiten im Vorhaben

Die nachfolgenden Arbeitsbereiche bildeten die Struktur im Vorhaben und bündeln die Arbeiten bei der Umsetzung der Ziele des Verbundprojekts.

### Projektmanagement

Das Projektbüro im SI-Lab bildete die Anlaufstelle für alle Aufgaben, die außerhalb der wissenschaftlichen Arbeiten lagen. Die Aufgaben waren die Unterstützung der internen Projektkommunikation, die Dokumentation der Fortschritte und (Zwischen-) Ergebnisse, die Kommunikation mit dem Träger und Fördermittelgeber, die Vorbereitung der notwendigen Treffen und Reisen und Außendarstellung des Vorhabens u.a. durch eine Projekthomepage. Zudem wurden der Fortschritt der Arbeiten überwacht und diese entsprechend der Zielerreichung angepasst. Folgend die Illustration des tatsächlichen Arbeitsablaufs.

Arbeits- und Zeitplan		2021		2022				2023			
		III	IV	I	II	III	IV	I	II	III	IV
AP 0	Projektmanagement			M1						M21	
AP 1	Erstellung eines skalierbaren Simulationsframeworks			M1				M15			
AP 2	Modellcontainer für energietechnische Basiskomponenten						M10		M18		
AP 3	Automatisierung der Modellabstraktion und -reduktion										
AP 4	Visualisierung und grundlegende GUI zur Konfiguration							M15		M21	
AP 5	Reinforcement Learning Anwendungsbeispiele							M15		M21	
AP 6	Sicherheitsvalidierung mittels Adversarial ML										
AP 7	Erstellung von standardisierten Benchmarks								M18	M21	
AP 8	Nutzer- und Code-Dokumentation			M4						M21	
AP 9	Wissenschaftliche Veröffentlichungen								M18	M21	
<b>Meilensteine</b>											
Meilenstein 0 bis M3: Technischer Projektstart erfolgt mit Außendarstellung											
Meilenstein 1 zwischen M3 und M15: erstes Lauffähiges, skalierbares Simulationsframework mit ersten Systembeispielen											
Meilenstein 2 zwischen M15 und M26: Reinforcement Learning Trainingspipeline mit konkreten Anwendungsbeispielen											
Meilenstein 3 in M33 mit Projektabschluss und Ergebnis Demonstration & Dokumentation abgeschlossen											

### Erstellung eines skalierbaren Simulationsframeworks

Die Aufgaben in diesem Bereich in der ersten Projekthälfte umfassten die Erarbeitung einer Softwarearchitektur zur Abbildung strukturvarianter differential-algebraischer Gleichungssysteme. Zudem bedurfte es der Erweiterung der Architektur für unterschiedliche Zeitskalen inkl. Abstraktionsmethoden, sodass aus detaillierten Modellen mit kleinen Zeitschritten automatisch vereinfachte Modelle für größere Zeitskalen abgeleitet werden konnten. Eine Herausforderung bildete die Implementierung der Softwarearchitektur als Grundgerüst der Open-Source Softwarelösung, die Einbindung und ggf. Erweiterung numerischer Solver für DAEs und die numerischen Voruntersuchungen anhand beispielhafter, manuell erstellter Modellierungsszenarien. Zudem waren Vergleich und die Auswahl des am besten geeigneten Solvers hinsichtlich Lösungsgeschwindigkeit und dessen numerische Robustheit notwendig. Neben der Erarbeitung einer Modellierungstoolchain, um mit wenigen Zeilen Code beliebige Netzwerkstrukturen entsprechend der vorherigen Architektur abbilden zu können, musste eine leistungsfähigen API, insbesondere in Hinblick auf die simulative Anbindung von datengetriebenen Regelungsverfahren entwickelt werden. Zudem erfolgte die Implementierung von Unit-Tests zur Überprüfung des bisherigen Quellcodes

Das Simulationsframework umfasst so die Aufnahme und Verschaltung von energietechnischen Komponenten hin zu topologisch beliebigen  $\mu$ Gs. Die Modellbildung erfolgt im Zustandsraum, wobei für die Abbildung der verschiedenen Betriebsebenen bzw. resultierenden Zeitskalen dynamische Modellcontainer mit unterschiedlichen Detailgrad vorgesehen werden. Das Framework mündet in der Zusammenstellung eines differential-algebraischen Gleichungssystem für ein zu modellierendes  $\mu$ G, welches über numerische Solver integriert und mit einer RL-Schnittstelle (vermutlich OpenAI Gym) zum Austausch von Zustandsinformationen und Aktionen versehen wird.

Als Ergebnisse standen so eine performante skalierbare Architektur zur Modellierung und Simulation dynamischer Netze und eine auf Ausführbare Simulationsumgebung (Kommandozeilenebene) zur Verfügung.

### **Modellcontainer für energietechnische Basiskomponenten**

Das zuvor ausgearbeitete Modell- und Simulationsframework musste mit konkreten, energietechnischen Modellen (Modellgleichungen) befüllt werden. Hierzu wurden parametrisierbare Komponentenmodelle entwickelt. Diese sind generalisierbar ausgelegt, sodass mit einem Komponentenmodell verschiedene Typen der jeweiligen Komponentenkategorie abgebildet werden können (bspw. ein Batterie-Modellcontainer kann verschiedene Batterietypen wie Li-Ion, Blei-Säure, ... unterschiedlicher Leistungsklassen abbilden). Für die jeweiligen Modellcontainer wurden für Testzwecke konkrete, vorparametrierte Beispiele angelegt. So wurden die besonders relevanten energietechnische Basiskomponenten (z. B. Windkraftanlage, Photovoltaik, Batteriespeicher...) strukturell modelliert und in Containern abgebildet und im Simulationsframework verschaltet. Wichtig war dafür auch die parametrische Komponentenbeschreibung, um Differentialgleichungen zu ergänzen, um die signifikanten Nebenbedingungen abzubilden. Es wurde hierbei nicht die Energietechnik in Gänze abgebildet, sondern nur ein Grundstock an Komponenten, da davon ausgegangen wurde, dass externe Nutzer/innen und Mitwirkende nach und nach weitere Modellcontainer beisteuern würden. Für eine höhere Realitätsnähe wurden auch noch leichte Umweltmodelle eingebunden, die z. B. Auswirkungen auf das Lastverhalten von angeschlossenen Verbrauchern durch das Wetter und dessen Auswirkung erzeugten.

### **Automatisierung der Modellabstraktion**

Ein wichtiges Ziel und Aufgabe war die Erstellung von Algorithmen zur Modellabstraktion und -reduktion, die basierend auf einem fein aufgelöstem und detaillierten Komponentenmodell vereinfachte Modelle zur Simulation längerer Zeitintervalle ermöglichen. Primär sollte eine hohe Genauigkeit dieser Modelle bei gleichzeitiger Performanz erreicht werden. Im Laufe der Entwicklung hat sich jedoch gezeigt, dass die Modellreduktion ob der erreichten Performanz der Entwicklung nicht notwendig war. Praktisch wurde daher nur der Abstraktionsalgorithmus entworfen und implementiert. Ob der Durchführung von Simulationsstudien zu Testzwecken, der Implementierung von Unit-Tests zur Überprüfung der Modellabstraktion und der Bewertung wurde der Reduktionsalgorithmus nicht weiter betrachtet.

Die Notwendigkeit der Aufgabenstellung ergab sich aus der DNA energietechnische Systeme. Sie müssen und können auf unterschiedlichen Zeitskalen behandelt werden. Auf Komponentenebene (bspw. Batterieumrichter) ist eine Zeitauflösung im Mikrosekundenbereich notwendig, was zur Folge hat, dass das System sehr detailliert und genau simuliert werden muss, allerdings auf Kosten eines hohen numerischen Aufwands. Letzteres bedingt, dass auf Komponentenebene nur kurze Zeitintervalle sinnvoll simuliert werden können. Zur Abbildung größerer Zeitskalen, welche notwendig sind, um überlagerte Regelungsverfahren auf Primär- und Sekundärebene zu evaluieren, müssen notwendigerweise abstrahierte Modelle mit größerer Simulationsschrittweite genutzt werden.

Diese Abstraktion ist i. A. nicht trivial, da die Parameter der Komponentenmodelle nicht ohne Weiteres auf vereinfachte Modelle (z. B. sog. swing equation) umgerechnet werden können. Insofern war der Entwurf entsprechender Algorithmen substanziell. Darüber hinaus ist es für große Netzwerke mit vielen Komponenten sinnvoll, solche Komponentencluster zusammenzufassen. Insbesondere wenn sie benachbart und im Sinne ihres Betriebsverhalten gleichartig sind. Doch diese Modellreduktion zur erhöhten Simulationsgeschwindigkeit war nach Bewertung der Beispielm Modelle nicht notwendig.

### **Visualisierungen und Konfigurierbarkeit**

Sowohl die Visualisierung von Simulationsergebnissen als auch die Darstellung sowie Konfiguration von Netzwerktopologien sollten skalierbar und flexibel sein, da ein Netzwerk typischerweise  $1, \dots, N$  Komponenten enthalten kann. Insbesondere die Darstellungen von Ergebnissen sollte automatisiert erfolgen, aber zudem auch manuelle Eingriffs- und Konfigurationsmöglichkeiten durch den Nutzer ermöglichen. Daher wurde eine graphische Nutzeroberfläche zur einfachen Konfiguration und Zusammenstellung eines  $\mu\text{Gs}$  auf Basis der verfügbaren Komponentencontainern ist umgesetzt. Die Arbeiten umfassten daher auch die rudimentäre grafische Aufarbeitung (Dashboard) von wichtigen Systemzuständen und der Visualisierung von Wechselwirkungen (virtuelle Messgrößen im  $\mu\text{G}$ ) und dem RL-Trainingsfortschritt.

### **Die Anwendung von Reinforcement Learning**

Durch Verschaltung exemplarischer  $\mu\text{Gs}$  mit vorkonfektionierten, sowie frei verfügbaren RL-Anwendungstoolboxen konnten die grundlegende Funktions- und Nutzungsweise der Simulationstoolbox demonstriert werden. Dies umfasste u. a. das Zusammenspiel von RL-Algorithmen auf den unterschiedlichen Zeitskalen, welches gegenüber dem Stand der Technik einen signifikanten wissenschaftlichen Beitrag darstellte.

Mit Fertigstellung der Simulationsumgebung wurden datengetriebene RL-Regler entworfen. Ihre wesentliche Besonderheit ist hierbei die Regelung auf verschiedenen Zeitskalen, sowie sicherheitskritische Systembegrenzungen, welche im Kontext der Verfügbarkeit von Energienetzen noch immer eine wesentliche Rolle spielen. Ein übergeordnetes Ziel der Arbeiten war es den Nutzen und die Anwendung der Simulationsumgebung zu demonstrieren sowie maßgeschneiderte RL Algorithmen für sicherheitskritische Anwendungen zu entfernen, welche auch außerhalb der energietechnischen Domäne eingesetzt werden könnten.

Das zentrale Ergebnis der Arbeiten waren der grundsätzliche Funktionsnachweis der Toolbox im Sinne der Entwicklung datengetriebener RL-Regler für Energienetze. Zudem sind RL-Regelungsalgorithmen unter besonderer Berücksichtigung von Zustandsbeschränkungen entstanden.

### **Sicherheitsvalidierung mittels Adversarial ML**

Gegenstand dieses Aufgabenbereiches war die Erarbeitung einer Adversarial ML-Schnittstelle für die Simulationsumgebung, d. h. es sollte ein RL-Gegenspieler versuchen die einstellbaren Parameter der Simulation derart abzuändern, sodass der eigentliche RL-Regelungsalgorithmus besonders herausfordernden Betriebsszenarien gegenübergestellt wird. Das zu regelnde Energienetz könnte dann als sicher bezeichnet werden, wenn es der KI-Gegenspieler nicht schafft ein Betriebsszenario zu generieren, welches zum Ausfall der Energieversorgung bzw. zu einem Komponentenschaden führt.

Die notwendigen Arbeiten konnten ob unterschiedlicher Verzögerungen im Vorhaben leider nicht gestartet werden. Die Relevanz der Idee im Vorgehen ist aber nach wie vor gegeben und wir eventuell über ein Folgevorhaben angegangen. Im skizzierten Gedanken, Geg $\mu$ Gs unterliegen vielfältigen exogenen, häufig stochastischen Einflüssen (z. B. Wetter, Lastgang), welche den Betrieb und die Regelung besonders anspruchsvoll machen. Diese Einflüsse stellen im Sinne der Simulationsumgebung einstellbare Parameter bzw. Prozesse dar, welche die Regelungsgüte eines RL-Algorithmus maßgeblich beeinflussen. Diese Freiheitsgrade könnten vielfältig manipuliert werden, um die sichere Funktionsweise und somit Verfügbarkeit eines Energienetzes unter Führung eines RL-Algorithmus abzuprüfen.

### **Erstellung von standardisierten Benchmarks**

Die Erforschung von datengetriebenen Reglern, insbesondere für kritische Infrastrukturen, ist ein weltweit vielbeachtetes Forschungsfeld. Da es an standardisierten Vergleichsumgebungen mit Praxisrelevanz fehlt, sind die Ergebnisse unterschiedlicher Forschergruppen i. d. R. nicht vergleichbar. Es werden meistens eigene, stark abstrahierte und vereinfachte Modellumgebungen sowie Betriebsfälle verwendet. Die Folge, der Vergleich von Lösungsmethoden für datengetriebene Regelungen im energietechnischen Kontext ist auf Basis quantifizierbarer Vergleichsgrößen nicht möglich.

Die Aufgabe war es daher eine Reihe gleichbleibender und herausfordernder Benchmarkszenarien zu definieren. Diese wurden als Teil der Open-Source Toolbox anderen Wissenschaftlern/innen zur Verfügung gestellt. Unter Einbeziehung der assoziierten Partner wurden standardisierte Testprofile, also Sets an  $\mu$ G Topologien in Kombinationen mit exogenen Betriebsparametern erstellt, welche als Benchmark zur Bewertung von Regelungsverfahren genutzt werden können.

### **Nutzer- und Code-Dokumentation**

Ein unbeliebtes Thema aber für die Breiten- und Tiefenwirkung wissenschaftlicher Erkenntnisse ist die Erstellung einer einsteigerfreundlichen Dokumentation zur Nutzung und Programmierung der Toolbox unabdingbar. Insbesondere die aktive Mitwirkung externer Programmierer/innen und Ingenieure /innen im geplanten Open-Source Projekt kann und soll dadurch belebt werden. Dazu wurde in unserem

Vorhaben folgendes umfassend durchgeführt: Eine In-line Dokumentierung, die API-Dokumentierung, ein Quickstart Guide inkl. Dokumentierung von einfachen Beispielen zur Nachahmung und Anpassung, die ausführliche Dokumentierung der Benchmarkszenarien inkl. Hintergrund, ein FAQ und es wurde versucht (Video-)Tutorials zu erstellen.

### **Wissenschaftliche Veröffentlichungen**

Wie in allen wissenschaftlichen Vorhaben war geplant über die Toolbox sowie ihre Anwendungsmöglichkeiten wissenschaftliche Veröffentlichungen in einschlägigen Journalen und Fachkonferenzen zu erreichen und die Ergebnisse nutzbar zu machen. Der Erfolg ist im folgenden Kapitel beschrieben.

## 6. Wesentliche Ergebnisse und Verwertung der Erkenntnisse

### 6.1 Wesentliche Ergebnisse

Damit das Projekt unabhängig von den Interessen einzelner Unternehmen einen möglichst breiten wissenschaftlichen und industriellen Nutzen stiften konnte, wurden die geförderten Partner im Konsortium ausschließlich durch akademische Partner besetzt. Somit wurde, nicht zuletzt auch ob der engen Zusammenarbeit keine differente Verwertungsziele verfolgt. Zur Ermöglichung einer industriellen Verwertbarkeit wurde zu Projektbeginn ein Industriebeirat initiiert, der sich insbesondere aus Energieversorgungsunternehmen, sowie energietechnischen Komponenten- und Systemherstellern zusammensetzte. Involvierte Unternehmen waren u. a. die WestfalenWind, AEG Power Solutions, Westfalen Weser Netz, Energie Impuls OWL, LTI ReEnergy.

Die erstellte Toolbox wurde als Open-Source Software der Allgemeinheit zur Verfügung gestellt. So konnte auch interessierten Unternehmen aus der freien Wirtschaft einen Nutzen erbracht werden, beispielsweise als ergänzendes Entwicklungstool zur Auslegung und Analyse von in Planung befindlichen dezentralen Energienetzen. Darüber hinaus kann die Toolbox von akademischen Institutionen sowie Beratungsbüros genutzt werden, um derartige Analysen für wirtschaftliche Entwicklungsprojekte im Kontext dezentrale Netze als Beratungsdienstleistung durchzuführen.

Das zentrale Ergebnis des Projekts ist die frei verfügbare Toolbox „ElectricGrid.jl“, welche die oben genannten Nachteile des Stands der Technik adressiert. Die Toolbox wurde quelloffen entwickelt und steht interessierten Anwendern/innen via GitHub zur Verfügung:

<https://github.com/upb-lea/ElectricGrid.jl>

Im Sinne einer Zertifizierung der Open-Source Software wurde ein Kurzartikel im Journal of Open Source Software ElectricGrid.jl eingereicht, begutachtet und veröffentlicht:

- Wallscheid et al., (2023). ElectricGrid.jl - A Julia-based modeling and simulation tool for power electronics-driven electric energy grids. Journal of Open Source Software, 8(89), 5616, <https://doi.org/10.21105/joss.05616>

Darüber hinaus wurden mittels der Toolbox weitere wissenschaftliche Untersuchungen und Veröffentlichungen produziert, die aktuell in der finalen Veröffentlichungsphase sind (akzeptierte Konferenzpublikationen):

- M. Meyer et al., (2023). ElectricGrid.jl – Automated Modeling of Decentralized Electrical Energy Grids, IEEE Power and Energy Student Summit (PESS), Bielefeld
- J. Stenner et al., (2023). Hybrid Control of Interconnected Power Converters using both Expert-Driven Droop and Data-Driven Reinforcement Learning Approaches, IEEE Power and Energy Student Summit (PESS), Bielefeld

Die erarbeitete Software als auch die wissenschaftlichen Beiträge belegen, dass das Hauptziel des Vorhabens, die Erstellung von Trainings-, Validierungs- und Benchmarkwerkzeuge zur Entwicklung datengetriebener Betriebs- und Regelungsverfahren für intelligente, lokale Energiesysteme erfolgreich erreicht wurde.

Schließlich wurden im Rahmen des Projektes DARE auch – unabhängig von der entwickelten Toolbox, verschiedene Experimente durchgeführt, wie sich Systemwissen im Reinforcement Learning ausnutzen lässt, um das Training effizienter zu gestalten. In diesem Kontext ist ein sehr effizientes Multi-Agenten-Verfahren für hochdimensionale Differentialgleichungen entstanden, die Ergebnisse sind in folgender Arbeit publiziert:

- S. Peitz et al., (2024). Distributed control of partial differential equations using convolutional reinforcement learning, *Physica D: Nonlinear Phenomena*, Vol. 461, 134096

### 6.2 Wissenschaftlich-technische Verwertung

Die unmittelbare Verwertung nach Abschluss des Projekts liegt in der Nutzung der skizzierten Toolbox, um zunächst simulativ zielführende RL Verfahren zu erarbeiten und hinsichtlich eines späteren Praxiseinsatz zu ertüchtigen. Dies stellt einen wichtigen Zwischenschritt für den Praxistransfer von datengetriebenen Verfahren, beispielsweise im Kontext von Reallaboren, dar. Hierzu baut die Universität Paderborn zurzeit die Forschungsinfrastruktur „Microgrid-Labor“ auf, welche für diesen Transfer nach Projektabschluss zur Verfügung stehen wird. Da die geplante Toolbox darüber hinaus der Wissenschafts- und Industriegemeinde als Open-Source Lösung vollständig zur Verfügung stehen wird, kann so der breitangelegte Praxistransfer von datengetriebenen Regelungslösungen in weitere Reallabore deutschland- bzw. weltweit erfolgen.

Darüber hinaus steht im wissenschaftlichen Bereich ein Nutzen in der akademischen Lehre in Aussicht. Die Toolbox kann als forschungsorientiertes Simulations- und Regelungswerkzeug von Lehrenden und Studierenden frei genutzt werden, um so einen Beitrag zur Ausbildung angehender Ingenieure/innen, Informatiker/innen und benachbarter Studienbereiche zu leisten. Als kostenfreie und offene Entwicklungsumgebung ist die Toolbox zudem bestens geeignet, um als Simulations- und Analysegrundlage für studentische Abschlussarbeiten, freie wissenschaftliche Untersuchungen im Kontext von Forschungsprojekten sowie davon abgeleitet für Doktorarbeiten als Grundlage zu dienen.

### 6.3 Wissenschaftliche und wirtschaftliche Anschlussfähigkeit

Neben den bereits dargestellten Verwertungsmöglichkeiten in Wissenschaft und Wirtschaft wird angestrebt die Toolbox auch nach erfolgreicher Projektbeendigung weiterzuentwickeln und im Funktionsumfang zu erweitern, was wiederum dem wissenschaftlichen und wirtschaftlichen Nutzerkreis zugutekommt. Geplant ist der Aufbau einer User-and-Developer-Group, welche im Sinne eines neutralen, übergeordnetes Konsortiums die weiteren Entwicklungsschritte begleitet. Wie im Arbeitsplan bereits dargelegt sollen hierzu schon im Projektzeitraum möglichst externe Entwickler/innen zur

Mitarbeit motiviert und aktiv in das Projekt einbezogen werden. Diese Öffnung hin zu externen Partnern außerhalb des Projektkonsortiums dient der Ergebnisverstärkung und Bekanntmachung der Projekthalte in der interessierten Fachwelt.

#### 6.4 Nachhaltigkeit der Verwertung

Die im Konsortium assoziierten Partner besitzen bereits eine längerfristige Historie in der Zusammenarbeit in Forschungsvorhaben. Diese über alle Partner positiv bewertete Historie beruht mit auf einem Kooperationsmodell der Universität Paderborn für die Wirtschaft – dem Software Innovation Campus Paderborn. Unter anderen ist ein strategisches Ziel des SICPs eine mittel- und langfristige Verwertung der Erkenntnisse und Ergebnisse aus Forschungsprojekten in die Wirtschaft zu erreichen.

Der SICP versteht sich als strategischer Forschungs- und Innovationsverbund der Universität Paderborn und zahlreicher Unternehmen mit weiteren Partnern aus Wirtschaft, Wissenschaft und Gesellschaft, der in seinem Kern als Forschungscampus organisiert ist und auf einem Kooperationsvertrag basiert. Der SICP befasst sich transorganisational und interdisziplinär mit den Themen der Digitalisierung. Gemeinsam erforschen, gestalten und entwickeln die Mitglieder des SICP die software- und daten- getriebenen Innovationen für alle Bereiche der digital vernetzten Gesellschaft (Mobilität, Energie, Gesundheit, u.v.m.). Auf Seiten der Universität Paderborn bündelt die zentrale wissenschaftliche Einrichtung Software Innovation Lab (kurz: SI-Lab) die Aktivitäten im SICP.

Ziel ist es, durch eine intensive, strategische und langfristig angelegte öffentlich-privat Partnerschaft (PPP – Private Public Partnership), in der viele Fachgebiete und Institutionen der Universität Paderborn und viele Partner aus Wirtschaft, Forschung und Gesellschaft kooperieren, eine schlagkräftige, regional verankerte, aber national und international wirkende, transorganisationale Institution zu formen, die exzellente Forschung über Anwendungsorientierung und Kollaboration mit einem effektiven Forschungs- und Wissenschaftstransfer verknüpft.

Das zentrale Ergebnis des Projekts ist die frei verfügbare Toolbox „ElectricGrid.jl“, welche die umfassend genannten Nachteile des Stands der Technik adressiert. Die Toolbox wurde quelloffen entwickelt und steht interessierten Anwendern/innen via GitHub zur Verfügung. Sie daher den wichtigsten Anlaufpunkt der nachhaltigen Verwertung der Vorhabenergebnisse ( <https://github.com/upb-lea/ElectricGrid.jl> )

## 7. Wichtigste Positionen des zahlenmäßigen Nachweises

Die wichtigsten Positionen bzgl. der Ausgaben bezogen sich in erster Linie auf das eingesetzte Personal, sowie auf einige Dienstreisen, die innerhalb dieses Projektes durchgeführt wurden. Da Team setzte sich dabei aus mehreren wissenschaftlichen Mitarbeitern, sowie weiteren studentischen Hilfskräften zusammen. Im Detail kamen folgende Personen wie folgt zum Einsatz:

- Doktoranden:
  - Jan Stenner                      10/2021 – 09/2023
  - Septimus Boshoff              05/2022 – 09/2023
  - Daniel Weber                    10/2021 – 09/2023
  - Marvin Meyer                     12/2022 – 09/2023
  - Marius Becker                 06/2023 – 09/2023
- Studentische Hilfskräfte
  - Vikas Chidananda              04/2022 – 09/2023
  - Marvin Meyer                     10/2021 – 11/2022
  - Oliver Schweins                12/2022 – 03/2023

Folgende Dienstreisen wurden weiterhin durchgeführt. Bei allen handelt es sich um internationale wissenschaftliche Konferenzen, auf denen wissenschaftliche Mitarbeiter aus dem Projekt ihre Ergebnisse präsentiert haben.

- 09/2022  
European Conference on Power Electronics and Applications (EPE2023)  
Hannover, Deutschland  
Daniel Weber
- 06/2023  
International Conference on Future Energy Solutions (FES2023)  
Vaasa, Finland  
Daniel Weber
- 08/2023  
10th International Congress on Industrial and Applied Mathematics (ICIAM2023)  
Tokio, Japan  
Jan Stenner
- 11/2023 (DARE-Ergebnisse präsentiert, jedoch nicht mehr durch DARE finanziert)  
IEEE Power and Energy Student Summit (PESS) 2023  
Bielefeld, Deutschland  
Daniel Weber, Jan Stenner, Septimus Boshoff, Marvin Meyer

## 10. Literaturverzeichnis

- (France), R. a. (2021). *pypowernet*. Von <https://github.com/MarvinLer/pypowernet> abgerufen
- A. Marot et al. (2021). *Learning to run a Power Network Challenge: a Retrospective Analysis*. Von <https://arxiv.org/abs/2103.03104> abgerufen
- Antoine, M., Benjamin, D., Gabriel, D.-A., Adrian, K. A., Mariette, A., Isabelle, G., . . . Camilo, R. (2021). Learning to run a Power Network Challenge: a Retrospective Analysis. *arXiv.org*( arXiv:2103.03104).
- Antsaklis, P., & Michel, A. (2006). *Linear Systems*. Springer Science & Business Media.
- Arwa, E., & Folly, K. (2020). Reinforcement Learning Techniques for Optimal Power Control in Grid-Connected Microgrids: A Comprehensive Review. *IEEE Access*, 8, 208992 - 209007.
- Babaeinejadsarookolae, S., Birchfield, A., Christie, R. D., Coffrin, C., DeMarco, C., Diao, R., & al., M. F. (2021). The Power Grid Library for Benchmarking AC Optimal Power Flow Algorithms. *arXiv.org*.
- Boglietti, A., Carpaneto, E., Cossale, M., & Vaschetto, S. (5 2016). Stator-Winding Thermal Models for Short-Time Thermal Transients: Definition and Validation. *IEEE Trans. on Ind. Electronics*, 63, 2713–2721. doi:10.1109/tie.2015.2511170
- Brockman, G., Cheung, V., Pettersson, L., Schneider, J., Schulman, J., Tang, J., & Zaremba, W. (2016). OpenAI Gym. *OpenAI Gym*. Von <http://arxiv.org/abs/1606.01540> abgerufen
- Brown, T., Hörsch, J., & Schlachtberger, D. (2018). PyPSA: Python for Power System Analysis. *Journal of Open Research Software*, 6(1).
- ChroniX2Grid*. (2021). Von <https://github.com/BDonnot/ChroniX2Grid> abgerufen
- Coffrin, C., Bent, R., Sundar, K., Ng, Y., & Lubin, M. (2018). PowerModels.jl: An Open-Source Framework for Exploring Power Flow Formulations. *IEEE Power Systems Computation Conference (PSCC)*. Von <https://github.com/lanl-ansi/PowerModels.jl> abgerufen
- Energy, H. (2021). <https://www.homerenergy.com/index.html>. (HOMER Energy by UL) Abgerufen am 2021
- Foruzan, E., Soh, L.-K., & Asgarpour, S. (2018). Reinforcement Learning Approach for Optimal Distributed Energy Management in a Microgrid. *IEEE Transactions on Power Systems*(33), 5749 - 5758.
- France, R. (2021). *Grid2Op*. Von <https://github.com/rte-france/Grid2Op> abgerufen
- France, R. (2021). *GridAlive*. Von <https://github.com/rte-france/gridAlive> abgerufen
- Gonzague, H., Tanguy, L., Avishai, H., Reda, A., & Cordier, P. (2020). pymgrid: An Open-Source Python Microgrid Simulator for Applied Artificial Intelligence Research. *arXiv*.
- Guerrero, J., Chandorkar, M., Lee, T., & Loh, P. (2013). Advanced Control Architectures for Intelligent Microgrids - Part I: Decentralized and Hierarchical Control. *IEEE Trans. on Industrial Electronics*, 60(4), 1254 - 1262.
- Huang, Q., Huang, R., Hao, W., Tan, J., Fan, R., & Huang, Z. (2019). *Adaptive Power System Emergency Control using Deep Reinforcement Learning*. IEEE.

- Keras RL2. (2021). Von <https://github.com/wau/keras-rl2> abgerufen
- Kuznetsova, E., Li, Y., Ruiz, C., Zio, E., Ault, G., & Bell, K. (2013). Reinforcement learning for microgrid energy management. *Energ*, 59, 133 - 146.
- Leo, R., Milton, R. S., & Sibi, S. (2014). Reinforcement learning for optimal energy management of a solar microgrid. *IEEE Global Humanitarian Technology Conference - South Asia Satellite (GHTC-SAS)*.
- Li, H., Wan, Z., & He, H. (2020). Real-Time Residential Demand Response. *IEEE Transactions on Smart Grid*, 11, 4144 - 4154.
- Lu, X., Xiao, X., Xiao, L., Dai, C., Peng, M., & Poor, H. V. (2019). Reinforcement Learning-Based Microgrid Energy Trading With a Reduced Power Plant Schedule. *IEEE Internet of Things Journal*.
- Mathworks. (2020). MATLAB Engine API for Python. *MATLAB Engine API for Python*. Von [https://de.mathworks.com/help/matlab/matlab\\_external/install-the-matlab-engine-for-python.html](https://de.mathworks.com/help/matlab/matlab_external/install-the-matlab-engine-for-python.html) abgerufen
- Mathworks. (2020). Simscape. *Simscape*. Von <https://www.mathworks.com/products/simscape.html> abgerufen
- Mbuwir, B., Ruelens, F., Spiessens, F., & Deconinck, G. (2017). Battery Energy Management in a Microgrid Using Batch Reinforcement Learning. *Energies*, 10.
- Melike Selcen, A., Rasoul, A.-A., & Vladimir, T. (2018). European LV microgrid benchmark network: Development and frequency response analysis. *IEEE International Energy Conference (ENERGYCON)*, S. 1-6.
- Meng, L., Shafiee, Q., Trecate, G., Karimi, H., Fulwani, D., Lu, X., & Guerrero, J. (2017). Review on Control of DC Microgrids and Multiple Microgrid Clusters. *IEEE Journal of Emerging and Selected Topics in Power Electronics*, 5(3), 928 - 948.
- Milano, F., Vanfretti, L., & Morataya, J. C. (2008). An Open Source Power System Virtual Laboratory: The PSAT Case and Experience. *IEEE Transactions on Education*, 51, 17-23.
- PES Task Force on Benchmarks for Validation of Emerging Power System Algorithms, I. (2021). *Power Grid Lib - Optimal Power Flow*. Von <https://github.com/power-grid-lib/pglib-opf> abgerufen
- Raffin, A., Hill, A., Ernestus, M., Gleave, A., Kanervisto, A., & Dormann, N. (2019). *Stable Baselines3*. Von <https://github.com/DLR-RM/stable-baselines3> abgerufen
- Sogabe, T., Malla, D. B., Takayama, S., Shin, S., Sakamoto, K., Yamaguchi, K., . . . Okada, Y. (2018). Smart Grid Optimization by Deep Reinforcement Learning over Discrete and Continuous Action Space. *IEEE 7th World Conference on Photovoltaic Energy Conversion (WCPEC)*.
- Syed A., R., & Jin, J. (kein Datum). A Benchmark Distribution System for Investigation of Residential Microgrids With Multiple Local Generation and Storage Devices. *IEEE Open Access Journal of Power and Energy*, S. 41-50.
- Turner, L., Scheidler, A., Schäfer, F., Menke, J., Dollichon, J., Meier, F., . . . Braun, M. (2018). pandapower - an Open Source Python Tool for Convenient Modeling, Analysis and Optimization of Electric Power Systems. *IEEE Transactions on Power Systems*, 33(6), 6510 - 6521.

- Total-R&D. (2021). *pymgrid - Python Microgrid*. Von <https://github.com/Total-RD/pymgrid> abgerufen
- VDE Verband der Elektrotechnik Elektronik Informationstechnik e.V. (2019). *Zellulares Energiesystem – Ein Beitrag zur Konkretisierung des zellularen Ansatzes mit Handlungsempfehlung*. Frankfurt am Main.
- Wang, H., Liao, X., Abu-Rub, H., & Chen, G. (2016). Reinforcement Learning in Energy Trading Game Among Smart Microgrids. *IEEE Transactions on Industrial Electronics*, 63(8), 5109 - 5119.
- Xi, Y., Chang, L., Mao, M., Jin, P., Hatziargyriou, N., & Xu, H. (2015). Q-learning algorithm based multi-agent coordinated control method for microgrids. *9th International Conference on Power Electronics and ECCE Asia (ICPE-ECCE Asia)*.
- Yang, T., Zhao, L., Li, W., & Zomaya, A. (2020). Reinforcement learning in sustainable energy and electric systems: a survey. *Annual Reviews in Control*, 49, 145 - 163.
- Zhang, Q., Dehghanpour, K., Wang, Z., Qiu, F., & Zhao, D. (2020). Multi-Agent Safe Policy Learning for Power Management of Networked Microgrids. *IEEE Transactions on Smart Grid*.
- Zhang, Z., Zhang, D., & Qiu, R. (2020). Deep Reinforcement Learning for Power System Applications: An Overview. *CSEE Journal of Power and Energy Systems*, 6(1).
- Zhou, S., Zhou, L., Mao, M., & Xi, X. (2020). Transfer Learning for Photovoltaic Power Forecasting with Long Short-Term Memory Neural Network. *IEEE International Conference on Big Data and Smart Computing (BigComp)*.
- Zimmerman, R. D., Murillo-Sanchez, C. E., & Thomas, R. J. (2011). MATPOWER: Steady-State Operations, Planning, and Analysis Tools for Power Systems Research and Education. *IEEE Transactions on Power Systems*, 26, 12-19.