

A. Dreher<sup>1</sup>, T. Bexten<sup>2</sup>, T. Sieker<sup>2</sup>, M. Lehna<sup>1</sup>, J. Bergsträßer<sup>1</sup>, C. Scholz<sup>1</sup>, M. Wirsum<sup>2</sup>

Kontakt: Alexander Dreher | Telefon +49 561 7294-1750 | alexander.dreher@iee.fraunhofer.de

<sup>1</sup>Fraunhofer IEE

<sup>2</sup>Institut für Kraftwerkstechnik, Dampf- und Gasturbinen, RWTH Aachen

Im Projekt **Cognition2HydrogenForce** wurden, gemeinsam mit dem Institut für Kraftwerkstechnik, Gas- und Dampfturbinen (IKDG) der RWTH Aachen, die Potenziale von Algorithmen des Deep Reinforcement Learning (DRL) für den Einsatz in der grünen Wasserstoff-Elektrolyse für industrielle Gasturbinen untersucht.

## Problembeschreibung

Das untersuchte System bestand dabei aus einem Windpark, einem Elektrolyseur für die Wasserstofferzeugung, einem Wasserstoffspeicher sowie einer Gasturbine zur Deckung der Wärme- und Strombedarfe eines industriellen Abnehmers, wie in der folgenden Abbildung schematisch dargestellt ist.

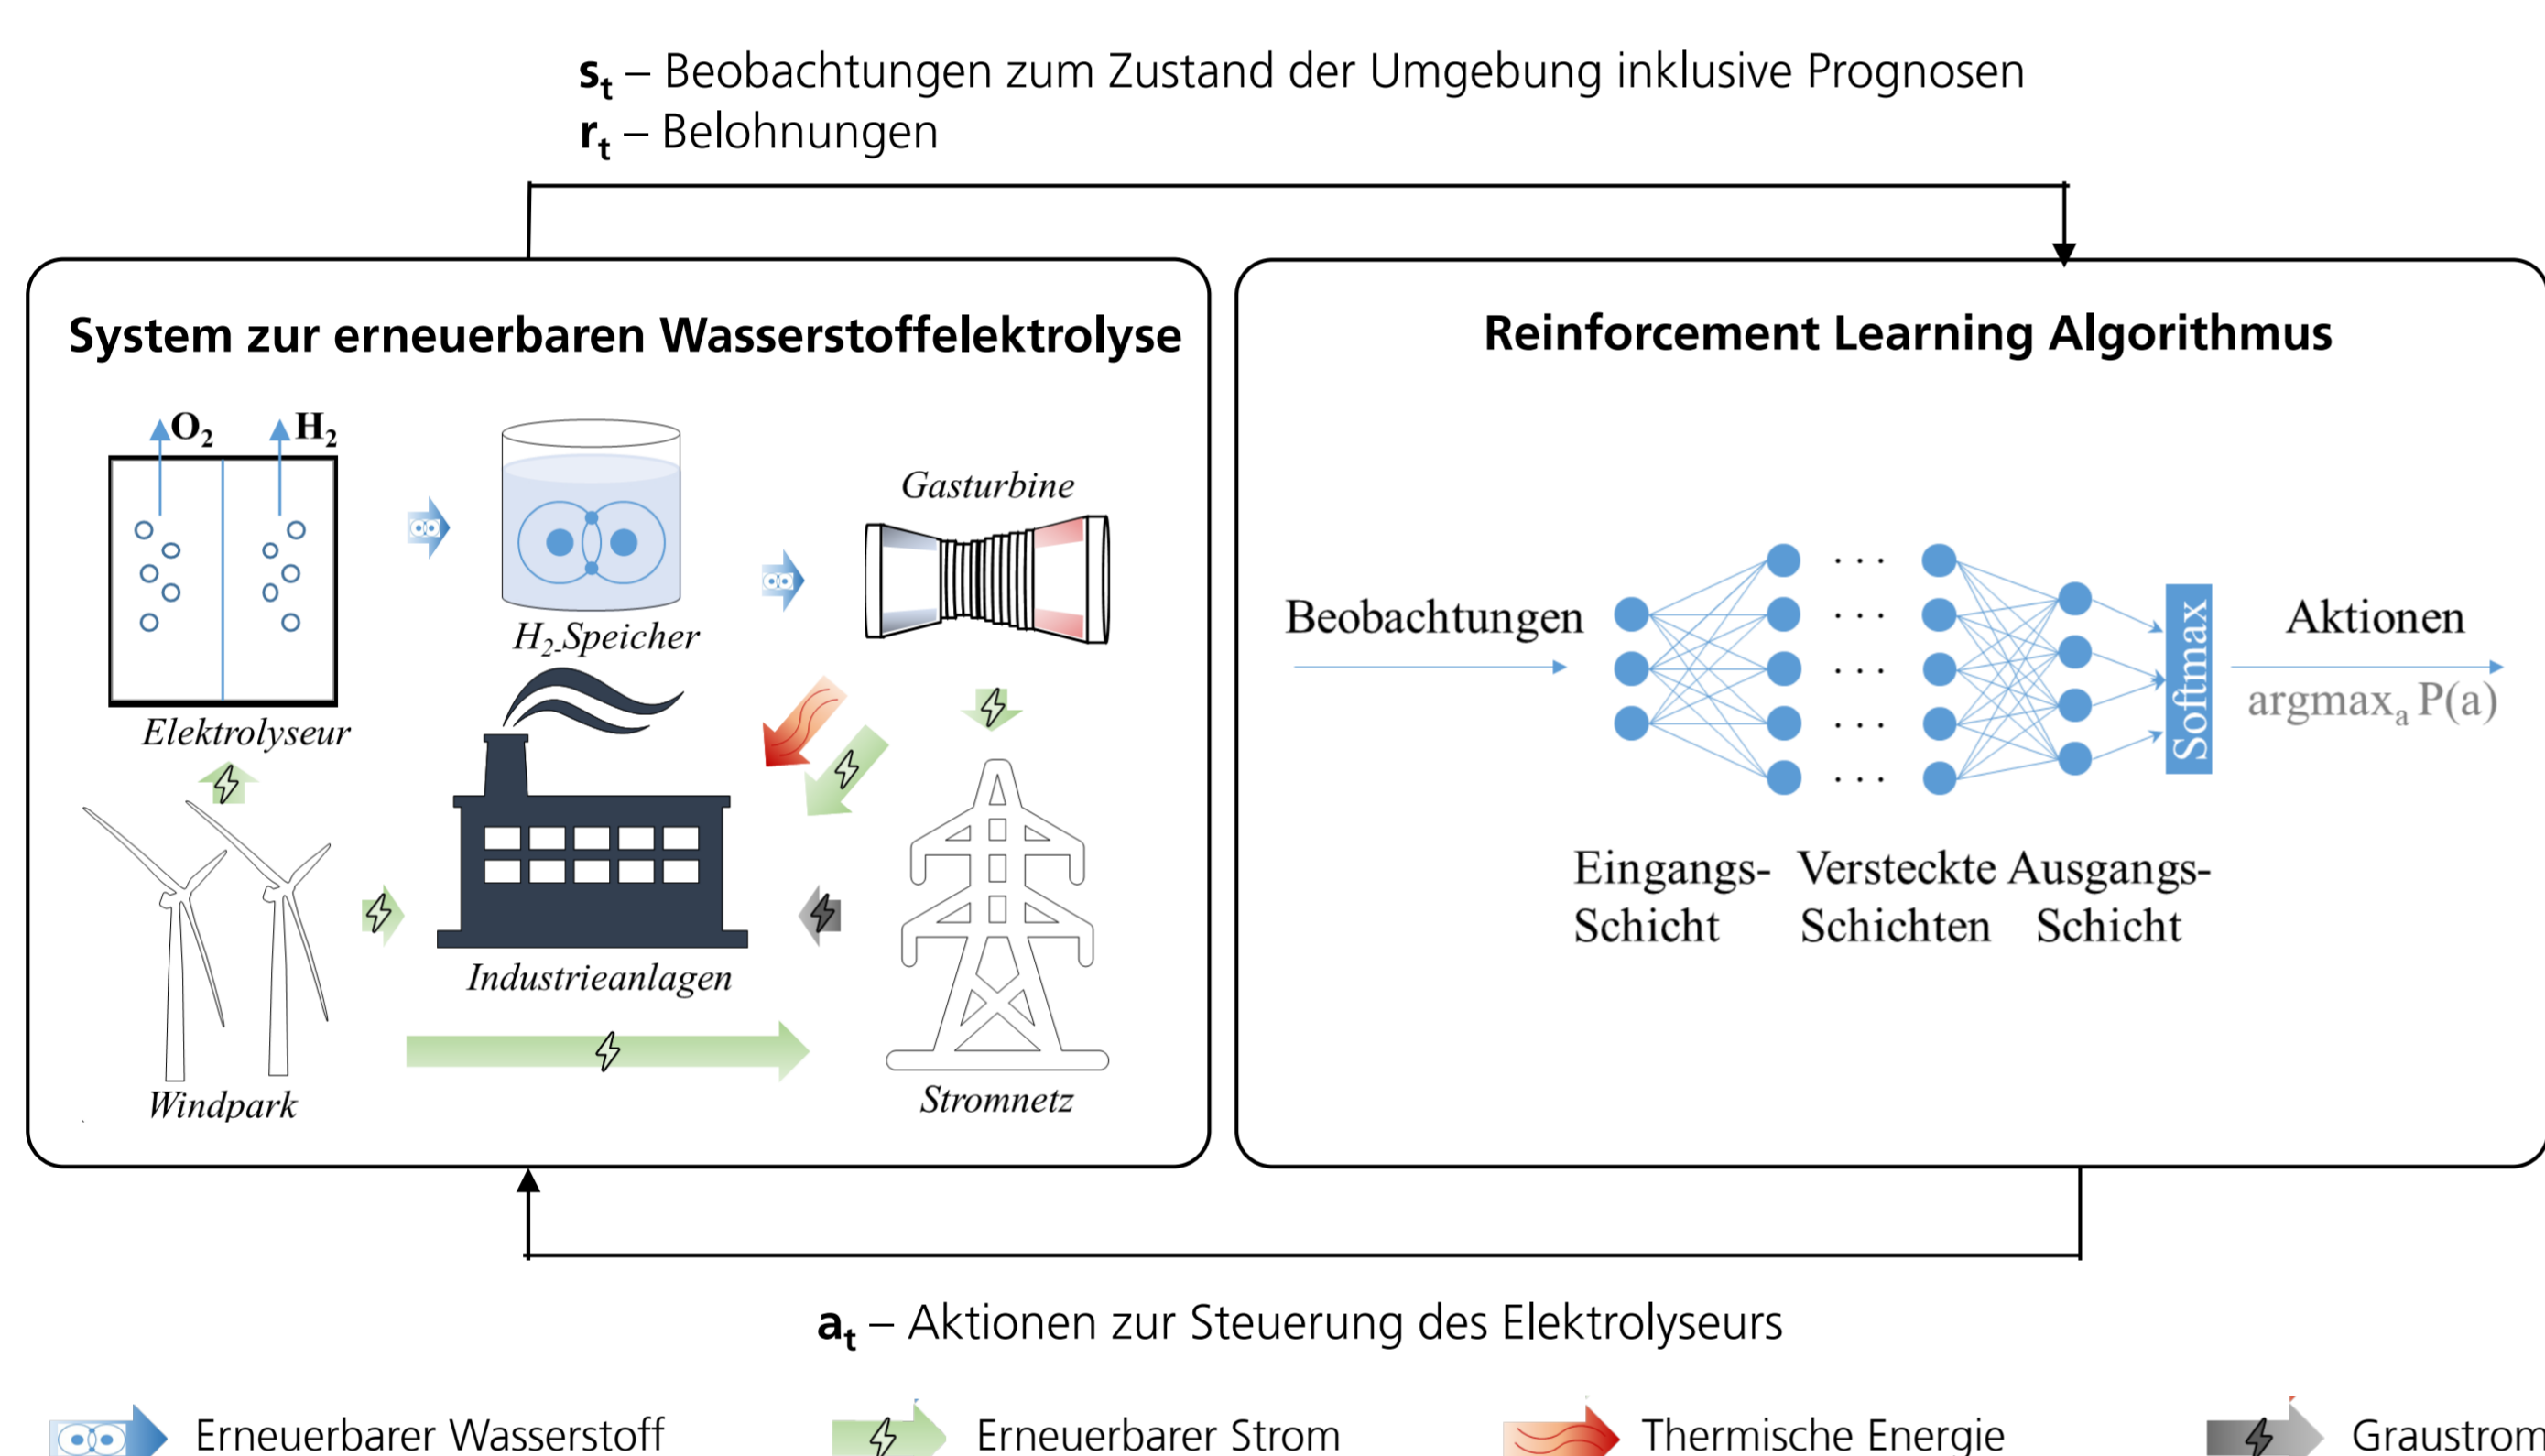


Abbildung 1: Graphische Darstellung des Systems zur erneuerbaren Wasserstoffelektrolyse sowie des Einsatzes der RL-Algorithmen<sup>1</sup>

Die zentrale Herausforderung des Projekts bestand in der Entwicklung einer geeigneten Trainingsumgebung für die selbstlernenden DRL-Algorithmen. In dieser Umgebung wurden die Anlagen des Systems präzise abgebildet, um die komplexen physikalischen Zusammenhänge des Systems zu erfassen. Die Anforderung: Finden eines Gleichgewichts zwischen detaillierter Abbildung und Komplexitätsreduzierung, sodass der Algorithmus erfolgreich lernen kann.

Gleichzeitig wurden seitens IKDG Referenzmodelle entwickelt, um die Güte der Ergebnisse der DRL-Algorithmen einordnen zu können. Hierbei wurde ein regelbasiertes (RB) Modell für den unteren Benchmark sowie ein Modell basierend auf der Dynamischen Programmierung (DP) als oberer Benchmark entwickelt.




Abbildung 2: Ausschnitt der industriellen Wärme- und Elektrizitätsbedarfe, die durch H<sub>2</sub>-Gasturbine und Windpark zu decken sind<sup>1</sup>

## Ergebnisse

Im Projekt und der daraus entstandenen Veröffentlichung<sup>1</sup> konnte im direkten Vergleich mit den RB- und DP-Modellen gezeigt werden, dass die DRL-Algorithmen bereits in der Lage sind, die Ergebnisse des gewählten regelbasierten Verfahrens deutlich zu übertreffen. Dies wird auch aus der nachfolgenden Abbildung ersichtlich, welche die simulierte Einsatzplanung der Wasserstoffelektrolyse darstellt. Die obere Teilabbildung zeigt dabei den Einsatz des Elektrolyseurs, welcher durch die volatile Windstromerzeugung auch etwas fluktuiert. In der unteren Teilabbildung ist die Befüllung des Wasserstoffspeichers im Vergleich zur optimalen DP, dem unteren Benchmark des RB-Modells und dem RL-Ansatz dargestellt. Es ist gut zu erkennen, dass der RL-Ansatz dabei deutlich näher an den Fahrplänen des optimalen DP-Modell liegt als am RB-Fahrplan.




Abbildung 3: Potenziale der RL-Algorithmen im Vergleich zu DP und RB<sup>1</sup>

## Fazit und Ausblick

Die DRL-basierten Simulationsergebnisse sind vielversprechend und zeigen bemerkenswerte Aktionen der Algorithmen zur Steuerung des Elektrolyseurs. Hervorzuheben ist dabei die besondere Komplexität des betrachteten Systems und seiner Einflussfaktoren, wie die volatile Windstromerzeugung und die variablen Börsenstrompreise, der H<sub>2</sub>-Speicher inklusive Kompression sowie der Betrieb der Gasturbine zur Deckung des Wärme- und Strombedarfs.

Gleichzeitig wurden erforderliche Weiterentwicklungsbedarfe der Algorithmen identifiziert, bevor sie im operativen Betrieb von Anlagen eingesetzt werden können. So ist es notwendig, auch bei selten auftretenden (Wetter-)Ereignissen konstante und gute Ergebnisse zu erzielen. Diese Konstanz konnte bislang nicht erreicht werden.

Im Projekt wurden Wege aufgezeigt, wie von einander abweichende Zielsetzungen des Systems, durch eine geeignete Definition der Trainingsumgebung, der Belohnungsfunktion und die Berücksichtigung von Prognosen erreicht werden können. Die Stärken von DRL-basierten Energiemanagement-Systemen können dann in den Fokus rücken, wenn diese Hürden überwunden wurden. Zu den Stärken gehören dabei der Umgang mit Unsicherheiten, die Fähigkeit sich über Zeit zu verbessern und sich an ändernde Umgebungen anzupassen. Nicht zuletzt bieten auch die geringeren Ressourcenbedarfe in der Anwendung eine attraktive Perspektive.

<sup>1</sup> AI agents envisioning the future: Forecast-based operation of renewable energy storage systems using hydrogen with Deep Reinforcement Learning: <https://doi.org/10.1016/j.enconman.2022.115401>

Gefördert durch: