

INDUSTRIELLE KÜNSTLICHE INTELLIGENZ FÜR SICHERE GASNETZE

Anja BASCHIN¹, Michelle BASCHIN¹, Reinhard BÖSELT¹, Rudolf FELIX²,
Cesareo FERNANDEZ³, Sven GEHRING¹, Alexander GÖRTZ², Lars HARPENG³,
Yuguang HEI¹, Niclas HILDEBRANDT², Thomas HÜGGING⁴, Pascal KÄTZEL²,
Kristoffer-Robin KOLBERG⁴, Leonid KUOZA¹, Lukas LUZIUS², Gheorghe
LISCA⁵, Lilia MICHAILOV², Werner MULTHAUP¹, Karima OUTAFRAOUT⁵,
Fabian PROCH¹, Alexander SCHIENDORFER⁵, Marcel SIMANNEK⁴, Tom
STREUBEL¹

Kurzfassung: Der Gassektor unterliegt aufgrund der Dekarbonisierungsbemühungen im Einklang mit dem Pariser Abkommen großen Veränderungen: Nicht-fossile Gase wie Biomethan oder erneuerbarer Wasserstoff können dazu führen, dass die bestehende Gasinfrastruktur für Gasspeicherung, -transport und -verteilung wiederverwendet wird, um Treibhausgasemissionen zu reduzieren und gleichzeitig eine hohe Energiesicherheit zu gewährleisten – des Weiteren benötigen Gaskraftwerke als künftige Residuallastversorger weiterhin eine gesicherte Infrastruktur. Derweil ist Erdgas in Deutschland immer noch der zweitwichtigste Primärenergieträger und wird in der EU-Taxonomie für eine nachhaltige Transformation berücksichtigt. Um einen Beitrag zum Sustainable Development Goal (SDG) 9 der Vereinten Nationen (resiliente Infrastruktur) zu leisten, entwickelt das Projekt IKIGas KI-Werkzeuge für den Betrieb von Gasnetzen: Es werden ML-Modelle entwickelt, um die Qualität und Sicherheit von Netzzuständen kontinuierlich zu bewerten und mögliche Anomalien zu identifizieren. KI-Agentensysteme werden in Simulationen trainiert, um ein Gasnetz mit Hilfe von Imitationslernen aus historisierten Betriebsdaten und adversarischem Training zu testen und zu steuern. Beide Ansätze werden mit einer auf Extended-Fuzzy-Logic basierenden Methodik kombiniert, die eine transparente, qualitative Kennzeichnung wünschenswerter Zustände und Ziele sowie die Analyse potenzieller Zielkonflikte ermöglicht.

Keywords: Gasnetze, Infrastruktur, Künstliche Intelligenz

1 Einleitung

Gas ist heute noch der zweitwichtigste Primärenergieträger in Deutschland. Um die Klima- und Energieziele zu erreichen, müssen nicht-fossile Gase wie Biogas, grüner Wasserstoff aus Elektrolyseuren und Biomethan aus Methanisierungsanlagen mittelfristig fossile Gase ersetzen. Gleichzeitig kommt Gasen innerhalb der Sektorenkopplung als Flexibilisierungselement eine besondere Bedeutung zu. Dieser Wandel erfordert einen

¹ PSI Software SE, Gasnetze und Pipelines, Berlin, <https://www.psigasandpipelines.com/>

² PSI FLS Fuzzy-Logik & Neuro Systeme GmbH, Dortmund, Germany, <https://fuzzy.de/>

³ Avacon Netz GmbH - Standort Salzgitter, Germany, <https://www.avacon-netz.de/>

⁴ Thyssengas GmbH, Dortmund, Germany, <https://thyssengas.com/>

⁵ Technische Hochschule Ingolstadt, Germany, <https://www.thi.de>

mbaschin@psi.de, alexander.schiendorfer@thi.de

zunehmend effizienten und zuverlässigen Betrieb der bestehenden und neu zu errichtenden

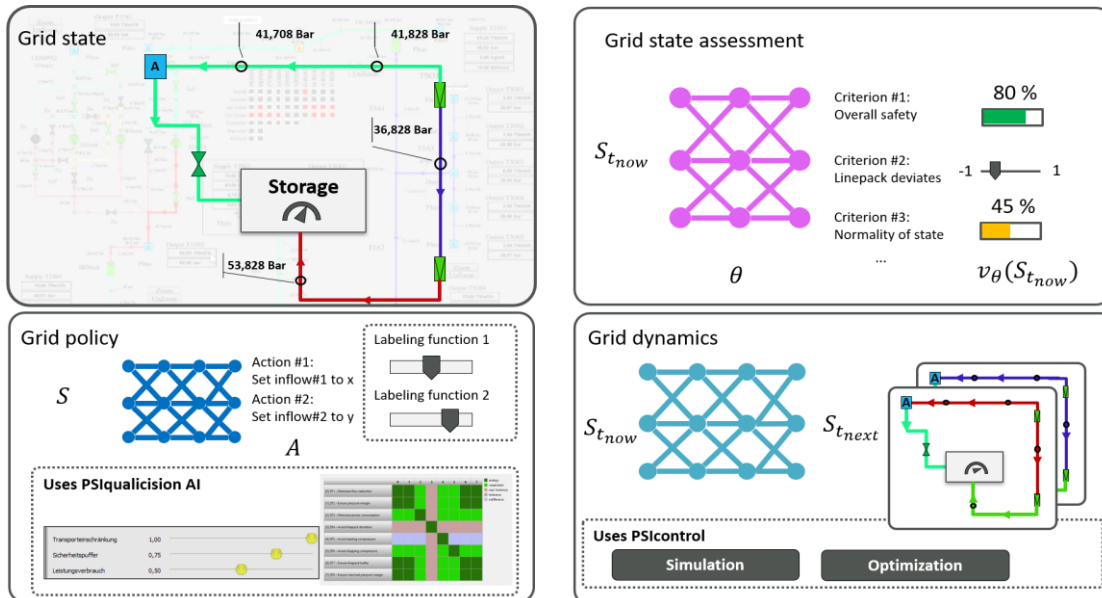


Abbildung 1 Übersicht über die verschiedenen Modelle, die in IKIGas zusammenarbeiten.

Gasinfrastruktur. Dabei geht es nicht nur um die ausreichende Verfügbarkeit von Gas, sondern auch um die Sicherheit der Gasnetze, die gegenwärtig immer wieder Vandalismus und Sabotage ausgesetzt sind. Um ein effizientes Management der Transport- und Verteilungsinfrastrukturen der Gasversorgung zu gewährleisten und Versorgungsunterbrechungen vorzubeugen, bedarf es einer Kombination von Maßnahmen, u.a. der Digitalisierung. Folgende Trends sind im Moment zu beobachten:

- Durch die Digitalisierung im Energiebereich steigt die **Anzahl der nutzbaren Daten** für die Beurteilung des Netzzustandes kontinuierlich.
- Der Transformationsprozess des Energiesystems zur **Substitution fossiler Brennstoffe** durch erneuerbare Energie und neue Lieferabhängigkeiten führen zu einer *großen Dynamik bei den Ein- und Ausspeisedaten* sowie zu spartenübergreifenden Abhängigkeiten. Insbesondere die Herausforderung der Gaseinspeisung verschiedener Beschaffenheiten, wie mitunter Wasserstoff, fordern einen enormen Überwachungs- und Steuerungsaufwand. Gerade in hochvermaschten Gasnetzen bedeutet dies einen hohen Arbeitsaufwand für Dispatcher und Systempfleger.
- Die **Cybersicherheit** nimmt einen zunehmenden höheren Stellenwert ein, da die Datenerfassung immer komplexer wird. Unbefugte Zugriffe und Datenmanipulationen müssen verhindert werden.

1.1 KI-basierte Ansätze zur Verbesserung der Versorgungssicherheit

Um diese Probleme zu adressieren, haben die PSI Software Gas Grids and Pipelines, PSI FLS Fuzzy Logik & Neuro Systeme, Avacon, Thyssengas und die Technische Hochschule Ingolstadt (THI) im Rahmen des Forschungsprojektes IKIGas (Industrielle Künstliche Intelligenz für Sicherheit in Gasnetzen) damit begonnen, ein auf Künstlicher Intelligenz (KI) basierendes Entscheidungsunterstützungssystem für den Betrieb von Gasnetzen und -pipelines zu entwickeln, was in Abbildung 1 dargestellt wird: Modelle des Maschinellen

Lernens (ML) werden anhand historisierter Betriebsdaten darauf trainiert, die Qualität und Sicherheit der Netzbetriebszustände kontinuierlich zu bewerten und mögliche Anomalien zu identifizieren. Sogenannte Software-Agenten werden anhand einer physikalischen Simulation zur Steuerung eines Gasnetzes sowohl durch Imitationslernen aus vergangenen Steueraktionen als auch durch Versuch und Irrtum trainiert, um insbesondere in der Realität unerwünschte Situationen simulativ zu betrachten. Beide Ansätze werden mit einer auf erweiterter Fuzzy-Logik basierenden Methodik kombiniert, die eine transparente, qualitative Charakterisierung wünschenswerter Zustände und Ziele sowie die Analyse potenziell widersprüchlicher Ziele ermöglicht. Dabei kommt die Software PSQualicision AI zum Einsatz.

1.2 Stand der Technik und Forschung

Donti et al. (Donti und Kolter 2021) präsentieren einen Überblick über Nachhaltigkeitsaspekte ML-gestützter Energiesysteme, einschließlich Strom- und Brennstoffversorgungssystemen wie Erdgasnetzen. (Ihsan und Astuti 2022) präsentiert einen Proof-of-Concept für die Erkennung von Anomalien auf der Grundlage von Autoencodern, die Rekonstruktionsfehler in einem zweijährigen Zeitreihendatensatz messen, und (Awuku et al. 2023) schlägt ein Zeitreihenvorhersagemodell vor, das in der Lage ist, Schadenssituationen zu erkennen. (Petkovic et al. 2022) schlug ein Deep-Learning-Modell für die räumlich-zeitliche Vorhersage von Angebot und Nachfrage in Erdgasübertragungsnetzen vor, das die modernsten Benchmarks übertraf. Verstärkendes Lernen, angewandt auf den Betrieb von Erdgasnetzen, hat im Vergleich zu Stromnetzen relativ wenig Aufmerksamkeit erhalten: (Fan et al. 2022) und (Awuku et al. 2023) präsentieren Agenten, die die Nachfragerreaktion optimieren, d.h. das Verbraucherverhalten anpassen, und (Yang et al. 2020) befasst sich speziell mit der Drucksteuerung in Erdgasnetzen unter Verwendung von Q-Learning außerhalb des Regelkreises.

Unsere Ziele konzentrieren sich stärker auf die Integration von Dispatcher-Feedback, das über eine in ein Kontrollsystem integrierte Benutzeroberfläche eingeholt wird, sowohl in die Anomalieerkennung als auch in selbstlernende Agenten.

2 Forschungsroadmap

Abbildung 1 zeigt die Bandbreite der Modelle, die im Rahmen des IKIGas-Projektes für die Gasnetzanalyse eingesetzt werden.

2.1 Netzzustandsbewertung

Netzbewertung: Das Konzept des Netzzustandes umfasst alle Parameter, die das Gasnetz zu einem bestimmten Zeitpunkt beschreiben. Diese Zustände werden im SCADA-System von PSControl über die Zeit aufgezeichnet. Mit Hilfe dieser historisierten Daten wird ein ML-Modell damit beauftragt, jeden Netzzustand hinsichtlich Sicherheit und Effizienz zu bewerten und mögliche Anomalien zu identifizieren. Die dazu notwendige Annotation der Zustände, im ML „Label“ genannt, erfolgt über mehrere Kanäle. Einerseits wird Expertenwissen von Dispatchern erfasst, welche Zeitabschnitte aus der Vergangenheit manuell bewerten, wozu eine an den

Fachbereich angepasste Labeling-Software auf der Basis von Label Studio² eingesetzt wird (siehe Abbildung 2). Die Bewertung erfolgt zunächst qualitativ auf einer fünfstufigen Likert-Skala von (1 = sehr schlecht bis 5 = sehr zufriedenstellend), wobei implizit Kriterien wie „wenig Eingriffe nötig“ oder „Wetterlage falsch eingeschätzt, zu wenig eingespeist“ über Zeiträume und nicht einzelne Zustände markiert werden. Natürlich kann diese Bewertung nur für ausgewählte, besonders informative Zustandssequenzen verfolgt werden, da ansonsten die Arbeitszeit der Dispatcher unnötig beanspruchen würde. Um einen möglichst guten Tradeoff zwischen investierter Labeling-Zeit und resultierender Performance zu erreichen, dient eine in der Industrie bewährte Methodik (Business-Entscheidungen und Optimierungen mit Qualicision von F/L/S 2007) als Basis: Anstatt Leitwartenmitarbeiter mit einem direkten Abbild des Netzzustandes zu konfrontieren, werden relevante Metriken aus der Repräsentation eines Zustandes mittels qualitativer Labeling-Funktionen abgeleitet, welche man sich als in [-1,1] normierte, berechenbare Funktionen vorstellen kann, die eine aggregierende Aufgabe wahrnehmen. Diese vorprogrammierten Kennzahlen werden dann als Grundlage für die Bewertung herangezogen, was einem wesentlichen geringeren kognitiven Aufwand entspricht. Ihre Priorisierung untereinander, d.h. wie stark sie zur Zufriedenheit des Labelers mit dem Zustand oder den auswählbaren Aktionen letztendlich beitragen, ist eine zusätzliche Information, die so gewonnen werden kann.

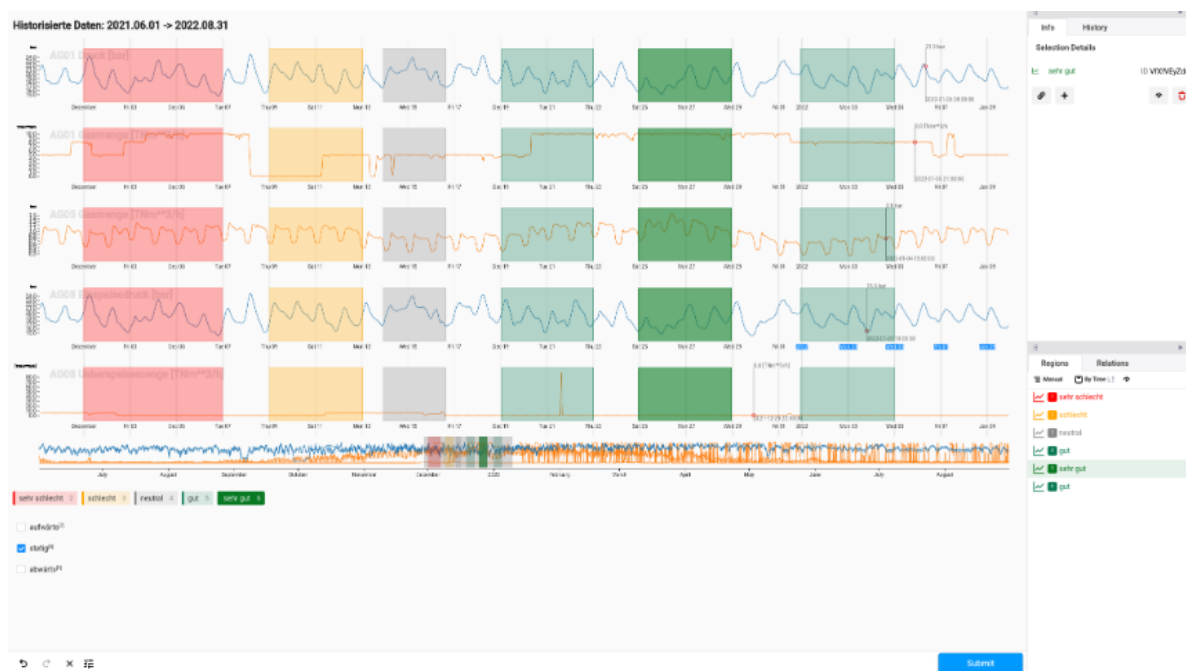


Abbildung 2 Label Studio zum qualitativen Bewerten von Zeitreihenabschnitten

Und abschließend kann auch aus den rohen Zeitreihendaten mit Verfahren des unüberwachten Lernens eine Anomaliebewertung gewonnen werden. Hierbei ist zwischen *Outlier-Detection* und *Anomaly-Detection* zu unterscheiden. Während die Anomaly-Detection davon ausgeht, dass die Trainingsdaten die korrekte Grundverteilung repräsentiert und lediglich davon abweichende Beobachtungen im Produktivbetrieb gekennzeichnet werden sollen, d.h. keine Anomalien im Training vorkommen, nimmt Outlier-Detection explizit an, dass sich Ausreißer (z.B. durch Messfehler) in den Trainingsdaten befinden und ggf. eliminiert

² <https://labelstud.io/>

werden sollten. In beiden Fällen kann durch ein unüberwachtes (d.h. ohne externe Bewertung / Labeling) Lernverfahren die Verteilung gültiger Zustände modelliert werden und ein Score für auffällige Situationen ohne menschliches Eingreifen ermittelt werden. Zusammengefasst ergeben sich folgende Möglichkeiten zur Bewertung von Zustandsfolgen, welche als sogenannte Labeling-Funktionen in der Software *PSIqualicision AI* eingesetzt werden:

- Explizit qualitativ bewertete Situationen (klassische gelabelte Datensätze)
- Abgeleitete, aggregierende und vorprogrammierte Funktionen, die KPIs darstellen
- Unüberwacht und datenbasiert trainierte Normalitätsmodelle

2.2 Netzdynamik und Entscheidungsvorschläge

Neben der Bereitstellung von datenbasierten Bewertungen des aktuellen Zustands für Dispatcher ist eine Lösung vorgesehen, die mögliche Entscheidungen (z.B. Änderung der Einspeisemenge oder Anpassung von Sollwerten für Druckregelventile) anleitet. Dazu wird bestärkendes Lernen (*Reinforcement-Learning*) eingesetzt (Di Cao et al. 2020), um Steuerungsmaßnahmen in der Gasnetzsimulation *PSIganesi* (Dynamic gas network simulation with GANESI 1999) zu erlernen und zu empfehlen, welche Maßnahmen ein Dispatcher einsetzen könnte, um sicherheitskritische Situationen präventiv zu erkennen und zu bewältigen. Vereinfacht ausgedrückt wird im bestärkenden Lernen ein sogenannter Software-Agent durch Interaktion mit einer simulierten oder realen Umgebung über Versuch und Irrtum möglichst gewinnbringende Handlungsweisen (sog. *policies*) zu entwickeln.

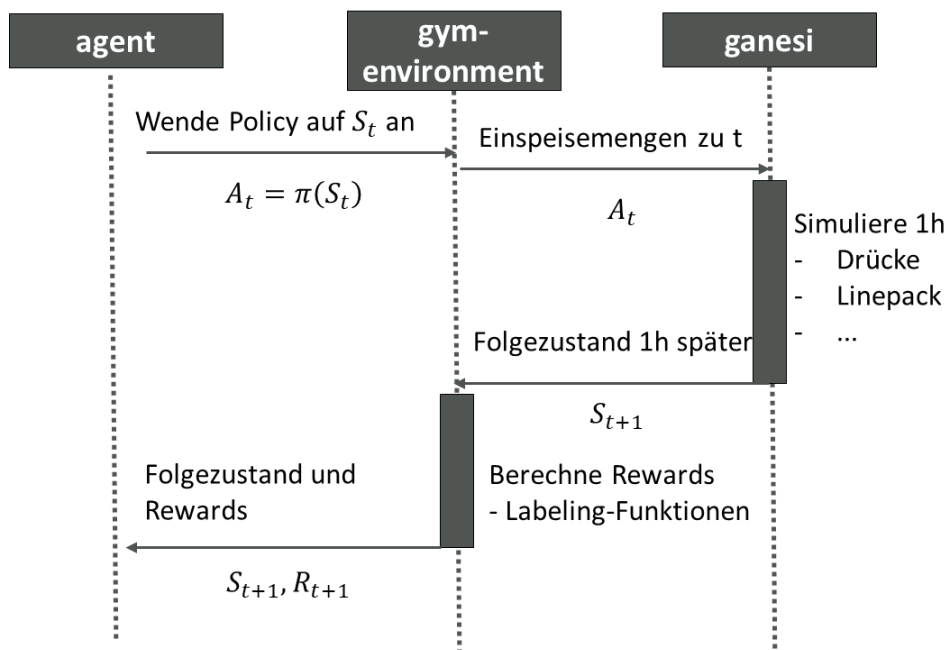


Abbildung 3 Schematischer Ablauf einer Interaktion im bestärkenden Lernen mit Ganesi

Im Gegensatz zu erfolgreichen und bekannten KI-Anwendungen von Firmen wie Google, z.B. aus Brettspielen wie Schach oder Go, spielen in realen Systemen eine Vielzahl von interagierenden Zielen (z.B. Versorgungssicherheit versus Überpufferung) sowie interaktive Entscheidungssituation mit Humans-in-the-loop eine Rolle. Dazu wird auf den beobachteten Systemzuständen eine multikriterielle Konflikt- und Interaktionsanalyse (Felix 2015) durchgeführt, um zu überprüfen, ob die Ziele positiv miteinander korrelieren ("Harmonisierung

der Ziele") oder im Konflikt zueinander stehen (z.B. Befriedigung eines plötzlichen Nachfrageanstiegs eines großen Industriekunden vs. Aufrechterhaltung des Netzpuffers in einem wünschenswerten Bereich) - wie in der Matrix in der linken unteren Ecke von Abbildung 1 dargestellt. In IKIGas beschäftigt sich eine Forschungsfrage damit, wie die von Dispatchern gewünschte Priorisierung von Zielen interaktiv als Spezifikation für lernende Softwareagenten übergeben werden kann. Erst daraus ergibt sich eine zielführende und adaptive Modellierung des Belohnungssignals, welches die Software-Agenten maximieren. Alle drei Varianten von Labeling-Funktionen, die in Abschnitt 2.1 vorgestellt wurden, eignen sich als Basisfunktionen für das Belohnungssignal: Entweder sollen Zustände angestrebt werden, die von Dispatchern als wünschenswert klassifiziert wurden, eine vordefinierte KPI maximieren oder einen Zustand erzeugen, der von einem unüberwacht trainierten Modell als normal eingeschätzt wurde. Die spezifische Aggregation der Bewertungen zu einer finalen Ordnung über Handlungsoptionen ist Gegenstand der Forschung (Christian Wirth et al. 2017).

2.3 Systematisches Testen durch Adversarisches Lernen

Nach Etablierung dieser Softwarearchitektur können damit auch *böswillige* Agenten simulativ trainiert werden, d.h. Agenten, die durch Manipulation des Systems (z.B. durch sog. False-Data-Injektionen von fehlerhaften, d.h., z.B. zu niedrigen Wetter-/Temperaturprognosen, vgl. (Weiss et al. 2022)) gezielt kritische Zustände herbeiführen – welche natürlich dementsprechend abgewendet werden müssen.




Abbildung 4 Nullsummenspiel zwischen Angreifer und Verteidiger zum Aufdecken von Schwachstellen in der Betriebsweise

Formal spielen der verteidigende und angreifende Agent ein Nullsummenspiel, wie in Abbildung 4 dargestellt. Angreifer werden i.A. über andere Aktionsmengen verfügen als Verteidiger, wie beispielsweise Prognosemanipulationen, das Einbringen von Sensormanipulationen oder (simulierte) physikalische Manipulationen wie Anbohren von Leitungen. Das Optimierungsproblem der Suche nach der maximalen, diskontierten Belohnung(en) weicht nun einer Suche nach einem Nash-Gleichgewicht. Neben der Belohnung, kritische Netzwerkzustände zu erreichen, ist für den subversiven Agenten auch eine Belohnung, unentdeckt zu bleiben, denkbar. Ähnliche Ansätze werden in der Literatur bereits im Software-Testen, dem Penetration-Testing von IT-Netzen oder auch in Windkraftwerken (Liu et al. 2020) eingesetzt. Hierin liegt eine der Stärken des KI-basierten verstärkenden Lernens, da durch die explorative Suche über Versuch und Irrtum Situationen identifiziert werden können

Zusammengefasst nutzt das Projekt zentrale KI-Techniken (die keinen Bezug zu aktuell medial im Vordergrund stehenden großen Sprachmodellen, bzw. generativer KI aufweisen), wie in Abb. 1 skizziert:

1. **Erweiterte Fuzzy-Logik** zur Ziel- und Interaktionsanalyse in Entscheidungsprozessen
2. **Unüberwachtes Lernen** zur Verarbeitung von **Zeitreihendaten** zur Identifikation von normalem und anormalem Verhalten;
3. **Bestärkendes Lernen** zur Entwicklung von Strategien zur Optimierung von Netzzuständen.

Erste empirische Ergebnisse zur Anomalieerkennung und zum Reinforcement Learning zeigen das Potenzial von IKIGas, den Betrieb und die Resilienz heutiger und vor allem zukünftiger Gasnetze zu verbessern. Die vorgestellte Methodik kann künftig insbesondere auch für die Sektorenkopplung und Wasserstoffnetze eine wichtige Rolle spielen.

3 Erste Ergebnisse

In einem ersten Testlauf wurden historisierte Zustandsdaten aus PSIcontrol mit drei Variablen über einen Zeitraum von Juni 2021 bis September 2022 exportiert: Netzpuffer (Linepack), Einspeisefluss und Ausspeisefluss. Ein zusätzliches abgeleitetes Signal war die Differenz zwischen Einspeise- und Ausspeisedurchfluss.

3.1 Anomalieerkennung mit Kernel-Density-Estimation

Unüberwachte Labeling-Funktionen wurden mit Hilfe der Kernel-Dichte-Schätzung über einen Zeitraum von Juni 2021 bis Juli 2022 trainiert und über einen zweimonatigen Zeitraum von Juli 2022 bis September 2022 angewendet. Die Ergebnisse sind in Abbildung 5 zu sehen.

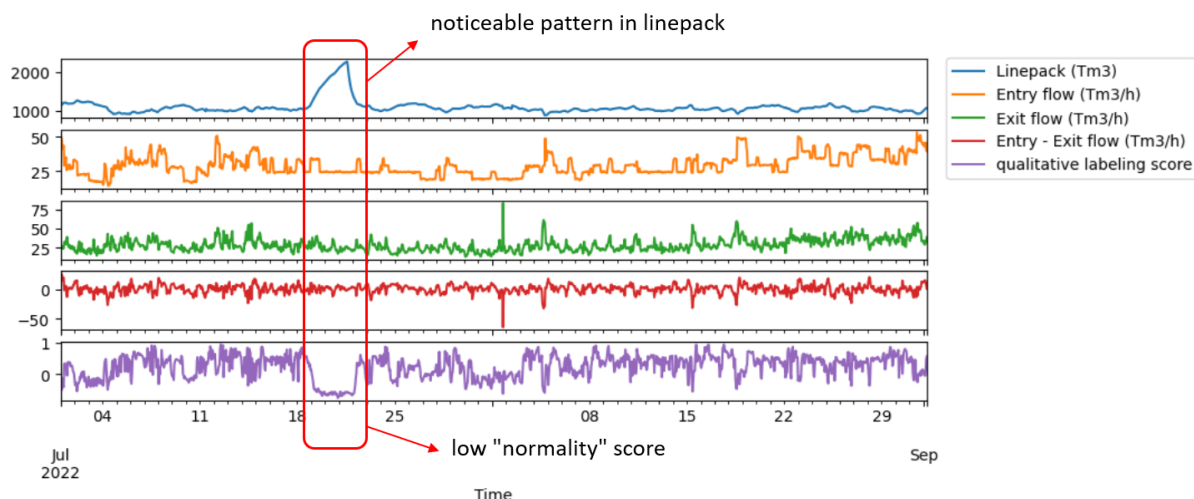


Abbildung 5 Anomalieerkennung mittels Kernel-Density-Schätzung auf historisierten Daten

Ein ungewöhnliches Muster ist zwischen dem 19. und 22. Juli 2022 zu beobachten (in Abbildung 5 mit einem roten Rahmen markiert): Die mit dem Linepack verknüpften Labeling-Funktionen für die „Normalität“ fielen auf -1, während andere (z. B. die Normalität für den Einlass- oder Auslassdurchfluss, nicht dargestellt) während dieser Zeit im normalen Bereich blieben. Die Ursache dieser Anomalie konnte ermittelt werden, indem festgestellt wurde,

welche Zustandswerte den starken Abfall des Anomalie-Scores verursachten: in diesem Fall anomale Werte im Netzpaket. Später stellte sich heraus, dass die zuverlässig erkannte Anomalie durch eine fehlerhafte Übertragung einer Ventilstellung verursacht wurde, die zu einem Berechnungsfehler in der Simulation führte, mit der der Netzpufferwert ermittelt wurde.

3.2 Imitationslernen von Dispatcher-Aktionen

Im Bereich des bestärkenden Lernens wurde zunächst eine vereinfachte Simulationsumgebung entwickelt, die sich an den internationalen Standard der Farama-Gymnasium-Schnittstelle³ (früher OpenAI Gym) hält. Dabei wurden die Referenzdaten von Juni 2021 bis September 2022 wiederum als Grundlage für die Simulation der Episoden der Trainingsumgebung eingesetzt. Diese Daten umfassen makroskopisch Einspeisung, Ausspeisung und Netzhalt für ein Testnetz der Avacon. Neben einer gründlichen Definition der Umgebung nach Software-Engineering-Prinzipien (z.B. Normierung des Zustands- und Aktionsvektors, Parallelisierbarkeit der Umgebungen, Reproduzierbarkeit durch fixierbare Zufalls-Seeds) wurden zwei KI-Agenten mit den für kontinuierliche Aktionsräume geeigneten Lernalgorithmen PPO (*proximal policy optimization*, (Schulman et al. 2017)) und SAC (*soft actor critic*, (Haarnoja et al. 2018)) in der Softwarebibliothek StableBaselines3 trainiert.

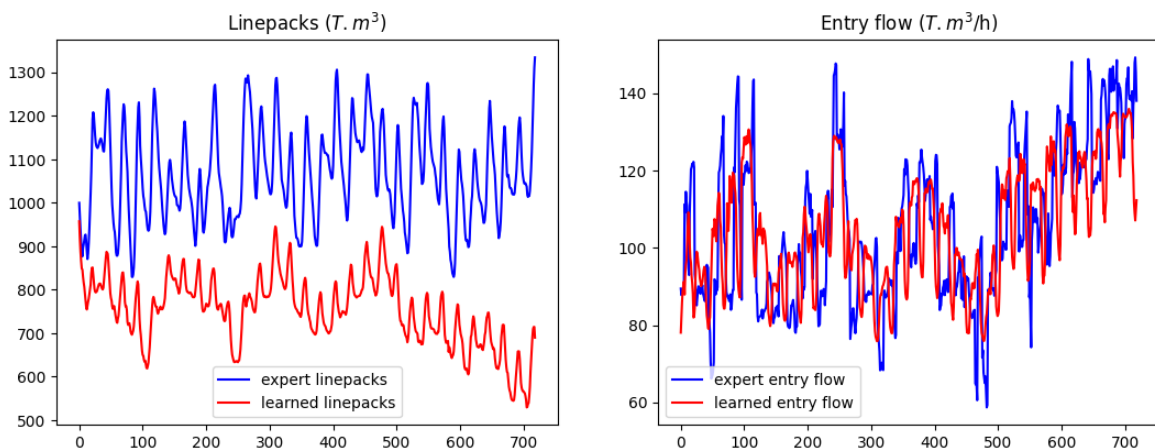


Abbildung 6 Beispiel für Imitationslernen nach historisierten

Dabei stellte sich heraus, dass von Grund auf per Versuch-und-Irrtum trainierte Agenten teilweise zu Ein- und Ausspeisungen geführt haben, die stark im Widerspruch zu den von Expert:innen erwarteten Fahrweisen stehen, was eine niedrige Akzeptanz und Vertrauen in die Technologie zur Folge hätten – selbst wenn diese unkonventionellen Fahrweisen zu höheren Belohnungswerten der modellierten Zielfunktion führten. Aus diesem Grund wird nun zunächst versucht, die real ausgeführten Einspeisungen per Imitationslernen als Ausgangsbasis für das weitere Training der Policies zu verwenden – im Gegensatz zu überwachtem Lernen (Labelinformation ist als Trainingsziel vorhanden) versuchen die Agenten hier sowohl hohe Belohnungen zu erreichen, als auch erwartungskonforme Aktionen auszuwählen. Abbildung 6 zeigt erste Ergebnisse mit *Generative Adversarial Imitation Learning* (Ho und Ermon 2016), wobei ein Diskriminatormodell darauf trainiert wird, zwischen den Aktionen von Experten und denen von Lernenden zu unterscheiden. Auch wenn die

³ <https://gymnasium.farama.org/index.html>

Netzpufferwerte und Einspeisemengen noch nicht 1:1 getroffen werden, zeigt sich, dass der prinzipielle Trend gut getroffen wurde. Dies ist insbesondere aufgrund des Umstandes erfreulich, dass den Softwareagenten in ihrem Beobachtungszustand noch keine Prognosen über die Wetter- und Nachfrageentwicklung zur Verfügung gestellt wurde – was natürlich Entscheidungsgrundlage der Dispatcher ist.

4 Ausblick

In den nächsten Schritten des Projekts wird das einfache Trainingssystem für Agenten auf ein Testnetz mit mehreren Einspeisepunkten erweitert und mit weiteren historisierten Betriebsdaten aufgewertet. Zudem erhalten die Softwareagenten Prognosewerte, um zu besseren Entscheidungen zu kommen. Gleichzeitig wird der Ansatz ausgebaut, aus Konzepten der multikriteriellen Entscheidungsfindung Präferenz- und Belohnungsmodelle abzuleiten, mit denen Agenten gut und erwartungskonform trainiert werden können. Technisch erfordert der Sprung auf die Einbindung der Software PSIGanesi auch die verstärkte Parallelisierung durch industrielle KI-Frameworks wie Ray. Im Umfeld der Anomalieerkennung und des unüberwachten Lernens sollen höherdimensionale Daten verarbeitet werden und in Datenworkshops mit Dispatchern besprochen und analysiert werden. Dies geht Hand in Hand mit der Anpassung des Label-Studios auf die Bedürfnisse der beteiligten Stakeholder. Letztendlich wird sich die Leistungsfähigkeit und Nützlichkeit der Ansätze im adversarischen Lernen zeigen, wobei kritische Situationen gezielt in der Simulation herbeigeführt werden können. Sollten sich die KI-Ansätze als erfolgreich erweisen, ist eine Ausweitung auf weitere Anwendungsfälle (u.a. Sektorkopplung, Wasserstoffnetze, gemischte Einspeisungen) geplant.

Gefördert durch das Bundesministerium für Bildung und Forschung (BMBF), Deutschland im Rahmen des Programms ``Forschung für die zivile Sicherheit Bekanntmachung: „Künstliche Intelligenz in der zivilen Sicherheitsforschung II“ Förderkennzeichen 13N16366 bis 13N16370. Autor:innen in alphabetischer Reihenfolge.

5 Referenzen

Awuku, Bright; Huang, Ying; Yodo, Nita (2023): Predicting Natural Gas Pipeline Failures Caused by Natural Forces: An Artificial Intelligence Classification Approach. In: *Applied Sciences* 13 (7), S. 4322. DOI: 10.3390/app13074322.

Business-Entscheidungen und Optimierungen mit Qualicision von F/L/S (2007).

Christian Wirth; Riad Akrouf; Gerhard Neumann; Johannes Fürnkranz (2017): A Survey of Preference-Based Reinforcement Learning Methods. In: *Journal of Machine Learning Research* 18 (136), S. 1–46. Online verfügbar unter <https://jmlr.org/papers/v18/16-634.html>.

Di Cao; Hu, Weihao; Zhao, Junbo; Zhang, Guozhou; Zhang, Bin; Liu, Zhou et al. (2020): Reinforcement Learning and Its Applications in Modern Power and Energy Systems: A Review. In: *Journal of Modern Power Systems and Clean Energy* 8 (6), S. 1029–1042. DOI: 10.35833/MPCE.2020.000552.

Donti, Priya L.; Kolter, J. Zico (2021): Machine Learning for Sustainable Energy Systems. In: *Annu. Rev. Environ. Resour.* 46 (1), S. 719–747. DOI: 10.1146/annurev-environ-020220-061831.

Dynamic gas network simulation with GANESI (1999).

Fan, Lin; Su, Huai; Zio, Enrico; Chi, Lixun; Zhang, Li; Zhou, Jing et al. (2022): A deep reinforcement learning-based method for predictive management of demand response in natural gas pipeline networks. In: *Journal of Cleaner Production* 335, S. 130274. DOI: 10.1016/j.jclepro.2021.130274.

Felix, Rudolf (2015): On Consistency of Decision Goals and Separability of Preferences of Decision Alternatives. In: *2015 Conference of the International Fuzzy Systems Association and the European Society for Fuzzy Logic and Technology (IFSA-EUSFLAT-15)*, S. 844–850. DOI: 10.2991/ifsa-eusflat-15.2015.119.

Haarnoja, Tuomas; Zhou, Aurick; Abbeel, Pieter; Levine, Sergey (2018): Soft Actor-Critic: Off-Policy Maximum Entropy Deep Reinforcement Learning with a Stochastic Actor. Online verfügbar unter <http://arxiv.org/pdf/1801.01290.pdf>.

Ho, Jonathan; Ermon, Stefano (2016): Generative Adversarial Imitation Learning. Online verfügbar unter <http://arxiv.org/pdf/1606.03476.pdf>.

Ihsan, Aditya Firman; Astuti, Widi (2022): Deep Learning Based Anomaly Detection on Natural Gas Pipeline Operational Data. In: *2022 2nd International Conference on Intelligent Cybernetics Technology & Applications (ICICyTA)*: IEEE.

Liu, Xiaorui; Ospina, Juan; Konstantinou, Charalambos (2020): Deep Reinforcement Learning for Cybersecurity Assessment of Wind Integrated Power Systems. In: *IEEE Access* 8, S. 208378–208394. DOI: 10.1109/ACCESS.2020.3038769.

Petkovic, Milena; Koch, Thorsten; Zittel, Janina (2022): Deep learning for spatio-temporal supply and demand forecasting in natural gas transmission networks. In: *Energy Science & Engineering* 10 (6), S. 1812–1825. DOI: 10.1002/ese3.932.

Schulman, John; Wolski, Filip; Dhariwal, Prafulla; Radford, Alec; Klimov, Oleg (2017): Proximal Policy Optimization Algorithms. Online verfügbar unter <http://arxiv.org/pdf/1707.06347.pdf>.

Weiss, Joseph; Stephens, Rob; Miller, Nadine; Michael, James Bret (2022): Control System Cyber Incidents Are Real—and Current Prevention and Mitigation Strategies Are Not Working. In: *Computer* 55 (1), S. 128–137. DOI: 10.1109/MC.2021.3124359.

Yang, Dong; Yan, Siyun; Zhou, Dengji; Shao, Tiemin; Zhang, Lin; Xing, Tongsheng (2020): Reinforcement Learning Methods on Optimization Problems of Natural Gas Pipeline Networks. In: *4th International Conference on Smart Grid and Smart Cities (ICSGSC)*, S. 29–34. DOI: 10.1109/ICSGSC50906.2020.9248563.