

IMPULSPAPIER

KI in der Energiesystemanalyse: Vier Hebel für die nächste Entwicklungsstufe

Themengruppe 5 - KI und Energiesystemanalyse | **Jahrestreffen 2026, 28./29. April 2026**

Tanja Kneiske (tanja.kneiske@ieg.fraunhofer.de), Uwe Krien, Mihail Ketov, Yash Patel, Daniel Horst für die Mitglieder der TG5

1 Einordnung und Zielsetzung

Die Energiesystemanalyse befindet sich in einer Phase beschleunigter Transformation. Neben der zunehmenden Kopplung von Strom-, Wärme-, Gas- und Wasserstoffsystemen verändern insbesondere Methoden der Künstlichen Intelligenz (KI) die Art und Weise, wie Daten erstellt und verarbeitet sowie Modelle genutzt und Entscheidungen vorbereitet werden. Diese Entwicklung wird auch in jüngeren Überblicksarbeiten hervorgehoben, etwa in ^[1] Datenanalyse und Künstliche Intelligenz im Stromverteilernetz (Fraunhofer IEE) sowie ^[2] Generative Artificial Intelligence in the Energy Sector (Fraunhofer CINES), die KI zunehmend als strukturellen Bestandteil zukünftiger Energiesystemanalyse beschreiben.

Während KI bislang vor allem in klar abgegrenzten Teilbereichen eingesetzt wurde, zeichnet sich aktuell eine Entwicklung hin zu einer durchgängigen Integration entlang der gesamten Analysepipeline ab. Diese reicht von der Datenbasis über Prognosen und Optimierung bis hin zur Interaktion mit komplexen Modellen.

Dieses Impulspapier strukturiert diese Entwicklung entlang von vier Themenfeldern, die sich durch ihren Neuheitsgrad unterscheiden: von etablierten Anwendungen im Bereich Daten und Prognosen bis hin zu neu entstehenden Konzepten, in denen KI als aktiver Interaktionspartner in Modellierungs- und Entscheidungsprozessen agiert. Ziel ist es, zentrale Entwicklungen einzuordnen, Forschungsfragen zu bündeln und Impulse für die weitere Arbeit in der Community zu geben, für Einsteigende ebenso wie für erfahrene KI-Anwenderinnen und -Anwender in der Energiesystemanalyse.

2 Zentrale Entwicklungslinie

Die Integration von KI in die Energiesystemanalyse folgt einer klaren Entwicklung (siehe auch Abbildung 1):

- Zunächst wird KI genutzt, um bestehende Datenprobleme einzeln zu adressieren,
- darauf aufbauend verbessert sie Prognosen als Grundlage der Modellierung,
- im nächsten Schritt verändert sie Optimierungsverfahren zu lernenden und adaptiven Entscheidungsprozessen,
- und schließlich agiert KI als Interaktions- und Orchestrierungspartner für Modelle, Simulationen und agentische Systemprozesse.

Diese Entwicklung beschreibt keinen Ersatz bestehender Methoden, sondern eine zunehmende Durchdringung und Neuorganisation der gesamten Analyseketten.




Abbildung 1: Entwicklungslinie der KI in der Energiesystemanalyse (Quelle: Tanja und ChatGPT2025)

3 Vier Fokusthemen entlang des Neuheitsgrades

3.1 Generative KI für Daten: Von der Knappheit zur Gestaltbarkeit

Was ändert sich für die Praxis? Daten müssen nicht mehr ausschließlich erhoben werden - sie können zunehmend aktiv generiert, ergänzt und variiert werden. Das eröffnet neue Möglichkeiten, ist aber kein Freifahrtschein: Qualität und physikalische Konsistenz müssen sichergestellt bleiben.

Daten bilden die Grundlage jeder Energiesystemanalyse, sind jedoch häufig unvollständig, heterogen oder nur eingeschränkt zugänglich. Der Einsatz von generativer KI markiert hier eine erste, bereits heute sichtbare Erweiterung klassischer Ansätze.

Statt Daten ausschließlich zu erheben oder aufzubereiten, können sie zunehmend aktiv generiert oder ergänzt werden. Dies betrifft insbesondere synthetische Zeitreihen, räumliche Datenstrukturen oder konsistente Szenarien. Damit verschiebt sich die Rolle von Daten grundlegend: von einer gegebenen, statischen Eingangsgröße hin zu einer Ergebnisgröße, abgeleitet aus einem gestaltbaren Bestandteil der Analyse selbst.

Neuere Entwicklungen deuten darüber hinaus an, dass generative Modelle nicht nur Daten ergänzen, sondern zunehmend selbst als datengetriebene Repräsentationen komplexer Systemzustände, Szenarienräume oder digitaler Zwillinge fungieren können. Damit verschiebt sich der Fokus von synthetischer Datengenerierung hin zu generativen Modellen als Bestandteil physikalisch informierter Analyseumgebungen.

Diese Entwicklung eröffnet neue Möglichkeiten, etwa zur Überbrückung von Datentlücken oder zur systematischen Variation von Szenarien. Gleichzeitig entstehen neue Anforderungen an die Bewertung von Datentqualität sowie die Sicherstellung physikalischer Konsistenz.

Spannungsfeld: Die steigende Verfügbarkeit von Daten steht einer wachsenden Unsicherheit über deren Realitätsnahe gegenüber - eine zentrale methodische Herausforderung für die Community.

Zentrale Forschungsfragen

- In welchen Kontexten sind synthetische Daten valide und hilfreich?
- Wie lässt sich die Qualität und Plausibilität generierter Daten bewerten?
- Wie können physikalische Randbedingungen und systemische Zusammenhänge berücksichtigt werden?

Beispielanwendungen

SYLAS-KI^[9]: GAN-basierte synthetische Stromlastzeitreihen für verschiedene Verbrauchertypen - DSGVO-konform und für das Training datenintensiver Modelle geeignet.

AgentHomelD^[4]: Einsatz von Conditional Variational Autoencodern (CVAE) zur Generierung synthetischer Gebäude- und Haushaltsprofile; auf dieser Basis können konsistente Szenarien und Populationen erzeugt werden.

Foundation Models für Zeitreihen: Lag-Llama^[5], Moirai^[6], TimeGEN^[7] ermöglichen domänenübergreifende Generierung und Ergänzung synthetischer und fehlender Daten.

Neue Forschungsrichtungen adressieren zudem physik-informierte generative Modelle und sogenannte Generative World Models, in denen Daten nicht nur reproduziert, sondern unter Berücksichtigung physikalischer Nebenbedingungen simulativ erzeugt werden, etwa für Netz- und Systemzustände oder Szenarienräume. Ergänzend eröffnen generative Modelle für strukturierte Geodaten und digitale Zwillinge, etwa auf Basis diffuser oder graphbasierter Modelle, neue Perspektiven für die Erzeugung konsistenter Infrastruktur- und Planungsdaten.

3.2 KI für Forecasting: Von Punktprognosen zu Unsicherheitsräumen

Was ändert sich für die Praxis? Prognosen werden nicht nur präziser - sie werden informativer. Unsicherheiten lassen sich explizit abbilden und direkt in Entscheidungsprozesse integrieren. Neue Foundation Models ermöglichen zudem, Prognosemodelle auf neue Regionen und Anwendungsfälle zu übertragen, ohne vollständiges Neutraining.

Auf der Datenbasis aufbauend spielen Prognosen eine zentrale Rolle in nahezu allen Bereichen der Energiesystemanalyse. KI-Methoden sind hier bereits etabliert, entwickeln sich jedoch aktuell in Richtung deutlich komplexerer und leistungsfähigerer Ansätze.

Während klassische Verfahren häufig auf Punktprognosen abzielen, rücken zunehmend Zeitreihen- und probabilistische Prognosemodelle in den Vordergrund. Prognosen werden damit nicht nur präziser, sondern auch informativer, da sie Unsicherheiten explizit abbilden und in Entscheidungsprozesse integrierbar machen.

Neue Entwicklungen wie Foundation Models oder kontextadaptive Ansätze deuten zudem darauf hin, dass Prognosemodelle künftig stärker übertragbar und flexibler einsetzbar werden. Gleichzeitig zeichnet sich eine Entwicklung von spezialisierten Prognosemodellen hin zu vortrainierten Foundation Models, multimodalen Prognosesystemen und agentisch orchestrierten Forecasting-Pipelines ab, in denen Modellwahl, Unsicherheitsquantifizierung und Szenarienbildung zunehmend integriert betrachtet werden.

Wichtige konzeptuelle Verschiebung: Prognosen sind nicht mehr nur Input für Modelle, sie strukturieren zunehmend selbst die Entscheidungslogik innerhalb der Analyse. Das verändert, wie Prognosequalität bewertet und kommuniziert werden muss.

Zentrale Forschungsfragen

- *Wie lassen sich Unsicherheiten systematisch in Modelle und Entscheidungsprozesse integrieren?*
- *Wie übertragbar sind neue Foundation Models auf spezifische Energieanwendungen in Deutschland und Europa?*
- *Welche Balance zwischen Modellkomplexität und Datenverfügbarkeit ist in der Praxis sinnvoll?*

Beispielanwendungen

Etabliert: KI-gestützte Prognosen für Last-, Wind- und PV-Einspeisung; probabilistische Vorhersagen für Flexibilitäten und Marktpreise.

Time-Series Foundation Models: TimeGPT (Nixtla)^[7], TimesFM (Google)^[8], Chronos (Amazon)^[9]. vortrainierte Modelle für übertragbare Prognosen über unterschiedliche Datendoemänen hinweg mit integrierter Unsicherheitsquantifizierung.

Mixture-of-Experts & agentisches Forecasting: Time-MoE^[10] und TimeCopilot^[11] adressieren automatisierte Modellwahl, adaptive Prognosepipelines und die Kombination mehrerer Modelle in dynamischen Unsicherheitsräumen.

Ergänzend entstehen **physik-informierte und multimodale Prognosemodelle**, die Wetter-, Markt-, Sensor- und Infrastrukturdaten gemeinsam berücksichtigen und damit neue Perspektiven für adaptive und robuste Energiesystemanalysen eröffnen.

3.3 KI und Optimierung: Von exakten Lösungen zu lernenden Approximationen

Was ändert sich fuer die Praxis? Rechenintensive Optimierungsprobleme, die bisher Stunden dauerten, lassen sich durch KI-basierte Surrogatmodelle und lernende Verfahren drastisch beschleunigen - ohne zwingend physikalische Konsistenz zu opfern, wenn hybride Ansätze gut gestaltet sind.

Optimierungsprobleme sind ein Kernbestandteil der Energiesystemanalyse, stoßen jedoch bei steigender Systemkomplexität schnell an rechnerische Grenzen. KI eröffnet hier neue Möglichkeiten, indem sie klassische Verfahren ergänzt und teilweise neu strukturiert. Besonders relevant sind dabei lernbasierte Ansätze zur Beschleunigung:

- Verbesserte Initialisierung (Hot-Starts) und Reduktion des Lösungsraums,
- Surrogatmodelle als schnelle Approximation rechenintensiver Berechnungen,
- Adaptive Such- und Entscheidungsstrategien durch lernende Agenten.

Diese Ansätze führen nicht zu einer Ablösung klassischer Optimierung, sondern zu hybriden Verfahren, in denen datengetriebene und physikalisch fundierte Modelle kombiniert werden. Neuere Entwicklungen gehen darüber hinaus und adressieren Optimierung zunehmend als lernenden und adaptiven Prozess - etwa durch differenzierbare Optimierung, agentische Suchverfahren oder KI-gestützte Exploration hochdimensionaler Lösungsräume.

Zentrales Spannungsfeld: Effizienzgewinne durch Approximation stehen der Notwendigkeit physikalischer Konsistenz und methodischer Transparenz gegenüber. Wann eine Approximation ausreichend genau ist, bleibt eine offene Forschungsfrage.

Zentrale Forschungsfragen

- *Wann ist eine lernbasierte Approximation ausreichend genau - und wie lässt sich das systematisch validieren?*
- *Wie lassen sich physikalische Nebenbedingungen in lernbasierte Modelle zuverlässig integrieren?*
- *Welche Rolle spielt Interpretierbarkeit bei zunehmend komplexen, lernenden Optimierungsverfahren?*

Beispielanwendungen

Re-Twin^[12,13]: KI-basierte Surrogatmodelle für unsicherheitsbehaftete Erlösprognosen und Entscheidungsunterstützung im BESS-Betrieb; illustriert die Einbettung schneller Approximationen in Digital-Twin- und Optimierungsumgebungen.

Lernende Optimierungsverfahren: Physics-Informed Neural Networks (PINNs), Neural Operators (Fourier Neural Operator^[14]), Deep Reinforcement Learning für Steuerungs- und Dispatchprobleme - kombiniert mit klassischen Optimierern.

Differentiable Optimization & Learning to Optimize^[15]: KI nicht mehr nur zur Approximation einzelner Rechenschritte, sondern zur strukturellen Unterstützung oder teilweisen Neugestaltung des Lösungsprozesses.

Frontier: Agentische LLM-gestützte Optimierungsansätze, Multi-Agent Reinforcement Learning für gekoppelte Energiesysteme, GFlowNets^[16] für kombinatorische Lösungsräume, AlphaEvolve-artige Verfahren^[17] - Optimierung entwickelt sich von einem rein numerischen Verfahren zu einem kooperativen, lernenden und teilweise selbstadaptiven Entscheidungsprozess.

3.4 KI-Modell-Simulations-Kopplung: Vom Werkzeug zum Interaktionspartner

Was ändert sich für die Praxis? Simulationsmodelle und Datensysteme werden zugänglicher - nicht mehr nur für Spezialistinnen und Spezialisten, sondern über natürlichsprachliche Schnittstellen für breitere Nutzergruppen. Gleichzeitig entstehen neue Fragen zu Vertrauen, Nachvollziehbarkeit und Qualitätssicherung.

Die bislang beschriebenen Entwicklungen kulminieren in einem qualitativ neuen Paradigma: der Nutzung von KI als aktiver Interaktionspartner im Umgang mit Modellen und Simulationen. Im Mittelpunkt steht nicht mehr nur die Verbesserung einzelner Methoden, sondern die Orchestrierung gesamter Modellketten durch KI-Systeme, die Modelle auswählen, parametrisieren, koppeln und ihre Ergebnisse interpretieren.

Perspektivisch erweitert sich dies zu agentischen und kooperativen Systemen, in denen KI nicht nur Modellketten orchestriert, sondern innerhalb simulativer Umgebungen selbst lernen, experimentieren und mit physikalischen Modellen rückgekoppelt interagieren kann. Insbesondere Large Language Models ermöglichen dabei eine neue Form der Interaktion: Modelle werden über natürliche Sprache zugänglich, Ergebnisse können kontextabhängig erklärt und für unterschiedliche Zielgruppen aufbereitet werden.

Damit verändert sich die Rolle von Modellen grundlegend, sie werden nicht mehr ausschließlich von Expertinnen und Experten bedient, sondern können über KI-basierte Schnittstellen breiter nutzbar gemacht werden.

Zentrale Forschungsfragen

- *Wie lässt sich Vertrauen in KI-orchestrierte Modellketten systematisch aufbauen und sicherstellen?*
- *Welche neuen Anforderungen entstehen an Validierung und Qualitätssicherung bei LLM-gestützter Modellbedienung?*
- *Wie weit kann die Automatisierung von Modellpipelines gehen - und wo sind Grenzen sinnvoll?*
- *Inwiefern lässt sich eine KI innerhalb einer Simulationsumgebung trainieren und verbessern?*

Beispielanwendungen

KI-gestützter Datenbankzugriff (Urban Twin / MinIO): Über eine KI-basierte Schnittstelle werden große, heterogene Datenbestände aus MinIO sowie strukturierte Urban-Twin-Daten in PostgreSQL/PostGIS niedrigschwellig zugänglich gemacht. Unterstützt durch GitHub Copilot können auch komplexe Datenbankinhalte explorativ erschlossen werden, ein konkretes Beispiel dafür, wie KI den Zugang zu umfangreichen Datenbeständen für breitere Nutzergruppen öffnet.

Fr.E.D. / HEATogether (Start Juni 2026): Fr.E.D. (derzeit Fraunhofer-Energie-Diologs-Assistent des Fraunhofer IEG) ist ein dialogbasierter KI-Assistent für sektorübergreifende Wärmeplanung, in dem Large Language Models über standardisierte Schnittstellen (Model Context Protocol, MCP) mit Simulationswerkzeugen, Datensystemen und Planungsmodellen gekoppelt werden, um Modelle interaktiv zugänglich zu machen, Szenarien im Dialog zu explorieren und Entscheidungen zielgruppenspezifisch zu unterstützen.

Agentische Frameworks: ReAct^[18], LangGraph^[19], MetaGPT^[20] - Tool-augmented LLMs, die Simulationsmodelle nicht nur abfragen, sondern orchestrieren, parametrisieren und in iterative Analyseprozesse einbinden.

Frontier: Reinforcement-Learning-basierte Simulationsagenten, digitale Zwillinge als KI-Trainingsumgebungen, World Models^[21]. Erste Entwicklungen in Richtung autonomer wissenschaftlicher Agentensysteme deuten darauf hin, dass sich Modell-Simulation-Kopplung perspektivisch zu einer neuen Form kollaborativer Mensch-KI-Systeme weiterentwickeln könnte.

4 Verbindungslinien: Integration statt Einzelanwendungen

Die vier beschriebenen Themenfelder bauen inhaltlich aufeinander auf und sind eng miteinander verknüpft. Daten bilden die Grundlage für Prognosen, diese wiederum beeinflussen Optimierungsprozesse, die schließlich in komplexe Modellketten eingebettet sind.

KI wirkt dabei zunehmend als verbindende Schicht zwischen diesen Ebenen. Es entsteht ein integriertes System, in dem Daten, Modelle und Algorithmen nicht mehr isoliert betrachtet werden, sondern dynamisch miteinander interagieren. Dabei zeigt sich eine Entwicklung von spezialisierten Einzelverfahren hin zu foundation-basierten, lernenden und zunehmend agentischen Systemen, in denen Datengenerierung, Prognose, Optimierung und Simulation nicht nur gekoppelt, sondern teilweise gemeinsam neu organisiert werden.

Insbesondere physik-informierte Foundation Models, agentische Optimierungsansätze und kooperative Mensch-KI-Simulationsumgebungen deuten darauf hin, dass sich die Energiesystemanalyse perspektivisch von einer sequenziellen Werkzeugkette zu einem adaptiven, interaktiven Analyse- und Entscheidungsraum entwickeln könnte. Dies erfordert nicht nur eine stärkere Integration von Methoden, sondern auch neue Formen des Zusammenspiels von Modellierung, maschinellem Lernen und wissenschaftlicher Entscheidungsunterstützung.

Die vier Hebel wirken dabei weniger als getrennte Technologiefelder, sondern als aufeinander aufbauende Stufen hin zu zunehmend integrierten, lernenden und agentischen Infrastrukturen für die Energiesystemanalyse.

5 Offene Forschungsfragen

Die beschriebenen Entwicklungen werfen eine Reihe grundlegender Fragen auf, die für die zukünftige Forschung zentral sind und sich nicht isoliert innerhalb einzelner Disziplinen lösen lassen. Zentrale offene Forschungsfragen betreffen dabei nicht nur die Validierung einzelner KI-Methoden, sondern zunehmend auch:

- die Zuverlässigkeit von Foundation Models in wissenschaftlichen Energieanwendungen - und wie sie systematisch bewertet werden kann,
- die Kopplung datengetriebener und physikalisch fundierter Modelle,
- lernende und agentische Optimierungsverfahren unter Sicherheits- und Robustheitsanforderungen,
- Gedächtnis-, Planungs- und Koordinationsmechanismen in Multi-Agent-Systemen für komplexe Modellumgebungen,
- sowie die systematische Zusammenführung von physikalischer Konsistenz, Unsicherheitsquantifizierung und erklärbarer KI mit generativen und agentischen Verfahren.

Im methodischen Bereich betrifft dies insbesondere die Vergleichbarkeit und Validierung von KI-gestützten Ansätzen sowie den Umgang mit Unsicherheiten. Technisch stehen Fragen der Integration, Skalierbarkeit und Robustheit im Vordergrund. Darüber hinaus gewinnen Transparenz, Nachvollziehbarkeit und Vertrauen in KI-basierte Systeme zunehmend an Bedeutung.

Diese Herausforderungen erfordern eine enge Verzahnung von Energiesystemanalyse, Informatik und anwendungsnaher Forschung - und damit genau die interdisziplinäre Zusammenarbeit, die das Forschungsnetzwerk Energiesystemanalyse ermöglichen kann.

6 Ausblick und Diskussionsimpuls

Die Integration von KI in die Energiesystemanalyse ist kein punktueller Entwicklungsschritt, sondern Teil eines umfassenden Wandels. Die hier dargestellten Themenfelder zeigen, dass sich nicht nur einzelne Methoden verändern, sondern die Struktur der gesamten Analyseprozesse, von der Datenbasis bis zur Modellorchestrierung.

Perspektivisch zeichnet sich dabei nicht nur eine Weiterentwicklung bestehender Werkzeuge ab, sondern möglicherweise ein Paradigmenwechsel hin zu kooperativen Mensch-KI-Systemen, in denen Daten, Modelle und intelligente Agenten gemeinsam neue Formen wissenschaftlicher Analyse und Entscheidungsunterstützung ermöglichen.

Für die Community stellt sich daher eine grundlegende Frage:

Ist die Energiesystemanalyse bereit für kooperative Mensch-KI-Systeme und was würde das methodisch, institutionell und für die Ausbildung des Nachwuchses bedeuten?

Dieses Impulspapier versteht sich als Einladung, diese Entwicklung gemeinsam weiterzudenken, konkrete Anwendungsbeispiele zu identifizieren und methodische Ansätze systematisch weiterzuentwickeln. Die Themengruppe 5 bietet hierfür einen Rahmen, um unterschiedliche Perspektiven zusammenzuführen und die Rolle von KI in der Energiesystemanalyse aktiv zu gestalten.

Referenzen

- [1] Fraunhofer IEE (2023): Datenanalyse und KI im Stromverteilernetz https://future-energy-lab.de/app/uploads/2023/01/Fraunhofer_Gutachten_KI_im_Stromnetz.pdf
- [2] Fraunhofer CINES (2024): Generative AI in the Energy Sector <https://epub.uni-bayreuth.de/id/eprint/7674/1/GenAI-in-the-Energy-Sector.pdf>
- [3] SYLAS-KI – Fraunhofer IEE Projektseite <https://www.iee.fraunhofer.de/de/projekte/suche/2021/sylas-ki.html>
- [4] AgentHomeID – Publica Fraunhofer (Konferenzbeitrag) <https://publica-rest.fraunhofer.de/server/api/core/bitstreams/c5e1e9b7-95ad-4312-95a1-60b3eed6133/content>
- [5] Rasul et al. (2023): Lag-Llama – arxiv:2310.08278 <https://arxiv.org/abs/2310.08278>
- [6] Liu et al. (2024): Moirai – arxiv:2402.02592 <https://arxiv.org/abs/2402.02592>
- [7] Nixtla: TimeGEN – Dokumentation [TimeGEN: A Cross-Domain and Generative Model for Time Series Forecasting | OpenReview](https://nixtla.com/timegen/)
- [8] Google Research: TimesFM – GitHub <https://github.com/google-research/timesfm>
- [9] Amazon Science: Chronos – GitHub <https://github.com/amazon-science/chronos-forecasting>
- [10] Shi et al. (2024): Time-MoE – arxiv:2409.16040 <https://arxiv.org/abs/2409.16040>
- [11] Garza & Rosillo (2025): TimeCopilot – arxiv:2509.00616 <https://arxiv.org/abs/2509.00616>
- [12] Khan et al. (2022): AI-based Digital Twins – arxiv:2210.00073 <https://arxiv.org/abs/2210.00073>
- [13] Re-Twin – Projektwebsite <https://re-twin.energy>
- [14] Li et al. (2020): Fourier Neural Operator – arxiv:2010.08895 <https://arxiv.org/abs/2010.08895>
- [15] Kotary et al. (2022): Differentiable Optimization – arxiv:2209.00606 <https://arxiv.org/abs/2209.00606>
- [16] Bengio et al. (2021): GFlowNets – arxiv:2111.09266 <https://arxiv.org/abs/2111.09266>
- [17] Novikov et al. (2025): AlphaEvolve – arxiv:2506.13131 <https://arxiv.org/abs/2506.13131>
- [18] Yao et al. (2022): ReAct – arxiv:2210.03629 <https://arxiv.org/abs/2210.03629>
- [19] LangChain: LangGraph – Website <https://www.langchain.com/langgraph>
- [20] Hong et al. (2023): MetaGPT – arxiv:2308.00352 <https://arxiv.org/abs/2308.00352>
- [21] Ha & Schmidhuber (2018): World Models – arxiv:1803.10122 <https://arxiv.org/abs/1803.10122>