

Vorhersage der dynamischen Stabilität von Stromnetzen durch Maschinelles Lernen

Christian Nauck

PIK RD 4 - Complexity Science - ICONE

Klimawandel als Herausforderung für Stromnetze

Die Adaption und Mitigation des Klimawandels beeinflussen beide die Zukunft der Stromnetze.

- 1) Die Mitigation des Klimawandels verlangt nach klimaneutraler Energieversorgung, bei der der Großteil der Energie durch Solar und Energie bereitgestellt werden soll. Erneuerbare Energien sind dezentraler, haben weniger Trägheit und die Produktion unterliegt natürlichen Schwankungen. Erneuerbare Energien müssen zukünftig einen Beitrag zur Stromnetzstabilität leisten.
- 2) Steigende globale Temperaturen erhöhen die Wahrscheinlichkeit und Intensität von Extremwetterereignissen wie Hurricanes und Hitzewellen, die besonders anspruchsvoll für den Betrieb der Stromnetze sind.

Um die Herausforderung des Klimawandels zu begegnen müssen beide Herausforderungen simultan angegangen werden und dies erfordert neue Ansätze um die Dynamik von Stromnetzen zu untersuchen.

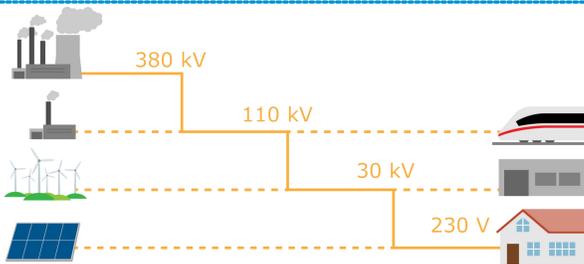


Abb. 1 Übersicht der Spannungsebenen, erneuerbare Energien sind im Vergleich zu konventionellen Kraftwerken bei niedrigerer Spannung angeschlossen

Modellierungen von Stromnetzen

Dynamische Modellierungen von Stromnetzen sind rechenintensiv und es ist unmöglich alle Konfigurationen zu analysieren. Ein gängiger Ansatz sind probabilistische Analysen von Stromnetzen, um Wahrscheinlichkeiten für kritische Zustände zu bestimmen. Als Alternative zu den rechenaufwändigen Simulationen bietet sich Maschinelles Lernen an, um zahlreiche unterschiedliche Konfiguration in Kürze analysieren zu können.

Vorhersage der dynamischen Stabilität mit Graph Neural Networks

Graph Neural Networks (GNNs) sind eine besondere Methode des Maschinellen Lernens, welche insbesondere für die Analyse von Graphen geeignet ist. Um die Plausibilität des Ansatzes zu beschreiben werden neue Datensätze generiert. Das Vorgehen ist in der folgenden Abbildung dargestellt.

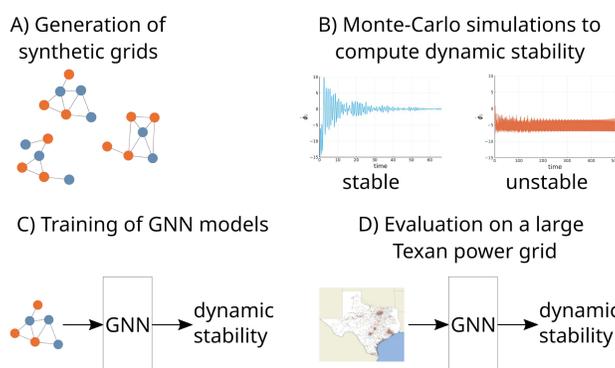


Abb. 2 Neue Datensätze der dynamischen Stabilität werden generiert mit A) synthetischen Stromnetzen, B) dynamischen Simulationen, C) die Datensätze sind Grundlage fürs Training der GNNs D) und die trainierten Modelle werden auf einem texanischen Stromnetz evaluiert

GNNs werden anhand des Datensatzes trainiert, um die die Stabilität nur auf Basis der Topologie vorauszusagen.

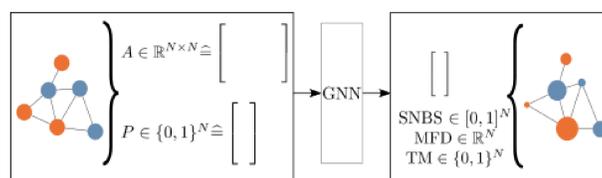


Abb. 2 Die dynamische Stabilität wird vorhergesagt auf Basis der Adjazenzmatrix, welche die Topologie beschreibt und den Knoteneigenschaften (Quelle oder Senke). Das Resultat sind Stabilitätsmaße (wie SNBS) für jeden Knoten, wobei jeweils die Reaktion des gesamten Gitters auf die Störungen an den Knoten beschrieben wird.

Die Performance verschiedener GNNs ist in der folgenden Tabelle dargestellt.

Tab. 1 Vorhersage von SNBS durch R²-Score. tr20ev20 (tr100ev100) bedeutet, dass die GNNs auf Netzen mit 20 (100) Knoten trainiert und evaluiert werden. GNNs sind besser als lineare Regression (linreg) und MLPs.

| model | tr20ev20 | tr100ev100 |
|----------|----------------|---------------|
| Ar-bench | 51.82 ± 2.388 | 60.34 ± 0.299 |
| ArmaNet | 80.63 ± 0.848 | 87.47 ± 0.073 |
| GCNNNet | 70.64 ± 0.262 | 75.49 ± 0.276 |
| SAGNet | 65.46 ± 0.208 | 75.57 ± 0.228 |
| TAGNet | 82.49 ± 0.455 | 88.22 ± 0.135 |
| linreg | 41.75 | 36.29 |
| MLP1 | 58.47 ± 0.149 | 63.59 ± 0.051 |
| MLP2 | 58.20 ± 0.0422 | 65.52 ± 0.038 |

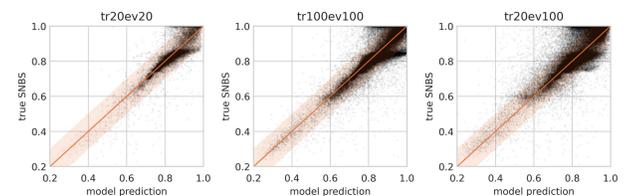


Abb. 3 Visualisierung der Tabelle 2. Ein perfektes Modell wäre immer auf der orangenen Linie. Die schraffierte Fläche zeigt den Bereich mit einem Fehler von ± 0.1.

Da der Rechenaufwand der dynamischen Simulationen mindestens quadratisch mit der Anzahl der Knoten wächst, sind vollwertige Simulationen von Stromnetzen realer Größe wenn überhaupt nur begrenzt möglich. Alternativ wäre es hilfreich, wenn GNNs auch mit kleineren Stromnetzen trainiert werden können und dennoch für alle Größen anwendbar wären. Die Resultate sind in der folgenden Tabelle dargestellt.

Tab. 2 Performance beim Training auf kleinen Netzen und Evaluieren auf größeren, beispielsweise tr20ev100 (tr20evTexas): trainiert auf Netzen mit 20 Knoten, evaluiert auf Netzen mit 100 Knoten (Texas-Stromnetz).

| model | tr20ev100 | tr20evTexas | tr100evTexas |
|----------|---------------|-----------------|----------------|
| Ar-bench | 38.80 ± 1.327 | 38.55 ± 5.897 | 55.22 ± 6.349 |
| ArmaNet | 66.75 ± 1.500 | 60.54 ± 5.622 | 73.47 ± 2.786 |
| GCNNNet | 59.46 ± 0.450 | 2.27 ± 6.210 | -46.02 ± 1.575 |
| SAGNet | 52.27 ± 0.784 | 33.47 ± 0.509 | 55.38 ± 1.390 |
| TAGNet | 66.10 ± 0.508 | 62.69 ± 2.029 | 84.41 ± 0.947 |
| linreg | 5.98 | -11.39 | -22.62 |
| MLP1 | 28.49 ± 1.493 | -34.52 ± 17.934 | 19.79 ± 8.659 |
| MLP2 | 19.65 ± 2.109 | 5.81 ± 10.58 | 58.46 ± 0.480 |

Die Leistungsfähigkeit der GNNs wächst mit der verfügbaren Datenmenge zum Trainieren.

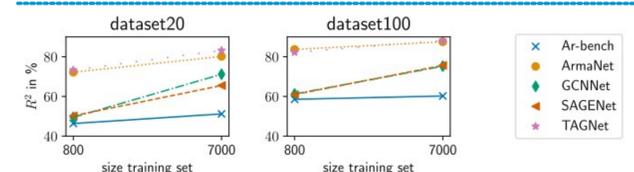


Abb. 3 Mehr Daten erhöhen die Performance.

Ausblick

Für zukünftige Anwendungen müssen die Stromnetzmodelle noch komplexer werden, um das reale Verhalten besser abzubilden. Hierfür gibt es bereits vielversprechende erste Ergebnisse. Außerdem sollte der Entscheidungsprozess der GNNs analysiert werden, um die Ergebnisse erklärbar zu machen.