

Case Study

KI-basierte Netzplanung

Reasonance. Digitale Transformation vorantreiben.

Herausforderung

Die Planung von zuverlässigen, effizienten und kosteneffektiven Stromnetzen ist ein anspruchsvoller Prozess. Darüber hinaus stellen zusätzliche Anforderungen an das Netz wie ein Zusammenschluss von zentraler und dezentraler Energieerzeugung sowie bidirektionale Energieflüsse zusätzliche Komplexitäten dar. Um die Netzplanung zu unterstützen und Teile des Prozesses zu automatisieren, sollte ein Konzepttool entwickelt werden, das weniger Modellierungsaufwand erfordert, aber auch weniger rechenintensiv ist als bestehende Netzplanungsalgorithmen. Ziel der Planung ist es, eine optimierte Netztopologie zu liefern, die geringere Baukosten, weniger Energieübertragungsverluste sowie eine erhöhte Zuverlässigkeit darstellt.

Ansatz

Da die zugrundeliegenden mathematischen Probleme der Netzplanung auf NP-harte Probleme hinauslaufen, wurde ein auf Heuristiken und dem Einsatz von Deep Reinforcement Learning basierender Ansatz entwickelt, um eine praktikable Lösung zu liefern. Als Grundlage für das Projekt wurden die Daten eines bestehenden Stromnetzes eines Verteilnetzbetreibers (VNB) in den Niederlanden verwendet, bestehend aus einer Graphendarstellung des Netzes und dem Strombedarf der einzelnen Verbraucherknotten. Dies ermöglicht den Vergleich der Lösung mit einem realen Netz sowie mit anderen Netzoptimierungstools und -bibliotheken. Nach der Modellierung des Netzes als reguläres Grid mit beliebiger Granularität wurde das Netzplanungsproblem in zwei Probleme aufgeteilt - erstens - das Finden einer optimalen Positionierung von Transformatoren und Erzeugern basierend auf einer Stromverbrauchsverteilung und zweitens - das Finden optimaler Verbindungen zwischen Verbrauchern und Erzeugern. Basierend auf den aktuellen Entwicklungen der Deep Reinforcement Learning-Methoden für kombinatorische Optimierung wurde ein metaheuristischer Ansatz entwickelt, um gleichzeitig eine Kombination von NP-harten Problemen

anzugehen. Ein weiterer heuristischer Algorithmus wird dann verwendet, um anschließend praktikable Lösungen für die resultierenden Teilnetzprobleme zu finden. Die vorgeschlagene Lösung arbeitet auf zwei Ebenen, indem die Teilnetze baumförmig miteinander verbunden werden und auf das Ziel "Min-Kosten-Max-Fluss" optimiert werden. Der Massenschwerpunkt jedes Mikronetzes ist mit dem Netzwerk der höheren Ebene in einer Ringtopologie verbunden, wobei eine generierte Näherungslösung für das Travelling-Salesman-Problem verwendet wird. Die Architektur des neuronalen Netzes mit Reinforcement Learning basiert auf einem Pointer Network mit Attention Modul für Zeitreihen für den Encoder- und Decoderteile. Das Tool wurde als REST-API in der Google Cloud Platform in Betrieb genommen. Dies ermöglicht eine einfache Skalierung der benötigten Rechenressourcen für unterschiedlich große Grids.

Ergebnis

Die von Reasonance entwickelte Lösung bietet eine extrem schnelle Möglichkeit für Netzbetreiber, neue Netzinfrastruktur zu bewerten, indem Baukosten, Übertragungsverluste und der erwartete Strombedarf im gesamten Netz berücksichtigt werden. Wir konnten eine Kosteneinsparung von bis zu 30 % im Vergleich zu realen Stromnetzen und vergleichbare und in einigen Fällen bessere Ergebnisse zu bestehenden Tools und Bibliotheken erzielen. Die Proof-of-Concept-Lösung könnte eine nützliche Grundlage sein, um die Herausforderungen des Netzausbaus und der Netzauslegung für Energieunternehmen zu bewältigen, wobei auch Anwendungen für Gas- oder Wärmenetze möglich sind.

Kontaktdaten

Reasonance GmbH
Todor Kostov
kostov@reasonance.de
+49 721 98991310

DUINN B.V.
Age van der Mei
age.vandermei@duinn.nl