

KI im Netzbetrieb – Chance für die Energiewende?

Zhenqi Wang, Alexander Scheidler, Sebastian Wende-von Berg

Kontakt: Dr. Sebastian Wende-von Berg | +49 561- 7294-298 | sebastian.wende-von.berg@iee.fraunhofer.de

Optimierung unter Unsicherheiten – KI-OPF1+2

Motivation

Neben den Unsicherheiten aus Erzeugungsprognosen beinhalten insbesondere vertikale Lastprognosen an Mittelspannungsumspannwerken eine große Streuung bzgl. ihrer P-Q-Abhängigkeiten. Die können ebenfalls zu Unsicherheiten an z. B. Netzverknüpfungspunkten zwischen HS- und HÖS-Netzen führen und damit auch in Betriebsmittelverletzungen wie z. B. Überschreitungen des Spannungsbandes resultieren.




Abb. 1: Unsicherheiten in der P-Q-Abhängigkeit an MS/HS Umspannwerken (oben links) führen zu Unsicherheiten beim Einstellen fester Arbeitspunkte an Netzverknüpfungspunkten zwischen HS und HÖS (oben rechts). Diese wiederum summieren sich für ganze Netzgruppen/gebiete auf und führen zu signifikanten Abweichungen der Arbeitspunkte (unten links mit unterschiedlichen Unsicherheiten von 5% und 20%). Ebenfalls führen diese Unsicherheiten zu Abweichungen in den erwarteten Spannungsprofilen und können im Extremfall zu Betriebsmittelverletzungen führen.

Weiterhin müssen in einer Optimierung von Netzzuständen für den realen Netzbetrieb diverse Nebenbedingungen und Netzrestriktionen berücksichtigt werden. Neben den relativ gut zu modellierenden Bedingungen wie Spannungsgrenzen oder Leitungsauslastungen, stellt die Berücksichtigung von N-1 Ausfallsicherheit viele Optimierungen vor eine größere Herausforderungen. Insbesondere was die Rechenzeit und somit Echtzeitfähigkeit angeht.




Abb. 2: Zerlegung der N-1 relevanten Netzsituationen, die dann von KNNs erlernt werden können und somit in einer späteren Optimierung berücksichtigt werden.

Umsetzung

In den Projekten KI-OPF1+2 wurden Ansätze zur Optimierung von Netzzuständen unter der Berücksichtigung von oben genannten Unsicherheiten und der Nutzung von Blind- und Wirkleistungsstellmöglichkeiten erneuerbarer Energieanlagen untersucht. Hierbei wurden künstliche neuronale Netze (KNN) auf Grundlage von probabilistischen Netzberechnungen trainiert. Neben den Unsicherheiten wurden zusätzlich auch Netzrestriktionen wie N-1 Sicherheit berücksichtigt und somit in einer späteren Optimierung gewährleistet. Dazu wurde ein kombinierter Ansatz aus überwachtem Lernen und selbstlernenden Algorithmen genutzt.




Abb. 3: Vereinfachter skizzierter Prozess des Trainings der KNNs. Diese KNNs werden später in den selbstlernenden Agenten überführt, so dass diese mit in der Optimierung berücksichtigt werden.

Dabei wird das nichtlineare Optimal Power Flow Problem für das überwachte Lernen formuliert und mithilfe gradientenbasierter Optimierung gelöst (Differential Programming). Der Agent lernt anschließend selbstständig geeignete Sollwerte für die Anlagen im Netz zu finden und kann durch die Kombination mit trainierten KNNs, Unsicherheiten und Netzrestriktionen berücksichtigen. Die trainierten KNNs werden mithilfe einer extrem hohen Anzahl von Netzberechnungen angelernet und beinhalten dann Informationen über N-1 Beschränkungen sowie mögliche Abweichungen der Netzzustände durch Fehler in Messungen und Prognosen.

Erste Ergebnisse und potenzielle Anwendung

Nachdem die Schätzungen der trainierten KNNs validiert wurde, konnte der KI-OPF auf einem Satz von Netzszenerarien P-Q-Stellbereiche bestimmen. In der unteren Abbildung ist zu erkennen, dass der für den Netzbetrieb gültige Stellbereich unter Berücksichtigung von N-1 und Unsicherheiten im Training der KNNs die größte Fläche umfasst und somit das größte Flexibilitätspotenzial erfasst.




Abb. 4: Mögliche P-Q-Stellbereiche aus Optimierungsergebnissen unter den verschiedenen Trainingsgrundlagen für einen Netzzustand. (Die gesamte Fläche variiert aufgrund der unterschiedlichen Nebenbedingungen im Training der KNNs).