

# Prognose von Leistungsflüssen im elektrischen Netz mit Graph Neural Networks

Dominik Beinert, Clara Holzhüter

Kontakt: Dominik Beinert | +49 561 7294-252 | dominik.beinert@iee.fraunhofer.de

## Projektidee von PowerGraph

Die Leistungsflüsse im elektrischen Netz, die an Erzeugern wie Wind- und Photovoltaikanlagen, Verbrauchern oder an Transformatoren messbar sind, sind nicht voneinander unabhängig, sondern bedingen sich gegenseitig. Mithilfe von Graph Neural Networks (GNN) sollen die Beziehungen von Systemkomponenten untereinander erlernt und für die Prognose der einzelnen Leistungszeitreihen genutzt werden. Dabei soll aus vorhanden lokalen Features (Wetterprognosen, Verbrauchsprognosen, kalendarische Daten etc.) unter Berücksichtigung der benachbarten Knoten das gewünschte Knotenattribut (Leistungswert am Transformator) berechnet werden.

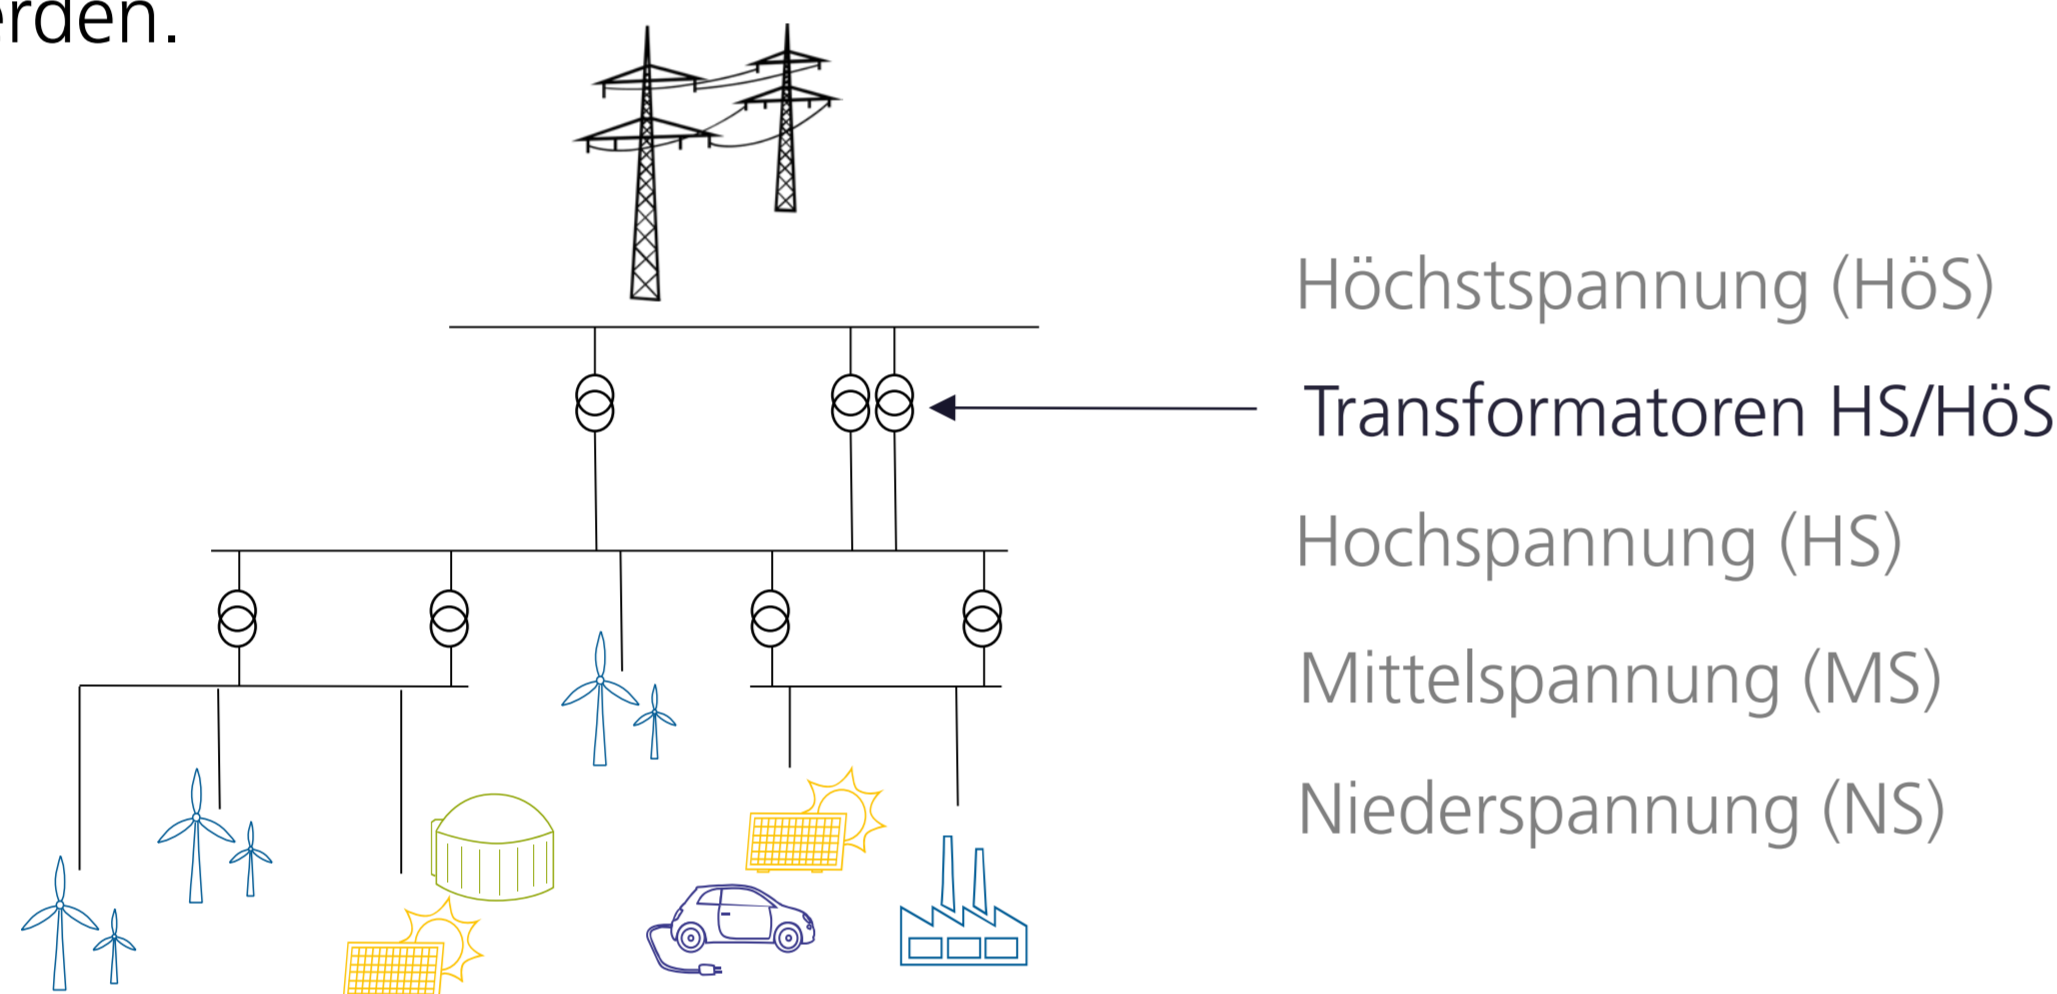


Abb. 1: Schematische Darstellung des elektrischen Netzes sowie der im Projekt untersuchten Transformatoren zwischen Hoch- und Höchstspannung

## Motivation

- Machine-Learning Ansätze mit lokalen Modellen sind nicht in der Lage, Abhängigkeiten zwischen einzelnen Elementen im Netz zu berücksichtigen.
- Beispiel für Abhängigkeiten: Die Wartung eines Transformators kann dazu führen, dass ein oder mehrere „benachbarte“ Transformatoren dessen Aufgabe übernehmen und dadurch eine veränderte Zeitreihencharakteristik zeigen.
- Transformatoren im elektrischen Netz lassen sich durch einen Graphen darstellen, in dem ein Transformator durch einen Knoten repräsentiert ist, während die Kanten zwischen den Knoten anzeigen, ob zwei Transformatoren über elektrische Leiter miteinander verbunden sind.
- GNN können mehrere Eingangsmerkmale pro Knoten unter Berücksichtigung einer Adjazenzmatrix, die die Kanteninformationen des Graphen enthält, auf die jeweiligen Zielwerte abbilden.

## Herausforderungen

- Unterschiedliches Zeitreihenverhalten an verschiedenen Trafos
- GNN erlernen typischerweise die gleich Prognosefunktion für alle Knoten → Ansatz: Kombination aus GNN und Embedding Multi-Task Learning
- Erlernen von Kantengewichten für stark vernetzten Graphen gestaltet sich schwierig → zunächst Annahme eines schwach vernetzten Graphen

## Experimente

- Daten: 175 Trafos zwischen HS und HÖS (1 Jahr Training, 10 Monate Test)
- Nur Trafos am gleichen Standort sind über Kanten verbunden
- Bayesian Embedding als Multi-Task Learning Ansatz
- Attention Convolution (TransformerConv) als GNN Layer

## Ergebnisse

- Beste Performance wird mit attention-based GNN erzielt
- Korreliertes Verhalten von Trafos bei schwach vernetztem Graphen erlernt

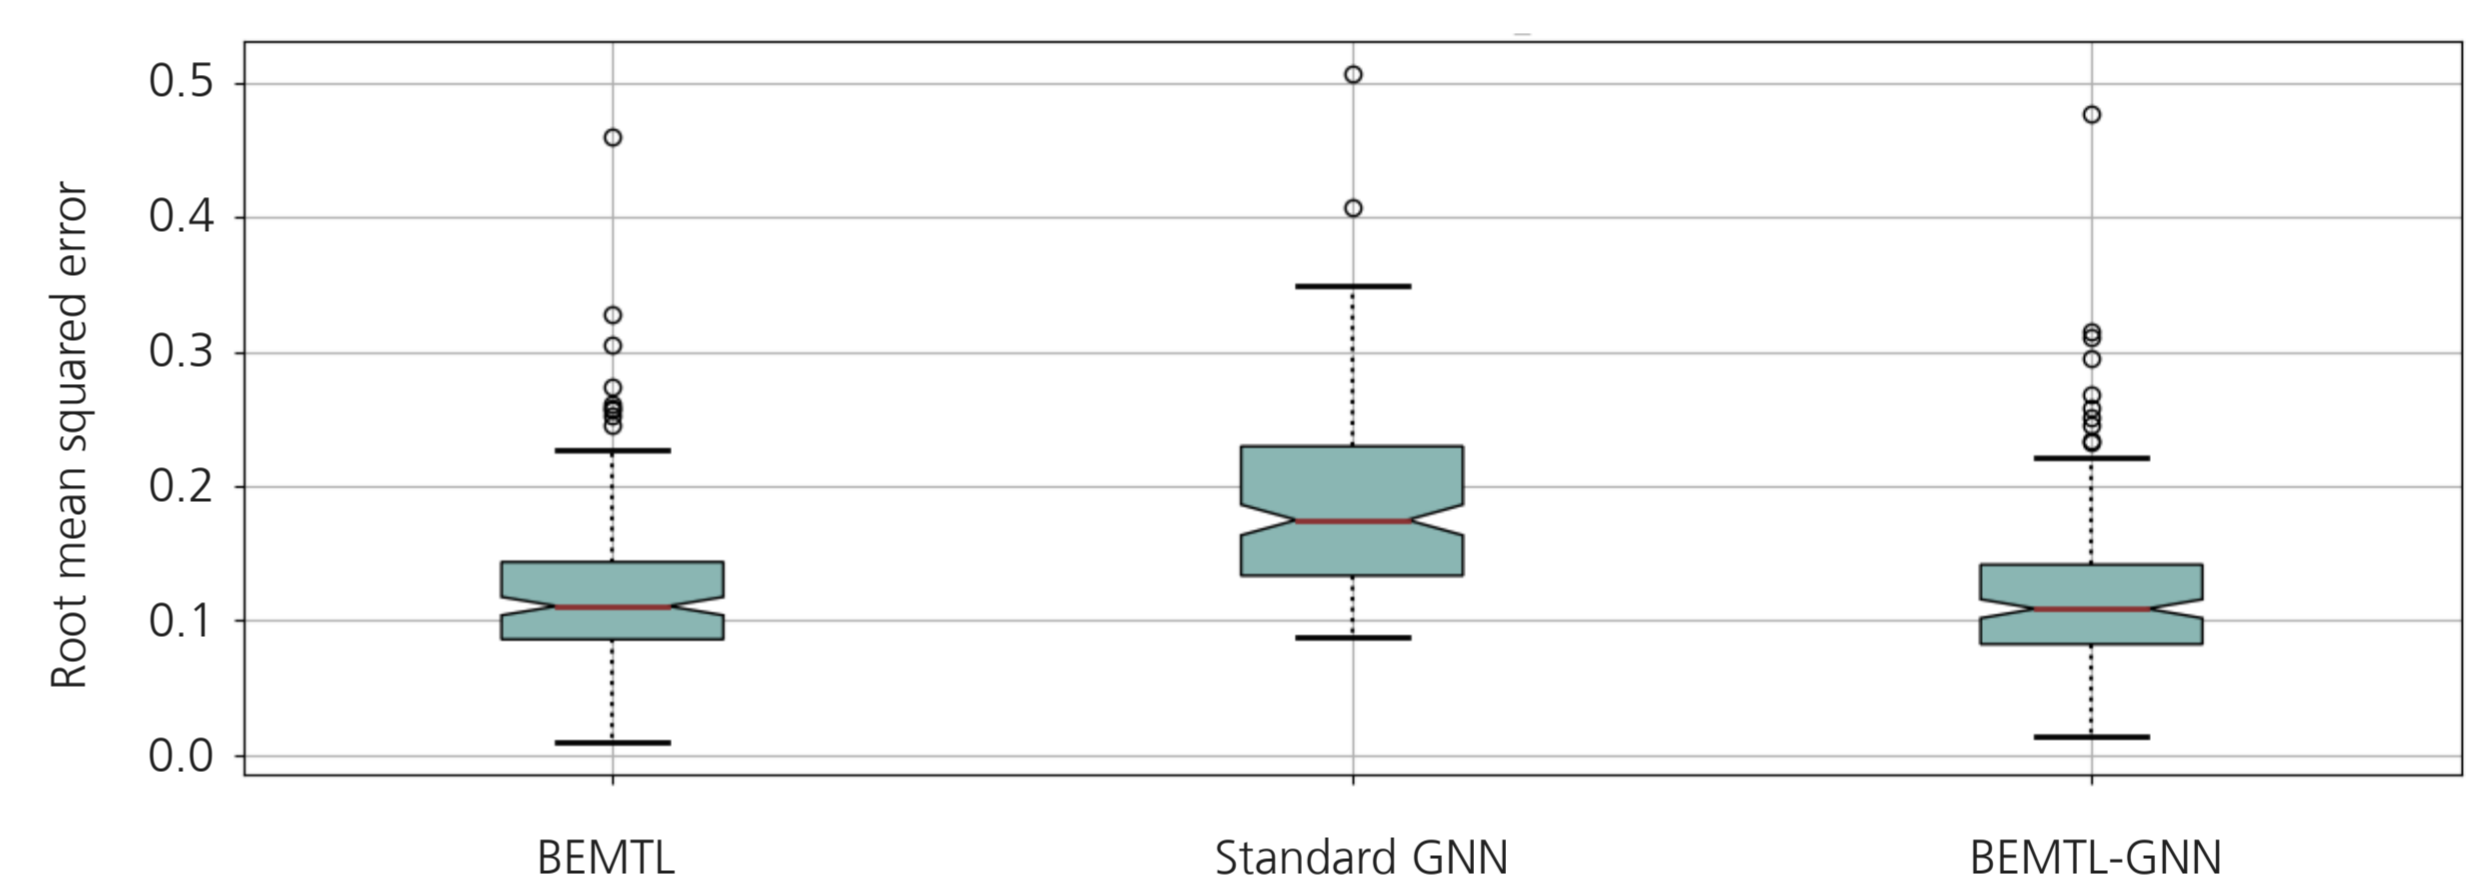


Abb. 2: Testfehler (Root Mean Squared Error) des Benchmarkmodells Bayesian Embedding Multi-Task Learning (BEMTL), eines Standard-GNNs und der im Projekt entwickelten Methode BEMTL-GNN




Abb. 3: Leistungsflussprognosen des Benchmarkmodells BEMTL (Mitte) und des im Projekt entwickelten Modells BEMTL-GNN (unten) an zwei Transformatoren

## Fazit und Ausblick

- Proof of Concept gelungen
- Unser GNN führt zu einer leichten Verbesserung des Testfehlers und einer deutlichen Verbesserung des Prognoseverhaltens
- Erlernen von Ausgleichsverhalten bisher nur bei schwach vernetzten Graphen möglich → Forschungsbedarf
- Erweiterung: zusätzlich Erzeuger / Verbraucher im Graph darstellen
- Geplantes Paper in Energy and AI special issue Smart Grid and AI