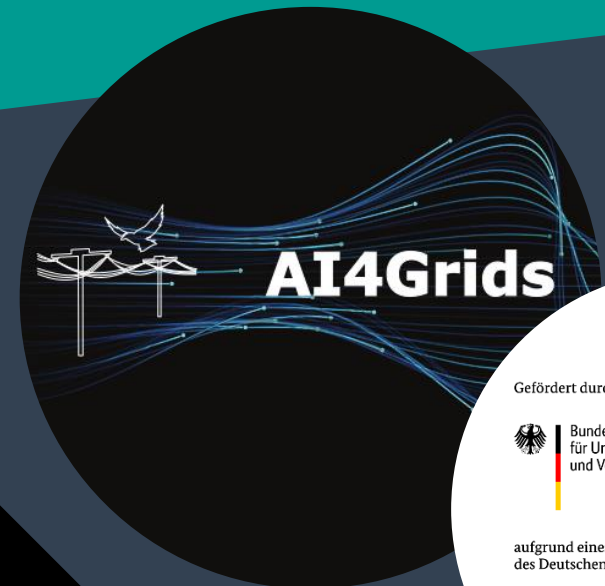


H T
W E
G I

Hochschule Konstanz
Fakultät Elektrotechnik
und Informationstechnik

Betriebsführung für das Verteilnetz mittels Graph Neural Networks

Manuela Linke



Gefördert durch:



Bundesministerium
für Umwelt, Naturschutz, nukleare Sicherheit
und Verbraucherschutz

aufgrund eines Beschlusses
des Deutschen Bundestages

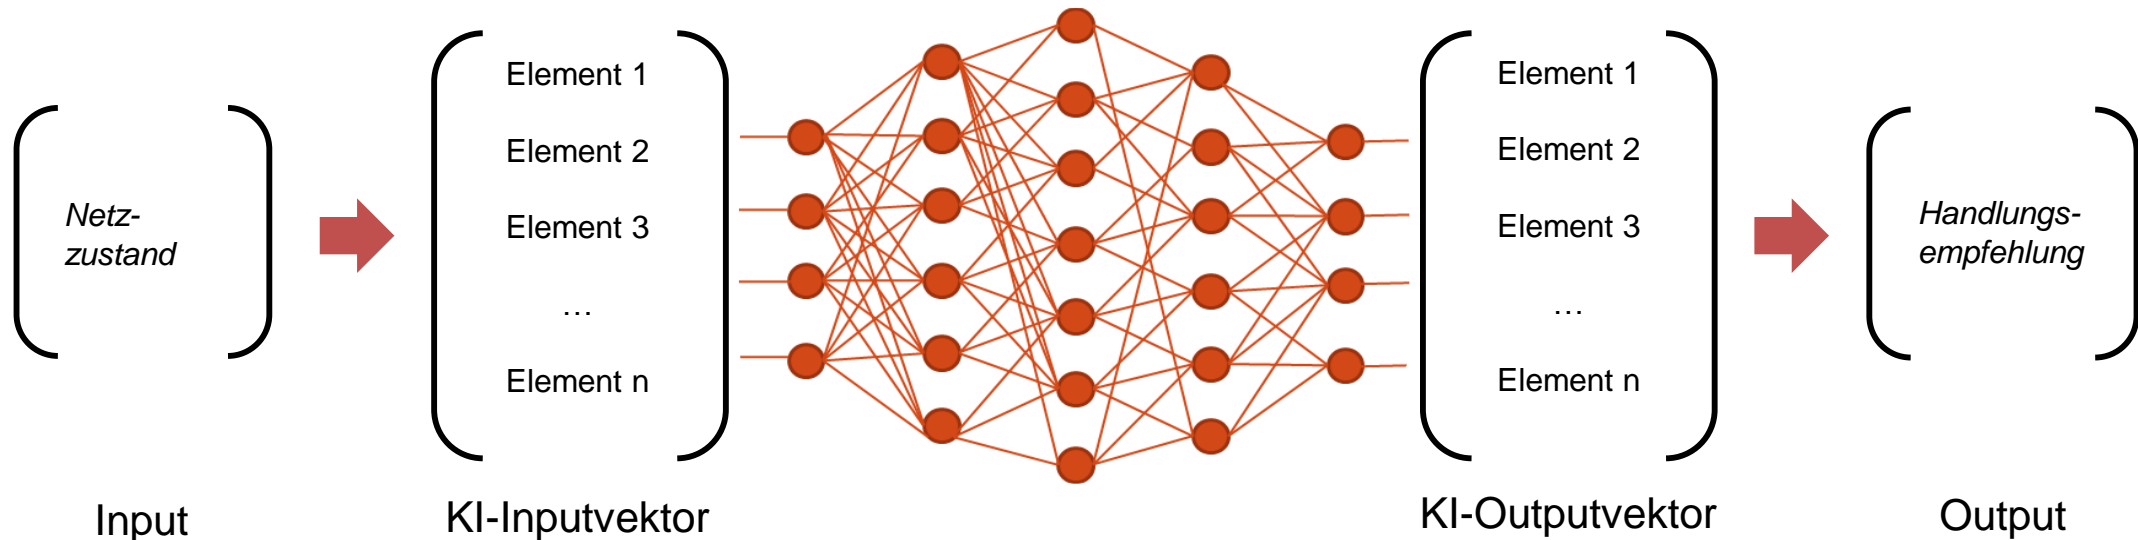
AI4Grids Symposium 26. September 2023

Netzbetriebsführung

Sicherstellung eines einwandfreien Betriebs der elektrischen Anlagen



Netzbetriebsführung mit Künstlicher Intelligenz (KI)



Betrachtete Störfälle im Netz:

- Spannungsabweichung ≥ 3 Prozent
- Leitung oder Transformator überlastet

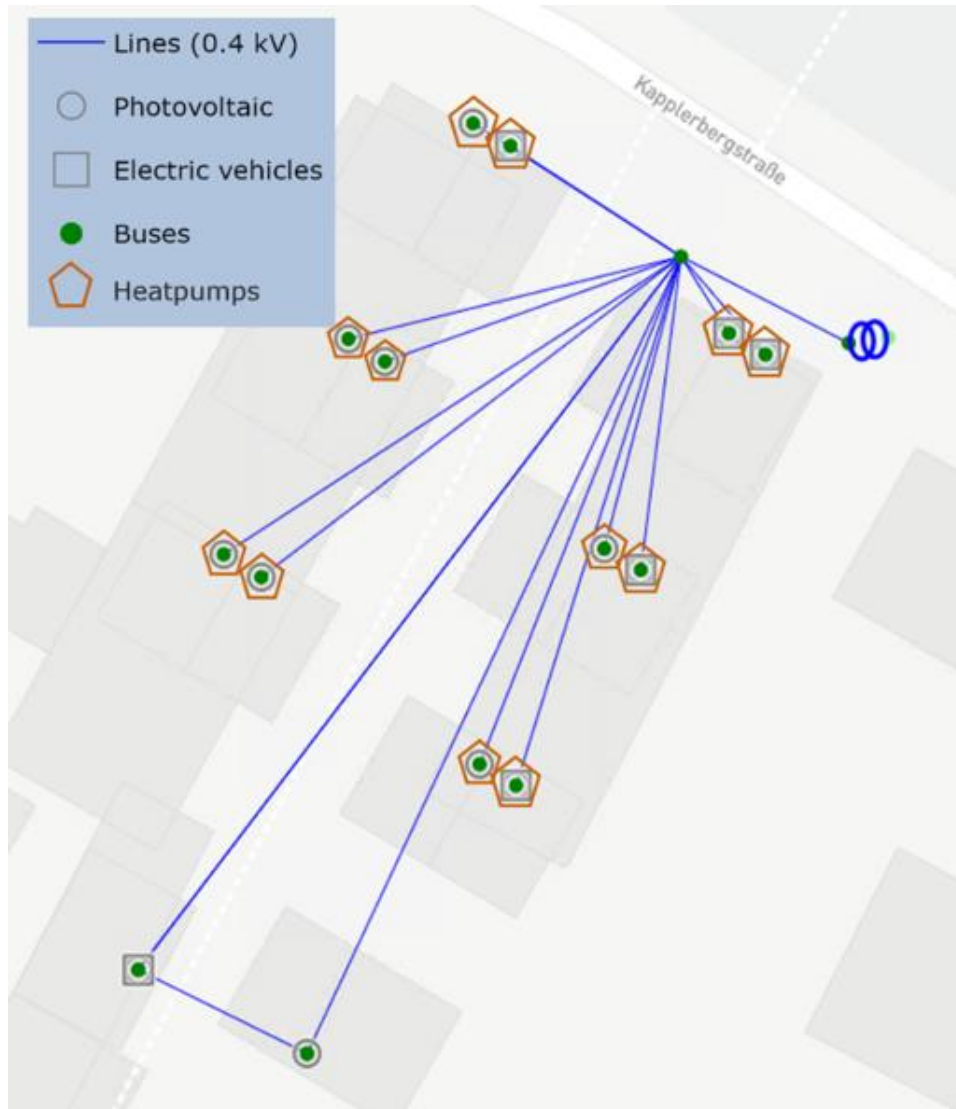
Wahrscheinlichkeit für Lösung:

- Status Quo beibehalten
- Stufensteller der Transformatoren
- Fernsteuerbare Schalter
- Abregelung von Erzeugung / Verbrauch


Was wird für das Training der KI benötigt?

- Vollständige Abbildung eines Stromnetzes
- Trainingsdatensatz: Störfälle und Lösungen (real oder simuliert)
- Einen geeigneten KI-Algorithmus

Stromnetz



Liegenschaft mit 19 Knoten

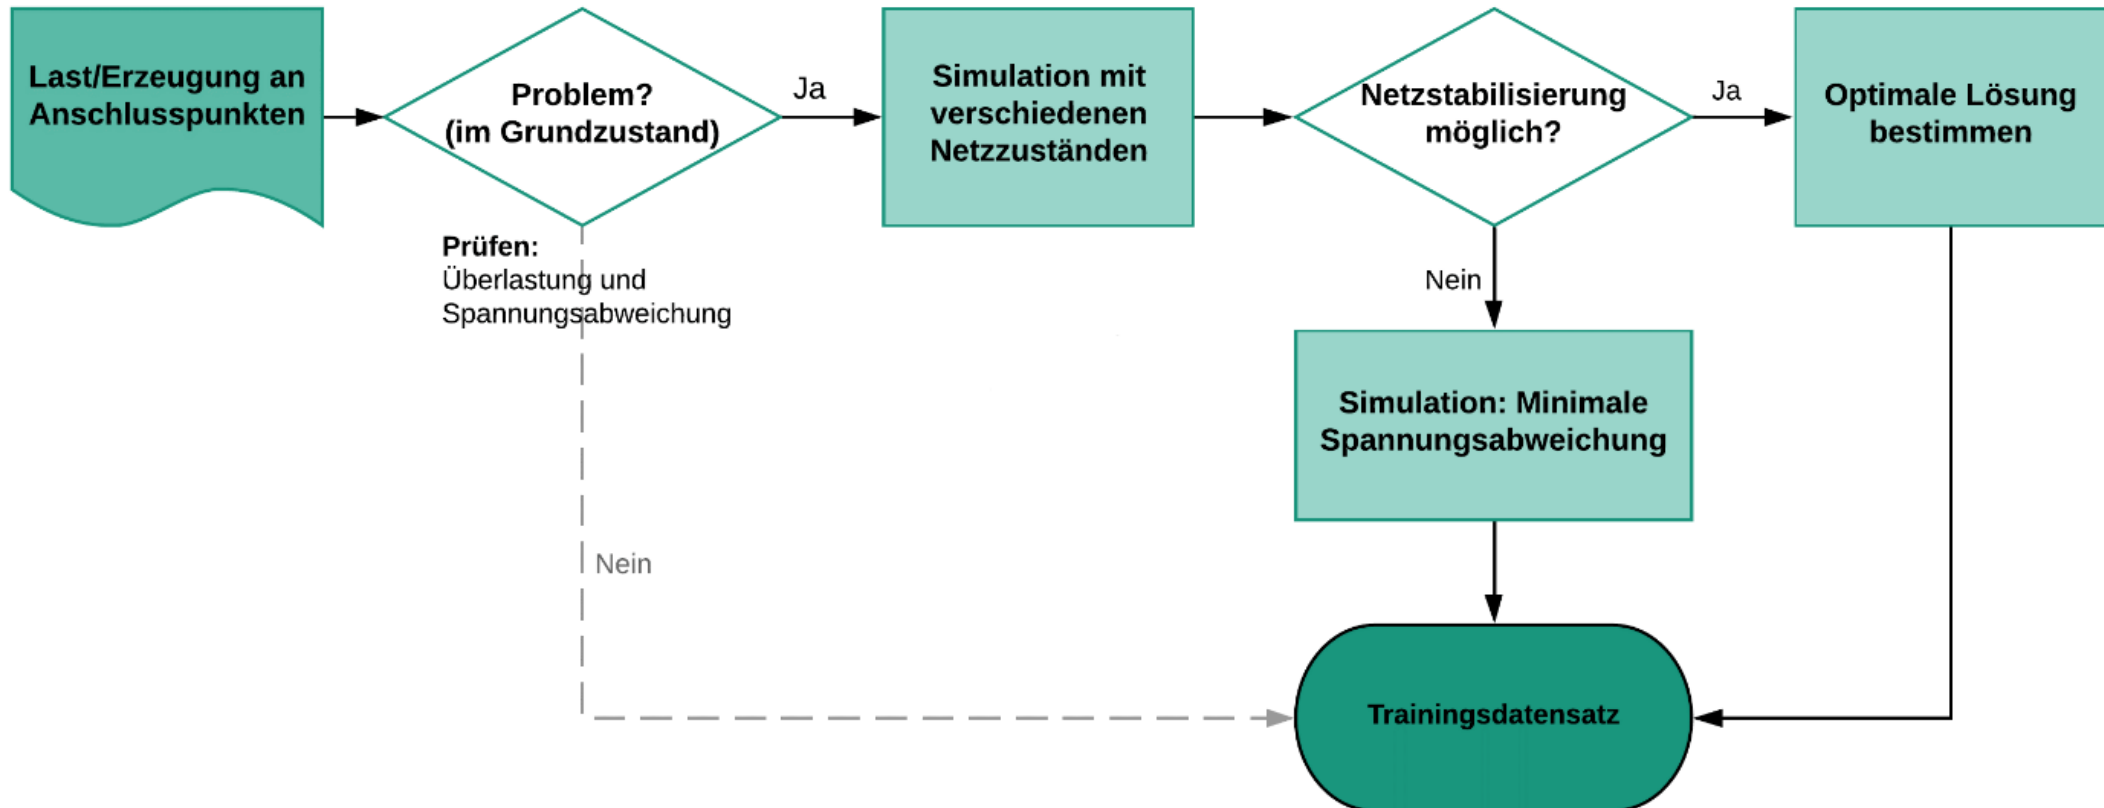
Simulationsumgebung:  PyPSA¹

Implementierte Lösungsmechanismen:

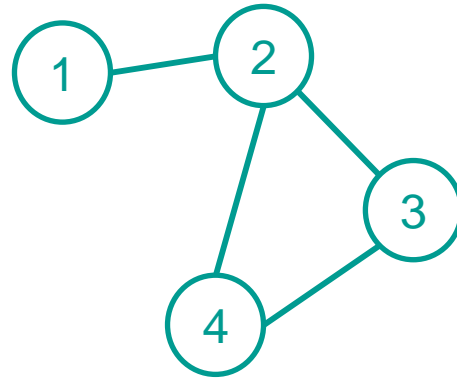
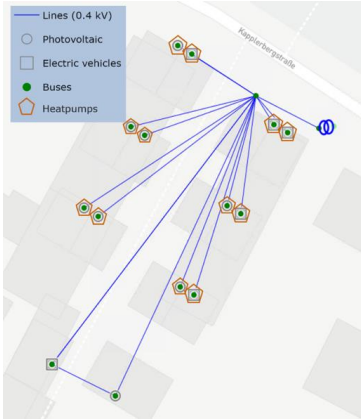
Transformatorstufen

¹T. Brown, J. Hörsch, D. Schlachtberger, [PyPSA: Python for Power System Analysis](#), 2018, Journal of Open Research Software, 6(1), arXiv:1707.09913, DOI:10.5334/jors.188

Generierung des Trainingsdatensatzes



Graph Neural Networks



Input:

Node features	Last/Erzeugung
Edge features	Leitungsparameter
Edge index	Adjazenzmatrix
y	Lösungsvektor

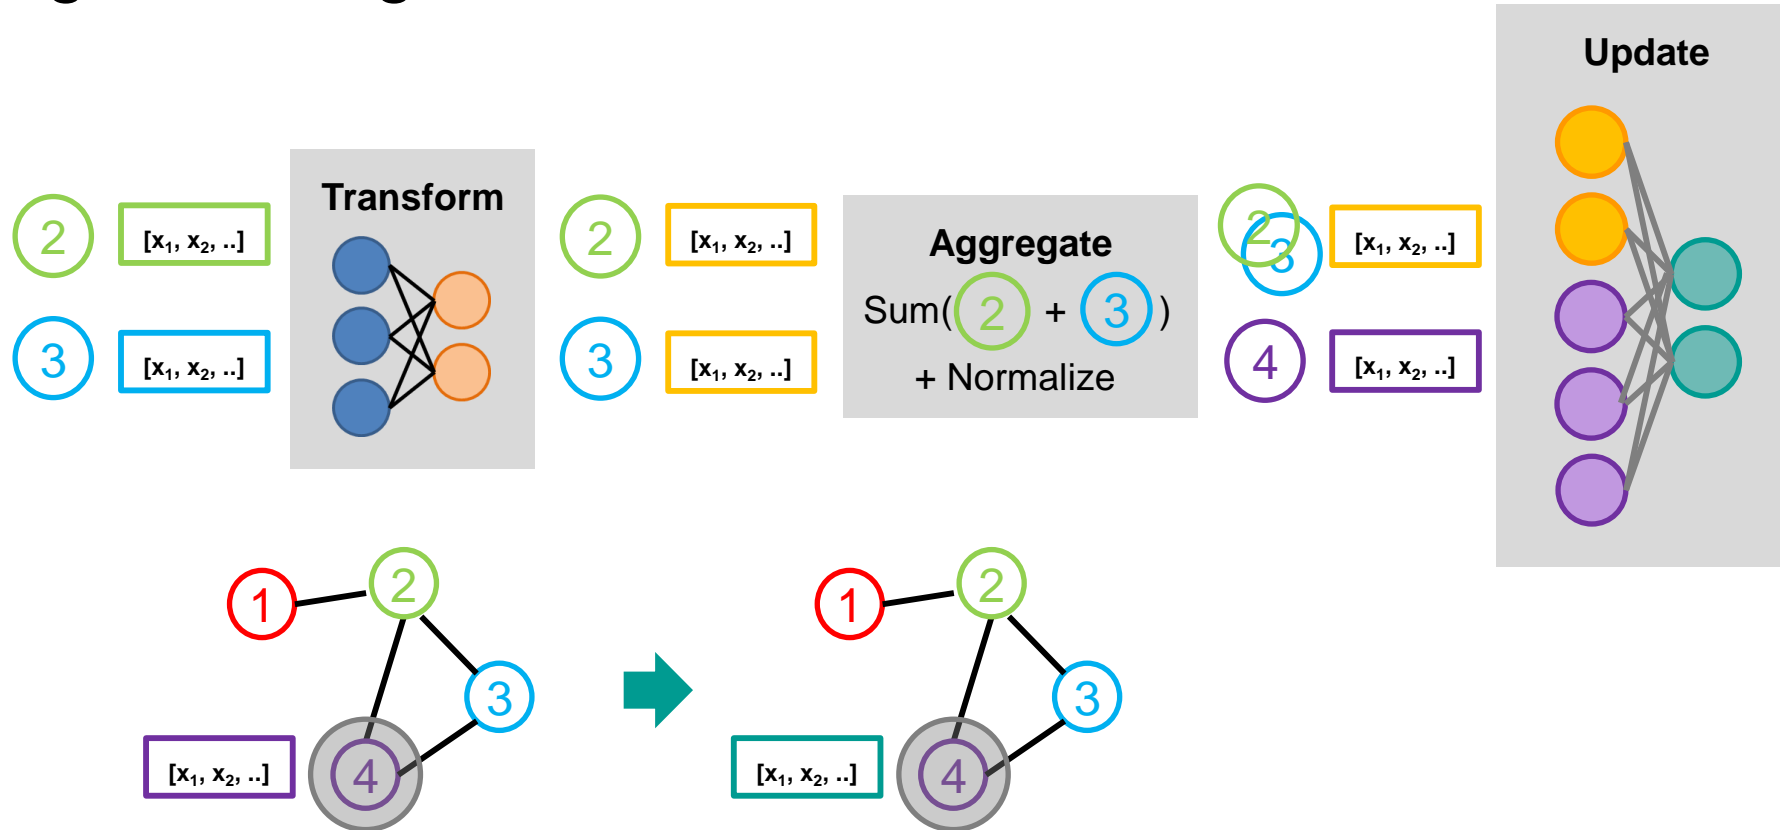
Vorteil GNNs:

- Unabhängig von der Größe des Inputs und permutationsinvariant (im Gegensatz zu FCNNs und CNNs)
- Topologie des Netzes wird für das Training genutzt (Nachbarschaftsbeziehungen)
- Generalisierbarkeit: Trainiertes GNN auch auf neue Topologien anwendbar

¹M. Fey, J. E. Lenssen, [Fast Graph Representation Learning with PyTorch Geometric](https://doi.org/10.48550/arXiv.1903.02428), 2019, ICLR 2019 (RLGM Workshop), <https://doi.org/10.48550/arXiv.1903.02428>

Graph Neural Networks

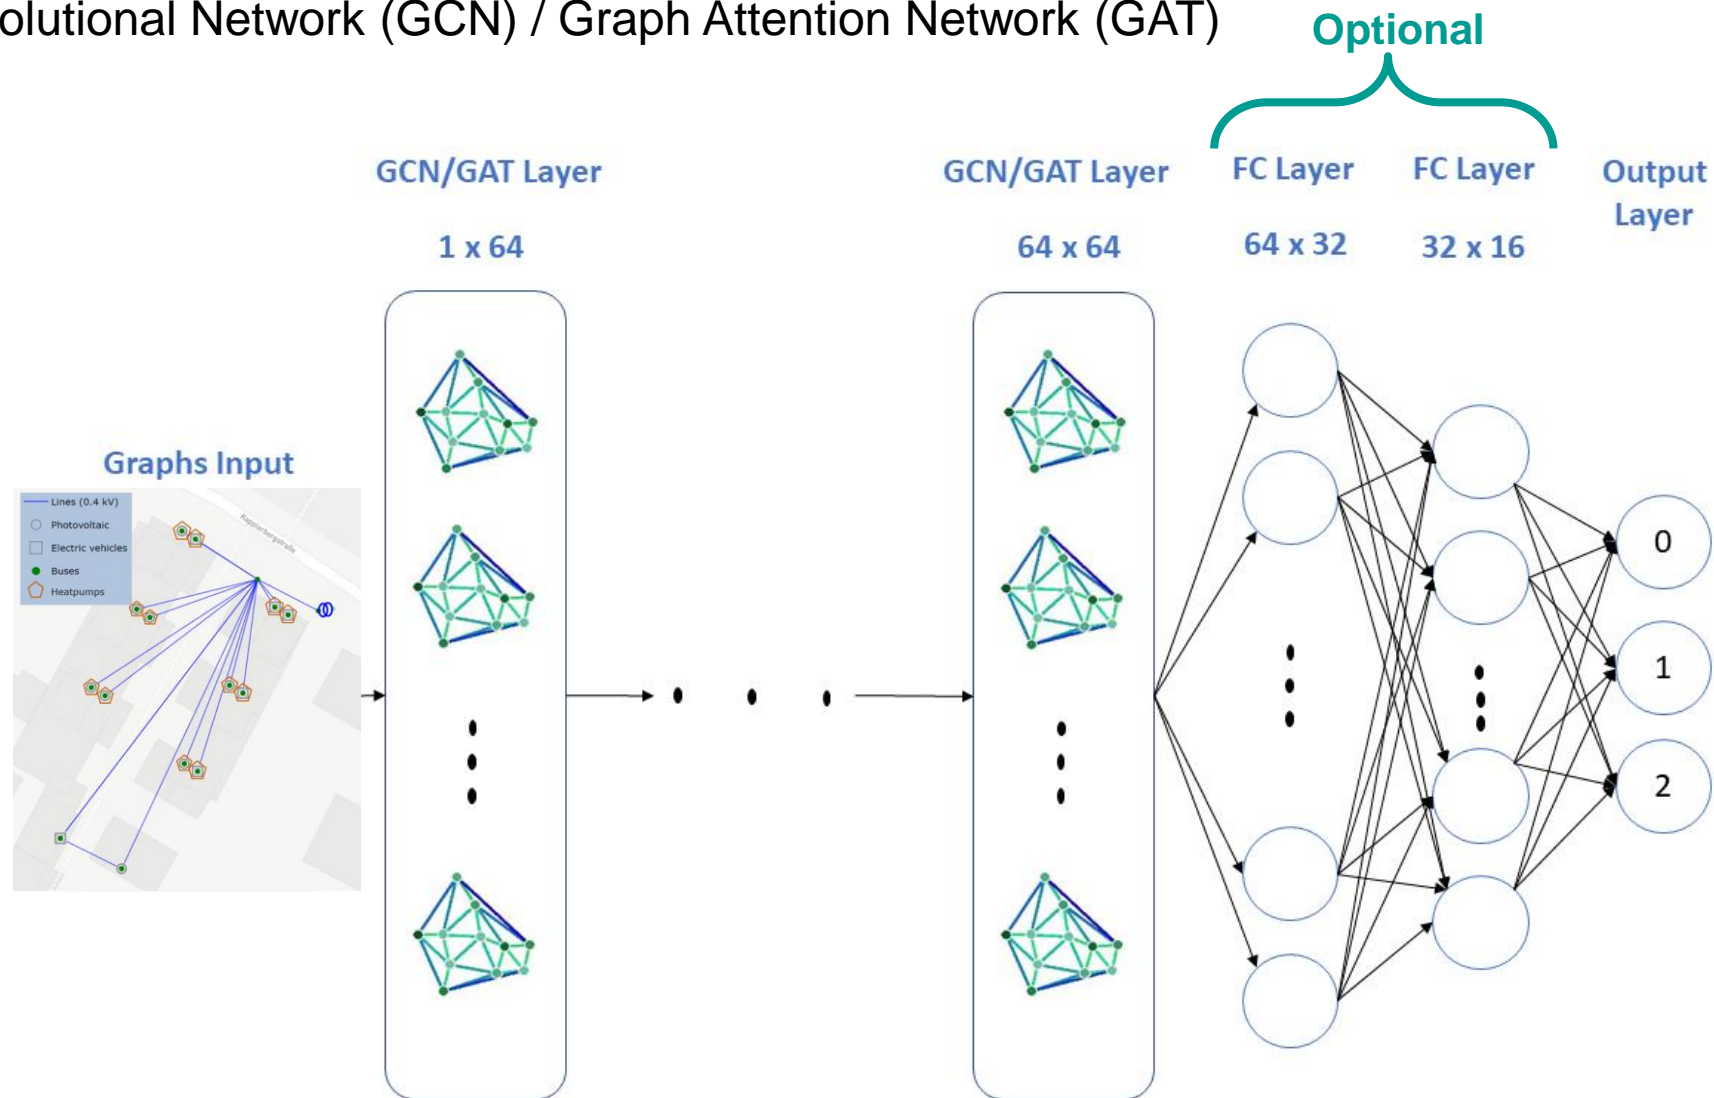
Message Passing Mechanismus



$$h_i^{(k+1)} = \text{Update} \left(h_i^{(k)}, \text{Aggregate} \left(\text{Transform} \left\{ h_j^{(k)}, \forall j \in N(i) \right\} \right) \right)$$

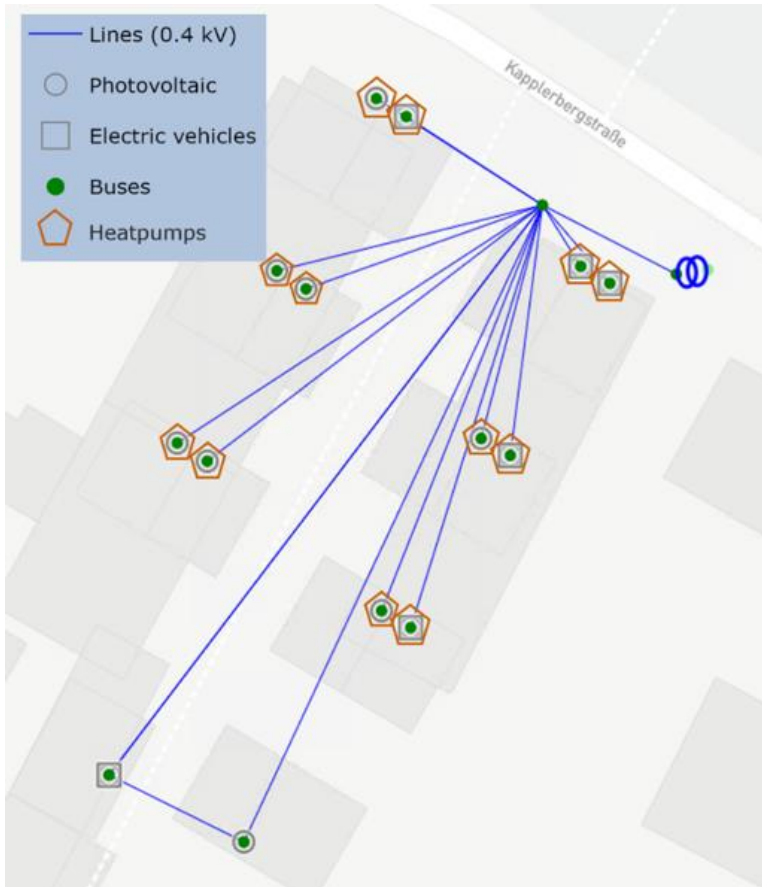
Modellaufbau

Graph Convolutional Network (GCN) / Graph Attention Network (GAT)



Stromnetz

Liegenschaft mit 19 Knoten



	Feature	Symbol	Einheit
Knoten	Last	loads	MW
	Erzeugte PV Leistung	pv_generators	MW
	Abgenommene Ladeleistung	storage_units	MW
	Spannungsamplitude	buses.v_mag	per unit
	Spannungswinkel	buses.v_ang	radian
Kanten	Leitungslänge	length	km
	Series reactance	x	Ohm
	Series resistance	r	Ohm
	Shunt conductivity	g	Siemens
	Shunt susceptance	b	Siemens
	Ratio of per unit voltages at each bus for tap changed	tap_ratio	per unit

Ergebnisse

Graph Convolutional Network (GCN) / Graph Attention Network (GAT)

Model	Training Loss	Validation Loss	Training Accuracy	Validation Accuracy	Test Accuracy
GCN	0.191	0.152	0.945	0.944	0.922
GAT	0.099	0.079	0.964	0.976	0.944
GCN-FCL	0.238	0.164	0.949	0.933	0.930
GAT-FCL	0.097	0.108	0.968	0.981	0.936

FCL: Fully Connected Layer

Zusammenfassung & Ausblick

Netzbetriebsführung mit GNNs

- Ist generell möglich mit Vorhersagegenauigkeiten von 94% auf unserem Datensatz
- Handlungsfähig bei kurzfristig auftretende Überlastungen im Netz
- GNN mit Attention Mechanismus liefert besten Ergebnisse

Ausblick

- Trainingsdatensatz optimieren
- Abregelung von Erzeugung und Verbrauch integrieren
- Test am Digital Grid Lab (Fraunhofer ISE)

**Vielen Dank für Ihre
Aufmerksamkeit!**

Kontakt:
mlinke@htwg-konstanz.de

Vielen Dank an **Mohamad Ali Rajeh**, der im Rahmen seiner Bachelorarbeit maßgeblich zu den Ergebnissen dieser Arbeit beigetragen hat.

