

딥러닝 기반 전력조류계산 모델의 배전계통 토폴로지 구조에 따른 성능 분석

이경영, 임세현, 윤성국
송실대학교

Performance Analysis for DNN-Based Power Flow Calculation Model According to Distribution System Topology

Kyeong-Yeong Lee, Se-Heon Lim, Sung-Guk Yoon
Soongsil University

Abstract - 최근 전력조류계산을 딥러닝으로 수행하는 시도가 계속되고 있다. 본 논문에서는 배전계통에 적합한 딥러닝 기반 전력조류계산 모델이 무엇인지 파악하기 위해 딥러닝 기반 전력조류계산 모델의 예측 성능에 영향을 주는 계통 구조를 분석한다. 사례연구에서 IEEE 33-모선을 기본으로 배전계통 구조를 재구성하여 다양한 형태의 배전계통의 구조와 예측 오차 간의 상관관계를 확인하였다. 사례연구를 통해 딥러닝 기반 전력조류계산 모델을 설계할 때 배전계통의 구조에 따른 전압 표준편차의 영향을 고려하는 것이 중요하다는 것을 확인하였다.

1. 서 론

전력계통에서 전력조류계산은 비선형 문제로서 일반적으로 반복적인 계산을 통해 수치해석 기법으로 계산한다. 위 과정에서 일반적으로 토폴로지 및 계통 파라미터와 같은 정확한 정보를 알고 있다고 가정한다. 그러나 전통적인 수치해석 기법은 실 계통 파라미터에 대한 정확도가 떨어진다 오차가 발생할 수 있으며 [1] 계통의 모선 수 증가에 따른 계산 복잡도가 기하급수적으로 증가하여 빠른 제어를 위한 조류 계산에서 한계점을 가진다 [2]. 이를 위해 계통 파라미터를 사용하지 않고 빅데이터를 사용한 딥러닝 기반 전력조류계산에 대한 연구들이 진행되고 있다 [3].

본 연구는 방사형 구조를 고려하여 다양한 배전계통 케이스에 적합한 딥러닝 기반 전력조류계산 모델을 위한 기초연구로서 예측오차에 영향을 주는 배전계통의 구조와 그 영향의 상관관계를 분석하였다. 사례연구를 통해 딥러닝 기반 전력조류계산 모델의 예측오차는 토폴로지의 구조에 따라 발생하는 전압의 표준편차와 상관성이 있음을 보였다.

2. 본 론

2.1 수치해석 기반 전력조류계산

전력조류계산은 효율적인 운용과 제어의 목적에서 중요한 요소이다. 일반적으로 전력 방정식은 키르히호프 법칙에 따라 다음과 같은 비선형 대수식을 따른다.

$$P_i = \sum_{k=1}^N V_i V_k (G_{ik} \cos \theta_{ik} + B_{ik} \sin \theta_{ik}) \quad (1)$$

$$Q_i = \sum_{k=1}^N V_i V_k (G_{ik} \sin \theta_{ik} - B_{ik} \cos \theta_{ik}) \quad (2)$$

P_i , Q_i 는 i 번째 모선의 유효전력과 무효전력이다. G_{ik} , B_{ik} 는 모선 어드미턴스 행렬에서 (i, k) 번째 요소이다. V_i 는 해당 모선의 전압의 크기이고 θ_{ik} 는 모선과 모선 사이의 전압 위상각 차이를 의미한다. N 은 전력 계통의 총 모선 개수이다.


모든 모선에 대한 전압, 위상 정보를 특정하기 위해

일반적으로 수치해석 기법 중 하나인 뉴턴-랩슨법의 반복적인 계산을 통해 전력 방정식의 해에 가까운 수렴된 전압, 위상값을 구해낸다. 하지만 계통 파라미터의 불확실성과 누락된 정보로 인해 어드미턴스 행렬을 구성하지 못하여 수치해석 기법을 적용하기 어려운 경우가 있다. 또한 수치해석 방법은 모선 수 N 에 따라 계산 복잡도가 지수적으로 증가하는 한계점이 존재한다.

2.2 딥러닝 기반 전력조류계산

딥러닝은 머신러닝 알고리즘의 하나로 인공신경망을 여러 층으로 구성하여 데이터를 바탕으로 패턴을 학습하고 학습된 지식을 통해 다양한 문제를 해결하는 데 사용된다. 일반적으로 딥러닝에 사용되는 네트워크 구조는 DNN(Deep Neural Network)이다. DNN은 입력층, 은닉층, 출력층의 구조를 갖는다. 특히 은닉층의 구성과 동작의 특징은 딥러닝의 장점과 단점을 보여준다. 학습 과정은 자동화되어 복잡한 데이터의 표현과 패턴을 자동으로 학습하는 장점이 있는 반면 딥러닝 모델 내부 동작을 외부에서 명시적으로 설계하고 설명하기 어렵다는 단점이 존재한다. 때문에 딥러닝을 기반으로 설계된 모델의 신뢰성 평가는 보다 엄밀하게 검토되어야 할 필요성이 있다.

딥러닝 기반 전력조류계산 모델은 PMU(Phasor Measurement Unit)와 같은 측정장비로부터 측정된 과거 계통운영데이터를 통해 입력-출력 데이터의 관계를 학습시키고 전력조류계산을 수행한다. GNN(Graph Neural Network)과 같이 선로정수를 통해 토폴로지 정보를 입력으로 사용하는 전력조류계산도 연구되었지만 [4] 선로 정수의 불확실성을 고려하여 별도의 선로정수 없이도 학습이 가능한 DNN 구조를 사용한다. 사용되는 입력값으로 각 모선의 유효/무효전력 출력값은 각 모선의 전압, 위상이 된다. 본 논문에서는 유효/무효전력을 통한 전압 계산 모델 성능에 대한 분석을 진행한다.



〈그림 1〉 전력조류계산을 위한 DNN 구조


$$V = f([P; Q]) \quad (3)$$

전력조류계산 모델은 식 (3)을 통해 표현 가능하다. 모선 수 N 에 따라서 입력 (P , Q)과 출력 (V)은 다음과 같이 벡터 형태로 표현된다. $P = [p_1, p_2, p_3, \dots, p_{N-1}]$, $Q = [q_1, q_2, q_3, \dots, q_{N-1}]$, $V = [v_1, v_2, v_3, \dots, v_{N-1}]$. P , Q , V 는 각 모선에서 측정된 유효전력, 무효전력, 전압을 의미한다. DNN 모델 학습에는 각각 기준 모선을 제외한 $N-1$ 개의 입력, 출력값을 사용한다.

3. 사례연구


3.1 시뮬레이션 설계 및 실험

본 연구에서 배전계통의 토폴로지 구조는 IEEE-33 계통(C2)과 이를 변형한 총 3가지의 계통(C: Case)을 사용하였다.



〈그림 2〉 토폴로지 사례 구성

본 논문에서는 d_i 를 i 번 모선과 기준 모선 사이에 연결된 선로 개수로 정의한다. 다음 정의를 통해 토폴로지마다 각 모선별 깊이를 수치화할 수 있고 이를 통해 각 토폴로지는 최대깊이(d_{max}), 평균깊이(d_{mean})를 구할 수 있다. 값은 아래의 〈표 1〉을 통해 확인할 수 있다. 일반적으로 모선의 깊이(d)에 따라 $V_{i,std}$ (i 번 모선의 전압의 표준편차)가 커지는 경향성이 나타난다(그림 3).



〈그림 3〉 모선의 번호에 따른 전압 표준편차

시뮬레이션 환경은 Python을 이용하여 총 38가지의 딥러닝 모델을 통해 학습 후 평가하였다. 사용한 딥러닝 모델 파라미터 개수 M_n 은 식 (4)와 같이 딥러닝 모델 복잡도 n 에 따라 선형적으로 증가하게 설정하였다. n 은 3부터 40까지 총 38가지의 모델 성능을 테스트하였다.

$$M_n = 2^9 \cdot (2^9 + 1) \cdot n + 1558816 \quad (4)$$

모델 학습에 사용된 입력값으로는 기준 모선을 제외한 각 모선의 유효전력, 무효전력(32×2), 출력은 기준 모선을 제외한 각 모선의 전압(32×1)이다. Iowa 부하 데이터[5]로 학습을 진행하였고 역률은 0.89~0.97범위의 랜덤하게 분포하여 유효전력, 무효전력 총 8760개(24시간 365일)으로 구성하였다. 우리나라의 태양광 실 데이터[6]를 사용하여 발전 패턴을 모델링 하였다. 모델링 된 4MW 용량 태양광 발전원은 각각 11, 18, 28, 33 모선에 접속되었다. 훈련, 검증, 테스트 데이터는 60%, 20%, 20% 비율로 하였다. IEEE-33 모선의 선로 정수를 사용하여 각각의 케이스에 대해 전압을 뉴턴-랩슨법으로 구하여 타겟 값으로 사용하였다.

3.2 실험 결과


〈표 2〉 토폴로지 구조에 따른 모델 성능

토폴로지	d_{max}	d_{mean}	$V_{std}(10^{-3})$	MSE ($\times 10^{-4}$)
C1	9	5.44	5.94	2.34
C2	17	7.97	18.80	3.76
C3	32	16.50	53.37	7.91

〈표 2〉는 IEEE 33-모선 계통(C2)을 기준으로 변형한 총 3가지 토폴로지 구조에 대한 토폴로지의 수치화된 특징(d_{max} , d_{mean}), 전압 표준편차(V_{std}), 그리고 모델 예측 오차 MSE(Mean Square Error)를 정리한 것이다. MSE는 38개의 딥러닝 모델 중 대부분의 케이스에서 성능이 우수한 모델의 MSE 값을 기입하였다. d_{max} , d_{mean} 와 V_{std} 에서 깊이가 깊어질수록 전압 표준편차가 증가하는 경향성이 나타난다. 또한 전압 표준편차가 증가

할수록 전력 조류 계산의 MSE 값 또한 증가하는 경향성을 확인할 수 있다.

보다 일반화된 결과를 확인하기 위해 토폴로지 별 모델 복잡도(n)에 따른 예측 오차(MSE) 간의 산점도를 〈그림 4〉에 도시하였다.



〈그림 4〉 토폴로지 별 모델 복잡도에 따른 MSE

〈그림 4〉의 결과에서 전압 표준편차의 상대적 크기의 상관관계에 따라 다양한 모델 복잡도를 갖는 딥러닝 모델의 성능이 계층적으로 나누어지며 모델 복잡도와 오차 간 상관성이 없는 것으로 보인다. 이와 같은 결과는 단순히 모델의 복잡도의 증가로는 전압 표준편차로 인한 예측 오차 증가 문제를 해결하지 못하는 것을 시사한다.

4. 결론

본 논문에서는 딥러닝 기반 조류계산 모델의 성능과 배전계통 토폴로지의 구조에 따라 달라지는 전압 표준편차 간의 상관관계에 대해 분석하였다. 일반화를 위해 IEEE 33-모선을 기반으로 한 다양한 형태의 계통 토폴로지 변형을 통해 여러 가지 경우를 구성하고 각각의 경우의 결과값을 토대로 계통 토폴로지와 모델 성능 간의 상관관계를 보였다. 모선의 깊이에 따라 전압 표준편차가 증가하게 되는데 이는 딥러닝 기반 조류 계산모델의 전압 예측 성능을 저하시키는 요인이 된다.

일정 이상의 성능을 보장하는 딥러닝 기반 전력조류계산 모델 제작을 위해서는 전압 표준편차에 의한 예측 오차를 줄이는 추가적인 연구가 필요하다. 딥러닝 기반 전력조류계산 모델의 성능 향상을 위해 기존 입력 데이터로 쓰이는 유효전력, 무효전력 데이터 이외에 프로파일링 된 전압 표준편차를 고려한다면 보다 신뢰 가능한 계산 모델 제작이 가능할 것으로 기대한다.

감사의 글

이 성과는 한국전력공사의 2022년 착수 기초연구 개발 과제의 지원(과제번호: R22XO02-19)을 받아 수행된 연구임.

참고문헌

- [1] Cao, Di, et al. "Deep reinforcement learning enabled physical-model-free two-timescale voltage control method for active distribution systems," IEEE Transactions on Smart Grid, 13.1, 149-165, 2021
- [2] Huang, Qihua, et al. "Adaptive power system emergency control using deep reinforcement learning," IEEE Transactions on Smart Grid, 11.2, 1171-1182, 2019
- [3] Hu, Xinyue, et al. "Physics-guided deep neural networks for power flow analysis," IEEE Transactions on Power Systems, 36.3, 2082-2092, 2020
- [4] Donon, Balthazar, et al. "Neural networks for power flow: Graph neural solver," Electric Power Systems Research, 189, 106547, 2020
- [5] Wang, Zhaoyu, Dr. Zhaoyu Wang's Homepage. Available online: <http://wzy.ece.iastate.edu/Testsystem.html>
- [6] Korea Western Power Company Limited. Photovoltaic Generation Status of Korea Western Power Company Limited. Available online: <https://www.data.go.kr/dataset/15025486/fileData.do>