

물리 정보 신경망 기반 전력계통 관성 추정


장은혁*, 최주승**, 최동희*, 이수형*, 백승묵*
국립공주대*, 연세대**

Inertia Estimation of Power System Based on Physics-Informed Neural Networks

Eun-Hyuk Jang*, Juseung Choi**, Donghee Choi*, Soo Hyeong Lee*, Seung-Mook Baek*
Kongju National University*, Yonsei University**

Abstract - 신재생 에너지원의 증가로 인한 동기 발전기의 대체는 전력계통의 관성 감소를 야기하며, 이는 계통 안정도에 심각한 영향을 미친다. 본 논문에서는 물리 정보 신경망(Physics-Informed Neural Network, PINN)을 활용하여 IEEE 39-bus 계통의 관성 상수(H)를 추정하는 새로운 방법을 제안한다. 제안된 방법은 순수 데이터 기반 학습 방식과 달리, 전력계통의 Swing Equation을 물리적 제약조건으로 신경망 학습에 통합함으로써 주파수 및 유효전력 측정 데이터로부터 정확한 관성 상수 식별을 가능하게 한다. 부하 고장 시나리오에서 측정된 주파수 편차와 발전기 출력 응답 데이터를 사용하여 방법론을 검증하였으며, 지배 미분방정식을 손실함수에 내재함으로써 신경망이 주파수 응답을 학습하는 동시에 계통의 관성 상수를 추정한다. 시뮬레이션 결과, 제안된 방법이 이론적 참값 대비 3% 이내의 오차로 계통 관성 상수를 정확하게 추정할 수 있음을 확인하였다.

정규화하여 사용한다. PINN의 구조는 그림 1과 같다.



〈그림 1〉 PINN 구조도

1. 서 론

전 세계적인 탄소 중립 정책에 따라 재생에너지원의 보급이 급격히 증가하면서, 전력전자 인터페이스 기반 전원이 기존 동기 발전기를 대체하고 있다. 이로 인해 전력계통의 회전 관성이 감소하여 주파수 변동률(Rate of Change of Frequency, RoCoF)이 증가하고 주파수 안정도가 저하되는 문제가 발생하고 있다[1]. 따라서 실시간으로 변화하는 계통 관성 상수(H)를 정확히 추정하는 것이 안정적인 계통 운영의 핵심 과제로 부각되고 있다.

기존의 관성 추정 방법은 동요 방정식(Swing Equation)을 활용하여 측정된 주파수 및 전력 데이터로부터 관성을 추정하는 방식이 주로 사용되어 왔으나[2][3], 측정 노이즈와 수치 미분 과정의 오차로 인해 추정 성능이 저하되는 한계가 있다. 최근 머신러닝 기법을 활용한 연구가 진행되고 있으나[4], 순수 데이터 기반 방법은 물리적 제약조건을 고려하지 않아 일반화 성능이 제한적이다.

본 논문에서는 물리 정보 신경망(Physics-Informed Neural Network, PINN)[5]을 활용하여 전력계통의 관성 상수를 추정하는 방법을 제안한다. 제안 방법은 Swing Equation을 손실함수에 직접 통합함으로써 자동 미분을 통한 정확한 주파수 변화율 계산과 노이즈에 강건한 추정을 가능하게 한다. IEEE 39-bus 표준 계통에서 부하 탈락 시나리오를 통해 제안 방법의 유효성을 검증한다.

2. 본 론

2.1 PINN 구조

제안하는 PINN은 정규화된 시간과 전력 편차를 입력으로 받아 주파수 편차를 예측하는 신경망으로 구성된다. 신경망의 출력은 자동 미분(Automatic Differentiation)을 통해 시간에 대한 고차도함수가 계산되며, 이는 물리 법칙을 손실함수에 포함시키기 위한 핵심 요소이다. 신경망의 입력은 학습 안정성 향상을 위해

2.1.1 손실함수

PINN의 핵심은 데이터 적합성(Data Fitting)과 물리 법칙(Physics Law)을 동시에 만족하도록 학습하는 것이다. 총 손실 함수는 데이터 손실과 물리 손실의 가중합으로 식 1과 같이 구성된다.

$$L_{total} = \lambda_{data} L_{data} + \lambda_{phys} L_{phys} \quad (1)$$

데이터 손실 L_{data} 는 신경망이 예측한 주파수 편차와 실제 측정된 주파수 편차의 평균제곱오차로 정의되며, 신경망이 관측 데이터를 충실히 따르도록 유도한다.

물리 손실 L_{phys} 는 신경망 출력이 전력계통 동요 방정식을 만족하도록 강제하는 잔차(Residual)로 정의된다. 측정 데이터 지점뿐만 아니라 학습 구간 내 지정된 점에서도 평가함으로써, 연속적인 시간 영역 전반에 걸쳐 물리 법칙이 만족되도록 한다. 이때 주파수 미분 항은 수치 미분이 아닌 자동 미분을 통해 해석적으로 계산되므로 측정 노이즈에 의한 오차가 발생하지 않는다.

학습 과정에서는 식(1)의 총 손실함수에 대한 역전파(Backpropagation)를 통해 신경망 가중치와 관성 상수 파라미터의 기울기(Gradient)가 동시에 계산되며, 이 기울기를 기반으로 두 대상이 함께 갱신된다. 즉, 데이터 손실과 물리 손실이 모두 최소화되는 지점으로 파라미터가 수렴함에 따라, 신경망은 측정 데이터를 재현하는 동시에 물리 법칙에 부합하는 해를 학습하게 되고, 이 과정에서 관성 상수 H 의 참값도 함께 추정된다.

2.1.2 파라미터 추정

추정 대상인 관성 상수 H 는 물리적으로 타당한 범위 내에서 수렴하도록 경계 제약(Bounded Parameterization)기법을 적용하여 학습 가능한 변수로 설정된다. 이를 통해 추정값이 물리적 의미를 갖는 범위를 벗어나지 않고 안정적으로 수렴한다.

2.2 전력계통 동요 방정식 및 물리 제약

전력계통의 주파수 동특성은 동요 방정식으로 표현되며, 계통 전체 등가 모델은 다음과 같다.


$$2H\frac{d\Delta f}{dt} + D\Delta f = \Delta P \quad (2)$$

본 연구에서는 식 2의 동요 방정식을 PINN 학습의 물리 제약식(Physics-Constraint Equation)으로 활용한다. 즉, 신경망이 예측한 주파수 편차와 측정된 전력 편차가 동요 방정식을 만족하도록 손실함수에 잔차항을 부여하며, 이 잔차가 최소화되는 방향으로 학습이 진행되면서 관성 상수가 신경망 가중치와 함께 동시에 추정된다.

2.3 결과

2.3.1 시뮬레이션 환경


제안된 PINN 기반 관성 추정 방법의 유효성을 검증하기 위해 IEEE 39-bus 계통에서 부하 탈락 시나리오를 모의하였다. 그림 1은 사용한 모의 계통도이다. 모선 12번에 있는 부하를 탈락시켰으며, 탈락 부하량은 41.5MW이다.




〈그림 1〉 IEEE 39-bus 계통도

2.3.2 주파수 편차 추정 결과 및 관성 추정 결과


그림 2는 PINN이 데이터 정합성과 물리식의 정합성을 만족하며 오차를 줄이면서 생성한 주파수 파형이다. 학습 횟수가 증가함에 따라 원래의 주파수를 잘 따라가는 것을 확인할 수 있다.



(a) 학습 횟수 : 1회



(b) 학습 횟수 : 500회



(c) 학습횟수 : 10000회

〈그림 2〉 주파수 편차 추정 그래프

해당 계통의 관성의 참값은 4.1064[s]이다. PINN이 추정한 관성 상수는 4.2278[s]로 오차율 2.96%로 우수하게 추정하는 것을 확인할 수 있다.

3. 결 론

본 논문에서는 전력계통 주파수 응답 예측을 위한 Physics-Informed Neural Network(PINN)를 제안하였다. 제안된 PINN은 전력계통 동요 방정식을 손실함수에 적용하여 데이터 손실과 물리 손실을 동시에 최소화하도록 학습하였다. 학습 횟수가 증가함에 따라 PINN이 추정하는 주파수 파형이 원본 주파수 파형을 점점 더 따라가게 되고 이 과정을 거치면서 파라미터 업데이트가 진행된다. 결과적으로 관성 상수를 오차율 3% 이내로 추정하였다. 향후 연구에서는 더욱 복잡한 전력계통으로 확장하고 실제 계통 데이터를 통한 검증을 수행할 예정이다.

감사의 글

본 연구는 기후에너지환경부(MCEE)와 한국에너지기술평가원(KETEP)의 지원을 받아 수행한 연구 과제입니다. (No. RS-2026-25543600)

[참 고 문 헌]

- [1] A. Fernández-Guillamón, E. Gómez-Lázaro, E. Muljadi, and Á. Molina-García, "Power systems with high renewable energy sources: A review of inertia and frequency control strategies over time", Renewable and Sustainable Energy Reviews, vol. 115, art. 109369, 2019.
- [2] P. Wall and V. Terzija, "Simultaneous Estimation of the Time of Disturbance and Inertia in Power Systems", IEEE Transactions on Power Delivery, vol. 29, no. 4, pp. 2018 - 2031, 2014.
- [3] K. Tuttlberg, J. Kilter, D. Wilson, and K. Uhlen, "Estimation of Power System Inertia from Ambient Wide Area Measurements", IEEE Transactions on Power Systems, vol. 33, no. 6, pp. 7249 - 7257, 2018.
- [4] D. Linaro, F. Bizzarri, D. Del Giudice, C. Pisani, G. M. Giannuzzi, S. Grillo, and A. M. Brambilla, "Continuous estimation of power system inertia using convolutional neural networks", Nature Communications, vol. 14, art. 4440, 2023.
- [5] M. Raissi, P. Perdikaris, and G. E. Karniadakis, "Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations", Journal of Computational Physics, vol. 378, pp. 686 - 707, 2019.