

D-PMU 데이터를 사용한 심층 합성곱 생성적 적대신경망(DCGAN) 기반 이벤트 감지 기법

양준혁, 김태근, 윤성국
송실대학교

Event Detection Method Based on DCGAN Using D-PMU Data

Yang-June Hyuck, Kim-Tae Geun, Yon-Sung Guk
Songsil University

Abstract - 배전계통에 증가하고 있는 소규모 재생에너지 자원에 대응하기 위하여 D-PMU(Distribution Phasor Measurement Unit)와 같은 고사양의 계측기가 필요하다. D-PMU는 1초당 120회의 데이터 측정 가능한 계측기로 고품질, 다량의 전력 데이터를 생성한다. 본 논문에서는 심층 합성곱 생성적 적대신경망(Deep Convolutional Generative Adversarial Network, DCGAN) 기반 이벤트 감지 기법을 제안한다. 송실대학교의 A, B 건물에 설치된 D-PMU의 실제 전압 데이터를 사용하여 제안한 기법이 세밀한 시간 단위의 이벤트 검출이 가능함을 확인하였다.

1. 서 론

세계적으로 전력수요가 지속해서 증가하는 상황에서 환경적인 문제를 방지하고 부족한 전력량을 충당하는 수단으로 재생에너지가 널리 보급되고 있다. 재생에너지의 다수는 kW급의 소규모로 배전망에 인입되고 있다. 배전망에서의 재생에너지의 도입은 역조류를 발생시켜 기존의 단방향 흐름만 가정한 배전망에서는 전력 품질 및 보호에 악영향을 미친다. 따라서 다수의 재생에너지가 배전망에 유입된 경우에 전력 품질을 유지하고 공급 신뢰도 향상을 위한 노력이 요구되고 있다. [1]

이를 위한 가장 기본적인 조치는 배전망의 상황을 정확히 파악하는 것이다. D-PMU(Distribution Phasor Measurement Unit)는 전류와 전압의 크기, 위상각, 주파수 등 다양한 상태정보를 1초당 120샘플의 주파수로 측정할 수 있는 최선의 계측기이다. D-PMU로 취득된 데이터는 부하 모델링 검증, 전압 안전성 관찰/관리, 시스템 복원, 이벤트 분석, 상태 추정 등에 쓰이고 있다. [2], [3]

스마트미터, PMU 등의 디지털 계측기들로 인하여 전력 계통 분야에서도 다량의 양질의 데이터 취득이 가능해졌고 이를 이용한 기계학습 연구가 활발히 진행되고 있다. 배전망에서 D-PMU를 사용한 기계학습 기법연구로는 부하예측, 에너지 스케줄링, 손실 데이터 복원 등이 있다. [4], [5]

본 논문에서는 안정적인 전력품질 유지를 위하여 심층 합성곱 생성적 적대신경망(Deep Convolutional Generative Adversarial Network, DCGAN)에 D-PMU 데이터를 적용하여 기존보다 세밀한 시간 단위의 전압 이벤트를 검출하는 연구를 진행하였다. 송실대학교의 A, B 건물에 설치한 D-PMU 전압 데이터를 사용하여 학습된 판별기 모델을 통해 이벤트 검출을 진행하고 이벤트 감지 모델에 대한 성능을 평가하였다. [6]

2. 본 론

2.1 심층 합성곱 생성적 적대신경망(DCGAN)

생성적 적대신경망(Generative Adversarial Network,

GAN)은 생성기(Generator)와 판별기(Discriminator)의 두 개의 신경망으로 구성되어 있다. 생성적 적대신경망에서는 생성기와 판별기가 서로 경쟁하며 학습 과정을 거친 뒤 생성모델(Generative model)을 만들어 낸다. 데이터를 입력받아 생성기가 만들어 낸 새로운 데이터는 판별기의 입력으로 쓰인다. 판별기는 생성기로부터 수신한 데이터와 실제 데이터를 비교하며 데이터의 진실 여부를 판별해낸다. 생성적 적대신경망은 이러한 과정을 통해 생성기와 판별기를 학습하여 생성기의 실제 데이터와 유사한 데이터를 생성하는 능력과 판별기의 판별 능력을 향상시키는 것을 목표로 한다.

본 논문에서는 생성적 적대신경망의 생성기와 판별기를 합성곱 신경망(Convolutional Neural Network, CNN)으로 변경한 기법을 사용하였다. 두 모델을 합성곱 신경망으로 변경하고 배치정규화를 사용하여 수렴의 불안정성을 해결하고 성능을 개선했다. Adam 최적화기를 사용하고 과적합을 방지하기 위해 드롭아웃을 적용한 심층 합성곱 생성적 적대신경망을 사용하였다.

2.2 사용 데이터

본 논문에서는 송실대학교 A, B 건물에 설치된 D-PMU 데이터를 정규화 과정을 거친 뒤 사용하였다. 본 논문에서는 이론상 정상 전압에서 10% 이하, 이상의 상태를 50ms 이상 유지하는 상황을 전압강하, 과전압 이벤트로 정의하였다. 이벤트 학습 데이터로 약 0.5초간 측정된 3상 전압의 160개의 샘플로 구성된 데이터 세트를 총 8세트 사용하였다.

모델 테스트에 사용된 데이터는 송실대학교에 설치된 D-PMU 실제 데이터를 사용하였다. 이 실험에서는 이상 전압 발생 시간을 기준으로 전후 10분 데이터를 입력하여 총 33x20x60초의 데이터로 실험을 진행하였다.

2.3 생성기와 판별기의 최대·최소 알고리즘

생성적 적대신경망에서는 생성기와 판별기 두 개의 신경망이 서로 경쟁하면서 학습한다. 생성기의 손실함수($Loss_G$)와 판별기의 손실함수($Loss_D$)는 다음과 같이 정의한다.

$$Loss_G = E_z [\log(1 - D(G(z)))] \quad (1)$$

$$Loss_D = E_x [\log(D(x))] + E_z [\log(1 - D(G(z)))] \quad (2)$$

$G(\cdot)$, $D(\cdot)$ 는 각각 생성기, 판별기의 함수이고 z 는 임의의 잡음(noise)이다. 각 신경망은 손실함수를 최소화하도록 학습이 이뤄지며, 수식 [3]으로 정의된 최대·최소 알고리즘을 만족하게 하는 것을 최종 목표로 학습한다.

$$\min_G \max_D V(D, G) = E_x [\log(D(x))] + E_z [\log(1 - D(G(z)))] \quad (3)$$

$V(D, G)$ 는 생성적 적대신경망의 목적 함수를 의미한다. $D(G(z))$ 는 생성기에서 생성한 데이터를 판별기에 입력하였을 때의 출력이고 $D(x)$ 는 실제 데이터를 판별기에 넣었을 때 출력이다. 학습과정에서 생성기는 판별기가 구분을 하지 못하게 $D(G(z))=1$ 되도록 학습한다. 판별기는 생성기가 만든 가짜 데이터를 잘 구분할 수 있도록

$D(x)=1, D(G(z))=0$ 이 되도록 학습한다. 학습 과정을 거쳐 두 신경망이 모두 만족한 값을 얻어 손실함수가 일치할 때 학습이 종료된다.




그림 1. 실험 구조

2.4 실험 과정

실험은 <그림 1>과 같이 학습과정과 감지과정으로 나누어 진행되었다. 학습과정에서 생성기가 만든 데이터와 실제 데이터를 판별기의 입력된다. 생성기와 판별기의 경쟁적 학습을 반복하여 손실함수의 오차가 1% 이하이며 학습 데이터로 사용된 데이터가 판별기에 입력 시 출력이 0.99 이상일 때 판별기의 학습을 완료시켰다.

학습된 판별기의 출력은 학습된 데이터의 분포와 입력 데이터의 분포 간에 유사성을 나타낸다. 이 성질을 이용하여 새로운 데이터를 학습된 판별기에 입력으로 사용하여 출력에 따라 이벤트 감지 여부를 결정하였다. 학습된 판별기에 송실대학교 D-PMU 실시간 데이터 혹은 기록된 데이터를 입력하였다. 정상상태일 때의 데이터를 판별기에 입력하면 0.55의 반경의 값을 출력하고 이상 전압을 보이는 데이터를 입력하면 전압 오차의 크기와 이상 전압 유지 시간에 따라 0.75 이상 0.99 이하의 출력을 얻었다. 본 실험에서는 0.75 미만일 때는 정상상태 0.75 이상일 때는 이벤트로 판정하였다.

2.5 실험 결과

2.5.1 생성기 출력 결과




그림 2. 과전압 데이터




그림 3. 전압 강하 데이터

<그림 2>와 <그림 3>은 각 이벤트에 대한 학습 데이터와 학습이 완료된 생성기 모델에서 생성된 데이터를 보여준다. 학습에 사용된 데이터는 정상상태일 때 안정적인 그래프 파형을 보이지만 생성된 데이터는 불안정한 파형을 보인다. 이로 인하여 테스트 데이터의 정상상태 데이터가 일정 수준 이하의 오차를 보이더라도 정상적인 이벤트 감지가 가능함을 확인하였다.

2.5.1 송실대학교 데이터의 판별기 결과

<표 1>은 3개월 동안의 송실대학교 A 건물 D-PMU 데이터와 6개월 동안의 B 건물 D-PMU 데이터를 판별기 모델에 입력한 실험결과이다.

표 1. 송실대학교 데이터 실험 결과

	감지	오감지	미감지
형남공학관	10	0	0
송덕경상관	22	0	1

<표 2>는 기계학습에서 모델이나 패턴의 분류 성능 평가에 사용되는 지표인 정밀도 (4), 재현율 (5), 정확도 (6)를 통해 이벤트 감지 모델에 대한 성능을 평가한 표이다.

$$\text{정밀도} = \frac{\text{감지}}{\text{감지} + \text{오감지}} \quad (4)$$

$$\text{재현율} = \frac{\text{감지}}{\text{감지} + \text{미감지}} \quad (5)$$

$$\text{정확도} = \frac{\text{감지}}{\text{감지} + \text{오감지} + \text{미감지}} \quad (6)$$

표 2. 이벤트 감지 모델 성능 평가

	정밀도	재현율	정확도
건물 A	1	1	1
건물 B	1	0.96	0.96

3. 결론

본 논문에서는 D-PMU 데이터를 이용한 심층 합성곱 생성적 적대신경망(DCGAN) 기반 이벤트 감지 기법을 제안하였다. 송실대학교에 설치한 D-PMU를 통해 수집한 실제 데이터를 통해 심층 합성곱 생성적 적대신경망을 학습시켜 판별기 모델을 이벤트 감지 모델로서 사용하였다. 과전압/전압강하 두 가지 이벤트를 감지하도록 학습시켰으며 송실대학교의 두 가지 D-PMU로 실험한 결과 96.7%의 이벤트를 감지하여 초 단위 이하의 순간적인 이벤트도 감지할 수 있음을 확인하였다.

후속 연구로서, 다양한 기계학습 기법을 활용하여 이벤트 감지 모델의 성능을 향상시키고 더 많은 종류의 이벤트를 감지하는 모델을 개발할 계획이다.

감사의 글

본 논문은 한국전력공사의 에너지 거점대학 클러스터 사업(R18XA04)과 산업통상자원부의 재원으로 한국에너지기술평가원(KETEP)의 에너지인력양성사업(No. 201919082010)으로 지원받아 수행된 연구임.

[참고문헌]

- [1] Bogdan Constantin Neagu, "The Optimal Operation of Active Distribution Networks with Smart Systems", IntechOpen, 88032, 2019
- [2] X. Wang et al., "Micro-PMU for distribution power lines", CIRED, vol. 2017, no. 1, 2017
- [3] Y. Zhou, R. Arghandeh, I. Konstantakopoulos, S. Abdullah, A. von Meier and C. J. Spanos, "Abnormal event detection with high resolution micro-PMU data," PSCC, 10.1109/PSCC.7540980, 2016
- [4] Armin Aligholian1, Alireza Shahsavari1, Ed Cortez2, Emma Stewart3 and Hamed Mohsenian-Rad, 'Event Detection in Micro-PMU Data: A Generative Adversarial Network Scoring Method', eess.SY, 1912.05103v2, 2020
- [5] Armin Aligholian1, Alireza Shahsavari1, Ed Cortez2, Emma Stewart3 and Hamed Mohsenian-Rad, 'Event Detection in Micro-PMU Data: A Generative Adversarial Network Scoring Method', eess.SY, 1912.05103v2, 2020
- [6] Alec Radford, Luke Metz, Soumith Chintala, "Unsupervised Representation Learning with Deep Convolutional Generative Adversarial Networks", ICLR, 19 Nov 2015 (v1), 2016