

DCGAN based Event Detection Scheme Using D-PMU Data in Distribution Systems

D-PMU 데이터를 이용한 DCGAN 기반 실시간 배전계통 이벤트 감지기법

June-Hyuck Yang · Tae-Geun Kim · Sung-Guk Yoon

양준혁* · 김태근* · 윤성국†

Abstract

Distribution-phasor measurement units (D-PMUs) measuring magnitude and phasor angle with high resolution make detailed observations of the distribution system. In this paper, we propose a deep convolutional generative adversarial networks (DCGAN) base event detection method using D-PMU data. GAN is trained through the adversarial process of two models: generator and discriminator. This process helps the discriminator train well without much training data. Also, DCGAN has convolutional layers for better event recognition. After training the proposed DCGAN model using labeled D-PMU data, we use the discriminator to identify distribution system events. The target events to detect are voltage dip, over-voltage, harmonic, and transient. Through a case study with real data from two D-PMUs installed at Soongsil university, the detection performance of the proposed detection method is verified. It is confirmed that the proposed method shows a good detection performance compared to other schemes.

Key Words

distribution systems, distribution-phasor measurement units (D-PMU), event detection, machine learning, deep convolutional generative adversarial networks (DCGAN), power quality

1. 서론

최근 배전계통은 태양광발전과 같은 분산 전원의 활성화로 인하여 양방향 조류가 빈번히 발생하고 있으며 전기자동차, ESS(Energy Storage System) 등의 다양한 인버터 기반 설비를 포함하고 있다. 인버터 기반 설비는 간혹 리플/잡음을 포함한 전압을 생성하기 때문에 인버터 기반으로 계통 환경이 변화함에 따라 배전계통에서 전압강하, 과전압, 과도현상, 고주파 현상과 같은 전력품질이 저하되는 이벤트가 빈번히 발생하고 있다. 배전망은 인버터 기반 설비 및 다양한 부하가 증가하여 불안정성이 커지고 있는 상황에서 전력 품질을 개선하고 재생에너지 수용용량을 최대화하기 위해 계통을 적극적으로 제어 가능한 능동배전망 형태로 변화하고 있다. 능동배전망에서는 획득한 데이터/신호를 이용하여 최적화된 운영을 위한 제어/지령을 결정하는 관제센터가 존재한다. 스마트 보호기기와 개선된 관측기기 등과같은 통신장비를 통하여 전력품질 및 수용용량 향상이 가능하다[1-2].

이에따라 배전계통의 상태를 정밀하게 확인할 수 있는 고성능

시각 동기화 관측기기인 D-PMU(Distribution Phasor Measurement Units)의 중요성이 강조되고 있다. D-PMU는 1주기당 1,024번 샘플링하여 전압·전류·위상·주파수·임피던스 등 다양한 계측값을 60Hz 이상의 고해상도로 관측한다. D-PMU를 사용하여 배전계통을 정밀하게 측정함으로써 계통에 긴 시간 동안에 큰 영향을 미치는 사고 이벤트뿐만 아니라 간헐적으로 발생하며 짧은 지속시간을 가진 이벤트 또한 감지할 수 있게 되었다. 최근 D-PMU의 고해상도 데이터를 이용한 배전계통의 장비 상태 진단, 상태추정, 이벤트 분석 및 고장 위치추정 등 다양한 연구가 진행되었다[3-5].

배전계통은 목적 및 규모에 따라 토폴로지 및 부하특성이 각기 다르게 구성되어 한 배전계통에서 발생한 이벤트로 모든 배전계통에 일반화하여 적용하기 어려운 특성이 있다. 이에 따라, 배전계통에 악영향을 미치는 현상을 수식적으로 해석하고 특정 함수로 규정짓기에 어려움이 존재한다. 배전계통에서 불확실성과 변동성이 더욱 확대되는 상황과 계통 구성 정보 및 전력 데이터의 기밀성에 따라 동반되는 한계를 극복하기 위한 연구가 요구되고 있다. 따라서 각 배전계통에서 수집한 고해상

† Corresponding Author : Dept. of Electrical Engineering, Soongsil University, Korea.
E-mail: sgyoon@ssu.ac.kr
<https://orcid.org/0000-0002-8987-6628>

* Dept. of Electrical Engineering, Soongsil University, Korea.
<https://orcid.org/0000-0002-4343-9449> <https://orcid.org/0000-0002-6676-4869>

Received: Aug. 03, 2021 Revised: Feb. 21, 2022 Accepted: Mar. 25, 2022

도 데이터를 이용하여 이벤트 특성 분석 및 대응에 필요한 동일 배전계통의 이벤트 감지를 진행하여 계통 안정을 위한 다양한 대책 및 계획에 사용 가능한 데이터 기반 연구가 주목받고 있다. 기존의 전력계통에서 이벤트 감지에 관한 연구는 통계학적 방법을 통해 진행된 연구[6]와 PCA(Principal Components Analysis)[7], GAN(Generative Adversarial Network)[8-9], CNN(Convolutional Neural Network)[10-11] 등 기계학습 기법을 사용한 것으로 구분할 수 있다. 추가로 이전의 연구에서는 정상 데이터를 사용하여 비정상 데이터를 감지하고 이벤트 분류를 따로 진행하는 알고리즘을 사용하였다[7-8].

GAN은 생성기(Generator)와 판별기(Discriminator)의 적대적 학습 관계를 통해 적은 학습 데이터로도 학습이 가능한 특징을 가진다[12]. 생성기와 판별기는 각각 학습 데이터와 유사한 데이터를 생성하는 것과 생성기에서 생성된 데이터와 실제 데이터를 구분하는 것을 학습 목적으로 둔다. DCGAN(deep convolutional generative adversarial networks)은 GAN의 생성기와 판별기를 CNN에서 사용되는 합성곱 신경망(Convolutional layer)으로 구성한 기법이다[13]. 합성곱 신경망은 저차원의 데이터를 고차원의 데이터로 변형하여 입력한 데이터가 가진 특징을 추출하는 데 강점이 있다.

일반적인 GAN을 활용한 연구는 생성기를 학습시켜 실제 데이터와 유사한 데이터 세트를 생성하는 것을 목적으로 한다. 본 연구에서는 GAN을 반대로 활용하여 학습된 판별기를 통해 현재 입력된 데이터가 정상 데이터인지 여부를 판단하는 방식으로 사용하였다. 또한 제한하는 기법은 특징 추출에 장점이 있는 DCGAN을 사용하여 제한된 개수의 이벤트 데이터로도 판별기를 잘 훈련하여 이벤트의 감지율을 높였다. 학습 데이터로는 D-PMU로부터 취득한 이벤트 상태의 전압 데이터를 사용하였다. 학습이 완료된 후 판별기는 기존 이벤트 데이터와 유사한 특징을 지니는 데이터인지 아닌지를 판별하여 이벤트를 감지하도록 하였다.

본 연구에서는 배전계통에서 발생하는 다양한 이벤트를 감지하기 위해 2가지의 DCGAN 모델을 제안한다. 첫 번째로 전압강하, 과전압 등을 감지하기 위해 전압 실효값 기반 전압변동 감지 모델과 두 번째로 과도현상, 고조파현상 등 고조파 투입에 의한 이벤트를 감지하기 위한 전압 순시값 기반 전압왜곡 감지 모델을 제안하였다. 제안하는 기법의 성능을 분석하기 위해 송실대학교 두 건물에 설치된 실제 D-PMU에서 얻은 데이터를 이용하였다. 비교 기법으로는 Elspec 사에서 제공하는 PMU 데이터 분석 소프트웨어인 PQS Sapphire를 사용하였다.

2. DCGAN 기법 이론 및 적용

2.1 생성적 적대 신경망(GAN)

GAN은 [그림 1]과 같이 생성기와 판별기가 인공신경망으로 구성되어 있다. GAN에서는 생성기와 판별기가 서로 경쟁하며

학습 과정을 거친 뒤 생성모델을 만들어 낸다. 잠재공간(Latent Space)으로부터 무작위의 벡터 데이터(z)를 입력받아 생성기가 만들어 낸 새로운 데이터는 판별기의 입력으로 쓰인다. 판별기는 생성기로부터 수신한 데이터와 실제 데이터를 비교하며 데이터의 진위를 판별한다. 이러한 적대적 학습 과정을 통해 생성기는 판별기의 출력을 이용하여 학습 데이터와 유사한 데이터를 생성하는 능력을 향상시키고 판별기는 생성기의 출력과 실제 데이터를 비교하며 판별 능력을 향상시키는 것을 목표로 학습한다.




그림 1. GAN 구조 예시[14]

Fig. 1. GAN Composition example[14]

생성기에 중점을 둔 주요 응용 분야는 이미지 생성과 복원, 동작을 흉내 내는 인공지능, 신약 개발 등이 있고 향후에는 음성 관련 분야에서도 적용되어 데이터의 생성·편집·변환·복원에 활용될 가능성이 논의되고 있다[13]. 본 연구에서는 기존의 GAN을 활용한 연구와는 다르게 자가지도 학습 모델의 구조로서 생성기의 변화하는 출력을 판별기의 학습 데이터의 일부로 이용하여 학습한 판별기를 활용한 이벤트 감지 기법을 제안한다.

2.2 생성기(Generator)




그림 2. 심층 합성곱 신경망으로 구성된 생성기 내부 구조 예시[15]

Fig. 2. Composition example of Generator in DCGAN

생성기는 [그림 2]와 같이 잠재공간으로부터 무작위 벡터 데이터(z)를 입력받아 역합성곱 과정을 통해 데이터 상관관계를 분석한다. 분석된 데이터는 판별기의 입력으로 쓰이며 실제 데이터와 유사한 데이터를 만들어 판별기가 실제 데이터로 판단하도록 속이는 것이 목표이다. 무작위 벡터(z)를 통해 생성한 가짜 데이터는 $G(z)$ 로 정의한다. 함수 G 의 입력은 100차원의 벡터이고 출력은 학습 데이터와 동일한 2차원 벡터이다.

2.3 판별기(Discriminator)



그림 3. 심층 합성곱 신경망으로 구성된 판별기 구조 예시[15]

Fig 3. Composition example of Discriminator in DCGAN

판별기의 구조를 [그림 3]에 도시하였다. 판별기는 생성기의 출력 데이터인 가짜 데이터 혹은 실제 데이터를 입력으로 받아 합성곱 과정을 통해 데이터 상관관계를 분석하고 이를 통해 가짜 데이터와 실제 데이터를 정확하게 분류하여 판별하는 것이 목표이다. 판별기 함수 $D(\cdot)$ 의 입력은 학습 데이터 차원의 벡터이며 출력은 스칼라값이다. 판별기 함수의 출력이 1 일 때 100%의 확률로 학습 데이터와 비슷한 특징을 지닌 데이터라는 의미이기에 이상적인 학습기의 출력은 가짜 데이터를 포함한 실제 데이터가 아닌 데이터가 입력으로 들어왔을 때 최대한 1에서 먼 1 이하의 값을 출력하고 학습 데이터가 입력으로 들어왔을 때 1과 가까운 값을 출력하는 것이다.

2.4 적대적 학습 이론

GAN은 생성기와 판별기가 서로 적대적 관계를 가지며, 상대방의 출력을 입력으로 받아 학습시키는 구조이다. 생성기의 관점에서 살펴보면 자신이 만든 데이터를 판별기가 진짜 데이터로 구분하게 만들기 위해 학습한다. 생성기의 목적 함수는 (식 1)과 같다. 이는 가짜 데이터에 대한 판별기의 출력이 1이 되는 것을 목표로 학습하는 것을 의미한다.

$$\min \log(1 - D(G(z))) \quad (\text{식 1})$$

반면 판별기는 생성기가 만든 가짜 데이터와 학습 데이터를 구분하기 위해 학습한다. 판별기는 (식 2)와 (식 3)과 같이 진짜 데이터(real)에 대한 판별기의 출력이 높아지고 가짜 데이터($G(z)$)에 대한 판별기의 출력은 낮아지도록 학습하는 것이다.

$$D(\text{real}) > 0 \quad (\text{식 2})$$

$$D(G(z)) \leq 0 \quad (\text{식 3})$$

이러한 생성기와 판별기의 경쟁 학습과정은 최대-최소 목적 함수로 정의될 수 있다.(식 4) 이때 V 함수는 value 함수라고 명명한다.

$$\min_G \max_D V(G, D) = E_{\text{real}}[D(\text{real})] - E_z[D(G(z))] \quad (\text{식 4})$$

2.5 합성곱 신경망(Convolutional Layers)

기존의 완전 연결 계층(Fully Connected Layer)으로 구성된 인공신경망의 입력 데이터는 1차원(배열) 형태로 한정된다. 합성곱 신경망에서는 1차원 형태의 정보의 한계를 극복하기 위해 입력 데이터를 다차원으로 변형시킨 후 커널을 사용하여 공간 정보를 재분석하여 정보를 유지한 상태로 다음 신경망으로 전달하는 과정을 반복한다. 이러한 과정은 데이터의 특징을 추출하는데 성능이 특화되어 고해상도 데이터 분석에 주로 사용된다.




그림 4. 합성곱 신경망의 커널 크기 3x3의 합성곱 과정[16]

Fig 4. The process of 3x3 sizes Convolutional layers

[그림 4]는 입력 커널 크기 3x3, 출력 커널 크기 1x1에 해당하는 합성곱 신경망의 합성곱 과정에 대한 예시를 나타내고 있다[16].

2.6 심층 합성곱 생성적 적대 신경망(DCGAN)

심층 합성곱 생성적 적대 신경망(DCGAN)은 생성기와 판별기 두 개의 심층 합성곱 신경망으로 구성되어 있다. GAN과 기본적으로 동일한 구조와 학습 과정으로 구성되어 있으나, 심층 합성곱 신경망을 사용한다는 차이가 존재한다. DCGAN에서는 심층 합성곱 신경망의 데이터 관계 및 특징 분석 능력을 이용하여 생성기와 판별기를 학습시킨다. 학습된 생성기는 기존의 GAN보다 학습 데이터와 유사한 특징을 가진 데이터를 출력하며 학습된 판별기는 정확한 분류 성능을 보였다.

3. D-PMU 데이터 전처리

본 논문에서는 송일대학교 A와 B 건물에 설치된 D-PMU를 이용하여 측정한 3상의 전압 데이터를 사용하였다. 송일대학교 A 건물은 학교의 태양광 발전기가 직접 연결된 건물이며 100 kW와 41 kW 인버터가 설치되어 있고 1시간 최대 출력량은 129 kW이다. D-PMU는 변압기 1차 측과 2차 측에 설치하여 A 건물의 D-PMU는 22.9 kV, B 건물의 D-PMU는 220 V의 기준 전압으로 데이터를 측정하고 있다.

배전계통에서 이벤트 감지를 위해 순간의 데이터에 대한 정보를 모두 포착하고 분석하기 위한 이벤트의 지속시간-현상 등을 기반으로 적절한 단위의 데이터 1세트의 시간을 선정하였다. 구성된 데이터 1세트는 합성곱 신경망으로 이루어진 DCGAN 특성에 따라 연속적인 시계열 데이터가 아닌 순간의

데이터로 간주하여 학습과 테스트를 진행하였다. 이벤트 데이터 검출 성능을 향상시키기 위해 Z-score 정규화를 적용한 데이터가 사용되었다.

3.1 D-PMU(Elspec G4430)

연구에서 사용된 Elspec사의 G4430은 주기 당 최대 1,024개의 샘플 데이터를 취득할 수 있다. 3상 전력 시스템에 연결하여 전압·전류·주파수·위상·전력 등의 데이터가 취득 가능하며 측정 정확도는 PMU 데이터 품질을 정의한 IEC 61000-4-30 CLASS A 표준[18]을 능가한다. 사용된 2개의 D-PMU는 각각 전압 실효치 220V와 22.9kV에 연결되어 다른 표준 전압값을 사용하는 경우에도 이벤트 검출이 가능함을 확인하였다.

본 논문에서 활용할 이벤트 데이터를 추출하기 위해 각 이벤트의 기준을 선정하고 G4430의 연동 소프트웨어인 PQS Sapphire를 이용하여 CSV 파일로 데이터를 추출하였다. [그림 5]는 PQS Sapphire의 환경을 보여준다.




그림 5. PQS Sapphire 소프트웨어 환경 예시

Fig 5. Example of PQS Sapphire

3.2 정규화(Normalization)

정규화는 데이터를 일반화시켜 데이터 간의 관계를 뚜렷하게 보여주고 데이터를 일정한 기준이 되는 규모 내에 분포하게 해주는 역할을 한다. 본 연구에서는 정규화를 통해 데이터를 일정 구간 이내로 분포시키기 때문에 다른 위치에 존재하는 계측기의 전압 측정값을 같이 사용할 수 있다. 정규화를 통해 데이터 간의 관계가 더욱 뚜렷하게 나타나고 데이터 저장 공간을 적게 사용함으로 학습 시간을 단축되는 효과도 가진다. 본 논문에서는 모델 학습 개선을 위해 주로 사용되는 정규화 중 min-max 정규화와 Z-score 정규화를 비교하였다. (식 5)는 X 데이터의 최댓값과 최솟값을 이용한 min-max 정규화 수식을 나타내고 (식 6)은 X 데이터의 평균값인 $Mean(X)$, X 데이터의 표준편차인 $Std(X)$ 를 이용한 Z-score 정규화 수식을 나타낸다.

$$\frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad (\text{식 } 5)$$

$$\frac{X - Mean(X)}{Std(X)} \quad (\text{식 } 6)$$

Z-score 정규화는 평균값과 표준편차를 이용한 정규화로써 이상치에 민감하게 반응하기 때문에 이상치를 제거하기 위해 주로 사용된다. 이상치에 민감하게 반응하는 Z-score 정규화는 본 논문의 목적인 이상 데이터 검출에 좋은 성능을 보이기에 [17] 제안하는 기법의 정규화로 사용하였다.

3.3 이벤트 감지를 위한 학습/테스트 데이터

실제 설치된 D-PMU 2기로부터 취득한 8개월 데이터에 PQS Sapphire를 사용하여 이벤트 데이터를 추출하였다. 각 모델에 이벤트당 8개에 해당하는 학습 데이터 세트를 이용하여 모델을 학습하고 나머지 이벤트 판별데이터(전후 10초) 데이터, 정상 데이터(각 30초), 무작위 선출데이터(각 10초)가 테스트에 사용되었다. 사용된 테스트 데이터는 약 30분에 해당하며 동 시간대에 2개의 D-PMU에서 계측된 데이터를 모두 사용하였다.

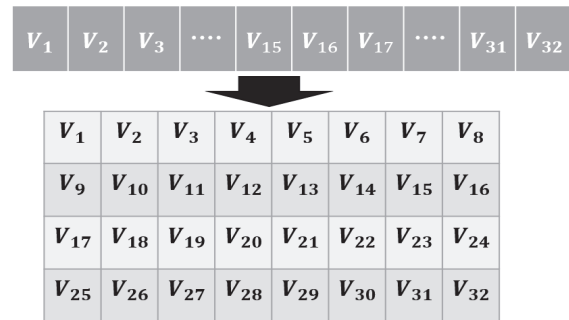


그림 6. 합성곱 신경망을 위한 데이터 재구성 예시

Fig 6. Data reconstruction example for convolutional layer

각 이벤트에 해당하는 데이터 세트 구성은 4절에서 다루었다. 이벤트의 특징을 모두 담아내면서도 학습 및 테스트 속도를 최소화할 수 있는 샘플링으로 설정하였다. 생성기와 판별기의 구조인 합성곱 신경망에 입력하기 위해 [그림 6]과 같이 데이터를 배열에서 2차원으로 재구성하여 합성곱 신경망으로 구성된 판별기 모델의 입력으로 사용되었다.

3.4 롤링 윈도우(Rolling Window)

테스트 데이터는 학습 데이터와 다르게 한 세트의 구성이 아닌 연속된 셀로 구성된다. 롤링 윈도우는 수많은 셀이 연속해서 입력될 때 데이터 세트의 시작점을 일정 기준마다 늦춰가며 중첩된 데이터로 세트를 구성하여 하나의 셀이 여러 데이터 세트에 속하게 하는 방법이다. 구성된 데이터 세트에 따라 데이터의 평균값과 표준편차는 민감하게 변하는 특징이 있다. 특히, 이상치가 포함된 데이터 세트에서는 더욱 민감하게 변한다. 따라서 본 논문에서는 합성곱 신경망의 특성뿐 아니라 시계열 데이터의 특성을 반영하여 이벤트 감지 성능을 개선하기 위해 테스트 데이터 중 이상치가 포함된 셀이 여러 데이터 세트에 속하게 되는 롤링 윈도우 방식을 사용하였다[18].

4. DCGAN 기반 이벤트 감지법

4.1 DCGAN 기반 배전계통 이벤트 감지법

본 논문에서는 D-PMU 데이터와 생성기와 판별기를 합성곱 신경망으로 구성된 DCGAN을 이용한 배전계통 이벤트 감지법을 제안한다. 배전계통 이벤트 데이터는 토폴로지 및 구성요소 별로 그 특징이 다르게 나타날 수 있어 많은 학습 데이터를 확보하기 어렵다는 특징이 있다. 이를 해결하기 위해 본 논문에서는 GAN의 생성기와 판별기의 적대적 학습을 사용하였다[12]. 제안하는 기법은 D-PMU로 계측된 전압의 크기 변동에 대한 강인성을 높이기 위해 입력값을 Z-score 정규화를 진행하였다.

[그림 7]은 DCGAN 기법 기반 이벤트 감지 모델 적용 배전계통 구성도이다. 학습된 DCGAN 모델을 이용하여 관제센터에서 이벤트 감지를 진행하여 실시간으로 배전계통을 감시하고자 하였다. 본 연구에서 목표로 하는 전압변동과 전압왜곡을 기반으로 일차적인 감지 이후에 새로운 현상이 포착된다면 구체적인 이벤트 분류를 위해 하나의 학습 데이터 세트를 이용하여 새로운 판별기 모델을 학습한다. 새로운 모델을 기반으로 지난 데이터를 검토하여 동일 현상을 감지하고 특성, 주기성, 반복성 등을 분석하여 대책 마련이 가능하다. 최종적으로 발생하는 모든 현상에 대해 복잡한 함수 모델링 없이 실시간으로 이벤트를 분류할 수 있다. 자동 제어가 구축된 배전계통에서는 필요시에 감지된 이벤트에 따라 자동 제어를 통해 이벤트 상황 처리가 가능하다. 또한, 자율 계통 재구성과 같은 전력 효율을 극대화하기 위한 제어가 진행될 때 전력 효율뿐 아니라 전력품질까지 고려한 제어의 참고 요소로 사용될 수 있다.




그림 7. 배전계통 이벤트 감지 모델 적용 구성도
Fig 7. Example of event detection in Distribution networks

4.2 이벤트 데이터 선정

D-PMU 데이터를 이용함으로써 기존의 측정기에서 감지하기 어려웠던 ms 단위의 이벤트 분석이 가능해졌다. 본 논문에서 감지할 이벤트는 전력품질에 민감한 전기기기에 부정적인 영향을 미칠 수 있는 전압강하, 과전압, 과도현상, 고조파현상의 4가지 이벤트로 설정하였다. 대상 이벤트는 주로 태양광 발전기 출력용 인버터, 전기 자동차 충전기, 다양한 공학용 실험기기의 동작으로 기인한다[19-20]. [그림 8]은 D-PMU로 획득

한 4가지 이벤트의 샘플 파형을 보여준다.

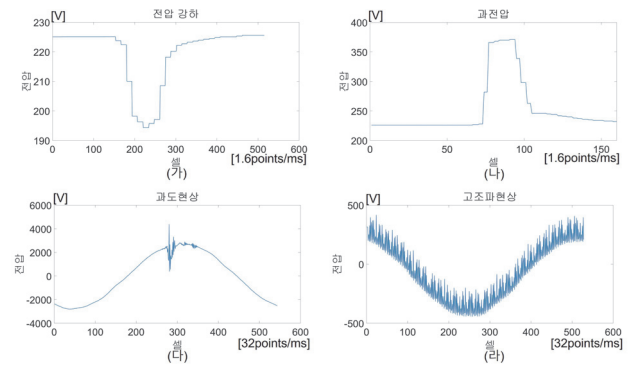


그림 8. 이벤트 데이터: (가) 전압강하, (나) 과전압, (다) 과도현상, (라) 고조파현상
Fig 8. The used event data: (a) voltage drop, (b) over voltage, (c) transient, (d) harmonics

4.2.1 전압강하

본 논문에서는 전압강하 이벤트는 정상 전압에서 10% 이상의 전압 감소가 10ms 이상 유지되는 현상으로 정의하였다. 전압강하 이벤트는 최대 100ms의 유지 시간을 가지기 때문에 판별기의 입력으로 들어가는 데이터 세트를 100ms 동안 160개의 전압 실효값으로 지정하였다. 제안하는 DCGAN 기반 이벤트 감지법은 2차원 데이터를 입력으로 받기 때문에 160개의 데이터를 8×20의 2차원 데이터로 재구성하여 사용하였다.

4.2.2 과전압

과전압 이벤트는 전압강하 이벤트의 반대 현상이다. 본 논문에서는 전압강하와 유사하게 과전압 이벤트를 정상 전압에서 10% 이상의 전압 상승이 10ms 이상 유지되는 현상으로 정의하였다. 입력 데이터 세트도 동일하게 100ms 동안 160개의 전압 실효값을 8×20으로 재구성하여 사용하였다.

4.2.3 과도현상

과도현상은 [그림 8]의 (다)와 같이 전압 혹은 전류가 불안정한 파형을 보이는 것을 뜻한다. 본 논문에서는 과도현상은 10ms 이내로 임계값을 벗어난 값을 가진 현상으로 정의하였다. 임계값은 실패 데이터를 관측하여 80%로 설정하였다. 과도현상은 매우 짧게 관찰되고 사라지기 때문에 전압강하와 과전압 이벤트보다 세밀한 샘플링으로 데이터 세트를 구성하였다. 즉, 1ms 동안 32개의 전압 순시값을 데이터 세트로 구성하였다. 합성곱 신경망의 입력으로 넣기 위해 32개의 전압 순시값 데이터를 4×8로 재구성하여 사용하였다.

4.2.4 고조파현상

고조파는 전압/전류에 기본 주파수보다 높은 배수의 고조파를 가진 성분이 혼재하는 것을 의미한다. 고조파가 투입되면

높은 주파수의 성분으로 인해 [그림 8]의 (라)와 같은 전압왜곡이 발생한다. 본 논문에서 고조파 현상은 전고조파왜율(Total Harmonic Distortion)값이 8% 이상으로 3분 이상의 지속시간을 가지는 현상으로 정의했다. 고조파 현상이 나타날 때 [그림 8]의 (라)와 같이 16ms 이상 지속되는 전압왜곡을 관찰하였다. 고조파현상 감지 모델은 과도현상 감지 모델과 동일하게 1ms 동안 32개의 전압 순시값 사용하여 데이터 세트를 구성하고 4×8로 재구성하여 DCGAN 모델에 입력하였다. 고조파 현상은 1~2ms에 해당하는 과도현상에 비교하여 비교적 긴 지속시간을 가진다. 따라서 본 논문에서는 지속시간으로 두 이벤트를 구분하였다. 즉, 전압왜곡 지속시간 8ms를 기준으로 초과일 때 고조파현상, 이하일 때 과도현상으로 정의하였다.

4.3 이벤트 특성에 따른 감지 모델 분류

본 논문에서는 4가지 목표 이벤트의 특성에 따라 2가지 이벤트 감지 모델로 구분하였다. 전압변동 감지 모델(1)은 전압 실효값을 사용하여 전압강하와 과전압에 해당하는 이상 전압을 감지하는 모델이다. 전압 강하 현상을 기반으로 추출한 데이터로 학습한 모델과 과전압 현상을 기반으로 추출한 데이터로 학습한 모델 두 가지의 판별기 모델을 혼합해둔 모델이다. 전압왜곡 감지 모델(2)은 전압 순시값을 사용하여 과도현상과 고조파현상에 해당하는 이상 전압을 감지하는 모델이다. 과도현상과 고조파현상을 나타내는 전고조파왜율을 감지하는 하나의 판별기 모델이며 두 가지 이벤트는 지속시간에 따라 구분하였다.

4.4 DCGAN 모델의 구성

[표 1]은 본 연구에서 사용한 생성기와 판별기의 내부 구조 및 구성을 보여준다. 생성기는 합성곱 신경망은 각 합성곱에 설정된 필터의 개수이다. 활성화 함수는 비선형적인 성질을 보완하여 출력층과 멀리 있는 신경망까지 정보 전달을 개선시키는 ReLU를 사용하였다. 최적화기는 학습이 진행될수록 학습의 정도를 감소시켜 발산을 방지할 수 있는 Adam 최적화기를 사용하였으며 생성기보다 판별기의 학습도를 높게 설정하여, 판별기의 판별 능력이 우선되며 가짜 데이터가 온전히 진짜 데이터로 인식되는 현상을 방지하였다. 추가로 신경망 간의 계산을 일부 생략하여 연산 속도를 개선시키고 과적합 문제를 방지하는 Dropout을 사용하였다.

표 3. 생성기·판별기 구조 및 구성

Table 1. Configuration of generator and discriminator

	합성곱 신경망	활성화 함수	Dropout 계수	최적화기 (학습도)
생성기	128-64-32-1	ReLU	0.5	Adam (0.0005)
판별기	1-32-64-128	ReLU	0.5	Adam (0.0007)

4.5 DCGAN 모델의 학습

DCGAN을 학습하기 위해 이벤트당 8개의 데이터 세트를 구성하였다. 전압강하와 과전압은 전압의 실효값을 160지점/100ms로 추출하여 전압변동 감지 모델 학습에 사용하였고, 과도현상과 고조파현상은 전압의 순시값을 32지점/1ms로 추출하여 전압왜곡 감지 모델 학습에 사용하였다. 모든 데이터는 Z-score 정규화를 진행한 후 사용하였으며 학습 반복 횟수는 2,000회에 해당한다.

[그림 9]는 학습 순서도를 보여준다. 판별기는 학습 데이터가 입력 데이터와 유사하다고 판단하면 0 이상의 양수를 출력하고, 유사하지 않다고 판단하면 0에 가까운 양수 혹은 0 이하의 음수를 출력한다. 판별기에 학습에 사용한 이벤트 데이터를 입력하였을 때 판별기가 양수를 출력하는지 확인하고 이벤트 데이터가 아닌 정상 상태 데이터를 입력하였을 때 판별기가 음수를 출력하는지 확인하며 조건에 만족하지 못하면 학습 반복을 100회씩 진행하였다. 학습 반복을 100회씩 진행할 때마다 정상 데이터와 이벤트 데이터로 테스트를 진행하여 상기 조건을 모두 만족할 때 결과와 생성된 가짜 데이터를 관찰하였다. 정상 데이터와 이벤트 데이터는 200회 학습 후에도 구분하였으나 학습이 진행될수록 판별기 테스트 출력값과 생성된 가짜 데이터가 안정되는 경향을 보이기에 추가 학습을 진행하였다. 전압변동 감지 모델과 전압왜곡 감지 모델 모두 학습 반복 횟수 2,000회 이후에 큰 변화를 보이지 않기에 학습을 종료하였다.

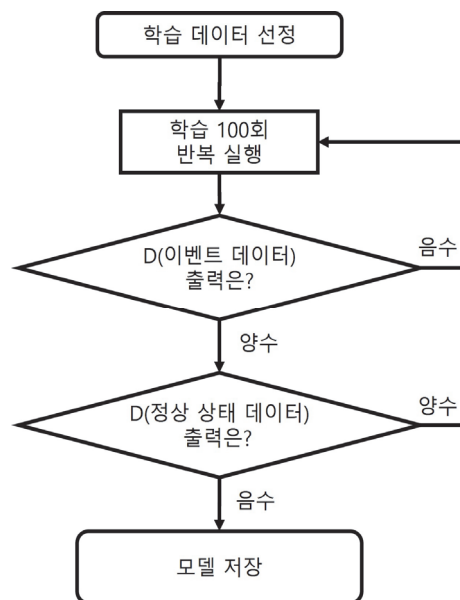


그림 9. 생성기/판별기 학습 순서도

Fig 9. Algorithm of training generator and discriminator

5. 실험 및 결과

본 장에서는 제안하는 DCGAN 기반 이벤트 감지방법의 성능을 송실대학교에 설치한 D-PMU 데이터를 통해 검증한다.

제안하는 기법과 PQS Sapphire 소프트웨어 이벤트 로그와 비교하여 전압강하, 과전압, 과도현상, 고조파현상 이벤트를 감지 결과를 비교하였다. DCGAN은 전압강하, 과전압과 같은 전압변동을 감지하기 위한 전압변동 감지 모델과 과도현상, 고조파현상과 같은 전압왜곡을 감지하기 위한 전압왜곡 감지 모델을 사용하였다.

5.1 학습 결과

[그림 10]은 학습에 사용된 실제 데이터(가)(다)(마)와 학습된 생성기의 출력인 가짜 데이터(나)(라)(바)을 보여준다. [그림 10]의 (가)(나)는 전압강하, [그림 10]의 (다)(라)는 과전압, [그림 10]의 (마)(바)는 과도현상과 고조파에 해당하는 그래프이다. [그림 10]의 (나)(라)(바)가 보여주는 생성기의 출력은 이번 연구와 직접적인 관련은 없지만, 판별기와의 적대적 학습 관계에 따라 학습의 완성도를 확인하기 위해 도시하였다.

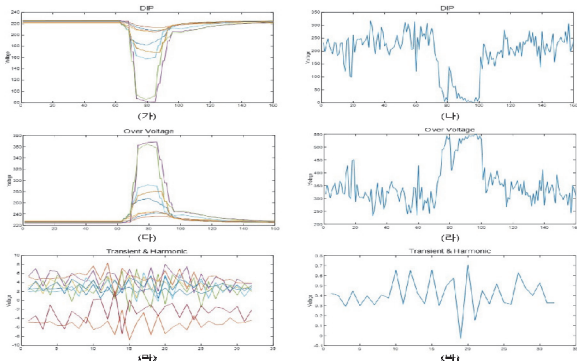


그림 10. 학습 데이터(가, 다, 마)/생성된 가짜 데이터(나, 라, 바) 비교. 전압강하(가,나), 과전압(다,라), 과도현상 및 고조파(마,바)

Fig 10. Training data(a, c, e), Generated data(b, d, f), voltage drop(a, b), over voltage(c, d), transient&harmonics(e, f)

학습 반복 횟수 2,000회에 생성된 가짜 데이터는 학습 데이터의 이벤트 특징을 잘 모방한 것을 관찰할 수 있으며, 가짜 데이터에서 잡음을 포함한 다른 특징을 띠는 점은 유사한 특징을 가진 파형을 모두 감지하기 위해 학습한 합성곱 신경망의 특성으로 해석된다. 학습 반복 횟수 2,000회가 진행되었을 때 생성기의 출력인 가짜 데이터의 완성도가 충분하다고 판단하여 판별기의 학습을 종료하였다. 학습 종료 이후 생성기를 이용하여 100개의 데이터를 생성하여 이벤트 상태에 해당하는 셀을 제외한 데이터의 평균을 구한 결과 2.5% 미만인 것을 확인하였다.

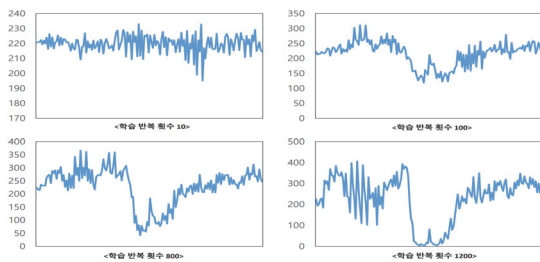


그림 11. 학습에 따른 생성기의 출력 변화

Fig 11. Change of generated data according to training

[그림 11]은 학습 반복 횟수에 따른 생성기의 출력 변화를 보여준다. 생성기는 이벤트 감지에 직접적으로 사용되지 않으나 생성기의 양질 출력은 판별기 학습의 완성도와 비례 추론이 가능하다. 적대적 학습 관계에 의해 학습이 반복될 때마다 생성기의 출력이 변화하는 것을 관찰하였다. 학습 반복 횟수 1,200회 이후에서는 생성기의 출력에 큰 변화를 보이지 않았다.

[그림 12]는 학습 반복 횟수에 따라 변화하는 판별기의 출력을 보여준다. 초록색 선은 학습 데이터 전체가 입력되었을 때 판별기 출력값의 평균이며, 노란색 선은 생성기가 생성한 가짜 데이터에 대한 판별기의 출력값이다. GAN은 생성기와 판별기가 동시에 학습되는 구조이기 때문에 가짜 데이터에 대한 판별기 출력값이 0 근처로 나오지만, [표 1]에 나타난 것 같이 생성기의 Adam 최적화기 계수가 판별기의 계수보다 높으므로 학습이 반복됨에 따라 음수를 출력하는 경향을 보여 정상적으로 훈련이 되고 있음을 확인하였다.

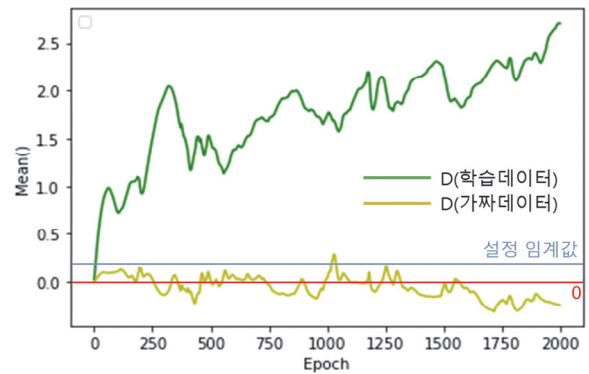


그림 12. 학습에 따른 판별기의 출력 변화

Fig 12. Change of output of discriminator according to training

5.2 판별 결과

제안하는 DCGAN 기반 이벤트 감지기법의 모델 성능 평가를 위하여 다른 크기의 전압을 측정하고 있는 두 개의 D-PMU에서 약 30분 데이터를 추출하였다.

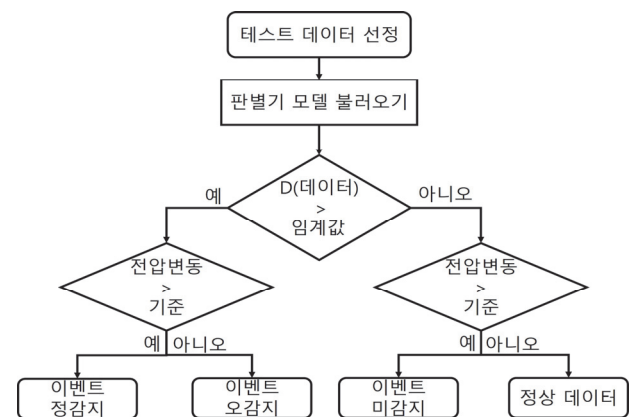


그림 13. 모델 성능 실험 알고리즘

Fig 13. Algorithm of performance test

[그림 13]은 모델 성능 검증을 위한 실험 알고리즘이다. 추출한 데이터는 학습된 판별기의 입력으로 넣어 출력하는 값 D(데이터)가 임계값을 넘는지를 확인하였다. 임계값이 넘는다는 것은 제안하는 이벤트 감지기법이 이벤트로 판단했다는 의미이고 해당 데이터를 실제 이벤트로 판단하여 이벤트 정감지 혹은 오감지로 결정된다. 임계값이 넘지 않은 경우에도 실제 이벤트 여부를 판단하여 이벤트 미감지 혹은 정상 데이터로 구분한다. 본 논문에서는 학습 이후 정상 데이터 테스트 결과를 기반으로 임계값을 0.15로 설정하였다.

(식 7)과 (식 8)는 전압변동과 전압왜곡의 기준으로 사용한 수식이다.

$$\text{실효값전압변동} = \left| \frac{V_i - V_{i+1}}{V_{i+1}} \right| \geq 0.01 \quad (\text{식 7})$$

$$\text{순시값전압변동} = \left| \frac{V_i - V_{i+1}}{V_i} \right| > \left| \frac{V_{\max} \text{Sim}\theta_i - V_{\max} \text{Sim}\theta_{i+1}}{V_{\max} \text{Sim}\theta_i} \right\}$$

실효값을 사용하는 전압변동은 1%를 기준으로 설정하였다. 순시값은 데이터가 구성된 세트의 시간과 동일한 시간 동안 정현파의 변동을 기준으로 분류하였다. [표 2]는 각 모델에 사용된 입력 데이터의 크기, 입력 데이터의 시간, 학습 이벤트 종류, 학습 이벤트 평균 지속시간, 학습 데이터 개수, 총 데이터 크기, 롤링 윈도우 크기 정보를 보여준다.

표 2. 판별기 모델별 데이터 구성 정보

Table 2. Configuration information of detection model

	전압변동 감지 모델	전압왜곡 감지 모델
데이터 1세트 구성 크기(셀)	8×20	4×8
데이터 1세트 구성 시간(ms)	100	1
감지 이벤트	전압 강하, 과전압	과도현상, 고조파현상
이벤트 평균 지속시간(ms)	20	1.5(과도), 18(고조파)
학습 데이터 세트	8	8
테스트 데이터 지점	3,124,486	39,056,075
Rolling window size	20	8

5.4 실험 결과 분석

이벤트 감지 실험은 전압변동 감지 모델 3가지와 전압왜곡 감지 모델 3가지로 총 6가지의 경우를 진행하고 PQS Sapphire에서 감지된 이벤트 결과를 추가하여 비교하였다. 제안하는 방식(1)(4)은 이벤트 데이터로 학습하고 Z-score 정규화를 진행한 것이나, 성능 비교를 위해 학습을 정상 데이터로 진행한 것(2)(5)과 정규화를 min-max 정규화로 진행한 것(3)(6)을 추가하였다. 이벤트 1회 감지의 기준은 1개의 데이터 세트 안에 각 이벤트에 해당하는 지속시간 이상의 이벤트가 검출되는 것으로 정의하였다. 추가로 순시전압 1주기에 1회 감지로 제한하여 중복 감지를 방지하

였다. 0.1% 미만의 전압변동이나 전압왜곡을 감지한 과민한 감지는 후처리 과정을 통해 실험 결과에서 제외하였다.

[그림 14]는 이벤트 감지기법의 실험 결과를 보여준다. 정감지는 모든 이벤트 감지기법의 정감지 결과를 다 합친 것으로 정의하였고 미감지는 정의한 정감지 이벤트를 놓친 수로 정의하였다. 전압왜곡의 오감지는 순간 전압변동률이 일반 정현파의 전압변동률보다 낮을 때와 감지하고자 하는 이벤트가 아닌 다른 이벤트 감지할 때 오감지로 정의하였다. 과감지는 순간적으로 0.1~3%의 전압변동과 2~5%의 전고조파왜율을 보이는 데이터를 감지한 경우를 뜻한다. 이 수치는 전압 품질에 영향을 미치긴 하나 가벼운 수준의 영향으로 판단하여 감지 결과에서 제외하였다. 실험 결과 제안하는 전압변동 감지 모델은 다른 DCGAN 기반 감지기법과 PQS Sapphire의 이벤트 감지와 비교하여 가장 좋은 성능을 보이는 것을 확인하였다.




그림 14. 모델별 이벤트 감지 결과 비교
Fig 14. Comparison of detection result

[그림 15]는 (1)(2)(3), (4)(5)(6) 모델에서 모두 감지된 정감지 데이터와 (2)(5) 모델에서 감지된 오감지 데이터의 예시이다. 예시는 감지된 데이터를 포함한 전압 2주기의 데이터를 추출하여 도시하였다. 전압변동 감지 모델은 데이터 1세트에 해당하는 100ms 동안 약 3~30%의 전압변동이 일어난 데이터를 올바르게 감지하였을 때 정감지로 분류하였고, 아주 미세한 전압변동을 제외한 전압변동이 없는 데이터를 감지하였을 때 오감지로 분류하였다. 전압왜곡 모델은 데이터 1세트에 해당하는 1ms 동안 약 5~40%의 전고조파왜율을 보이는 데이터를 올바르게 감지하였을 때 정감지로 분류하였고, 약 2% 이하의 작은 수치의 전고조파왜율을 보이는 데이터를 감지하였을 때 오감지로 분류하였다.

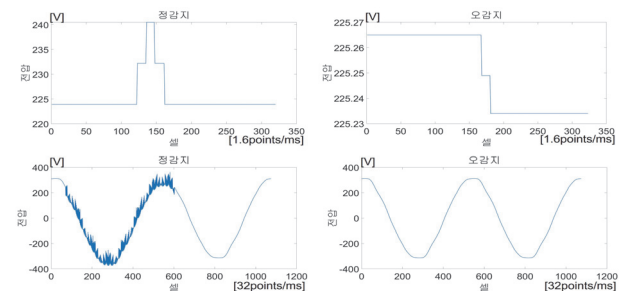


그림 15. 정감지·오감지 예시(상단 : 전압변동 감지, 하단 : 전압왜곡 감지)
Fig 15. Example of True positive and True negative

5.5 모델 성능 평가

제안하는 이벤트 감지기법의 성능을 정밀도(Precision), 재현율(Recall), F1 score로 평가하였다. 제안하는 기법 (1)(4), 정상 데이터 학습 모델 (2)(5), min-max 정규화 모델 (3)(6), PQS Sapphire 결과를 비교하였다. 정밀도와 재현율은 이벤트 정감지(True Positive, TP), 이벤트 미감지(True Negative, TN), 이벤트 오감지(False Positive, FP)로 (식 10)과 (식 11)로 구할 수 있다.

$$\text{정밀도} = \frac{\text{이벤트감지}}{\text{이벤트감지} + \text{이벤트오감지}} \quad (\text{식 } 10)$$

$$\text{재현율} = \frac{\text{이벤트감지}}{\text{이벤트감지} + \text{이벤트미감지}} \quad (\text{식 } 11)$$

모델의 최종 성능 평가는 (식 12)에 해당하는 정밀도와 재현율의 조화평균인 F1 Score를 통해 진행한다.

$$F1\text{Score} = 2 * \frac{\text{정밀도} * \text{재현율}}{\text{정밀도} + \text{재현율}} \quad (\text{식 } 12)$$

[표 3]과 [표 4]는 이벤트에 따라 분류한 전압변동 감지 모델과 전압왜곡 감지 모델의 성능 평가 결과이다. PQS Sapphire는 일정 기간에 이상 데이터가 한계빈도 및 한계치(envelope)를 동시에 초과하는 경우 이벤트 감지로 처리하기 때문에 제안한 모델보다 낮은 재현율을 보였다. 정상 데이터로 학습한 모델은 일반 데이터 감지와 다른 이벤트 감지로 오감지가 다수 발생하여 낮은 정밀도를 보였으며, min-max 정규화로 학습한 모델은 이상치에 민감하게 반응하지 않아 이벤트 미감지가 발생하여 낮은 재현율을 보인 것으로 확인했다.

표 3. 전압변동 감지 모델 성능 평가 결과

Table 3. Result of voltage variance model test

이벤트 종류	모델	정밀도	재현율	F1 Score
전압 강하	PQS Sapphire	1	0.656	0.792
	제안 모델(1)	1	1	1
	정상 데이터 학습 모델(2)	0.569	1	0.725
	min-max 정규화 모델(3)	1	0.295	0.456
과전압	PQS Sapphire	1	0.750	0.857
	제안 모델(1)	1	1	1
	정상 데이터 학습 모델(2)	0.461	0.857	0.600
	min-max 정규화 모델(3)	1	0.333	0.375
종합	PQS Sapphire	1	0.675	0.806
	제안 모델(1)	1	1	1
	정상 데이터 학습 모델(2)	0.549	0.975	0.703
	min-max 정규화 모델(3)	1	0.375	0.545

표 4. 전압왜곡 감지 모델 성능 평가 결과

Table 4. Result of voltage distortion model test

이벤트 종류	모델	정밀도	재현율	F1 Score
과도 현상	PQS Sapphire	1	1	1
	제안 모델(4)	0.813	1	0.897
	정상 데이터 학습 모델(5)	0.313	0.435	0.272
	min-max 정규화 모델(6)	0.267	0.571	0.364
고조파 현상	PQS Sapphire	1	0.151	0.263
	제안 모델(4)	1	1	1
	정상 데이터 학습 모델(5)	0.432	0.941	0.813
	min-max 정규화 모델(6)	0.796	0.614	0.693
종합	PQS Sapphire	1	0.163	0.281
	제안 모델(4)	0.979	1	0.990
	정상 데이터 학습 모델(5)	0.419	0.858	0.563
	min-max 정규화 모델(6)	0.672	0.610	0.639

제안하는 DCGAN 기반 이벤트 감지기법은 PQS Sapphire보다 많은 이벤트를 감지해내고 높은 F1 score를 보여 D-PMU 데이터를 이용한 이벤트 감지에 적합한 것을 확인하였다. 추가로 제안하는 기법의 판별기의 출력값이 높을수록 이벤트의 심각성이 높은 경향을 보이는 것과 미리 학습된 판별기를 이용하여 이벤트를 감지하기 때문에 빠른 감지 속도를 가지는 것을 확인하였다.

6. 결론

본 논문에서는 배전계통에서 일어나는 이벤트 감지를 위해 D-PMU 데이터를 사용한 DCGAN 기반 이상 전압 감지기법을 제안하였다. 본 논문에서 감지하고자 하는 이벤트는 전력품질에 악영향을 미치는 전압강하, 과전압, 과도현상, 고조파현상의 4가지이다. 이를 위해 실효치를 이용한 전압변동 감지 모델과 순시치를 이용한 전압왜곡 감지 모델로 나누어 이벤트 감지를 진행하였다.

DCGAN은 GAN의 적대적 학습 관계를 이용하여 적은 데이터로도 학습할 수 있으며 합성곱 신경망을 이용하여 향상된 이벤트의 특징 추출을 가지는 기법이다. 따라서 DCGAN은 빈번하게 발생하지 않는 배전계통 이벤트의 특징과 이벤트에 따라 다른 특징을 보이는 배전계통 이상 전압 이벤트에 적용하기에 적합하다. 제안하는 DCGAN 기반 이벤트 감지기법의 성능을 향상시키기 위해 D-PMU 데이터를 Z-score로 정규화시키고 ReLU 활성화 함수를 사용하며 dropout을 적용하였다. 다른 방식으로 학습시킨 DCGAN 기법과 Elspec사의 PQS Sapphire 소프트웨어와 성능을 비교한 결과 제안하는 기법이 가장 높은 정확도와 F1 score를 보이는 것을 확인하였다. 또한 제안하는 기

법은 1) 판별기의 출력값을 통해 이벤트의 진위뿐 아니라 심각성이 확인 가능하며 2) 학습된 판별기 모델을 사용하기에 빠른 감지 속도를 보이고 3) 이벤트 종류에 따라 독립적인 모델을 사용하기에 현상 감지가 혼선될 가능성이 적은 장점이 있다.

본 연구에서는 D-PMU 데이터 중 해당하는 상전압의 크기만 사용하여 하나의 채널로 구성된 모델로 전압변동과 전압왜곡 감지를 실행하였다. 이후 새로운 이벤트에 대한 기준을 설정하고 전압 전류의 크기 및 위상, 주파수, 유효전력, 무효전력 등 상관관계가 존재하는 데이터를 획득하여 다수의 채널로 구성된 DCGAN 모델에 적용한다면 더 많은 종류의 이벤트를 복잡한 함수 모델링 없이 감지할 것으로 기대한다. 제안하는 기법은 각 배전계통에 맞는 DCGAN 모델을 학습시키는 기법으로써 이 기법을 통해 분산 자원, 전기차, 마이크로그리드 등 다양한 설비로 구축된 배전계통의 안정적인 운영에 이바지할 것으로 기대한다.

Acknowledgements

This work was supported in part by the Ministry of Science, ICT (MSIT), South Korea, through the High-Potential Individuals Global Training Program, supervised by the Institute for Information & Communications Technology Planning & Evaluation (IITP) under Grant 2021-0-01525; and in part by the National Research Foundation of Korea (NRF) Funded by the MSIT, Korea Government, under Grant 2020R1F1A1075137.

References

- [1] A. K. Marvasti, Y. Fu, S. DorMohammadi and M. Rais-Rohani, "Optimal Operation of Active Distribution Grids: A System of Systems Framework," *IEEE Transactions on Smart Grid*, vol. 5, no. 3, pp. 1228-1237, May 2014.
- [2] V. F. Martins and C. L. T. Borges, "Active Distribution Network Integrated Planning Incorporating Distributed Generation and Load Response Uncertainties," *IEEE Transactions on Power Systems*, vol. 26, no. 4, pp. 2164-2172, 2011.
- [3] Shankar S., Yadav K.B., Priyadarshi A., Rathore V. Study of Phasor Measurement Unit and Its Applications. In: Gupta O.H., Sood V.K. (eds) *Recent Advances in Power Systems. Lecture Notes in Electrical Engineering*, 2021.
- [4] Emile Dusabimana, Sung-Guk Yoon, "A Survey on the Micro-Phasor Measurement Unit in Distribution Networks," *Electronics*, vol. 9, no. 2, 305, 2020.
- [5] Kyung-Min Lee, Chul-Won Park, "Big Data Analysis of PMU for Power Quality Review of Renewable Energy Sources in Gangwon Area," *Journal of the Korean Institute of Illuminating and Electrical Installation Engineers*, vol. 34, no.5, pp. 18-23, 2020.
- [6] S. Dasgupta, M. Paramasivam, U. Vaidya and V. Ajjrapu, "Real-Time Monitoring of Short-Term Voltage Stability Using PMU Data," *IEEE Transactions on Power Systems*, vol. 28, no. 4, pp. 3702-3711, 2013.
- [7] Y. Zhou, R. Arghandeh, I. Konstantakopoulos, S. Abdullah, A. von Meier and C. J. Spanos, "Abnormal event detection with high resolution micro-PMU data," *2016 Power Systems Computation Conference (PSCC)*, pp. 1-7, 2016.
- [8] A. Aligholian, A. Shahsavari, E. Cortez, E. Stewart and H. Mohsenian-Rad, "Event Detection in Micro-PMU Data: A Generative Adversarial Network Scoring Method," *2020 IEEE Power & Energy Society General Meeting (PESGM)*, pp. 1-5, 2020.
- [9] A. Aligholian, A. Shahsavari, E. M. Stewart, E. Cortez and H. Mohsenian-Rad, "Unsupervised Event Detection, Clustering, and Use Case Exposition in Micro-PMU Measurements," *IEEE Transactions on Smart Grid*, vol. 12, no. 4, pp. 3624-3636, 2021.
- [10] Kyung-Min Lee, Chul-Won Park, "A PMU Big Data based New Systematic Phenomenon Identification of RES using Deep Neural Network," *Trans. Korean. Inst. Elect. Eng.* vol. 70, no.1, pp. 045-050, 2021.
- [11] Sung-Bum Kang, Baekkyeong Ko, Su-Chul NAM, Yong-Do Cho, Yonghak Kim, Jeon Donghoon "Development of Classification Model of Power System Fault by Using PMU Big-Data," *Trans. Korean. Inst. Elect. Eng.* vol. 68, no9, pp. 1079-1084, 2019.
- [12] Ian J. Goodfellow, Jean Pouget-Abadie, Mehdi Mirza, Bing Xu, David Warde-Farley, Sherjil Ozair, Aaron Courville, Yoshua Bengio "Generative Adversarial Nets," *Part of Advances in Neural Information Processing Systems 27*, NIPS, 2014.
- [13] Q. Wu, Y. Chen and J. Meng, "DCGAN-Based Data Augmentation for Tomato Leaf Disease Identification," *IEEE Access*, vol. 8, pp. 98716-98728, 2020.
- [14] Feng, J.; Feng, X.; Chen, J.; Cao, X.; Zhang, X.; Jiao, L.; Yu, T. Generative Adversarial Networks Based on Collaborative Learning and Attention Mechanism for Hyperspectral Image Classification. *Remote Sens.* 1149, 2020.
- [15] Radford, Alec et al. "Unsupervised Representation Learning with Deep Convolutional Generative Adversarial Networks," *CoRR abs / 1511.06434*, 2016.
- [16] Dumoulin, V. and Visin, F., "A guide to convolution arithmetic for deep learning," *arXiv:1603.07285 [stat.ML]*, 2016.
- [17] S. Gopal Krishna Patro, Kishore Kumar Sahu, "Normalization: A Preprocessing Stage," *arXiv:1503.06462 [cs.OH]*, 2015.
- [18] Atsushi Inoue, Lu Jin, Barbara Rossi, Rolling window selection for out-of-sample forecasting with time-varying parameters, *Journal of Econometrics*, Volume 196, Issue 1, Pages 55-67, 2017.

- [19] N.B.G. Brinkel, M.K. Gerritsma, T.A. AlSkaif, I. Lampropoulos, A.M. van Voorden, H.A. Fidler, W.G.J.H.M. van Sark, Impact of rapid PV fluctuations on power quality in the low-voltage grid and mitigation strategies using electric vehicles, International Journal of Electrical Power & Energy Systems, Volume 118, 105741, 2020.
- [20] P. Khaledian, A. Aligholian and H. Mohsenian-Rad, "Event-Based Analysis of Solar Power Distribution Feeder Using Micro-PMU Measurements," 2021 IEEE Power & Energy Society Innovative Smart Grid Technologies Conference (ISGT), pp. 1-5, 2021.

저자소개



양준혁 (June-Hyuck Yang)

He received his B.S. and M.S. degree in Electrical Engineering from Soongsil University, Seoul, South Korea, in 2019 and 2022, respectively, Korea.

E-mail: mnb7192@naver.com



김태근 (Tae-Geun Kim)

He received his B.S degree in from Department of electrical and electronics engineering from Kangwon University, Chuncheon, South Korea, in 2020. Currently, he is pursuing Ph. D. degree at Soongsil University, Seoul, Korea.

E-mail: taegeun1520@gmail.com



윤성국 (Sung-Guk Yoon)

He received the B.S. and Ph.D. degrees in electrical engineering and computer science from Seoul National University, Seoul, South Korea, in 2006 and 2012, respectively. He is currently with Soongsil University as an associate professor. His research include energy big data, game theory for power system, and power system optimization.

E-mail: sgyoon@ssu.ac.kr