

# Data Augmentation Techniques of Power Facilities for Improve Deep Learning Performance

Seungmin Jang, Seungwoo Son, Bongsuck Kim  
장승민, 손승우, 김봉석

## Abstract

Diagnostic models are required. Data augmentation is one of the best ways to improve deep learning performance. Traditional augmentation techniques that modify image brightness or spatial information are difficult to achieve great results. To overcome this, a generative adversarial network (GAN) technology that generates virtual data to increase deep learning performance has emerged. GAN can create realistic-looking fake images by competitive learning two networks, a generator that creates fakes and a discriminator that determines whether images are real or fake made by the generator. GAN is being used in computer vision, IT solutions, and medical imaging fields. It is essential to secure additional learning data to advance deep learning-based fault diagnosis solutions in the power industry where facilities are strictly maintained more than other industries. In this paper, we propose a method for generating power facility images using GAN and a strategy for improving performance when only used a small amount of data. Finally, we analyze the performance of the augmented image to see if it could be utilized for the deep learning-based diagnosis system or not.

*Keywords: Generative Adversarial Network, GAN, Transfer Learning, Visual Intelligence*

## I. Introduction

최근 딥러닝 학습 알고리즘과 하드웨어 인프라 환경 개선 등에 힘입어 영상 인식 기술과 인지기술이 비약적으로 발전함에 따라 컴퓨터 비전, 스마트 팩토리, 의료산업 등에서 시각 지능을 활용한 솔루션 개발이 활발히 진행 중이다. 전력산업에서도 배전·송전·발전 등 전 분야서 전력 품질 확보, 고장 예방, 운영관리비 절감을 위해 인공지능을 활용한 지능형 설비 감시 기술 및 고장·결함 자동진단 기술 개발에 지속적인 관심을 쏟고 있다. 배전 분야를 사례로 들면 전주에 부착된 수많은 배전 기자재를 일일이 인력을 통해 관리하는 것은 많은 시간과 비용이 발생하는 업무이기에 이를 개선하고자 광학카메라를 부착한 순시 차량을 활용하여 합성곱 신경망(Convolutional Neural Network, CNN) 기반의 배전 설비 인식·추적·결함을 진단하는 솔루션을 개발하였다 [1, 2].

딥러닝은 수많은 양의 데이터 속에서 대상 특징을 추출하고 대응되는 레이블을 학습하는 기법이다. 딥러닝 모델은 사전에 학습한 데이터 유형의 경우에는 성능이 우수하지만 반대의 경우에는 성능이 저하된다. 또한 특정 대상의 데이터가 소량이거나 대상들의 수량이나 비율이 불균등하면 과적합(OverFitting) 현상도 발생하여 정확도 문제가 발생한다. 실제로 딥러닝을 활용한 영상기반 전력 설비 결함 검출 기술개발에서도 가장 어려운 점이 발생 빈도가 낮은 특정 결함 학습데이터 확보이다. 이처럼 특정 결함에 대하여 학

습이 부족하면 딥러닝 성능은 낮아지게 된다. 일반적으로 딥러닝 모델 개선을 위한 가장 효과적인 방법은 데이터 확보이나 부족한 수량 확보를 위해 현장에서 결함 데이터를 추가로 얻기에는 상당한 물리적 시간이 소요되어 적기에 기술개발이 이루어지기 어렵기 때문에 학습데이터를 확보할 수 있는 다른 방안이 필요하다.

이처럼 데이터를 추가로 구하기 어려운 상황에서 딥러닝 성능을 높이려 데이터의 다양성을 학습 시키기 위한 방안 중에 하나가 데이터 증강(data augmentation) 기법이다. 과거에는 데이터 증강을 위해 영상의 색상, 공간 변경시키는 전통적인 방법과 필터를 이용하여 영상을 변형시키는 Image Processing 기법들이 사용되었다 [3]. 하지만 영상의 밝기 정보나 색상 정보 등을 변형하는 것은 원본의 기본속성과 크게 차이가 없기 때문에 큰 효과를 보긴 어렵다. 따라서 기존의 문제를 극복하기 위해 최근에는 가상의 데이터를 생성하여 학습성능을 높이는 Generative Adversarial Network(GAN) [4] 기반의 데이터 증강기법들이 소개되고 있다.

이에 본 연구에서는 GAN을 통해 가상의 전력 설비 이미지 생성 여부와 가상 이미지 품질 확인에 목적을 두고자 한다. 배전 설비 중 확보 수량이 상대적으로 부족한 특정 결함 이미지에 GAN 모델 및 전이학습(Transfer Learning)을 적용하여 가상의 전력 설비 이미지를 생성하였고, 전력 설비 복잡도, 학습 수량에 따른 가

## Article Information

Manuscript Received July 28, 2020, Accepted September 29, 2020, Published online December 30, 2021

The Authors are with KEPCO Research Institute, Korea Electric Power Corporation, 105 Munji-ro Yuseong-gu, Daejeon 34056, Republic of Korea.

Correspondence Author: Seungmin Jang (smjang82@kepco.co.kr)

ORCID: 0000-0002-2636-2881 (Seungmin Jang); ORCID: 0000-0002-0748-0495 (Seungwoo Son); ORCID: 0000-0003-2574-7592 (Bongsuck Kim)



This paper is an open access article licensed under a Creative Commons Attribution-NonCommercial-NoDerivatives 4.0 International Public License.

To view a copy of this license, visit <http://creativecommons.org/licenses/by-nc-nd/4.0>

This paper, color print of one or more figures in this paper, and/or supplementary information are available at <http://journal.kepco.co.kr>.




Fig.1. Generative Adversarial Network model

상 데이터 생성 성능을 분석하였다. 2장에서는 GAN, 전이학습의 개념을 소개한다. 3장에서는 전력 설비의 GAN 적용 효과 분석을 위한 실험 대상 및 방법을 기술하였다. 4장에서는 실험 결과를 정리하였고, 5장에서 결론으로 마무리한다

## II. 가상 데이터 생성을 위한 적용기술

### A. GAN 기반 데이터 증강기술

인공지능을 통해 현실에 존재하지 않는 새로운 데이터를 만들어 낼 수 있는 비지도 학습 모델 중 하나인 GAN은 원본 이미지와 유사한 이미지를 생성하는 생성기(Generator)와 원본 이미지와 생성된 이미지를 구분하는 판별기(Discriminator)를 경쟁 시켜 상호 간의 피드백을 통해 원본 이미지와 가까운 이가상의 이미지를 생성하는 기법이다. 이안 굿펠로우(Ian Goodfellow)가 2014년에 최초로 GAN을 소개한 후 다양한 후속 기법들이 연구되고 있다.

GAN의 원리 및 구조는 Fig.1과 같다. 이미지를 입력받아 구분하는 판별기는 실제 이미지와 가상 이미지를 입력으로 받아 입력 이미지가 진짜 이미지인지, 혹은 생성기에서 생성한 가상 이미지인지 구분하는 역할을 한다. 생성기와 판별기 상호 간의 피드백 학습이 완료되면 생성기만 활용하여 새로운 합성 이미지를 만들 수 있게 된다. 이렇게 만든 가상의 이미지를 통해 딥러닝 학습에 필요한 데이터 증강이 가능하다.

GAN은 주로 이미지 생성 목적으로 활용된다. 엔비디아는 수십만 장 사람의 사진을 학습 시켜 가상의 사람들의 사진을 무한으로 생성할 수 있는 기술을 발표하였다. 이를 통해 과거에는 일일이 포토샵 등을 이용해 작업해야 했던 일들을 자동으로 할 수 있게 되어 상기 기술을 기반으로 하는 다양한 어플리케이션이 만들어지고 있다. 또한 GAN은 영상 합성에도 활용이 되어 이슈가 되었다. 미국 워싱턴대학교 연구진은 오바마 전 대통령의 연설 영상을 활용하여 음성에 맞게 입 모양을 학습 시켜 GAN을 통해 실제와




Fig.2. Transferring GANs

판별하기 어려운 정도의 가상 영상을 만들어 내었다. 그리고 의료 산업 분야에서도 GAN에 대한 연구가 확대되고 있다. 의료영상 진단 분야에서 X-ray, CT 영상 등의 환자의 개인 정보 활용의 어려움을 겪고 있던 상황에서 가상의 영상을 통해 영상 확보 문제를 해소하고 있다.


전력산업에서도 GAN을 통한 데이터 생성기술은 활용도가 매우 높을 것으로 판단된다. 일반적으로 딥러닝 기반 결함진단 학습에 활용하는 전력 설비 영상 데이터는 대부분이 실외에서 촬영되었고, 고정된 카메라가 아닌 이동식 카메라에 의해 획득된 영상이기 때문에 데이터마다 다른 배경을 가지고 있고, 또한 빛 반사 현상으로 인한 색상 왜곡, 촬영 각도의 다양성 등 많은 변수가 존재하여 인공지능 학습이 어렵다. 또한, 특정 설비 결함의 경우 학습을 위한 최소 수량의 데이터 확보가 어려워 결함진단 모델 개발이 어렵고, 결함 간의 데이터 수의 차이로 인한 과적합(Overfitting)이 문제가 야기된다. GAN을 활용하여 다양한 속성과 특징을 가진 가상의 전력 설비 영상을 무한히 생성하게 된다면 상기 언급한 문제 해결과 함께 시각 지능 기반 결함진단 기술의 고도화가 가능할 것으로 기대된다.

### B. 전이학습(Transfer Learning)

앞서 소개한 GAN은 컴퓨터 비전, IT 솔루션 등 시각 지능을 활용한 광범위한 응용 분야에서 널리 사용 중이고 성능고도화를 위한 기법들이 개발되고 있다. 최근 발표된 GAN 기법들은 1024x1024 이상의 고해상도 처리도 가능하고 성능도 좋으나 많은 양의 훈련 데이터와 무거운 계산 리소스가 필요하여 범용적 사용이 제한된다. 이러한 한계를 극복하기 위해 메타 지식학습 [5,6], 미니배치 샘플링 [7], 잘 훈련된 모델에 대한 지식전달 등 [8] 많은 기술이 제안되었다. 이러한 방식 중 전이 학습 [9]은 제한된 리소스와 부족한 학습데이터 셋(Training Set) 상황에서 모델을 훈련하는 가장 좋은 방법이다 [10]. 전이학습은 사전에 다른 문제에서



(a)



(b)



(c)

Fig. 3. GAN 학습에 활용된 배전 설비 데이터 샘플. (a) 변압기 누유/부식. (b) LP애자 박리/파손. (c) COS퓨즈 석면 노출

훈련(Training)된 고성능 모델을 비슷한 모델이 있을 때 사전 훈련된 하위층(lower layer)을 그대로 재활용하여 학습 속도를 빠르게 하는 지도학습 기법이다. 일반적으로 전이학습을 활용하면 학습에 드는 시간을 크게 줄일 수 있고 훈련에 필요한 학습데이터도 매우 적다 [11].

전이학습은 딥러닝 학습에 필요한 학습데이터가 적은 경우에 더 큰 효과를 발휘한다. 기본적으로 고성능의 GAN 모델 개발을 위해선 학습을 위해 적게는 10k에서 100k까지 데이터가 필요하지만, 학습을 위한 데이터가 확보되지 않은 경우 Fig.2와 같이 가상의 사람 얼굴을 생성하는 stylegan2-FFHQ(Flickr-Faces-HQ Dataset)모델 등과 같은 사전에 잘 학습된 모델의 생성기와 판별기를 가져와서 그대로 학습에 재사용하면 더 좋은 결과를 얻을 수 있게 된다 [10].

### III. 실험대상 및 방법

#### A. 실험대상 및 분류

배전 기자재 중 확보된 결함 데이터 수량이 300개 미만으로 상대적으로 학습데이터 수가 적은 변압기 누유/부식, LP애자 박리/파손, COS퓨즈 석면 노출 결함을 대상으로 하였다.

#### B. 실험 방법 및 평가

GAN 모델은 생성기와 판별기의 구성과 사용 목적, 모델링 방법에 따라 다양하나 본 연구에서는 데이터 셋이 소량일 때 성능을 낼 수 있는 유용한 모델인 StyleGan2-Ada [12]를 이용하였다. 추가적인 성능 향상과 학습시간 단축을 위해 전이학습 알고리즘을 추가하였다. 개발환경은 딥러닝 프레임워크인 Tensorflow 1.15.2 버전과 Python 3.6 언어 기반으로 구현하였다.

##### 1) 실험 방법

첫 번째 실험은 GAN 성능에 학습데이터 수가 미치는 효과를 알아보기 위해 설비별로 100, 200, 201~300개의 학습데이터를 확보하여 가상 이미지를 생성하는 StyleGan2-ADA(이하 A 모델)로 학습하고 성능을 비교 평가하였다. 두 번째 실험은 전이학습의 효과를 알아보기 위해 사전에 학습된 stylegan2-FFHQ 모델(가상의 사람 얼굴을 생성하는 GAN 모델)을 전이 학습한 B 모델(base:StyleGan2-ADA with Transfer Learning)을 구현하고 효과를 분석하였다. 이때, 모든 실험은 Google의 상용 GPU 서버인 Google Colaboratory 내 Tesla V100을 활용하여 500회 학습을 수행하였다. 입력 이미지의 해상도는 512x512, 출력 이미지의 해상도는 256x256으로 동일하였으며, 실험에 사용된 결함 이미지 샘플은 Fig.3과 같다.

##### 2) 평가 방법

학습된 GAN 모델을 통해 생성된 이미지가 실제 이미지와 얼마나 유사한지 정량적으로 평가하는 기법인 FID(Fréchet inception distance) score를 사용하였다. FID 는 GAN을 사용해 생성한 영상의 집합과 실제 클래스 데이터의 분포 거리를 계산해 점수화한 지표로 낮을 값일수록 유사한 영상임을 나타낸다. 현재 GAN을 평가하는 여러 가지 방법 중 가장 사람의 시각과 비슷하다는 평가를 받고 있다. 각 실험 목적 달성을 위해 GAN 모델 학습 단계별로 평균과 공분산으로 FID score를 계산하여 결과를 비교분석 하였다.

TABLE 1  
학습 데이터 수량과 GAN모델별 FID score (500 iterations)

Data	Number of Data (EA)	Best FID score	
		A 모델 (base:StyleGan2-ADA)	B 모델 (base:StyleGan2-ADA with Transfer Learning)
Transformer (변압기)	100	188.4729	124.5788
	200	156.5289	90.5625
	261	141.5795	90.7512
Line-Polymer insulator (LP애자)	100	171.2137	163.0498
	200	168.8284	121.4546
	295	196.2260	148.1181
Cutout Switch (COS)	100	204.6439	131.2884
	200	210.4004	121.4424
	224	171.0388	104.6012

#### IV. 실험 결과

##### A. 정량적 평가

공정한 실험 결과를 도출하기 위해 Learning rate, Batch size, 손실 함수, 학습 횟수 등 Hyper-parameter와 네트워크 구조 등의 학습구조를 동일하게 설계하여 실험을 진행하였다. 전력 설비 결합 종류에 따른 학습 수량별 FID 결과는 TABLE 1과 같다.

실험 결과에 따르면 학습 데이터 수량이 많을수록 A 모델과 전이학습을 적용한 B 모델 두 조건 전부 성능이 좋음을 알 수 있다. 또한 전이학습을 적용하면 설비 종류와 학습데이터 수량과는 무관하게 모든 조건에서 성능이 우수함을 나타내었다. LP애자의 경우 평균적으로 약 19% 정도 FID score가 개선됐으며, COS와 변압기의 경우 평균적으로 약 37%씩 FID score가 개선되었다. 특히 COS 데이터 200장, 224장과 변압기 200장의 경우 전이학습을 적용하기 전보다 약 40% FID score가 개선되었다. 이는 설비구조 특성상 나무, 구름 등 배경을 많이 포함하고 있는 COS의 학습데이터가 다른 학습데이터에 비해 데이터 분포의 복잡성이 높아 전이학습의 효과가 더 잘 드러난 것으로 분석된다.

Fig.4와 Fig.5는 A 모델과 B 모델의 Training 반복 횟수에 따른 FID score 추이를 보여준다(학습데이터 200장 기준). 두 모델 간 초기 FID score는 약 50점 정도 차이가 발생하였다. Fig.4에서 A 모델의 경우 모든 데이터에 대해 학습 초기에 최초의 FID score보다 증가하였다가 감소하는 경향을 보인다. 반면, Fig.5의 B 모델의 경우 최초의 FID score보다 낮은 값을 가지며 점차 감소하는 경향을 보였다. 이는 임의로 초기 데이터 분포를 선정하는 Model A와는 달리 전이학습 적용한 B 모델은 사전에 학습된 네트워크와 데이터 분포를 통해 빠르게 학습하기 때문으로 분석된다.




Fig.4. A 모델(StyleGan2-ADA)의 학습횟수에 따른 FID score 추이




Fig.5. B 모델(StyleGan2-ADA with Transfer Learning)의 학습횟수에 따른 FID score 추이

##### B. 정성적 평가

실험을 통해 A 모델과 B 모델로부터 생성된 전력 설비 가상 결합 데이터를 설비별로 각각 Fig.6과 Fig.7에 나타내었다. Fig.6의 A 모델로 생성된 가상 결합 데이터를 분석해보면 (a)변압기 누유/부식 이미지의 경우 주변 선로나 전주 등이 왜곡되고 끊기는 모습이 보인다. (b)LP애자 박리/파손 이미지의 경우 마찬가지로 애자의 구조가 정상적으로 표현되었으나 철타경관, 선로 등의 왜곡이 존재하며, 박리 및 파손된 모습이 잘 생성되지 않았다. (c)COS퓨즈 석면 노출 이미지의 경우 다른 설비 이미지에 비해 구조가 왜곡되어 생성되었다. A 모델에 전이학습을 적용한 B 모델의 경우(Fig.7) (a)변압기 누유/부식 이미지는 전이학습을 적용하기 전보다 전선이 끊어지거나 주변 설비들이 왜곡되는 현상이 많이 완화되는 등 선명한 결과를 보였다. (b)LP애자 박리/파손 이미지의 경우 전이학습



(a)



(a)



(b)



(b)



(c)



(c)

Fig.6. A 모델(StyleGan2-ADA)로 생성된 가상 전력 설비 결함 이미지. (a) 변압기 누유/부식 결함 이미지. (b) LP애자 박리/파손 결함 이미지. (c) COS퓨즈 석면노출 결함 이미지.

Fig.7. B 모델(StyleGan2-ADA with Transfer Learning)로 생성된 가상 전력 설비 결함 이미지. (a) 변압기 누유/부식 결함 이미지. (b) LP애자 박리/파손 결함 이미지. (c) COS퓨즈 석면노출 결함 이미지.

적용 전 모델과 유사하게 왜곡이 존재하지만, 기본모델과 달리 LP 애자 하단부가 박리된 모습이 구현되었다. 마지막으로 (c)COS퓨즈 석면 노출 이미지의 경우 기본 모델대비 왜곡이 많이 개선되어 결합애자, 퓨즈, 접속부 등 COS 구성 설비의 모습이 비교적 선명하게 구현되었다. 실험 결과로 미루어볼 때 Fine Tuning을 통한 추가적인 성능개선 및 10k 이상의 충분한 학습이 이루어지면 전력 설비의 경우에도 완성도 높은 가상 결함 데이터 생성을 통해 딥러닝 학습데이터로 활용할 수 있을 것으로 판단된다.

## V. CONCLUSION

본 논문에서는 GAN 기반 전력 설비 가상 결함 데이터 증강 가능성을 확인하기 위해 배전 설비 중 확보 수량이 상대적으로 부족한 특정 결함을 대상으로 GAN 알고리즘 및 전이학습을 적용하여 가상의 전력 설비 이미지를 생성하였고 정량적, 정성적 결과 분석을 통해 가상 데이터 생성 여부와 성능 확인을 하였다. 실험 결과 학습데이터 수량이 매우 적은 조건에서도 전이학습을 활용하면 사전에 학습한 네트워크를 기반으로 더 빠르고 정확한 학습을 수

행하고, 이를 통해 실제와 유사한 가상의 데이터를 생성할 수 있음을 확인하였다. 추가로 학습데이터 수량이 GAN 모델에 미치는 영향을 분석해볼 때 일반적으로 학습데이터 수가 많을 경우 가상데이터 생성 성능이 좋게 나왔지만 LP애자의 경우엔 특정 수량에서만 성능이 가장 높게 나타났다. 이는 단순히 많은 학습데이터 활용보다는 데이터 선별을 통한 양질의 데이터 활용이 더욱 중요하다는 시사점을 남긴다. 본연구결과로 미루어볼 때 전이학습 이후 Fine Tuning을 통한 추가적인 성능개선 및 10k 이상의 충분한 학습이 이루어지면 비교적 복잡한 전력 설비 영상도 완성도 높은 가상 결합 데이터 생성이 가능할 것으로 생각된다. 향후 딥러닝 학습에 활용될 수 있는 고품질의 가상 결합 데이터 생성을 위해 GAN 모델 개선 및 보완할 계획이다.

## ACKNOWLEDGEMENT

This research was supported by Korea Electric Power Corporation under Grant R21IA02.

## REFERENCES

- [1] 이동엽, 김준오, 윤정용, 신동열, 최민희 (2017). 인공지능 기반 배전 폴리머 현수애자 진단 장비 개발. 대한전기학회 학술대회 논문집, 1547-1548.
- [2] 이동엽, 김준오, 윤정용, 최민희 (2017). Deep Learning을 활용한 배전 기자재 영상 진단 알고리즘 개발. 대한전기학회 학술대회 논문집, 1504-1505.
- [3] Shorten, C., Khoshgoftaar, T.M. A survey on Image Data Augmentation for Deep Learning. J Big Data 6, 60 (2019). <https://doi.org/10.1186/s40537-019-0197-0>.
- [4] Goodfellow I, Pouget-Abadie J, Mirza M, Xu B, Warde-Farley D, Ozair S, et al. Generative adversarial nets. Adv Neural Inf Process Syst 2014:2672-2680.
- [5] M.-Y. Liu, X. Huang, A. Mallya, T. Karras, T. Aila, J. Lehtinen, and J. Kautz. Few-shot unsupervised image-to-image translation. In ICCV, 2019.
- [6] E. Zakharov, A. Shysheya, E. Burkov, and V. Lempitsky. Few-shot adversarial learning of realistic neural talking head models. arXiv preprint arXiv:1905.08233, 2019.
- [7] S. Sinha, H. Zhang, A. Goyal, Y. Bengio, H. Larochelle, and A. Odena. Small-gan: Speeding up gan training using coresets. arXiv preprint arXiv:1910.13540, 2019.
- [8] Y. Wang, A. Gonzalez-Garcia, D. Berga, L. Herranz, F. S. Khan, and J. van de Weijer. Minegan: effective knowledge transfer from gans to target domains with few images. arXiv preprint arXiv:1912.05270, 2019.
- [9] J. Yosinski, J. Clune, Y. Bengio, and H. Lipson. How transferable are features in deep neural networks? In NeurIPS, 2014.
- [10] Sangwoo Mo, Minsu Cho, and Jinwoo Shin. Freeze the Discriminator: a Simple Baseline for Fine-Tuning GANs. arXiv:2002.10964v2, 2020.
- [11] Transfer Learning, Lisa Torrey and Jude Shavlik, Handbook of Research on Machine Learning Applications, IGI Global, 2009.
- [12] Tero Karras, Miika Aittala, Janne Hellsten, Samuli Laine, Jaakko Lehtinen, and Timo Aila. Training Generative Adversarial Networks with Limited Data. arXiv:2006.06676v2 [cs.CV] 7 Oct 2020.