



자기애자의 유지 관리를 위한 CNN 기법을 이용한 이미지 분석

최인혁¹, 신구용¹, 구자빈¹, 손주암¹, 임대연², 오탈근^{2,3} , 윤영근² 

¹ 한국전력공사 전력연구원

² 인천대학교 안전공학과

³ 인천대학교 공학기술연구소

Image Analysis by CNN Technique for Maintenance of Porcelain Insulator

In-Hyuk Choi¹, Koo-Yong Shin¹, Ja-Bin Koo¹, Ju-Am Son¹, Dae-Yeon Lim², Tae-Keun Oh^{2,3}, and Young-Geun Yoon²

¹ Korea Electric Power Corporation (KEPCO) Research Institute, Daejeon 34056, Korea

² Department of Safety Engineering, Incheon National University, Incheon 22012, Korea

³ Research Institute for Engineering and Technology, Incheon National University, Incheon 22012, Korea

(Received February 6, 2020; Revised February 17, 2020; Accepted February 19, 2020)

Abstract: This study examines the feasibility of the image deep learning method using convolution neural networks (CNNs) to maintain a porcelain insulator. Data augmentation is performed to prevent over-fitting, and the classification performance is evaluated by training the age, material, region, and pollution level of the insulator using image data in which the background and labelling are removed. Based on the results, it was difficult to predict the age, but it was possible to classify 76% of the materials, 60% of the pollution level, and more than 90% of the regions. From the results of this study, we identified the potential and limitations of the CNN classification for the four groups currently classified. However, it was possible to detect discoloration of the porcelain insulator resulting from physical, chemical, and climatic factors. Based on this, it will be possible to estimate the corrosion of the cap and discoloration of the porcelain caused by environmental deterioration, abnormal voltage, and lightning.

Keywords: Convolution neural network, Image deep learning, Porcelain insulator, Maintenance, Augmentation

1. 서론

전력의 공급 및 수요는 기계 시스템 및 산업의 자동화, 디지털 사회와 같은 4차 산업혁명의 발달과 지구 온난화, 전기 자동차 등의 환경적인 요인으로 인해 현대에 급증하고 있다. 이로 인해 많은 양의 전력을 안정적으로 공급하기 위해서 송전선로에 높은 수준의 절

연이 필요하다. 자기애자는 송전탑과 송전선을 물리적으로 고정시키고, 절연을 통해 송전선로의 안전성을 유지하는 핵심적인 요소이다 [1].

이러한 자기애자는 크게 설치연도(경년연수), 소재, 지역, 해안가로부터의 거리에 따른 오손등급 등을 레이블화하여 관리하고 있다. 현재 자기애자는 사람에 의해 초기에 부착되었던 레이블을 확인하는 방식으로 관리되고 있다. 그러나 이러한 방식은 초기에 레이블을 부착하는 과정에서 사람의 실수에 의한 오류가 발생할 수 있다는 문제점이 있고, 송전탑에서 사용 중 레이블이 떨어지거나 벗겨진 경우에는 이를 확인할 수 있는 방법이 전무한 실정이다. 또한, 자기애자는 다양한 환경에서 사용되기 때문에 서로 다른 환경적 요인으로

✉ Tae-Keun Oh; tkoh@inu.ac.kr

Young-Geun Yoon; y_young_geun@naver.com

인한 금구의 부식 및 자기부의 변색, 깨짐 등이 발생되며 [2], 이에 따라 예상치 못한 사고를 유발할 수 있고 이러한 문제로 발생하는 사고는 막대한 손실을 동반하기 때문에 이를 빠르고 편하게 관리하기 위한 기술의 적용이 필요하다.

수 년 전부터 딥러닝(deep learning)과 기계 학습(machine learning)에 관한 관심이 증가하고 있으며 특히 딥러닝은 기계 학습에 포함되는 방법으로 컴퓨터가 스스로 데이터를 학습하는 네트워크 모델로 텍스트, 이미지 등을 분류하고 학습 및 예측하는 방법이다. 이러한 발전은 빅데이터의 활용, 고성능 GPU 같은 하드웨어의 발전과 인식알고리즘의 개발에 따라 활용성 높은 기술로 발전되었다 [3]. 이러한 시점에서 LeCun에 의해 초기 CNN(convolutional neural network) 모델인 LeNet이 개발되었으며, 최근에는 ILSVRC (imageNet large scale visual recognition challenge)가 개최되면서 수많은 이미지 분석 알고리즘이 개발되고 있다 [4]. 이미지 분석 알고리즘 중에서 AlexNet은 얇은 구조를 가짐에도 손실률을 10% 정도 낮추는 성과를 나타냈으며 [5], 다음 단계로 깊은 구조를 가진 알고리즘들이 연구되고 있다. CNN 분석은 다양한 분야에서 성공적으로 적용됨으로써 산업 전반에서 널리 이용되고 있다 [3].

따라서 본 연구에서는 자기애자를 유지 관리함에 있어 인적 오류에 의한 관리상의 미비점 및 다양한 환경에 의해 금구 및 자기부에 노화 및 열화가 발생한 자기애자의 이미지를 사용하여 설치연도, 소재, 지역, 오손 등급의 분류 및 예측을 통해 유지 관리에 효율성을 높이고자 하며, 이를 위해 합성곱 신경망 중에서 CNN의 inception V3를 사용한 딥러닝 기법을 적용하고자 한다.

2 실험 방법

2.1 Convolution neural network (CNN)

CNN은 인공지능의 한 종류로서 기계 학습의 세부 범주에 속하는 딥러닝 심층 신경망(deep neural network)이다. 그림 1은 CNN의 구조를 나타내며, CNN은 일반적인 신경망과 동일하게 입력층(input layer)과 출력층(output layer) 사이에 수많은 은닉층(hidden layer)을 포함한다 [3]. 은닉층은 대체로 필터에 의한 convolution, batch normalization, activation 및 pooling으로 구성되어 있다. Convolution은 특정한 크기의 필터를 입력값에 대해 일정한 간격으로 행렬에 대해 곱을 수행하는 것을 의미한다. 그 후, 출력층인 feature map은 batch normalization, ReLU층을 거치고 pooling을 통해 최소의 파라미터로 도드라진 특징만을 추출하는 과정을 가진다. 다음으로, 수많은 feature map은 마지막에 완전연결계층(fully connected layer)에서 일렬로 배열되어 분류하고자 하는 클래스의 개수만큼 출력하는 구조이다. 이러한 CNN은 LeNet으로 시작하여 다양한 모델들이 발표되며, 그중에서 ResNet (residual network)과 InceptionNet (inception network)의 연구가 활발히 진행되고 있다 [6,7].

ResNet은 224×224 해상도의 이미지를 입력하여 identity path를 사용하여 잔차학습(residual learning)을 통해 저차원에서 특징만을 뽑아 고차원 이미지로 복원하는 방법을 사용한다. 이러한 특징을 통해 기울기 소실, 과적합(over-fitting) 등의 문제를 방지한다는 장점이 있다. 그러나 이러한 구조는 residual에 집중하여 layer를

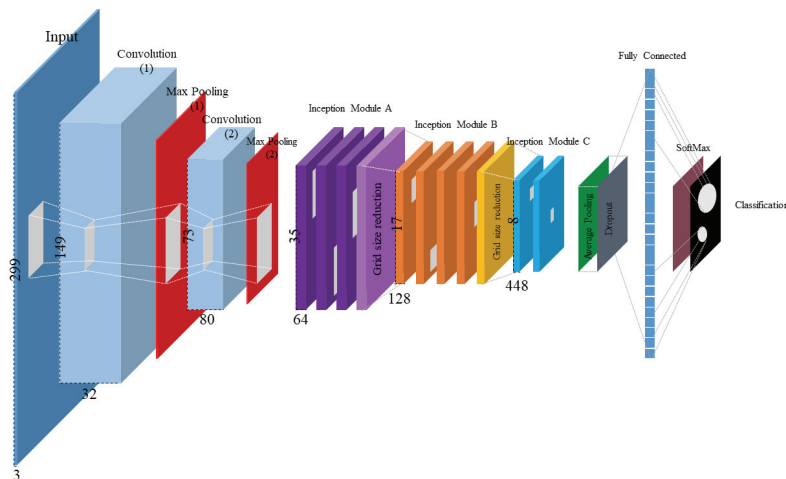


Fig. 1. Detailed structure of inception V3 model in CNN.

쌓기 때문에 좋은 성능을 보이기 위해서는 상당한 수의 layer가 필요하다. 따라서 InceptionNet보다 학습 연산에 있어서 낮은 효율을 나타내며, 높은 해상도의 경우 중복되는 feature가 생기는 문제점이 제기된 바 있었고, 저해상도의 이미지를 사용하여 저차원에서 특징을 추출하기 어려운 경우에는 학습이 제한될 수 있다.

InceptionNet은 2014년 ILSVRC에서 우수한 성능으로 1등을 차지한 GoogLeNet에서 거듭 발전된 알고리즘이다. InceptionNet은 299×299 해상도의 이미지를 입력하여 일반적인 과정을 거친 후 inception module에서 다양한 필터의 크기, 횟수의 병렬 연산으로 convolution을 수행한다. Inception module은 외부 노드 간의 연결을 최소화하고 내부의 4가지 convolution을 병렬로 깊게 연산시켜 대용량 학습과정을 효율적으로 처리하여 연산량, 과적합, 기울기 소실 등의 문제의 해결을 통해 ResNet의 문제점을 보완하였다는 장점을 가지고 있다.

본 연구에서는 inception V3를 사용하여 전이학습(transfer learning)을 사용하여 [8], 자기애자의 4가지 그룹에 대한 분석을 통해 한계점을 도출하고 이미지 딥러닝의 적용 가능성을 분석하였다.

2.2 데이터 세트 구축

본 연구에서는 자기애자의 다양한 분류를 위한 CNN 학습 및 분류 데이터의 수집은 실제 154 kV 송전탑에 설치되어 사용된 애자를 수거하여 사진 촬영을 통해 자기애자의 이미지를 수집하였다. 분류하고자 하는 자기애자 이미지 데이터는 표 1과 같으며, 경년에 따라 1969~1979년 사이의 7개의 그룹으로 구성되었으며, 소재는 크리스토팔라이트 및 알루미늄 2가지 그룹으로 구분되며, 오손등급의 경우 청정, A, B, C, D 5가지로 구분하였고, 지역은 강릉, 경남 등 총 8개의 지역으로 구분하여 기본 데이터로 사용하였다.

자기애자 이미지는 그림 2와 같이 총 3단계로 구분하여 분석되었다. 첫 번째, 각 지역에서 촬영된 자기애자의 이미지 원본을 사용하였으며, 두 번째는 자기애자 시험편이 각기 다른 장소에서 수집 및 촬영되었기 때문에 촬영한 이미지의 배경이 분석에 영향을 미치는 것을 고려하여 자기애자 이미지에서 배경을 제거하고 분석하였다. 배경색의 제거는 MATLAB 2019a image toolbox를 사용하여, 자기의 색과 배경색의 경계를 도출하고 배경 부분을 0으로 치환하는 방식으로 배경을 제거하였다. 세 번째는 배경을 제거한 이미지에서 특징 추출 시 글자 인식을 방지하기 위하여 레이블 부분을

Table 1. Categorization of images according to age, materials, pollution level and region.

	Years of age	Materials	Pollution level	Region
The number of images	100	600	100	100
The number of classes	8	2	5	8
The number of total image	800	1,200	500	800




Fig. 2. Three steps of image data classification.



Fig. 3. The augmentation against over-fitting.

제거한 이미지로 처리하였다. 이와 같은 다양한 분류를 통해 경년연수, 소재, 오손등급, 지역을 예측하고 각각의 클래스에 대한 예측 정확도 분석 및 이미지에 대한 특성분석을 진행하였다.

또한, CNN 학습의 과적합을 방지하고 정확도를 높이기 위해 그림 3과 같이 이미지 데이터에 대해 랜덤으로 -20~20°의 범위에서 회전 및 -3~3 픽셀 범위에서 좌우로 이동하여 데이터의 다양성을 증가시키는 방법이 적용되었다. 이와 같은 다양한 학습 데이터 구축을 통해 경년연수, 소재, 오손등급, 지역을 예측하고 각각의 클래스에 대한 예측 정확도 분석 및 이미지에 대한 특성 분석을 진행하였다.

3. 결과 및 고찰

3.1 CNN 분석 데이터 세트의 최적화

먼저, 자기애자 이미지에 대한 4가지 그룹의 학습 및 분류를 위해 최적의 데이터 세트를 구축하기 위한 분석을 진행하였다. 원본 이미지, 배경을 제거한 이미지, 배경을 제거한 후 레이블 부분을 제거한 이미지를 데이터 세트로 구축한 후 동일한 CNN 조건에서 분석을 진행하였고, 이에 대해 대표적으로 원본 이미지에 대한 예측 결과를 그림 4에 도식하였고, confusion matrix를 사용하여 그림 2의 3가지 조건에 대한 예측결과를 표 2에 제시하였다.

원본 이미지에 대한 예측 결과, 1975년이 93%의 예측률로 가장 높게 나타났고, 1973년이 83%, 1970년이 70%의 예측률을 가지는 것으로 분석되었으며, 1969년의 경우에는 16%로 가장 정확도가 낮은 것으로 분석되었다. 배경을 제거한 이미지의 예측 결과, 1975년이 100%의 정확도를 가지는 것으로 분석되었으며, 1969년 데이터는 36%로 가장 낮은 예측률을 보였지만, 원

Real Class	1968	18	3	1	3	1	2		2	
	1969	2	5	5	1	3	2	4	8	
	1970	1		21	4	1	2		1	
	1973	1		1	25		1	1	1	
	1975				1	28			1	
	1976	7		3	2		16		2	
	1977	5	1		2		2	15	5	
	1979	1	1		1	2		8	17	
			1968	1969	1970	1973	1975	1976	1977	1979
			Predicted Class							

Fig. 4. Confusion matrix for original images using inception V3.

Table 2. CNN prediction results for original, background removed and label removed images.

	Original	Background removed	Background removed & label removed
1968	60%	43%	60%
1969	16%	36%	13%
1970	70%	46%	86%
1973	83%	56%	56%
1975	93%	100%	93%
1976	53%	50%	46%
1977	50%	66%	33%
1979	56%	63%	56%



Fig. 5. Comparison of background color for images according to years of age.

본의 결과와 비교하였을 때 예측률이 일정 수준 상승한 것으로 나타났다. 배경 및 레이블을 제거한 이미지의 예측 결과, 1975년이 93%의 정확도로 분석되었으며, 1969년 데이터는 13%로 예측률이 하락하였고, 배경 제거에서 예측률이 하락하였던 1970년 데이터의 경우 86%로 예측정확도가 증가하는 것으로 분석되었다. 경년연수 분석 결과 원본, 배경 제거, 레이블제거 순으로 분류 정확도가 낮아지는 경향을 보였다. 경년연수를 분석한 결과 원본, 배경 제거, 레이블제거 순으로 분류 정확도가 낮아지는 경향을 보였다.

그림 5는 예측률의 변동이 아주 크거나 거의 없는 4가지 경년에 대한 이미지이며, 같은 경년에 대해서 배경의 밝기, 오염도 등은 유사하였고, 레이블의 위치는 다양한 방향에 걸쳐져 있기 때문에 배경 및 레이블이 CNN의 분류성능에 일정 비율 영향을 미치는 것으로 판단된다. 따라서 4가지 그룹에 대한 분석을 위해 배경 및 레이블을 제거한 데이터가 활용되었다.

3.2 4가지 그룹에 대한 CNN 예측 결과 분석

배경 및 레이블이 제거된 이미지를 사용하여 그림 4와 같은 방식으로 4개에 그룹에 대한 분석을 진행하였고, 실제 클래스에 대한 예측 결과를 그림 6에 도식하였다. 그림 6(a)는 경년에 대한 예측 결과이며, 그림 6(b)는 2가지 소재, 그림 6(c)는 8개의 지역에 대한 예측결과로 R1 (강릉), R2 (경남), R3 (구리), R4 (군산), R5 (대구 경북), R6 (대전), R7 (부산, 울산), R8 (순천)으로 구분하였으며, 그림 6(d)는 오손등급에 대한 예측결과를 도식하였으며, 오손등급 A~D 및 E (청정)으로 구분하여 총 5가지에 대한 예측 결과를 의미한다.

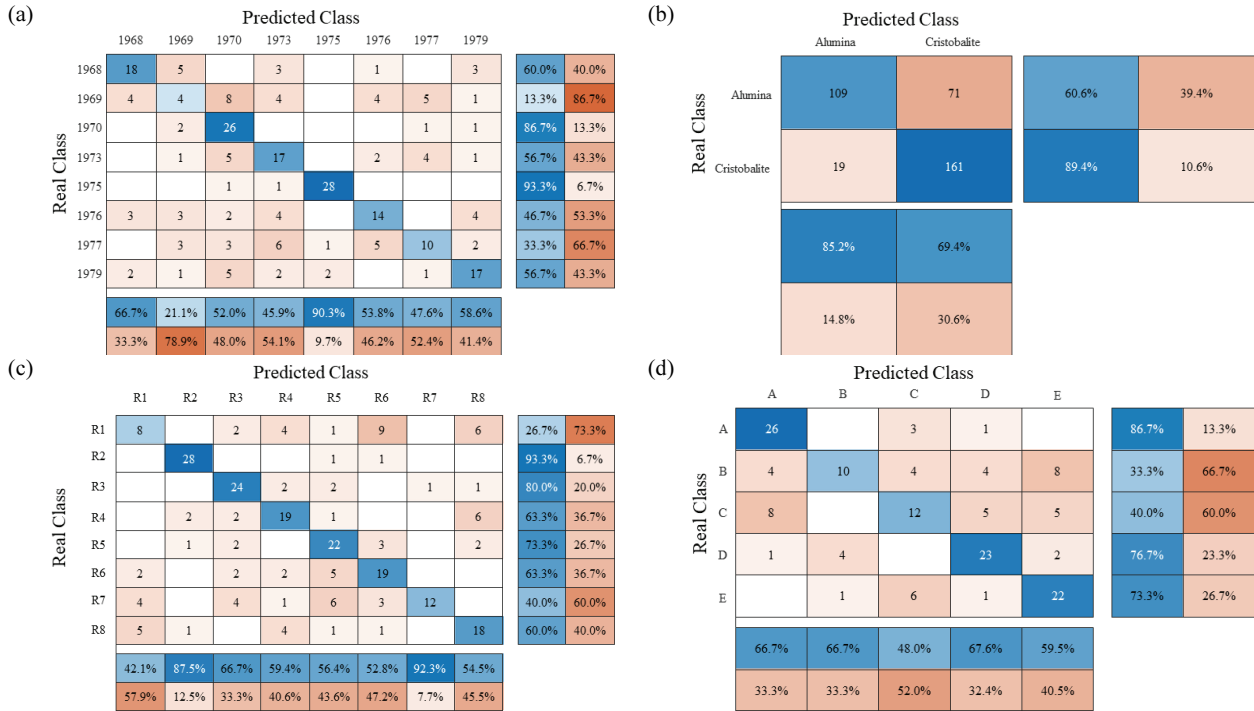


Fig. 6. Confusion matrix through CNN prediction for four groups. (a) Confusion matrix for prediction of years of age, (b) confusion matrix for prediction of material types, (c) confusion matrix for prediction of regions, and (d) confusion matrix for prediction of pollution level.

일반적으로 구분하고자 하는 데이터의 비율이 비슷하고 2개의 클래스에 대한 분석을 진행하는 경우에는 confusion matrix에서 정확도(accuracy)를 사용하여 모델의 성능을 분류한다. 하지만 본 연구의 데이터는 그룹에 따라 클래스가 2~8개이기 때문에 정확도만을 사용하여 모델을 평가하는 것은 정확성 검증에 어려움이 있다. 따라서 F1 score를 구하여 분석을 진행하였다. 각 클래스에 대해 TP (true positive)는 올바른 것에 대한 올바른 예측이고, FP (false positive)는 올바른 것에 대한 잘못된 예측이다. FN (false negative)은 잘못된 것에 대한 올바른 예측이다. 각 클래스의 TP 및 FP에 대해 식 (1)을 사용하여 정밀도를 계산하고, 각 클래스의 TP 및 FN에 대해 식 (2)를 사용하여 재현율을 계산할 수 있다.

$$Precision = TP / (TP + FP) \quad (1)$$

$$Recall = TP / (TP + FN) \quad (2)$$

각각의 클래스에서 계산된 정밀도를 P(A)~P(N), 재현율을 R(A)~R(N)으로 정의하고 식 (3) 및 (4)를 사용하여 정밀도 및 재현율의 평균을 구하고, 식 (5)를 사용

하여 F1 score를 계산할 수 있다. 여기서, F1 score는 정밀도와 재현율의 조화 평균이다.

$$Average Precision = \{P(A) + P(B) + \dots + P(N)\} / N \quad (3)$$

$$Average Recall = \{R(A) + R(B) + \dots + R(N)\} / N \quad (4)$$

$$F1 Score = 2 \times \frac{Average Precision \times Average Recall}{Average Precision + Average Recall} \quad (5)$$

그림 6(a)의 경년연수는 F1 score가 0.55로 가장 낮은 수치로 나타났다. 자기애자는 다양한 환경에서 사용되어 캡의 부식 및 자기부의 그을림이 발생할 수 있기 때문에 외관의 이미지 분석만을 통해서 경년연수를 예측하는 것은 어려운 것으로 사료된다. 그림 6(b)의 소재는 F1 score가 0.76으로 산출되었으며, 알루미늄이 크리스토팔라이트로 예측되는 경우가 많았기 때문에 소재별 적합한 특징의 추출이 어렵다는 것을 의미하며, 이미지 딥러닝을 활용하여 소재를 구분하는 것은 적합하지 않은 것으로 판단된다. 그림 6(c)의 지역은 F1 score가 0.63으로 산출되어 낮은 것으로 분석되었지만, 특정 지역인 경남 지역의 경우 93%로 높은 예

측 정확도를 보였으며, 구리 지역의 경우 80% 이상으로 예측되었다. 다른 지역과 비교하였을 때 경남 지역은 주변에 공장이 많이 있으며, 구리 지역은 공장이 거의 없는 청정지역이라는 차이점이 있다. 이에 따라 자기애자가 사용되는 지역의 특성에 따라 금구의 부식 및 자기부의 그을림 등 외관의 차이가 발생하며, 이러한 외관의 변화는 이미지 분석을 통해 구분이 가능한 것으로 판단된다. 그림 6(d)의 오손등급은 F1 score는 0.61로 산출되었으며, A등급의 경우 86%, D등급 76%, 청정 73%로 일정수준 이상의 예측률을 보였다. 그러나 B, C 등급의 경우 30% 정도의 예측률을 보이며, 해당 클래스에 대한 예측을 거의 하지 못하는 것으로 분석되었다.

자기애자의 외관 이미지를 활용하여 이미지 분석을 진행한 결과 외관의 상태에 영향을 미치는 다양한 조건 중에 지역적인 요인에 의해 발생하는 차이가 가장 큰 것으로 판단되며, 지역별로 물리적·화학적·기후학적 환경이 다르기 때문에 지역별로 딥러닝 결과를 활용해야 할 필요가 있다고 사료된다.

4. 결론

본 연구에서는 CNN 방법 중 inception V3 모델을 사용하여 자기애자의 경년연수, 소재, 지역, 오손등급에 대해 학습하고 예측 및 분류하기 위한 이미지 딥러닝 방법을 적용하였다. 온전히 자기애자의 외관에 대해서만 학습하기 위해 원본, 배경 제거, 레이블제거 총 3가지 이미지 데이터를 구축 및 분석하였다. 또한, 랜덤으로 이미지를 회전시키고 픽셀을 좌우로 이동시킨 데이터를 사용함으로써 CNN 학습의 과적합을 방지하였다.

- 1) 원본, 배경 제거, 레이블 제거에 대한 CNN의 분석 결과 분류 정확도가 점차 낮아지는 결과를 통해 배경 및 레이블이 분류 성능에 영향을 미치는 것으로 판단된다. 따라서 실제 자기애자의 외관에 대한 분류를 위해서는 배경 및 레이블을 제거하는 방식을 적용하는 것이 가장 현실성이 높은 것으로 사료된다.
- 2) 배경 및 레이블 제거 데이터를 사용한 경년연수는 가장 낮은 F1 score 값을 가지며, 예측이 어려운 것으로 분석되었고, 소재의 경우 F1 score는 0.76으로 가장 높았지만 알루미늄을 크리스토티

발라이트로 예측하는 비율이 높았으며, 지역의 경우 경남 및 구리 지역과 같이 육안으로 차이가 식별되는 경우에는 높은 정확도로 구분되는 것을 확인하였다. 오손등급의 경우 A, D, E 등급은 B, C 등급보다 비교적 높은 정확도로 구분되는 것이 확인되었다.

본 연구는 자기애자의 외관 촬영 이미지 분석을 통해 현재 유지 관리를 위해 구분하고 있는 경년연수, 소재, 지역, 오손등급에 대해서 분류를 진행하였고, 이미지 딥러닝 방법 적용의 한계점 및 특정 조건에서의 활용 가능성을 확인하였다. 이러한 결과는 향후 환경적 열화, 이상전압, 낙뢰 등에 의해 외관 상태가 노후화 및 손상된 경우 자기애자의 유지 관리에 유의미하게 활용될 수 있을 것으로 판단된다.

ORCID

Tae-Keun Oh

<https://orcid.org/0000-0003-3848-6248>

Young-Geun Yoon

<https://orcid.org/0000-0002-2846-9332>

REFERENCES

- [1] G. H. Vaillancourt, J. P. Bellerive, M. St-Jean, and C. Jean, *IEEE Trans. Power Del.*, **9**, 208 (1994). [DOI: <https://doi.org/10.1109/61.277692>]
- [2] A. Rawat and R. S. Gorur, *IEEE Trans. Dielectr. Electr. Insul.*, **16**, 107 (2009). [DOI: <https://doi.org/10.1109/TDEI.2009.4784557>]
- [3] Y. Lecun, L. Bottou, Y. Bengio, and P. Haffner, *Proc. IEEE*, **86**, 2278 (1998). [DOI: <https://doi.org/10.1109/5.726791>]
- [4] Stanford Vision Lab, Stanford University, Princeton University, *LSVRC*, Available: www.image-net.org (2016).
- [5] A. Krizhevsky, I. Sutskever, and G. E. Hinton, *Commun. ACM*, **60**, 84 (2017). [DOI: <https://doi.org/10.1145/3065386>]
- [6] K. He, X. Zhang, S. Ren, and J. Sun, *Proc. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (IEEE, Las Vegas, USA, 2016) p. 27. [DOI: <https://doi.org/10.1109/CVPR.2016.90>]
- [7] X. Xia, C. Xu, and B. Nan, *Proc. 2017 2nd International Conference on Image, Vision and Computing (ICIVC)* (IEEE, Chengdu, China, 2017) p. 2. [DOI: <https://doi.org/10.1109/ICIVC.2017.7984661>]
- [8] K. Simonyan and A. Zisserman, *3rd International Conference on Learning Representations*, Available: <https://arxiv.org/abs/1409.1556> (2015).