

부분 방전의 안전도 평가를 위한 예측 모델 설계

¹이수일, ²*고대식

A Study on the Design of Prediction Model for Safety Evaluation of Partial Discharge

¹Su-II Lee, ²*Dae-Sik Ko

요약

부분 방전 현상은 배전반, 트랜스포머, 스위치 기어 등 고압전력기기에서 많이 발생한다. 부분 방전은 절연체의 수명을 단축하고 절연과괴를 가져오게 되고 이로 인해 정전사고 등 대형피해가 발생하게 된다. 부분 방전 현상은 제품 내부에서 발생하는 경우와 표면에서 발생하는 여러 가지 유형을 가지고 있다. 본 논문에서는 부분 방전 현상에 대한 패턴 및 발생할 확률을 예측할 수 있는 예측 모델을 설계하는 것이다. 설계된 모델을 분석하기 위하여 부분 방전 현상을 발생시키는 시뮬레이터를 활용하여 각각의 부분 방전 유형에 대한 학습 데이터를 UHF 센서를 통하여 수집하였다. 본 논문에서 설계된 예측 모델은 딥 러닝 중 CNN을 기반으로 설계를 하였으며 학습을 통하여 모델을 검증하였다. 설계된 모델에 대한 학습을 위하여 5,000개의 훈련데이터를 만들었으며 훈련데이터의 형태는 UHF센서에서 입력되는 3차원의 원시데이터를 2차원 데이터로 전 처리하여 모델에 대한 입력데이터로 사용하였다. 실험결과, 학습을 통하여 설계된 모델에 대한 정확도는 0.9972의 정확도를 갖는 것을 알 수 있었으며 데이터를 2차원 이미지로 만들어 학습한 경우 보다 그레이 스케일 이미지 형태로 만들어 학습한 경우가 제안된 모델에 대해 정확도가 높음을 알 수 있었다.

Abstract

Partial discharge occurs a lot in high-voltage power equipment such as switchgear, transformers, and switch gears. Partial discharge shortens the life of the insulator and causes insulation breakdown, resulting in large-scale damage such as a power outage. There are several types of partial discharge that occur inside the product and the surface. In this paper, we design a predictive model that can predict the pattern and probability of occurrence of partial discharge. In order to analyze the designed model, learning data for each type of partial discharge was collected through the UHF sensor by using a simulator that generates partial discharge. The predictive model designed in this paper was designed based on CNN during deep learning, and the model was verified through learning. To learn about the designed model, 5000 training data were created, and the form of training data was used as input data for the model by pre-processing the 3D raw data input from the UHF sensor as 2D data. As a result of the experiment, it was found that the accuracy of the model designed through learning has an accuracy of 0.9972. It was found that the accuracy of the proposed model was higher in the case of learning by making the data into a two-dimensional image and learning it in the form of a grayscale image.

Keywords: Partial discharge, predictive model, Deep learning, Safety, UHF sensor

¹ 목원대학교 지능정보융합학과 박사과정 (silee@yale-tech.com)

² 교신저자 목원대학교 전자공학과 교수 (kds@mokwon.ac.kr)

I. 서론

산업이 고도화되고 공장이나 빌딩 등에서 많은 양의 전기를 사용하게 되었으며 지속적으로 전기 사용이 증가하고 있다. 따라서 정전 등 전기공급에 따른 문제에 대해 많은 연구가 이루어지고 있다. 국내 전력설비는 1962년 경제개발계획 시작 이후 산업발달에 따른 지속적인 전력수요증가로 설비증대와 함께 대형, 대용량화 되었다. 기 설치된 전력설비들은 장시간 사용에 따른 노후화로 인해 고장 건수가 증가되고 있다. 일반적으로 많이 사용되고 있는 고전압 전력설비로는 개폐 스위치, 전력 케이블, 배전반 및 트랜스포머 등이 사용하고 있다. 이러한 대용량 전력기기는 여러 가지 현상으로 인해 이상 상태를 가지게 된다. 이상상태의 대표적인 현상으로는 두 전도체 사이에 발생하는 불완전한 절연체 내부에 열화현상이 발생하는 경우이다. 대부분의 열화 현상은 높은 전압을 사용하는 전력기기에서 발생하게 된다. 열화현상이 발생하게 되면 기기의 손상이 발생하게 되며 이로 인해 장비가 이상 동작을 하게 됨으로써 전력공급이 원활하게 이루어지지 않게 된다. 따라서 이러한 열화현상이 언제 발생하는지를 알고 미리 대책을 세울 수 있다면 전력공급이 안 되는 경우로 발생할 수 있는 많은 재해를 예방할 수 있다. 대용량 전력기기에 열화가 발생하게 되면 내부에 부분 방전(Partial Discharge) 현상이 발생하게 된다. 부분 방전이란 고전압의 전기적인 스트레스 하에서 고체 또는 유체 전기 절연 시스템의 소량의 국부적 유전체 파괴 현상을 말한다. 부분 방전의 유형을 보면 보이드 방전(Void Discharge), 표면 방전(Surface Discharge), 코로나 방전(Corona Discharge), 플로팅 방전(Floating Discharge) 등이 있다. 보이드 방전은 절연체 내부에 아주 작은 공극이 발생하면서 나타나는 부분 방전 현상을 말한다. 표면방전은 고체 절연체의 표면에 발생하는 부분방전 현상을 말한다[1]. 코로나 방전은 도체의 주위의 유체가 이온화되며 발생하는 전기적인 방전을 말한다. 플로팅 방전은 전계 중 도전성 물질과 전 극사이에 발생한다. 이러한 부분 방전이 발생하는 원인은 제조상의 결함, 기계적인 스트레스, 절연 노화 및 공정상의 결함으로 인한 공극, 불순물 및 균열로 인해 발생하게 된다[2][3].

본 논문에서는 이러한 부분 방전이 발생할 수 있는 장치 중 빌딩이나 공장과 같은 대용량 수용가 부하에 전력을 공급하는 시스템인 배전반 시스템을 기반으로 한 부분 방전 안전도 평가를 위한 예측 모델을 설계하는 것이다. 배전반은 전력을 소비자에게 보내기 위해서 발전소에서 전송되는 특고압 전력을 받아 고압 및 저압 전력으로 변환하여 주는 장치이다. 배전반에 이상이 생기면 사용자에게 공급되는 전력에 문제가 생기게 되며 문제가 커지게 되면 대규모의 정전상태가 발생되어 재산상의 피해가 발생하게 되며 산업재해 및 인명피해로 연계될 수 있다. 배전반은 여러 장치로 구성되어 있으며 배전반에서 발생하는 대부분의 설비 사고는 제작 결함 및 노후화로 인한 절연파괴로 인하여 발생하는 비중이 매우 높다. 배전반의 설비 고장은 배전반 자체 고장뿐 만 아니라 화재 및 타 사고 전이로 인하여 2차 사고로 이어질 수 있어 매우 위험한 것이다. 따라서 배전반의 안전성을 평가하여 문제가 발생하기 전에 배전반에 대한 안전성을 확인할 수 있는 예측 모델이 포함된 배전반 안전관리 모니터링 시스템 설계가 필요하다. 본 논문에서는 이러한 배전반의 안전을 예측할 수 있는 예측 모델을 설계하고 학습을 통하여 설계된 모델에 대한 검증을 하는 것이다. 2 장은 부분 방전 예측 알고리즘에 구현을 위한 이론 및 모델 설계 방법에 대해 기술하였으며, 3 장에서는 설계된 모델을 이용하여 실험을 하였으며 4 장은 결론 및 향후 연구 방향에 대해 기술하였다.

II. 부분방전 예측 모델 알고리즘 설계

2.1 부분 방전 데이터 분석

일반적으로 부분 방전은 수 나노 초의 지속시간을 갖는 펄스로 나타나며 방전 중에 발생하는 에너지의 변화를 통해서 전기적인 임펄스, 전자파 방사등의 형태로 나타난다. 일반적으로 부분 방전 데이터를 수집하여 분석하는 방법으로는 전류센서, 초음파센서 및 UHF 센서를 이용하여 측정하고 분석하는 방법이 있다. 전류센서나 초음파 센서를 이용하여 부분 방전을 측정하는

방법은 주변의 노이즈에 영향을 많이 받고 입력되는 신호의 감도가 낮다는 점에서 많이 사용하지 않는다. 반면에 UHF 센서는 주변 노이즈에 강하고 전력기기의 초기 고장진단을 발견하는데 효과적이라고 인식하고 있다[4]. UHF 센서는 부분 방전 데이터를 수집하기 위해서는 수백 MHz 부터 GHz 까지 측정이 가능하다. UHF 센서를 이용하여 측정된 데이터를 분석하는 방법으로 많이 사용하는 방법으로는 PRPD(Phase Resolved Partial Discharge)을 사용한다. 이 방법은 펄스의 위상과 펄스의 크기 및 펄스의 빈도를 이용하여 진단하는 방법이다. 이 방법의 특징은 부분 방전이 일정한 유형을 가지고 있다는 것을 이용하여 부분 방전을 분석하는 방법이다. 이 방법은 위상과 파워 값을 기준으로 하는 2차원 형태를 가지며 여기에 시간 축을 추가하여 3차원 형태의 유형을 추가하여 분석하는 방법으로 PRPS(Phase Resolved Pulse Sequency)있다[4][5].

본 논문에서는 UHF 센서를 활용하여 부분방전에 데이터를 수집하고 수집된 데이터를 통해 유형을 분석하고 이를 기반으로 안전도를 평가할 수 있는 모델을 설계하려고 한다. 배전반에서 발생할 수 있는 부분 방전의 종류로는 CT 및 PT 를 구성하는 몰드에 공극이 발생하면서 고체 절연체 내부에서 발생하는 보이드 방전, 접촉면에서 발생하는 코로나 방전이 있다. 아래 ‘그림 1’은 UHF 센서를 이용하여 부분방전 데이터를 수집한 것으로 배전반에서 나타날 수 있는 부분 방전 현상에 대한 PRPS 방법으로 데이터를 수집한 부분 방전 유형을 보여주고 있다[6].

(a)는 코로나가 발생하는 경우에 나타나는 부분 방전 유형을 보여주고 있으며 (b)는 보이드가 발생하는 경우에 나타나는 부분 방전 유형을 보여주고 있다. ‘그림 1’에서 볼 수 있듯이 부분방전은 측정하는 방법과 발생하는 현상에 따라 각각의 고유의 유형을 가지고 있다는 것을 알 수 있다. 학습을 위한 데이터의 수집은 실질적으로 사고 데이터를 측정하는 것이 불가능하여 수배전반에서 발생할 수 있는 데이터를 모의 셀을 이용하여 측정하고 원시 데이터(raw data)로 만들어 학습에 필요한 데이터로 활용하였다. 실험을 위하여 개발된 UHF 센서를 통하여 수집된 데이터의 포맷은 보면 ‘표 1’과 같다.

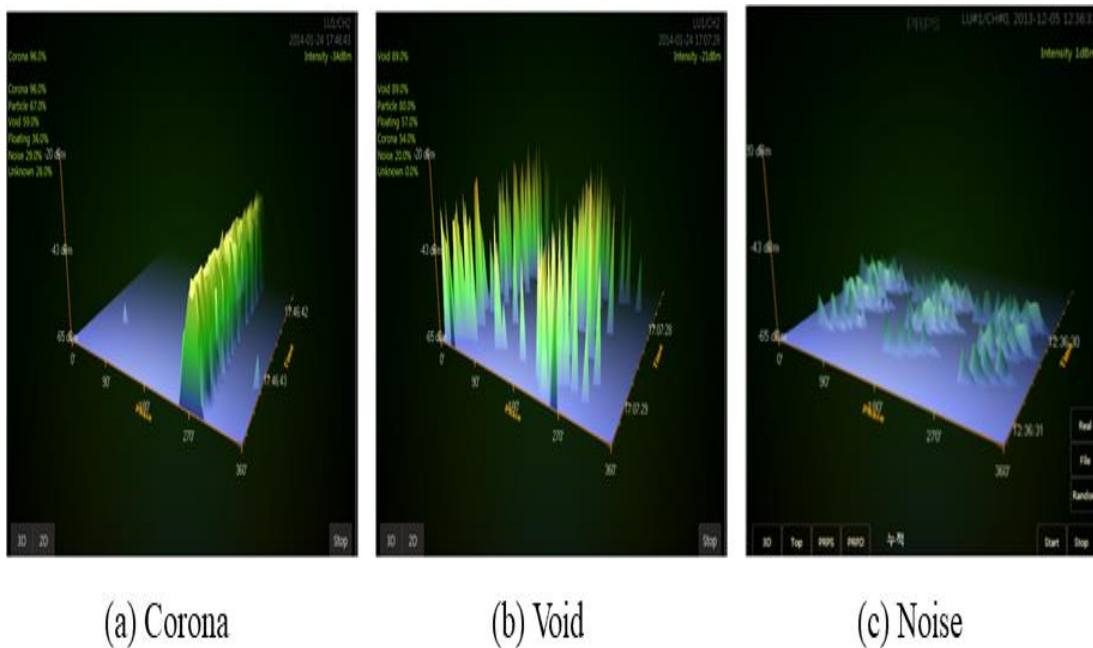
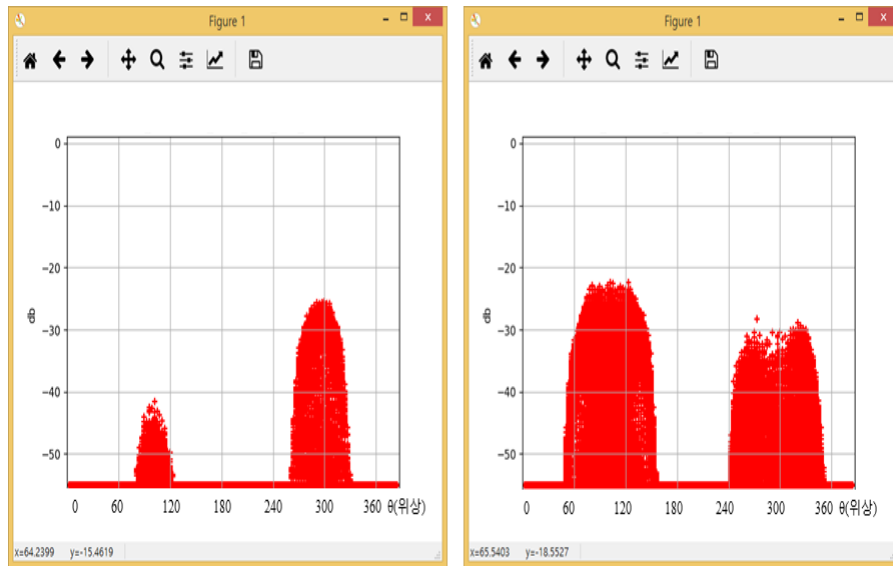


Figure 1. Partial discharge patterns that may appear in the Switchboard

Table 1. UHF Sensor Data Foramt

Total Size	구분	설명(Description)
461027 Byte	Header	- Size : 167Byte
	Data	- Size : 128 x 60 x 60 Byte - 실 데이터 영역 . Range(0~255) . 표현 Range(-55db~0dbm)
	ETC	- Size : 60Byte

UHF 센서는 배전반에서 발생하는 펄스를 RF 수신기를 이용하여 입력 받아 수신된 신호를 주파수영역에서 1 초에 128x60Byte의 데이터를 1분 동안 측정하였다. 수신된 신호의 크기는 -55dBm~0dBm의 크기를 갖는다. 측정된 데이터는 설계된 모델에 대한 학습을 위한 데이터로 사용하기 위하여 3 차원(위상, 파워, 시간) 데이터를 2 차원 데이터로 변환하였다. 2 차원 데이터를 만드는 방법은 매초마다 수집된 데이터를 2 차원 평면상에 파워 값으로 표시하여 이미지 형태로 만드는 방법과 파워 값을 그레이 스케일 형태의 이미지 형태로 만드는 방법을 사용하였다. 학습 모델을 만들기 위한 데이터는 수배전반에서 가장 많이 발생할 수 있는 부분 방전에 대한 현상을 선정하여 데이터를 수집하였다. ‘그림 2’는 보이드, 코로나에 대한 원시 데이터를 1분 동안 수신하여 제안된 모델에 적용하기 위한 전 처리 과정으로 3 차원 원시 데이터를 2 차원 형태로 만들어진 이미지를 보여주고 있다[7].



(a) Corona

(b) Void

Figure 2. 2D image training data[(a) Corona, (b) Void, H(Phase), V(dB)]

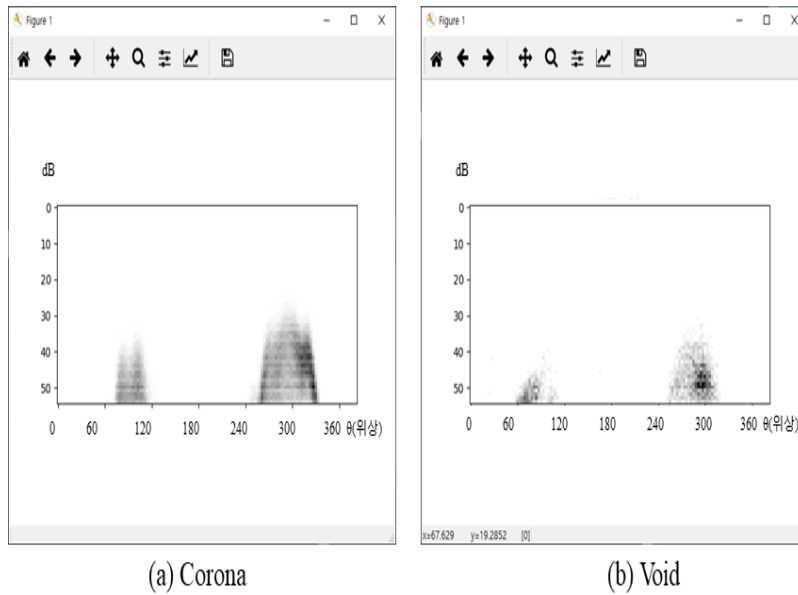


Figure 3. 2D gray scale data[(a) Corona, (b) Void, H(Phase), V(dB)]

‘그림 3’은 제안된 모델에 적용하기 위한 학습데이터로 3 차원 원시 데이터를 모델에 적용하기 전에 전 처리하여 2 차원 그레이 스케일 형태의 이미지 형태로 변환한 이미지를 보여주고 있다.

학습 모델 설계를 위한 데이터 셋은 코로나, 보이드, 노이즈의 3 개의 라벨을 가지도록 데이터 셋을 정의하였으며 학습모델을 설계하기 위한 각각의 데이터 셋의 크기는 Corona, Void 는 5,000 개의 데이터를 이용하여 학습을 진행하였다. 각각의 데이터 셋은 훈련 데이터 셋(train data set)과 검증 데이터 셋(Validate data set)으로 구분하여 데이터를 생성하고 설계된 모델에 대한 검증을 하였다.

2.2 부분 방전 예측 모델 설계

수배전반 열화진단에 대해 어떤 예측 모델을 적용할 것인가에 대해 여러 가지 예측 모델에 대한 기법을 분석하였다. 어떤 예측 모델을 설계하기 위하여 어떤 학습 알고리즘을 사용할 것인지를 정하는 방법은 데이터의 크기, 품질 및 특성 등을 고려하여 정하여야 한다. 알고리즘을 선택할 때에는 작업의 긴급성, 가용연산시간, 학습시간 및 사용 편의성을 고려하여야 한다. 어떤 알고리즘을 사용할 것인지에 대한 알고리즘에 초점을 맞추는 경향이 있으나 알고리즘 보다 정확성을 최우선으로 고려하여야 한다. 적용 가능 한 학습을 위한 알고리즘으로는 머신러닝(Machine Learning) 및 딥러닝(Deep Learning)이 많은 분야에서 학습 알고리즘으로 사용되고 있다. 머신러닝은 기본적으로 알고리즘을 이용해 데이터를 분석하고 분석을 통해 학습하며 학습기반으로 판단이나 예측을 하는 것이며 추천엔진으로 많이 사용되는 기법이다. 머신러닝의 기법으로는 선형회귀, 분류모델, 선형분류, 서포트 벡터 머신, 결정트리 및 앙상블 방법들이 있다. 딥러닝 기술을 보면 분류에 사용할 데이터를 스스로 학습하는 것으로 이미지의 학습을 통한 이미지 식별 능력이 매우 좋은 성능을 가진다. 적용하는 알고리즘으로는 컨볼루션 신경망(CNN:Convolution Neural Network)과 순환 신경망(RNN:Recurrent Neural Network)이 있으며 컨볼루션 신경망은 이미지 인식기술을 기반으로 한 이미지 인식(Image recognition)에 가장 많이 사용되고 있는 알고리즘이며 순환형 신경망 기술은 순차적인 데이터 처리를 기반으로 한 음성 및 음악, 문자열, 동영상등을 처리하는 데 많이 사용하는 알고리즘이다[8].

학습을 통한 모델을 개발하기 위하여 사용한 소프트웨어로는 파이썬(Python)을 사용하여 모델 설계 및 학습 프로그램을 개발하였으며 학습에 사용한 라이브러리는 텐서플로우(Tensorflow) 및 케라스(Keras)를 사용하여 예측 모델을 생성하였다. 텐서플로우는 기계학습과 딥러닝을 위해

구글에서 제공하는 오픈소스 라이브러리이다. 텐서플로우의 특징은 데이터 플로우 그래프를 통한 풍부한 표현력을 가지며 코드 수정 없이 CPU/GPU 모드로 동작을 한다. Unix 계열의 OS, Linux 계열 OS, Windows 및 MAC OS 에서 사용이 가능하다. 케라스(Keras)는 파이썬으로 구현된 쉽고 간결한 딥러닝 라이브러리 이다. 직관적인 API 를 제공하며 다층퍼셉트론 모델, 컨볼루션 신경망 모델, 순환 신경망 모델 또는 이를 조합한 모델은 물론 다중 입력 또는 다중 출력등 다양한 모델을 구성할 수 있다. 또한 케라스의 주요 특징은 모듈화가 가능하다는 것이다. 즉, 케라스에서 제공하는 모듈은 독립적이고 설정 가능하며, 가능한 최소한의 제약사항으로 서로 연결될 수 있다. 케라스에서 제공하는 순차적인 모델로 원하는 레이어를 쉽게 순차적으로 쌓을 수 있다.

본 논문에서는 안전도 평가를 위한 학습 데이터로 부분방전에 데이터를 사용하려고 한다. UHF 센서로 측정된 부분방전 데이터는 3 차원 데이터의 구조를 가지고 있다. 학습을 위하여 ‘그림 4’와 같이 입력데이터는 3 차원 데이터를 2 차원의 평면에 파워 값을 표시되는 이미지 데이터와 2 차원의 그레이스케일 이미지 데이터로 전처리 과정을 거친 학습 데이터로 구성하였다.

학습 데이터는 학습을 위하여 입력데이터(3 차원 데이터)를 재구성하여(reshape) 4 차원 학습 데이터로 구성하고 학습을 위하여 3 차원 데이터를 1 차원 데이터로 평면화시켜 학습 모델 알고리즘을 구현하도록 하였다.

이미지 데이터에 최적화된 딥러닝 알고리즘 중 CNN 알고리즘을 사용하였다. CNN 알고리즘은 컨볼루션 레이어(Convolution Layers)를 어떻게 구성할 것인지 몇 개의 가중치 변수(Weight Variable)를 사용할 것인지에 따라 학습에 대한 결과가 달라진다. 일반적으로 컨볼루션 레이어는 필터(Filter, Kernel)를 일정한 간격(Stride)으로 이동해가며 입력데이터에 적용하는 방법으로 일반적으로 3x3 커널(kernel)을 많이 사용하며 복잡도를 줄이기 위한 방법으로 맥스 풀링(max-pooling), hidden fc(Fully connected), 드롭 아웃(dropout)등을 사용한다.

일반적으로 CNN 은 컨볼루션 레이어와 풀링 레이어(Pooling Layer)로 구성된다. 풀링 레이어는 데이터의 공간적 크기를 축소하는데 사용된다. 주로 컨볼루션 레이어에서 출력데이터의 크기를 입력데이터의 크기로 그대로 유지하고, 풀링 레이어에서 크기를 조절한다. 풀링에는 맥스 풀링과 평균 풀링(Average-Pooling)이 있으며 맥스 풀링은 해당영역에서 최대값을 찾는 방법이고 평균 풀링은 해당영역에서 평균값을 계산하는 방법이다. 이미지 인식 분야에서는 주로 맥스 풀링을 사용한다. 또한 풀링의 윈도우의 크기와 스트라이드 값을 같은 값으로 설정한다. 풀링 레이어는 컨볼루션 레이어 바로 다음 계층에 오며 실질적으로 컨볼루션 연산 결과에 렐루(ReLU, Rectified Linear Unit) 와 같은 활성화 함수를 적용한 후 출력이 풀링 레이어의 입력으로 들어간다. 본 논문에서 적용한 딥 러닝 신경망의 계층 구조는 ‘그림 4’와 같은 구조를 가진다.




Figure 4. Deep Learning Layer Structure

본 논문에서 적용한 CNN은 컨볼루션 계층, 풀링 레이어 및 드롭아웃 계층은 fully-connected 계층 앞에 추가함으로써 원본 이미지의 필터링 기법을 적용한 뒤에 필터링 이미지에 대해 분류 연산을 수행하였다. 컨볼루션 계층은 이미지에 필터링 기법을 적용하고, 풀링 계층은 이미지의 국소적인 부분들을 하나의 대표적인 스칼라 값으로 변환함으로써 이미지의 크기를 줄이는 역할을 한다. 드롭아웃은 과 적합(Over-fit)을 막기 위한 방법으로 신경망(Neural Network)가 학습 중일 때 랜덤하게 뉴런을 꺼서 학습을 방해함으로써 학습모델이 학습데이터에 치우치는 현상을 막아주는 역할을 한다. 본 논문에서 설계한 학습 모델은 입력데이터를 받아 컨볼루션, 렐루, 풀링, 드롭아웃 레이어는 입력 데이터에 대한 특징을 추출하고 Fully-connected 을 통해 출력하는 구조를 가지고 있다[9][10].

2.3 학습을 위한 프로그램 구성

‘그림 5’는 본 논문에서 설계한 학습 모델은 파이썬 프로그램을 작성한 것이다. 그림에서와 같이 컨볼루션 계층 3 개 층과 Fully-connected 계층으로 구성되어 있으며 은닉층의 활성화 함수를 렐루 함수로 사용하고 있으며 출력 층에서는 패턴을 분류하는 것이므로 분류에 유리한 소프트맥스(Softmax)함수를 사용하고 있다. 은닉층은 컨볼루션 레이어, 맥스 풀링 레이어, 드롭아웃 계층으로 구성되어 진다.

학습 모델의 첫번째 레이어의 필터 맵(Filter map)의 개수가 128 개이며 필터의 크기는 2x2 이다. 패딩(padding)은 컨볼루션 결과 사이즈가 입력 사이즈와 같도록 설계하였다. 풀링은 맥스풀링을 사용하였으며 2x2의 크기를 가진다. ‘그림 6’은 이러한 학습 파라미터를 보여주고 있다.

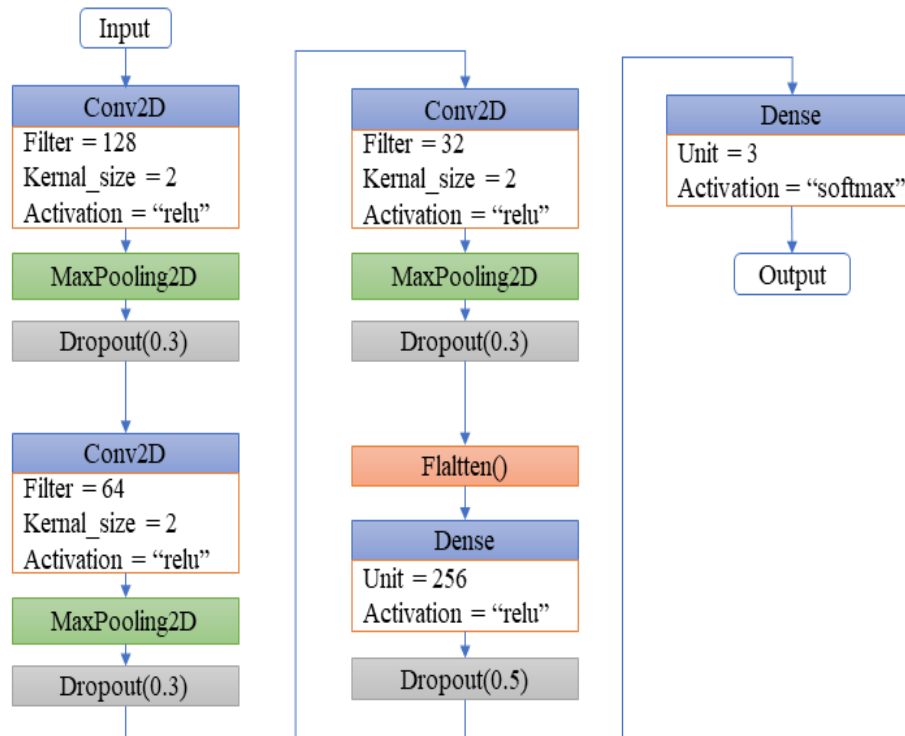


Figure 5. Learning Program

Layer (type)	Output Shape	Param #
conv2d (Conv2D)	(None, 60, 128, 128)	640
max_pooling2d (MaxPooling2D)	(None, 30, 64, 128)	0
dropout (Dropout)	(None, 30, 64, 128)	0
conv2d_1 (Conv2D)	(None, 30, 64, 64)	32832
max_pooling2d_1 (MaxPooling2D)	(None, 15, 32, 64)	0
dropout_1 (Dropout)	(None, 15, 32, 64)	0
conv2d_2 (Conv2D)	(None, 15, 32, 32)	8224
max_pooling2d_2 (MaxPooling2D)	(None, 7, 16, 32)	0
dropout_2 (Dropout)	(None, 7, 16, 32)	0
Flatten (Flatten)	(None, 3584)	0
dense (Dense)	(None, 256)	917760
dropout_3 (Dropout)	(None, 256)	0
dense_1 (Dense)	(None, 3)	771
Total params: 960,227		
Trainable params: 960,227		
Non-trainable params: 0		
Train on 9060 samples, validate on 1005 samples		

Figure 6. Training parameters for the model

제안된 모델에 대한 학습에 대한 결과를 보면 모델의 대략적인 구조를 파악해 보면 960,227 개의 학습 파라미터를 가지는 것을 알 수 있다.

학습 프로세서 설정에 있어서 최적의 학습 프로세서 정의를 위하여 학습 결과가 어떤 부분 방전이 발생하였나 하는 분류를 하는 것이므로 카테고리는 분류 카테고리인 “categorical crossentropy” 를 사용하였으며 알고리즘의 최적화를 위하여 “adam” 알고리즘을 사용하였다. 또한 학습 데이터로 학습하여 최적의 학습 모델을 찾기 위하여 학습 모델이 개선이 되면 개선된 학습 모델을 저장하도록 하였다. 손실(loss)함수는 현재 신경망의 성능이 “나쁨” 을 나타내는 지표이며 손실함수 값이 최소값이 될수록 성능이 좋은 것이다. 최적화 (Optimizer)는 손실함수의 값을 낮추기 위한 매개변수의 최적 값을 찾는 문제를 수행한다.

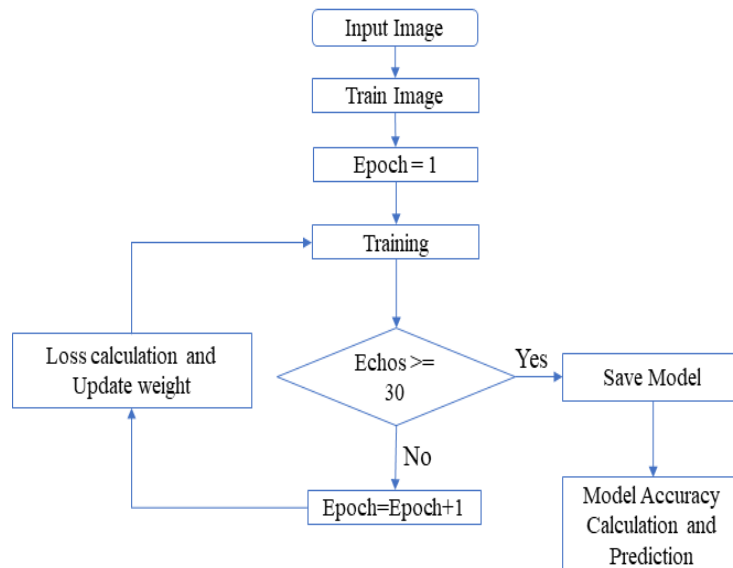


Figure 7. Learning program for the designed learning model

측정 기분(Metric)은 훈련 및 시험하는 동안 모델 평가항목을 정의하며, 본 모델에서는 분류 및 예측률에 대한 정확도(Accuracy)로 확인하겠다고 정의하였다.

III. 실험 및 고찰

3.1 학습 결과

제안된 딥러닝 학습 모델에 대한 학습을 각각의 패턴에 대해서 5,000 개의 라벨 데이터를 만들었으며 각각의 데이터에 대해서 훈련 데이터 셋 및 검증데이터 셋으로 구분하였다. 훈련데이터는 매개변수 학습에 사용되고 검증데이터(validation data)는 제안된 학습 모델에 대한 하이퍼 파라미터의 성능 평가에 사용된다. 검증데이터는 훈련 데이터 셋에 10%를 검증 데이터 셋으로 사용하였다. 설계된 학습 모델을 학습시키기 위하여 사용되는 학습 모델 함수는 fit()함수를 사용하였다. 여기서는 128 개의 데이터를 미니배치로 추출하여 30 회 학습하는 것으로 설정하여 학습을 진행하였다. 그림 8 은 모델에 대한 학습 결과를 보여주고 있다.

‘그림 8’에서 보듯이 학습은 30 번의 학습을 진행하도록 하였으며 이중 가장 성능이 좋은 학습 결과를 학습 모델로 저장하도록 프로그램 하였으며 학습 결과는 다음과 같은 특징을 가진다. (loss : 0.0085, acc : 0.9972, val_loss : 0.0334, val_acc : 0.9914)




Figure 8. Learning results(training data, verification data)

3.2 실험

제안된 학습 모델에 대한 검증을 위하여 UHF 입력 신호를 모델을 통하여 검증을 하였으며 검증 결과를 보면 다음과 같다. 그림 9는 제안된 모델에 대하여 UHF 센서로 입력된 신호에 대한 예측 유형 및 예측 값을 보여주고 있다. 실험은 제안된 모델에 데이터를 적용하기 전의 전처리 과정에서 일반적인 2D 형태의 데이터와 2D 그레이 스케일 이미지 데이터에 대한 실험을 진행하였다. 그림에서 볼 수 있듯이 일반적인 2D 데이터의 경우보다 그레이 스케일 형태의 이미지 데이터가 전반적으로 예측 값이 높다는 것을 알 수 있다.

‘그림 9’의 a), b)항은 동일한 예측값을 가지지만 c), d)항을 비교하여 보면 패턴은 같은 패턴으로 예측하지만 예측 값은 그레이 스케일 형태로 만들어진 데이터가 높다는 것을 알 수 있다. 보이드의 경우에도 예측패턴은 동일하게 예측을 하지만 예측값은 그레이 스케일로 만들어진 데이터가 높다는 것을 알 수 있다.

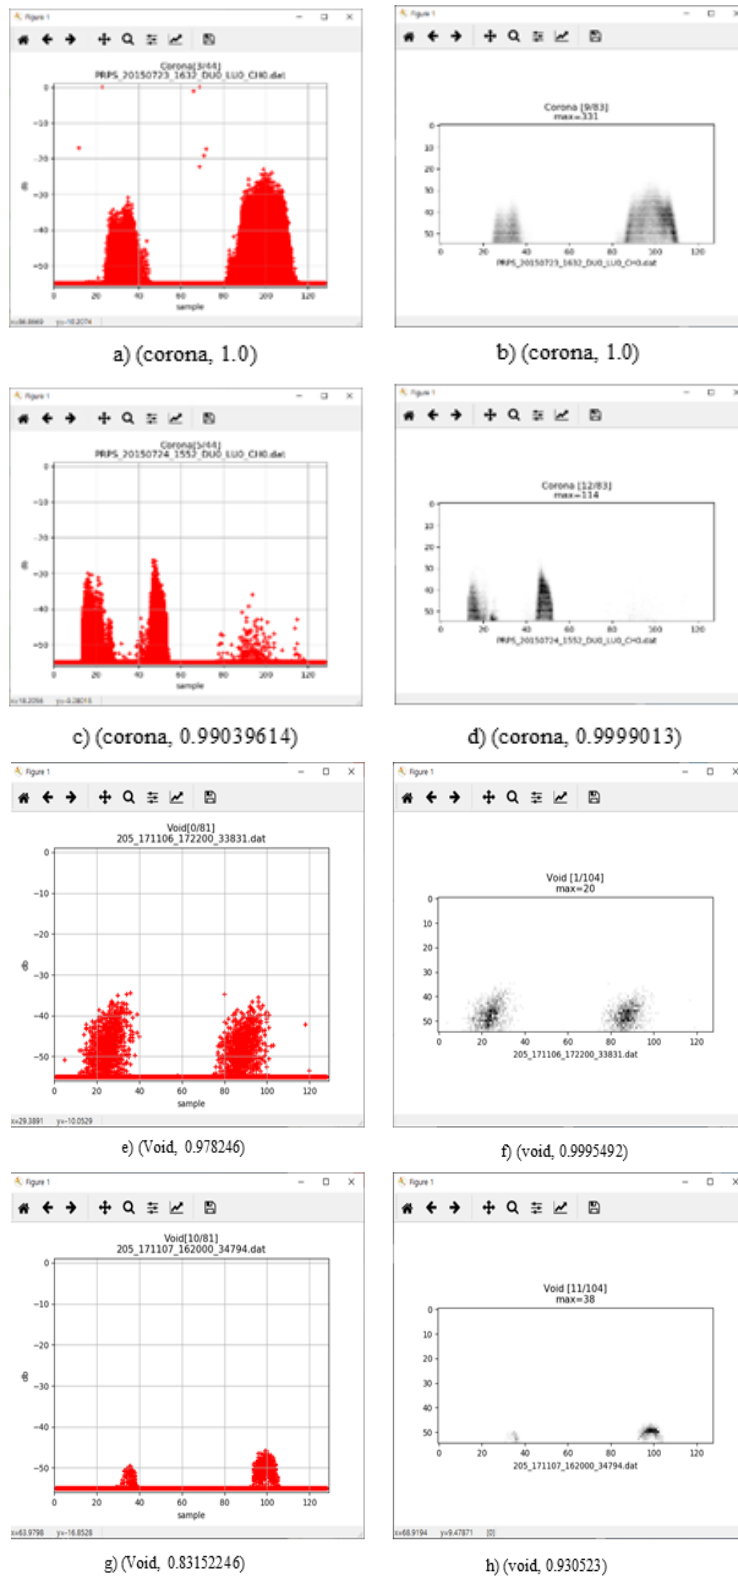


Figure 9. Prediction patterns and predicted value

IV. 결론

본 논문에서는 고압 전력기기에서 많이 발생하고 있는 부분 방전 현상에 대한 예측을 할 수 있는 예측 모델을 설계하고 검증하는 것이다. 설계된 모델에 대한 학습을 위하여 5,000 개의 훈련데이터를 만들었으며 훈련데이터의 형태는 UHF 센서에서 입력되는 3차원의 원시 데이터를 2차원 데이터로 전 처리하여 모델에 대한 입력데이터로 사용하였다. 2차원으로 전 처리하는 방법으로는 데이터를 2차원 평면에 표시하는 방법과 같은 위치의 값이 많을수록 색을 진하게 만들어 주는 그레이 스케일 이미지 형태로 만들어서 처리하는 방법을 사용하였다. 학습을 통하여 설계된 모델에 대한 정확도는 0.9972의 정확도를 갖는 것을 알 수 있었으며 데이터를 2차원 평면에 표시하는 경우보다 그레이 스케일 이미지 형태로 만들어진 데이터가 제안된 모델에 대해 정확도가 높음을 알 수 있었다.

V. 참고문헌

- [1] Mun-Gyu Choi, and Hanju Cha "The Noise Removal Method of Partial Discharger Signal" The transactions of the Korean Institute of Electrical Engineers Vol 65. No. 8. pp. 1436~1441, 2016
- [2] T. TanaKa, "Internal Partial Discharge and Material Degradation" IEEE Transactions on Electrical Insulation, Vol. E1-21, pp. 899-905, 1986
- [3] M.D. Judd, Li Yang, I.B.B. Hunter "Partial discharge monitoring of power transformers using UHF sensor. Part 1: sensor and signal interpretation" IEEE Insulation Magazine Vol. 21, pp.5-14, 2005
- [4] Chang-Won Kang "Diagnosis of partial discharge of GIS and cubicle using electromagnetic waves", Instrumentation technology, pp 102-111, 2012
- [5] Eun-Tae Ryu and Kyung-Rok Hwang, Jae-Ryong Jung, Hang-Jun Yang "Development of UHF sensor for partial discharger diagnosis of power transformer", KIEE Summer Conference 2011, pp20-22, 2011
- [6] D. Aschenbrenner, H.-G. Kranz "On line PD measurements and diagnosis on power transformers" IEEE Transactions on Dielectrics and Electrical Insulation, Vol. 12, pp. 216-222, 2005
- [7] Gyo-bum Chung and Sun-Geun Kwack "Comparison of Artificial Neural Network for Partial Discharge Diagnosis", Journal of the Korea Academia Industrial cooperation Society, Vol 14, No. 9, pp. 4455-4461, 2013
- [8] Eun-Sook Kang, Dae-Sik Ko "Automatic Classification Model of Electronic Documents Based on Machine Learning for Job Analysis", The Journal of Korean Institute of Information Technology, Vol. 17, No. 7, pp23-29, 2019
- [9] Hui Song, Jiejie Dai, Gehao Sheng, Xiuchen Jiang "GIS partial discharge patten recognition via deep convolutional neural network under complex data source" IEEE Transactions on Dielectrics and Electrical Insulation, Vol. 25, pp. 678-685, 2018
- [10] Gwon-dong Lee, Juhyoung Maeng, Seokil Song "Mobility Mode Classification Method for Trajectory Data Using CNN" The Journal of Korean Institute of Information Technology, Vol 17,

저자 소개



이수일 (Su-il Lee)

2015년 2월 목원대학교 대학원 전자정보통신학과 석사
2020년 9월 목원대학교 대학원 지능정보융합학과 박사과정

관심분야: 디지털트윈, 인공지능, IT 융합,



고대식 (Dae-Sik Ko)

1987년 2월 경희대학교 전자공학과 석사
1987년 2월 경희대학교 전자공학과 박사
1989년 ~ 현재 목원대학교 전자공학과 교수

관심분야: 디지털 트윈, 멀티미디어통신, 클라우드컴퓨팅
