

일반논문 (Regular Paper)

방송공학회논문지 제25권 제4호, 2020년 7월 (JBE Vol. 25, No. 4, July 2020)

<https://doi.org/10.5909/JBE.2020.25.4.569>

ISSN 2287-9137 (Online) ISSN 1226-7953 (Print)

합성곱 신경망을 이용한 전기 아크 신호 검출

이 상 익^{a)}, 강 석 우^{a)}, 김 태 원^{a)}, 김 만 배^{b)†}

Electrical Arc Detection using Convolutional Neural Network

Sangik Lee^{a)}, Seokwoo Kang^{a)}, Taewon Kim^{a)}, and Manbae Kim^{b)†}

요 약

전기화재의 원인중의 하나는 직렬 아크이다. 최근까지 아크 신호를 검출하기 위해 다양한 기법들이 진행되고 있다. 시간 신호에 푸리에 변환, 웨이블릿 변환, 또는 통계적 특징 등을 활용하여 아크 검출을 하는 방법들이 소개되었지만, 변환 및 특징 추출은 부가적인 처리 시간이 요구되는 단점이 있다. 반면에 최근의 딥러닝 모델은 종단간 학습으로 특징 추출 과정없이 직접 원시 데이터를 활용한다. 따라서, 1-D 시간 신호를 직접 활용하여 아크를 검출하는 것이 좋은데, 인공신경망의 분류 성능이 저하되는 문제점이 있다. 본 논문에서는 연속 입력 1-D 신호를 2-D로 변환한 후에, 합성곱신경망으로 분류하는 방법을 제안한다. 실험 데이터에 적용한 결과 합성곱신경망의 사용이 인공신경망보다 약 8.6%의 아크 분류 성능을 향상시켰다. 또한 2-D 데이터의 부족을 보완하기 위해서 데이터증강을 이용하여, 14%의 분류 성능을 개선하였다.

Abstract

The serial arc is one of factors causing electrical fires. Over past decades, various researches have been carried out to detect arc occurrences. Even though frequency analysis, wavelet, and statistical features have been used, additional steps such as transformation and feature extraction are required. On the contrary, deep learning models directly use the raw data without any feature extraction processes. Therefore, the usage of time-domain data is preferred, but the performance is not satisfactory. To solve this problem, subsequent 1-D signals are transformed into 2-D data that can feed into a convolutional neural network (CNN). Experiments validated that CNN model outperforms deep neural network (DNN) by the classification accuracy of 8.6%. In addition, data augmentation is utilized, resulting in the accuracy improvement by 14%.

Keyword : arc detection, convolutinoal neural network, 2-D transformation, data augmentation

a) 한국전기안전공사 전기안전연구원(Electrical Safety Research Institute & Korea Electrical Safety Corp.)

b) 강원대학교 컴퓨터정보통신공학과(Dept. of Computer & Communications Eng., Kangwon National University)

† Corresponding Author : 김만배(Manbae Kim)

E-mail: manbae@kangwon.ac.kr

Tel: +82-33-250-6395

ORCID: <https://orcid.org/0000-0002-4702-8276>

※ This research was supported by Korea Institute of Energy Technology Evaluation and Ministry of Trade Industry & Energy (MOTIE) of the Republic of Korea (No. 20172210200050).

※ This research was supported by the MSIT (Ministry of Science and ICT), Korea, under the ITRC (Information Technology Research Center) support program (IITP-2020-2018-0-01433) supervised by the IITP(Institute for Information & communications Technology Promotion)

• Manuscript received March 25, 2020; Revised June 3, 2020; Accepted June 24, 2020.

Copyright © 2020 Korean Institute of Broadcast and Media Engineers. All rights reserved.

“This is an Open-Access article distributed under the terms of the Creative Commons BY-NC-ND (<http://creativecommons.org/licenses/by-nc-nd/3.0>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited and not altered.”

1. 서론

2014년 소방방재청의 화재통계연감에 따르면 화재의 원인 중 전기적 요인이 22.4%로 가장 높게 나타났다. 전기적 요인 중 미확인 단락이 26.5%로 가장 많고, 절연 열화에 의한 단락 25.7%, 접촉 불량에 의한 단락 8.2% 등으로 나타났다. 이러한 전기화재 원인의 공통점은 아크(arc)를 동반하는 것이다. 그림 1은 정상 신호와 아크신호의 한가지 예를 보여준다.




그림 1. 정상 신호와 아크 신호의 예. (a) 정상신호 및 (b) 아크신호
Fig. 1. An example of normal and arc signals. (a) normal signal and (b) arc signal

일반적으로 아크신호의 특징은 1) 고주파 성분이 크고, 2) 숄더(shoulder)영역에서 납작한 형태를 가지고, 3) 짧은 시간동안 크기가 급격히 상승 및 하강이 발생한다. 그러나 이 특성은 부하별로 차이가 많아서, 검출에 사용할 수 있는 만족스러운 특징을 찾는 것은 어렵다. 따라서 딥러닝으로 아크를 검출하려는 연구가 최근 많이 진행되고 있다.

아크 신호 검출을 위해 매우 다양한 방법들이 사용되어 왔다. 이 분야에서는 일반적으로 아크 검출을 분류의 문제로 해결한다. 정상 및 아크의 2 클래스이므로, 이진 분류기(binary classifier)로 모델링한다. 기존의 기계학습 기법들의 성능을 개선할 수 있는 신경망이 최근 관심을 받고 있다^[1-6]. 신경망 모델로는 완전연결 심층신경망^[1-4], 자기부호화기(autoencoder)^[6] 등을 활용한다. 입력신호에서 아크검출에 필요한 특징(feature)을 찾은 후에, 이 특징을 입력으로 분류 모델을 학습하여 아크 신호를 검출하게 된다. 특징으로는 주로 주파수(frequency), 통계적 특징(statistical feature) 등을 사용한다. 푸리에변환^[7], 웨이블릿(wavelet)^[8,9,10] 변환을 이용하여 정상과 아크를 분별할 수 있는 특징들을

주파수 도메인에서 찾은 후에 이를 활용하여 검출한다. 이외에도 시간 및 주파수 신호에서 통계적 특징을 추출한 후에 아크 검출에 이용하기도 한다^[7-9].

최근의 딥러닝은 종단간 학습(end-to-end learning)으로 분류기를 만드는 작업이 주를 이루고 있다. 즉, 특징 추출 과정없이 원 데이터를 직접 신경망 모델의 입력으로 사용하고, 신경망 내부에서 자동으로 특징을 추출하게 된다. 특히 합성곱신경망(convolutional neural network; CNN)은 합성곱층에서 합성곱 필터를 사용하여 자동으로 분류에 사용할 수 있는 특징을 찾아내는 탁월한 능력을 가지고 있다.

따라서 종단간 학습에 맞추어 시간 신호(time-domain signal)를 직접 입력으로 사용하여 인공신경망의 성능을 검증하고자 한다. 이 방법은 주파수변환이 생략되어 처리속도를 줄일 수 있는 장점이 있으나, 상대적으로 성능이 저하되는 문제가 발생한다. 따라서, 아크 분류 성능을 높여주기 위해서 연속 1-D 시간신호를 2-D 영상으로 변환한 후에, CNN으로 학습하여 성능을 개선하는 것이 본 연구의 목적이다.

본 논문의 구성은 다음과 같다. 다음 장에서는 1-D 신호를 2-D로 변환하는 방법을 설명하고, III장에서는 합성곱신경망 모델을 설명한다. 실험 결과는 IV장에서 소개하고, 마지막으로 V장에서는 결론 및 향후 연구를 정리한다.

II. 시간 신호의 2-D 데이터 변환

CNN은 입력이 2-D 데이터이므로, 입력된 1-D 신호를 축적해서 2-D로 제작하는 과정이 필요하다. 그림 2에서 보는 것처럼, 연속적으로 길이가 W 인 x_i 를 N 개 취득하여, $x_1, x_2, \dots, x_N$ 으로 $N \times W$ 2-D 데이터를 만든다. 이 데이터는 CNN의 입력데이터로 사용된다. 각 2-D 데이터에는 정상, 아크를 가리키는 레이블이 할당되고, 이진 클래스 분류이다. 실험에서는 $N=20$ 이고, W 는 1 주기(cycle, period)로 샘플링률(sampling rate)에 의해 결정된다. 신호의 기본 주파수가 60HZ, 샘플링률이 27KHz이면 $W=27,000/60=450$ samples/cycle이다. 1주기 신호를 선택하는 시작점은 임의로 선택하는데, W 의 시작점은 성능에 거의 영향이 없다. 주기신호이기 때문에, 임의의 시작점으로부터 얻은 한주기

신호에는 필요한 정보는 모두 포함되어 있다고 판단된다.




그림 2. 1-D 시간 신호를 2-D 데이터로 변환하는 과정. $x_1, x_2, \dots, x_N$ 은 1-cycle 신호임

Fig. 2. Transformation of 1-D time-domain signal into 2-D data. $x_1, x_2, \dots, x_N$ are 1-cycle signals

그림 3은 실제 1-D 신호로부터 생성한 2-D 데이터를 보여준다. 그림 3(a)는 20-cycle의 지속을 가지는 시간 신호이고, 그림 3(b)는 이 신호로부터 생성된 해상도가 $N \times W = 20 \times 450$ 인 2-D 데이터를 보여준다. 신호는 양수, 음수 값을 가지기 때문에, 음수는 적색으로, 양수는 청색으로 표시하였다. 각 색의 밝기값은 샘플데이터의 크기에 비례한다.




그림 3. $N \times W$ 데이터 생성. (a) 20-cycle의 시간 신호 및 (b) 20x460 2-D 데이터. 적색 픽셀은 음수값, 청색 픽셀은 양수값이고, 시각화를 위해서 데이터값을 변환하였음

Fig. 3. $N \times W$ data generation. (a) 20-cycle time-domain signal and (b) 20x450 2-D data. Red pixel indicates negative value and blue pixel indicates positive value, where data is transformed for better visualization




그림 4. 실험에 사용한 합성곱신경망 모델

Fig. 4. Convolutional neural network used in experiments

III. CNN 모델

실험에서 사용하는 신경망은 CNN(convolutional neural network)을 기반으로 한다. CNN은 다양한 이미지 클래스 분류에서 월등한 성능을 보이며^[10,11], 기존 알고리즘보다 좋은 성능을 나타낸다. CNN은 특징점 추출과 동시에 클래스를 분류하기 때문이다.

CNN의 기본 구조는 합성곱층(conv layer), 풀링층(pooling layer), 완전결합층(fully connected layer)를 깊게 쌓아 이루어지는데, 배치정규화 및 드롭아웃(dropout)을 추가하였다. 적용한 CNN 구조는 총 3개의 합성곱층으로 이루어지며 입력된 영상에 합성곱 연산을 거쳐 영상의 특징을 추출한다. 입력영상이 $N \times W = 20 \times 450$ 이므로, 가로, 세로가 다른 것을 고려하여 3개의 합성곱층 모두 16개의 3×7 필터를 사용한다. 필터 크기는 다양한데, 3×7 에서 가장 성능이 우수하였다. 필터의 이동 거리인 스트라이드는 2이다. 특징을 추출할 때 활성화 함수로는 relu(rectified linear unit)를 사용한다. 그리고 풀링 단계에서는 추

출된 특징들을 서브샘플링하는데 max pooling을 사용하였다. 이는 합성곱층에서 추출된 특징들에서 약한 특징은 무시하고 강한 특징들을 추출하여 영상의 차원을 축소하는 방법으로, 강한 특징값이 다른 특징 값들을 대표한다는 개념을 기반으로 하고 있다.

그리고 완전결합층에서는 합성곱층과 max-pooling의 반복 수행에서, 추출된 특징을 완전결합층 신경망을 거치면서 정상과 아크 신호를 분류하게 된다. 은닉층은 1개 층으로 구성되며, 뉴런의 개수는 100이다. 출력층에서는 2개의 뉴런이 있으며 활성화 함수로 소프트맥스를 사용한다. 학습률은 0.001이고, 최적화는 adam을 사용하였다.

IV. 실험 결과 및 분석

본 장에서는 아크 신호 획득 과정 및 학습에 사용하는 2-D 데이터를 설명한다. 부족한 학습 데이터를 보충하기 위해서 사용한 데이터증강에 대해 소개한 후에, 실험결과를 검증한다.

1. 아크 데이터 획득

정상신호와 아크신호 데이터는 한국전기안전공사 전기

안전연구원에서 아크 생성기(arc generator)를 이용하여 제작하였다. 총 7개의 부하(load) S_i ($i \in 1, \dots, 7$)가 있으며, S_i 는 각각 정상신호와 아크신호의 데이터로 구성된다.

정상신호는 아크 생성기를 OFF한 후에, 부하 기기를 작동하여 취득하였다. 아크신호는 ON 상태에서 구리봉을 접촉시켜 생성하였다. 따라서 정상과 아크 신호 분류가 가능하다. 또한 구리봉 접촉은 지속적으로 작업하기 어려워서, 끈어진 신호 데이터는 서로 연결하여 사용하였다. 따라서 아크신호에 정상신호가 포함되거나 또는 그 반대의 경우는 발생하지 않았다.

표 1은 데이터의 7가지 부하 종류를 보여준다. 부하별 정상신호와 아크신호를 생성하였다. S_1 는 부하로 조광기(dimmer)와 백열등(incandescent lamp)을 사용하여 얻은 신

표 1. 아크 데이터의 부하 종류

Table 1. Load types of arc signal

Signal	Load
S_1	dimmer(100%) + Incandescent Lamp
S_2	dimmer(50%) + Incandescent Lamp
S_3	SMPS(220V → 24V, 5A) + Resistance 10 Ohm
S_4	Air Compressor (UDS3040)
S_5	Heater (Weak, Half-Wave Rectification)
S_6	Heater (Strong)
S_7	3 Fluorescent Lamps (FL40EX-D)




그림 5. 정상 및 아크 신호의 예. 1행은 정상, 2행은 아크임. (a) S_2 , (b) S_4 및 (c) S_7

Fig. 5. Examples of normal and arc signals. Top: normal, Bottom: arc. (a) S_2 , (b) S_4 and (c) S_7

호이다, 샘플링 주파수는 27KHz이다. 따라서 신호의 한 주기에서 450 개의 샘플을 얻는다. 각 신호 데이터에는 아크(1), 정상(0)으로 해당 레이블이 할당된다.

그림 5는 표 1의 S_2, S_4, S_7 의 정상신호와 아크신호의 예를 보여준다. 각 학습 데이터는 정상이면 레이블을 0, 아크이면 1로 클래스를 할당하여, 지도학습 이진 분류 신경망으로 학습한다.

II장에서 소개한 2-D 데이터 제작 방법으로 얻어진 부하 신호별 제작된 개수는 표 2에서 보여진다. S_1 에서는 2-D 아크는 36개, 정상은 37개가 얻어진다. 총 데이터 개수는 각각 396, 331개이다. 부하별 부하 신호 데이터의 부족이 발생하는데, 학습데이터의 부족은 CNN의 테스트 단계에서 과적합(overfitting)의 원인이 된다. 해결 방법은 데이터 증강에서 자주 사용하는 데이터증강이다.

표 2. 7개의 부하 신호의 2-D 데이터 개수

Table 2. The number of 2-D data produced by seven load signals

Load signal	2-D arc	2-D normal
S_1	36	37
S_2	42	36
S_3	91	58
S_4	76	43
S_5	62	73
S_6	44	42
S_7	45	42
Sum	396	331

2. 2-D 데이터 증강

학습데이터의 양이 부족해서 CNN으로 얻은 성능은 만족스럽지 않다. 따라서 데이터증강(data augmentation)으로 부족한 데이터 문제를 해결한다. 1-D 신호의 데이터증강 방법으로는 jittering, scaling, rotation, magnitude warping, time warping, cropping, permutation 등이 있다^[12]. 데이터 증강에서는 증강된 데이터가 신호의 특성 또는 도메인에 맞게 제작되어야 해서, 본 연구에서는 scaling과 새로운 기술로 line swapping을 2-D 데이터 증강에 활용하였다. line swapping은 N 개의 line 신호가 있으면, 랜덤하게 서로의 행(row)을 교환(swapping)하는 것이다. N 번 수행하여 가

능한 행들의 교환되도록 하였다. scaling은 $[0.8, 1.2]$ 의 값을 랜덤 균일분포로 얻은 후에 각 샘플 데이터에 곱해주는 방식이다. 각 부하신호별 200개의 데이터를 제작하였다. 증강데이터는 CNN 모델의 테스트에는 사용하지 않고, 학습에서만 사용하였다.

3. 분류 성능

실험에서 사용한 데이터의 정제 및 CNN의 구현은 MATLAB 2018a 버전에서 이루어졌다. 입력 데이터의 80%는 학습 데이터로 사용하고 20%는 테스트 데이터로 사용하였다. CNN으로 학습시킨 후 테스트 단계에서 분류 정확도(classification accuracy)를 측정하였다. 2-D 데이터는 입력 전에 $[0, 1]$ 의 정규화를 거쳤다.

비교 성능 검증을 위해 은닉층으로만 구성되는 완전결합층(fully-connected) DNN(deep neural network)을 사용한다. 입력신호는 2가지로 첫째는 크기가 $1 \times W$ 벡터 형태의 1-D 신호이다. 입력 노드의 수는 W 로 벡터의 차원과 동일하다. 둘째는 CNN의 입력인 $N \times W$ 와 동일한 개수를 맞추기 위해서, $1 \times (N \cdot W)$ 로 1-D 신호를 만들어서 완전결합층 DNN으로 성능을 분석하였다. 여기서는 CNN에서 line swapping 및 scaling한 2-D 데이터를 1차원으로 재구성하였다. 출력층은 아크 신호와 정상 신호만을 분류하는 이진 분류(binary classification)이므로 두 개의 노드를 갖는다. 은닉층은 3개의 층으로 구성되며, 각각 노드의 개수는 256, 128, 128로 설정하였다. 출력층에서는 활성 함수로 소프트맥스를 사용하고, 이외의 모든 계층에서는 relu이다. $1 \times W$ 1-D 시간신호의 개수는 충분하였기 때문에 데이터 증강은 활용하지 않았다.

실험 결과는 표 3에서 보여진다. CNN 모델은 데이터증강이 없으면 분류정확도는 88.04%이지만, line swapping을 적용하면 94.23%, scaling에서는 94.83%를 얻기 때문에, 각각 (6.19, 6.79)%의 정확도가 향상된다. $1 \times W$ 을 사용한 완전결합층 DNN의 분류정확도는 79.44%이다. $1 \times (N \cdot W)$ 을 사용한 완전결합층 DNN에서는 line swapping은 85.49%이고, scaling은 84.26%를 얻어서, 상대적으로 CNN 모델이 성능면에서 우수함을 알 수 있다.

표 3. CNN 모델의 아크 분류 정확도 (단위: 퍼센트). DA=Data Augmentation. FC=fully-connected

Table 3. Classification accuracy of CNN model. (Unit: %). DA=Data Augmentation. FC=fully-connected

FC- DNN (1xW)	FC-DNN (1x(N·W))		CNN (NxW)		
No DA	DA		No DA	DA	
	line swapping	scaling		line swapping	scaling
79.44	85.49	84.26	88.04	94.23	94.83

V. 결 론

전기신호에서 발생하는 아크신호의 검출은 화재의 위험 때문에, 높은 수준의 검출율이 필요하다. 기존의 아크 검출 기법들은 다양한 주파수, 웨이블릿의 특징을 사용하는데 반해서, 본 연구에서는 합성곱신경망(CNN)의 장점인 중간 학습에 맞추어 1-D 시간 신호를 2-D 데이터로 변환한 후에, 신경망 모델의 성능을 검증하였다. DNN 모델과 비교하면 8.6%의 분류정확도 향상이 있었다. 또한 데이터증강을 이용하면 약 14%의 성능 향상이 있음을 실험에서 증명하였다. 향후 연구에서는 2-D 데이터 제작 방법의 개선 및 CNN 모델 개선이 필요하다.

참 고 문 헌 (References)

- [1] C. Wu, Y. Liu and C. Hung, "Intelligent detection of serial arc fault on low voltage power lines", *J. of Marine Science and Technology*, Vol. 25, No. 1, pp. 43~53, 2017.
- [2] S. Ma, and L. Guan, "Arc fault recognition based on BP Neural Network", *Int' Conf. Measuring Technology and Mechatronics Automation*, 2011.
- [3] H. Yuanhang, Y. Wang, D. Enyuan, and Z. Jiyan, "Aviation arc fault diagnosis based on weight direct determined neural network", *Int. Conf. Electric Power Equipment*, 2013.
- [4] S. Hong, T. Kim, and S. Lee, "Study of series-arc detection algorithm", *KIEE Summer Conf.*, 2018.
- [5] N. Perera and A. Rajapakse, "Recognition of fault transients using a probabilistic neural network classifier", *IEEE Trans. Power Delivery*, Vol. 25, Iss. 1, 2011.
- [6] Z. Chen and W. Li, "Multisensor feature fusion for bearing fault diagnosis using sparse autoencoder and deep belief network", *IEEE Tran. Inst. and Measure.*, Vol. 66, No. 7, July 2017.
- [7] H. Gu, F. Zhang, Z. Wang, Q. Ning, and S. Zhang, "Identification method for low-voltage arc fault based on the loose combination of wavelet transformation and neural network", *Power Eng. and Auto. Conf.*, 2012.
- [8] P. Muller, S. Tenbohlen, R. Maier, and M. Anheuser, "Characteristics of series and parallel low current arc faults in the time and frequency domain", *Proc. of the 56th IEEE Holm Conf. Electrical Contacts*, 2010.
- [9] G. Yunmei, W. Li, W. Zhuoqi, and J. Binfeng, "Wavelet packet analysis applied in detection of low-voltage DC arc fault", *IEEE Industrial Electronics and Applications*, 2009.
- [10] S. Lee, C. Choi, and M. Kim, "CNN-based people recognition for vision occupancy sensors", *Journal of Broadcast Engineering*, Vol. 23, No. 2, March 2018, pp. 274-282.
- [11] E. Kim and W. Kim, "Face anti-spoofing based on combination of luminance and chrominance with convolutional neural networks", *Journal of Broadcast Engineering*, Vol. 24, No. 6, pp. 1113-1121, Nov. 2018.
- [12] T. Um, F. Pfister, D. Pichler, S. Endo, M. Lang, S. Hirche, U. Fietzek, and D. Kulić, "Data augmentation of wearable sensor data for Parkinson's disease monitoring using convolutional neural networks", *19th ACM International Conference on Multimodal Interaction (ICMI)*, Nov. 2017, Glasgow, UK.

저 자 소 개

이 상 익

- 2007년 : 건국대학교 전기공학과 공학박사
- 1996년 ~ 현재 : 전기안전연구원 수석연구원
- ORCID : <http://orcid.org/0000-0002-1150-1682>
- 주관심분야 : 딥러닝, 신호처리, 전원품질



저 자 소 개

강 석 우

- 1997년 : 호서대학교 제어계측공학과 학사
- 2017년 ~ 현재 : 한국전기안전공사 전기안전연구원 선임연구원
- ORCID : <https://orcid.org/0000-0002-1474-0646>
- 주관심분야 : System Architecture, Real Time Data Streaming Processing



김 태 원

- 2013년 : 충남대학교 전기공학과 학사
- 2016년 : 한밭대학교 산업대학원 전기공학과 공학석사
- 2016년 ~ 현재 : 한국전기안전공사 전기안전연구원 선임연구원
- ORCID : <https://orcid.org/0000-0003-1391-949X>
- 주관심분야 : IoT, 신호해석, 머신러닝, 전기전자통신



김 만 배

- 1983년 : 한양대학교 전자공학과 학사
- 1986년 : University of Washington, Seattle 전기공학과 공학석사
- 1992년 : University of Washington, Seattle 전기공학과 공학박사
- 1992년 ~ 1998년 : 삼성종합기술원 수석연구원
- 1998년 ~ 현재 : 강원대학교 컴퓨터정보통신공학과 교수
- 2016년 ~ 2018년 : 강원대학교 정보통신연구소 소장
- ORCID : <http://orcid.org/0000-0002-4702-8276>
- 주관심분야 : 컴퓨터비전, 3D영상처리, 머신러닝응용