

일반논문 (Regular Paper)

방송공학회논문지 제24권 제5호, 2019년 9월 (JBE Vol. 24, No. 5, September 2019)

<https://doi.org/10.5909/JBE.2019.24.5.791>

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

인공 신경망을 이용한 전기 아크 신호 검출

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

Electrical Arc Detection using Artificial Neural Network

Sangik Lee^{a)}, Seokwoo Kang^{a)}, Taewon Kim^{a)}, Seungsoo Lee^{b)}, 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, 또는 통계적 특징 등을 활용하여 아크 검출을 하는 방법들이 소개되었지만, 다양한 불규칙 아크 파형 때문에, 실제 환경에서는 아크 성능이 저하되는 문제가 있다. 따라서, 기존의 부족한 특징 데이터를 증가시켜, 성능을 개선하는 것이 요구된다. 본 논문에서는 입력신호를 변분 모드 분할을 통해 원신호를 분할한 후 통계적 특징을 추출한다. 변분 모드 분할로부터 추출한 통계적 특징의 성능이 원신호로부터 얻은 특징보다 개선된 성능을 얻는다. 아크 분류기로 인공 신경망을 이용하고, 14,000개의 학습 데이터에 적용한 결과 VMD의 사용이 약 4%의 아크 검출 성능을 높였다.

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, arc detection performance is degraded due to diverse arc waveforms. Therefore, there is a need to develop a method that could increase the feature dimension, thereby improving the detection performance. In this paper, we use variational mode decomposition (VMD) to obtain multiple decomposed signals and then extract statistical features from them. The features from VMD outperform those from no-VMD in terms of detection performance. Further, artificial neural network is employed as an arc classifier. Experiments validated that the use of VMD improves the classification accuracy by up to 4 percent, based on 14,000 training data.

Keyword : arc detection, deep neural network, variational mode decomposition, statistical features

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-2019-2018-0-01433) supervised by the IITP (Institute for Information & communications Technology Promotion). This study has been worked with the support of a research grant of Kangwon National University in 2019.

· Manuscript received May 7, 2019; Revised June 10, 2019; Accepted July 31, 2019.

Copyright © 2016 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 아크 신호의 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

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. 신호의 상관도(correlation), 주파수 특성, 및 스펙트럼 등을 이용하는 신호처리 기법 및 SVM(support vector machine), 결정트리 등을 이용하는 기계학습 기법들의 성능을 개선할 수 있는 심층 신경망이 최근 관심을 받고 있다^[1-6]. 신경망 모델로는 심층신경망^[1-4], 출력 부분에 분류기를 결합한 자기부호화기(auto-encoder)^[6] 등을 활용한다. 입력신호에서 아크 검출에 필요한 특징(feature)을 찾은 후에, 이 특징을 입력으로 분류모델을 학습하여 아크신호를 검출하게 된다. 특징으로는 주로 주파수(frequency), 통계적 특징(statistical feature) 등을 사용한다.

사용하는 특징으로는 푸리에 변환^[7], 웨이블릿(wavelet)^[8,9,10]을 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^[7-10]. 그러나 상기 방법들은 특정 환경에서는 높은 검출률을 얻을 수 있지만, 다양한 전기 부하(load)에서 발생하는 아크 신호는 파형(waveform)의 다양성으로 서로 상이한 특성들을 가지고 있다. 따라서 특정 부하에서 발생하는 아크 특성이 다른 부하에서는 발생하지 않기 때문에 검출 성능이 저하된다. 시간 신호(time-domain signal)를 직접 입력으로 사용하는 방법은 주파수변환이 생략되어 처리속도를 줄일 수 있는 장점이 있으나, 분류에 필요한 특징 정보의 획득에 어려움이 있다. 따라서 상대적으로 다른 특징들에 비해 성능이 저하되는 문제가 발생한다.

시간신호에서 주파수 특성을 사용하지 않고, 시간 데이터만 사용할때에는 주로 통계적 특징을 이용한다. 그런데 통계적 특징은 시간 신호에서 얻을 수 있는 특징의 한계로 성능 저하가 발생한다. 따라서, 시간신호로부터 아크 분류 성능을 높여줄 수 있는 효율적인 특징의 추출이 가능해야만, 검출 성능을 개선할 수 있다. 이 문제를 해결하고자 하는 것이 본 연구의 목적이다.

본 논문에서는 시간신호를 변분 모드 분할(Variational Mode Decomposition: VMD)을 이용하여 검출 성능을 개선하는 방법을 제안한다. VMD는 시간 신호를 R개의 신호로 분할하는 기술로 최근 주목을 받고 있는 기술이다^[11]. 원 신호뿐만 아니라 VMD 모드 신호로부터 통계적 특징을 추출하여, 특징의 차원을 증가시킨다. 아크 분류기로는 심층 신경망을 이용한다. 실험에서는 원 시간신호에서 직접 통계적 특징을 추출한 것과, VMD로부터 얻은 신호들로부터 추출한 통계적 특징의 아크 검출 성능의 비교를 통해서, VMD가 아크의 분류 성능을 높일 수 있다는 것을 보여준다. VMD는 시간신호를 여러 개의 시간신호로 분할하는 기법이다. 따라서 푸리에변환, 웨이블릿을 적용하는 것은 적합하지 않기 때문에, 본 논문에서는 상기 기법들은 고려하지 않는다

본 논문의 구성은 다음과 같다. 다음 장에서는 신호를 분할하는 방법인 VMD의 개념에 대해 설명하고, III장에서는 제안 방법을 설명한다. 실험 결과는 IV장에서 소개하고, 마지막으로 VI장에서는 결론 및 향후 연구를 정리한다.

II. 변분 모드 분할

변분 모드 분할(Variational Mode Decomposition: VMD)은 입력신호를 모드(mode) 신호 a_r ($r=1, \dots, R$)로 분할하는 신호처리 기술이다^[11]. a_k 들은 주 신호를 처리하는 동안 특정 희소(sparsity) 속성을 갖는다. 신호분할 과정에서 중심 파동 ω_k 가 결정되고, 각 모드 r 은 ω_r 를 중심으로 모인다. VMD는 비재귀적 적응 기법이다. VMD 모드는 시변 진폭 및 위상을 갖는 정현파로 생성된다. 신호 $a(t)$ 에 대해 모드는 다음과 같이 정의된다.

$$a(t) = \sum_{r=1}^R a_r(t) = \sum_{r=1}^R A_r(t) \cos \phi_r(t) \quad (1)$$

Wiener 필터는 VMD 모델을 설계할 때 사용되며 이것은 VMD 알고리즘의 가장 중요한 부분 중 하나이다. VMD의 다른 중요한 부분은 힐버트 변환(Hilbert Transform)과 주파수 이동이다. VMD 분할은 Lagrangian multiplier λ , 모드 개수 R , 및 DFCF(data fidelity constraint parameter) α 의 3가지 파라미터로 정의된다. 여기서 λ 는 복원의 품질 제약조건이고, α 는 서로 다른 모드에서 얻어진 주파수의 범위를 결정한다.

■ VMD 알고리즘 :

Step 1. 반복 횟수 $m=1$ 에서, r 번째 모드 a_r 의 스펙트럼 \hat{a}_r 와 중심 주파수 w'_r 가 생성된다. $r \in \{1, \dots, R\}$. Lagrangian multiplier λ'_1 는 $m=1$ 에서 시작된다.

Step 2. $m+1$ 에서, a_r 의 스펙트럼은 다음과 같이 갱신된다.

$$\hat{a}_r^{m+1}(t) = \frac{\hat{a}(w) - \sum_{i < r} \hat{a}_i^{m+1}(w) - \sum_{i > r} \hat{a}_i^m(w) + ((\hat{\lambda}^m(w))/2)}{1 + 2\alpha(w - w_r^m)^2} \quad (2)$$

각 모드의 중심 주파수는 다음과 같이 갱신된다.

$$w_r^{m+1} = \frac{\int_0^\infty w |a_r^{m+1}(w)|^2 dw}{\int_0^\infty |a_r^{m+1}(w)|^2 dw} \quad (3)$$

Lagrangian multiplier는 다음과 같이 갱신된다.

$$\hat{\lambda}^{m+1}(w) = \hat{\lambda}^m(w) + \tau(\hat{a}(w) - \sum_r \hat{a}_r^{m+1}(w)) \quad (4)$$

τ 는 Lagrangian multiplier 갱신 파라미터이다.

Step 3. $m = m + 1$. 미수렴시에는 Step 2부터 다시 시작한다. 수렴 기준은 다음과 같다.

$$\sum_r \frac{\|\hat{a}_r^{m+1} - \hat{a}_r^m\|_2^2}{\|\hat{a}_r^m\|_2^2} < \epsilon \quad (5)$$

그림 2는 시간신호에 VMD를 적용하여 얻어진 모드신호

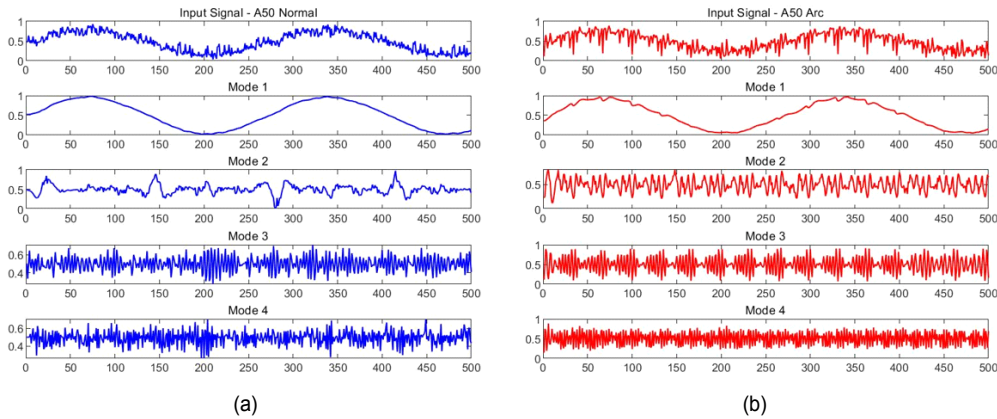


그림 2. 입력신호 및 VMD로 얻어진 4개의 모드 신호. (a) 정상 신호 및 (b) 아크 신호
 Fig. 2. Input signal and its decomposed four modes. (a) normal signal and (b) arc signal

를 보여준다. 정상신호 및 아크신호를 각각 $R=4$ 로 4개의 모드신호로 분할한다. 그림 2(a)는 정상신호, 2(b)는 아크신호이다. 1행은 입력신호 $a(t)$, 2~5행은 모드신호 a_1, a_2, a_3, a_4 를 보여준다. a_1 은 저주파 성분을 가지고, r 이 증가하면 모드신호는 고주파 성분을 가짐을 알 수 있다. 모드 신호들은 신호의 특성 차이를 보다 잘 보여준다. 이 차이는 아크검출의 성능 향상에 도움을 준다.

III. 제안 방법

본 장에서는 아크 분류를 위해 인공신경망을 이용하는데, 신경망의 입력으로 통계적 특징을 사용한다. 입력으로 원신호의 통계적 특징과 VMD 모드신호의 통계적 특징을 신경망으로 학습시키고, 검출 성능을 비교 검증한다.

1. 통계적 특징

아크 검출을 위해 사용된 특징의 종류는 매우 다양하다. 서론에서 언급한 것처럼, 본 논문의 목적은 아크 분류 성능의 개선을 위한 VMD의 활용이 목적이기 때문에, 새로운 특징을 제안하지 않고, Chakravorti1 등이 사용한 특징을 사용한다^[12].

표 1. 통계적 특징. \bar{A} , \hat{A} , σ 는 평균, 메디안, 표준편차이다.

Table 1. Statistical features. $\bar{A}_S, \hat{A}_S, \sigma_A$ are mean, median, and standard deviation of A_S .

Features	Expression	Entropy (f_4)	$\sum_{n=0}^{N-1} p(n) * \log_2 p(n)$
Median vs. mean (f_1)	$\frac{\bar{A}_S - \tilde{A}_S}{\sigma_A}$	Variance (f_5)	$\frac{1}{N-1} \sum_{n=1}^N A(n) - \mu ^2$
Median & mean difference (f_2)	$\tilde{A}_S - \bar{A}_S$	Kurtosis (f_6)	$\frac{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^4}{(\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2)^2}$
Energy (f_3)	$\sum_{n=0}^{N-1} A_k^2(n)$	Skewness (f_7)	$\frac{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^3}{(\sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2})^3}$

통계 기반 특징은 표 1에서 보여진다. $A(n)$ 은 이산 입력 신호이고, 표준화된 신호 $A_S(n)$ 는 다음 식과 같다.

$$A_S(n) = |A(n) - \hat{A}| \tag{6}$$

여기서 \hat{A} 은 $A(n)$ 의 메디안(median) 값이다.

R 개의 모드 신호에서는 두 모드 신호간의 연관성을 얻을 수 있는 특징을 얻을 수 있다. 예를 들어 두 모드 신호의 교차 상관도(cross correlation)를 활용할 수 있다. 두 모드 신호 $A(n)$ 과 $B(n)$ 의 교차 상관도 시퀀스 C 는 다음과 같이 정의된다.

$$\hat{C}_R(m) = \begin{cases} \sum_{n=0}^{N-m-1} A_{n+m} B_n, & m \geq 0 \\ \hat{C}_R(-m) & m < 0 \end{cases} \tag{7}$$

여기서 m 은 인덱스로 시간 이동(time shift) 파라메타이다.

신호의 표본 개수가 N 개일 때, C 는 $(2N-1)$ 개의 계수를 갖는다. 각각의 신호에서 VMD 모드들은 서로 다르고, 이를 분류하려 할 때 몇몇 특징들은 교차상관도에서 추출 되는데, 특징들은 표 2에서 자세히 기술된다. C_n 은 n 번째 계수이다.

표 2. 모드 교차상관도 기반 특징들

Table 2. Mode cross correlation-based features

Mode Features	Expression		
Centroid (f_1^C)	$\frac{\left[\sum_{n=-N}^N n C_n \right]}{\sum_{n=-N}^N C_n}$	Skewness (f_4^C)	$\frac{\sum_{n=-N}^N (C_n - \mu)^3}{2N\mu^3}$
Mean value (f_2^C)	$\sum_{n=-N}^N C_n / (2N+1)$	Kurtosis (f_5^C)	$\frac{\sum_{n=-N}^N (C_n - \mu)^4}{2N\mu^4}$
Standard deviation (f_3^C)	$\sqrt{\frac{\sum_{n=-N}^N (C_n - \mu)^2}{(2N+1)}}$		

표 1은 원신호에서 얻어지는 7개의 No-VMD 특징

f_i ($i \in [1,7]$)이고, VMD 피쳐는 표 1의 7개 및 표 2의 5개의 특징 f_i^C ($i \in [1,5]$)로 구성되기 때문에, 12개의 특징을 가지게 된다. $R=4$ 이면 4개의 모드신호로부터 교차상관도는 총 30개가 얻어지는데, 실험 결과 분별력이 좋은 것으로 판단된 $r=1$ 과 $r=3$ 을 선택하여 두 모드신호 간의 5개의 특징을 이용하였다. 따라서 No-VMD의 특징 차원은 7이고, VMD의 특징 차원은 12이다.

2. 아크 분류 심층 신경망

제안 방법의 흐름도는 그림 3에서 보여진다. No-VMD는 입력신호에서 표 1의 통계적 특징을 얻은 후에, 이 특징 벡터를 심층신경망(deep neural network: DNN)으로 학습한다. VMD에서는 원신호의 특징 및 표2의 VMD의 특징으로 특징 벡터를 구성한 후에 DNN으로 입력된다. 두 개 모두 동일한 구조의 DNN의 입력으로 사용된다. 출력은 이진 분류로 정상 또는 아크로 분류한다. 학습된 모델의 분류 정확

도를 비교하여 VMD의 성능 개선을 조사한다.

실험에서 사용하는 신경망은 DNN(Deep Neural Network)을 기반으로 한다. 입력 노드의 수는 입력될 특징 벡터의 차원과 동일하다. 출력층은 아크 신호와 정상 신호만을 분류하는 이진 분류(binary classification)이므로 두 개의 노드를 갖는다. 은닉층은 1~3개의 층으로 구성되며, 편의상 각각 H1-DNN, H2-DNN, H3-DNN으로 한다. VMD의 성능을 검증하기 위하여 다음 3가지 은닉층 노드 개수를 사용한다; (a) H1-DNN (512), H2-DNN (256 - 128), H3-DNN (128 - 64 - 32), (b) H1-DNN (256), H2-DNN (128 - 64), H3-DNN (64 - 32 - 8), 및 (c) H1-DNN (128), H2-DNN (64 - 32), H3-DNN (32 - 16 - 8). 객관적 검증을 위해서 다양한 깊이 및 폭을 사용한다. 출력층에서는 활성 함수로 Softmax 함수를 사용하고, 이외의 모든 계층에서는 ReLU이다. 가중치 초기화는 He 초기화를 사용하고, 학습률은 0.001이다.




그림 3. 제안 방법의 전체 흐름도.
 Fig. 3. The overall block diagram of the proposed method

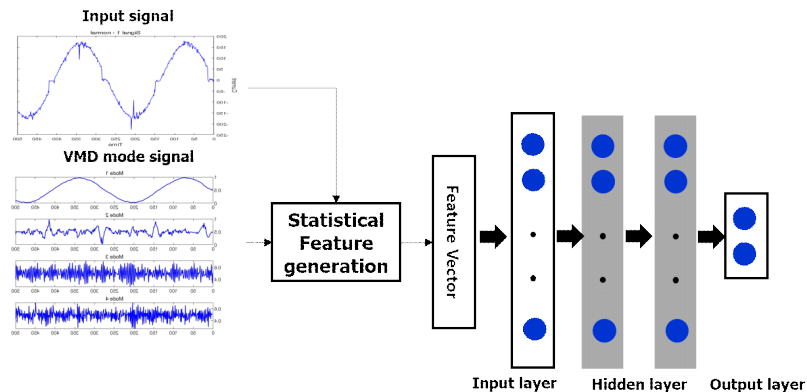


그림 4. 실험에 사용한 심층 신경망 모델
 Fig. 4. Deep neural network used in experiments

IV. 실험 결과 및 분석

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. 표 3은 데이터의 7가지 부하 종류를 보여준다. 부하별 정상신호 및 아크신호를 생성하였다. S_1 은 부하로 조광기(dimmer)와 백열등(incandescent lamp)을 사용하여 얻은 신호이다, 샘플링 주파수는 16kHz이다. 따라서 신호의 한 주기에서 269개의 샘플을 얻는다. 2 주기에서는 538개의 샘플이 있다. 각 신호 데이터에는 아크(1), 정상(0)으로 해당 레이블이 할당

표 3. 아크 데이터의 부하 종류
Table 3. 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)

된다.

학습 신호는 2주기의 538 샘플을 가지며, 부하별 아크신호는 1,000개, 정상신호는 1,000개의 데이터를 수집하였다. 따라서 총 $1,000 \times 7 \times 2 = 14,000$ 개의 학습 데이터를 생성하였다. 그림 5는 표 3의 S_2, S_4, S_7 의 정상신호와 아크신호의 예를 보여준다. 이 신호로부터 통계적 특징을 추출한다. 각 학습 데이터는 정상이면 레이블을 0, 아크이면 1로 클래스를 할당하여, 지도학습 이진 분류 신경망으로 학습한다.

비교 설명을 위해서 그림 5의 S_4 의 정상신호와 아크신호의 VMD 모드 신호는 그림 6에서 보여진다. 2~5행의 $R=4$ 개의 모드 신호를 관찰하면, 입력신호보다 신호의 차이를 알 수 있다. 실험에서는 $R > 4$ 이면 VMD의 처리시간이 증가하는 반면에, 뚜렷한 성능 개선은 없다. $R=2, 3$ 이면 검출능력의 저하가 발생하기 때문에, 실험에서는 $R=4$ 를 선택하였다.

그림 7은 통계적 특징의 분포를 보기 위해서 입력 데이터를 t-SNE(t-distributed stochastic neighbor embedding)로 시각화한 그림이다. t-SNE는 특징의 차원을 2차원 또는 3차원으로 축소하는 기술인데, 최근접점을 2~3차원으로 매핑해 차원을 축소한다^[13]. No-VMD와 VMD 모두 통계적 특징이 만족스럽게 arc([0,1])과 정상([1,0])으로 분류되는 것을 알 수 있지만, 일부 공간에서 겹침이 발생한다. 이것은

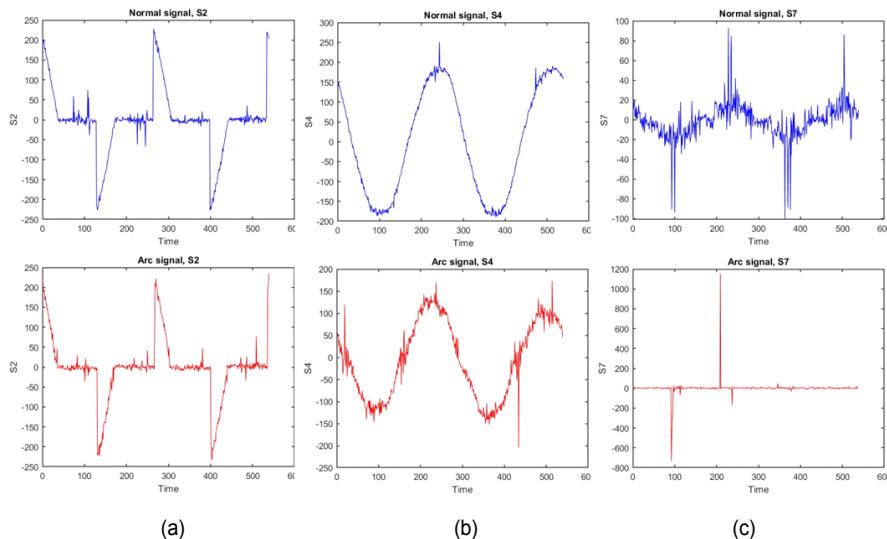


그림 5. 정상 및 아크 신호의 예. 1행은 정상, 2행은 아크임. (a) S_2 , (b) S_4 및 (c) S_7
Fig. 5. Examples of normal and arc signals. Top: normal, Bottom: arc. (a) S_2 , (b) S_4 and (c) S_7

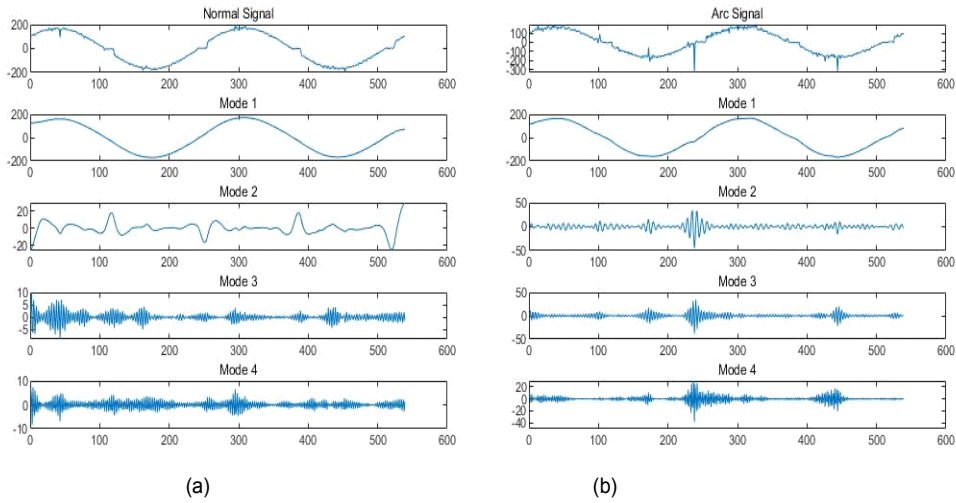


그림 6. S₄의 2-cycle 신호의 VMD 모드 신호. R=4. (a) 정상신호 및 (b) 아크신호
 Fig. 6. VMD mode signals of 2-cycle of S₄. R=4. (a) normal and (b) arc signals.

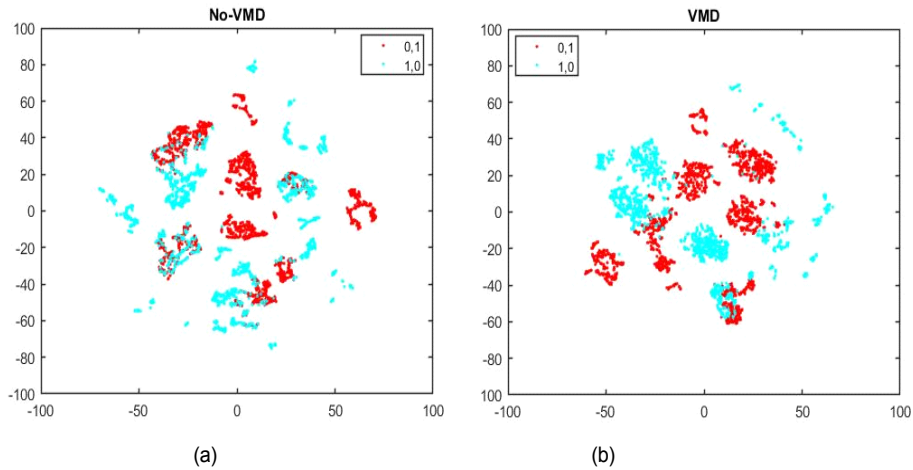


그림 7. 시각적 분류를 위해 t-SNE로 얻은 통계적 특징 분류. (a) No-VMD 및 (b) VMD
 Fig. 7. t-SNE visualization of classification. (a) No-VMD and (b) VMD

100%에 가까운 성능을 얻는 것이 쉽지 않다는 것을 보여준다. 서론에서 언급한 것처럼 본 연구는 통계적 특징과 아크 분류의 성능의 관계를 조사하는 것은 아니고, VMD가 No-VMD보다 성능을 개선한다는 것을 검증하는 것이다. 실험에서 사용한 데이터의 정제 및 DNN의 구현은 MATLAB 2018a 버전에서 이루어졌다. 입력 데이터의 80%는 학습데이터로 사용하고 20%는 테스트 데이터로 사용하였다. 동일한 구조의 신경망 모델에 No-VMD 특징 및 VMD 특징을 각각 입력으로 사용하여 학습시킨 후 테스트 단계에서 분

류 정확도(classification accuracy)를 측정하였다. 그림 8~10은 H1-DNN부터 H3-DNN까지 DNN에서 이진 분류 데이터 셋의 분류 정확도를 비교한 그래프이다. 수평축은 에폭이고 200으로 고정하였다. 수직축은 분류 정확도이다. 은닉층의 뉴런 개수는 은닉층의 개수에 따라, [128, 64-32, 32-16-8], [256, 128-64, 64-32-16], [512, 256-128, 128-63-32]의 3종류를 사용한다. 그림의 1행은 No-VMD, 2행은 VMD이다. 전체적으로 VMD가 No-VMD보다 향상된 결과를 보여주고 있다.

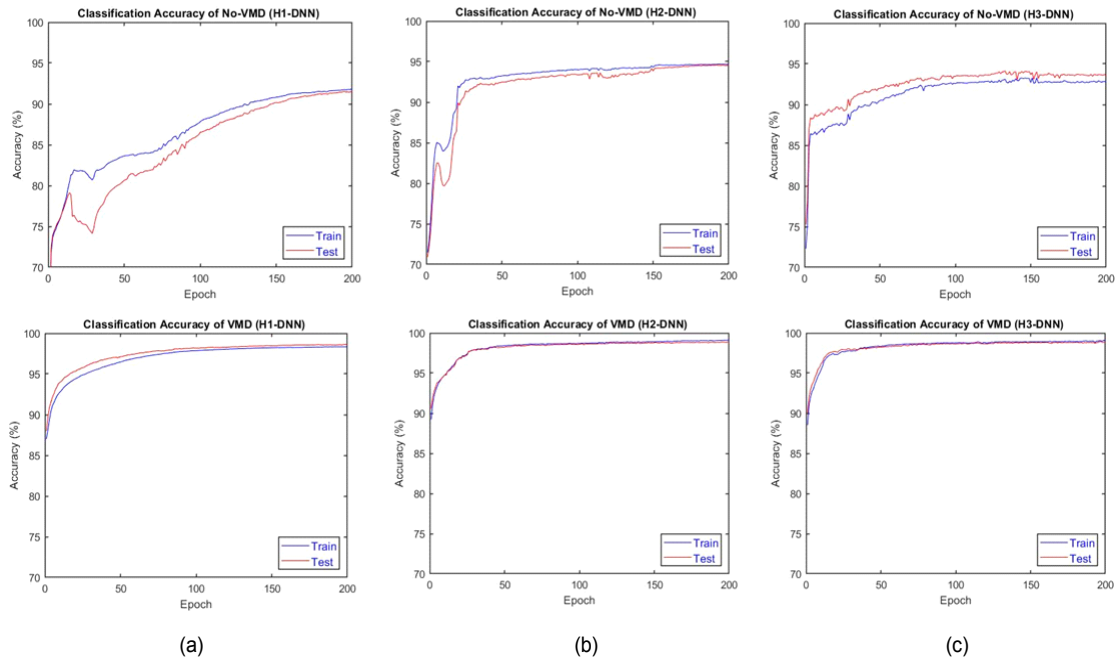


그림 8. 신경망으로부터 얻은 분류 정확도. (a) H1-DNN (128), (b) H2-DNN (64-32) 및 (c) H3-DNN (32-16-8)
 Fig. 8. Classification accuracy of DNN. (a) H1-DNN (128), (b) H2-DNN (64-32) and (c) H3-DNN (32-16-8)

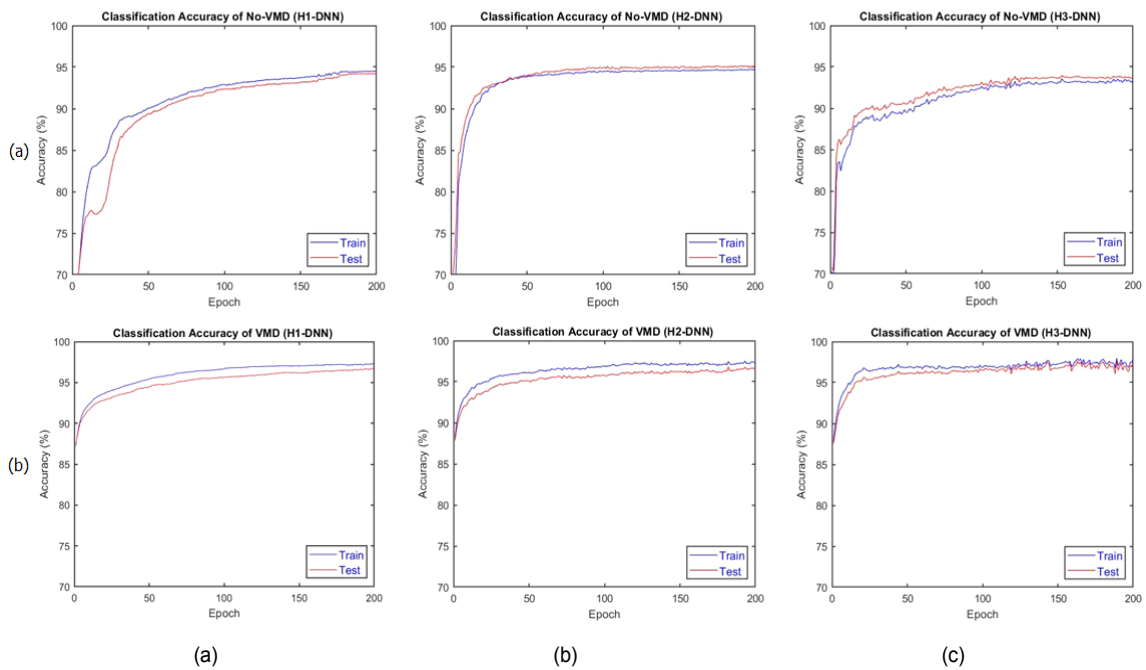


그림 9. 신경망으로부터 얻은 분류 정확도. (a) H1-DNN (256), (b) H2-DNN (128-64) 및 (c) H3-DNN (64-32-16)
 Fig. 9. Classification accuracy of DNN. (a) H1-DNN (256), (b) H2-DNN (128-64) and (c) H3-DNN (64-32-16)

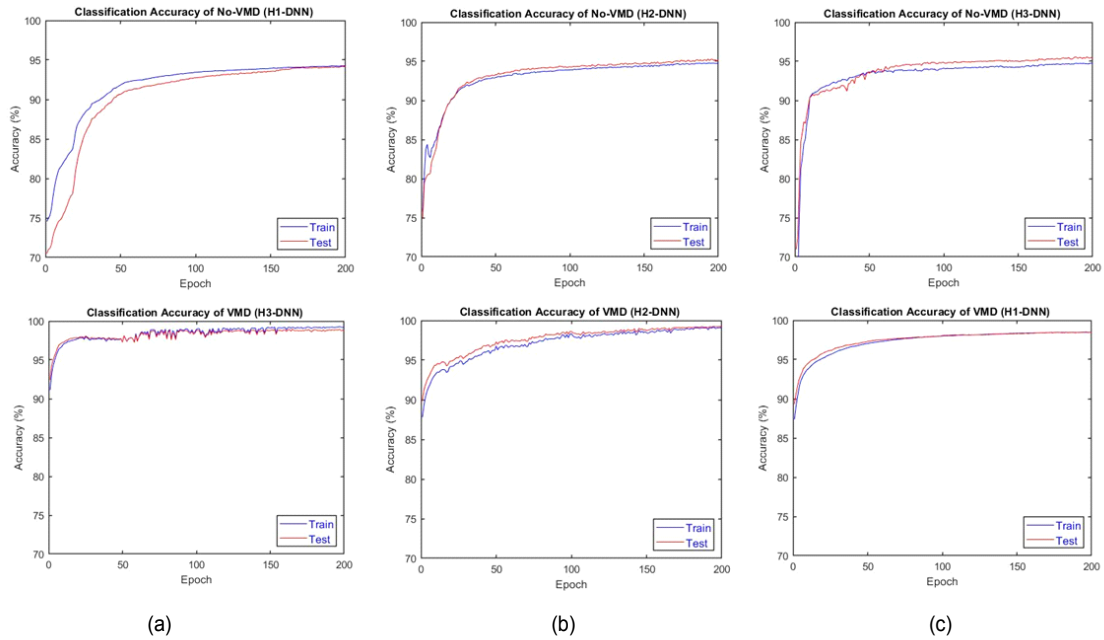


그림 10. 신경망으로부터 얻은 분류 정확도. (a) H1-DNN (512) (b) H2-DNN (256-128) 및 (c) H3-DNN (128-64-32)
 Fig. 10. Classification accuracy of DNN. (a) H1-DNN (512) (b) H2-DNN (256-128) and (c) H3-DNN (128-64-32)

표 4. No-VMD와 VMD의 분류 정확도 성능 비교 (단위: %)
 Table 4. Comparison of classification accuracy of No-VMD and VMD (unit: percent)

Figure	DNN Model	No. of nodes	No-VMD		VMD		Increment	
			Train	Test	Train	Test	Train	Test
Fig. 8	H1-DNN	128	91.84	91.57	98.34	98.59	6.50	7.02
	H2-DNN	64-32	94.68	94.59	99.13	98.82	4.45	4.23
	H3-DNN	32-16-8	92.84	93.70	99.08	98.84	6.24	5.14
Fig. 9	H1-DNN	256	94.51	94.18	97.31	96.70	2.80	2.52
	H2-DNN	128-64	94.68	95.15	97.20	96.52	2.52	1.37
	H3-DNN	64-32-16	93.33	93.80	97.90	97.58	4.57	3.78
Fig. 10	H1-DNN	512	94.30	94.17	98.46	98.47	4.16	4.30
	H2-DNN	256-128	94.75	95.17	99.01	99.18	4.26	4.01
	H3-DNN	128-64-32	94.74	95.46	99.18	98.78	4.44	3.32
Avg.			93.96	94.20	98.40	98.16	4.44	3.97

표 4는 No-VMD와 VMD의 분류 정확도를 숫자로 표시한 것이다. 그림 8의 H1-DNN에서 No-VMD는 (Train, Test)=(91.84%, 91.57%), VMD는 (Train, Test)=(98.34%, 98.59%)로 증가분(increment)은 (Train, Test)=(6.50, 7.02)%로 성능이 개선됨을 알 수 있다. DNN의 구조에 따라 다소 편차는 있지만, 평균 증가분은 (Train, Test)=(4.44%, 3.97%)

을 얻었다. 각각 세 가지의 깊이와 폭을 가지는 신경망 모델 모두에서 VMD를 사용할 때가 No-VMD보다 정확도가 향상되는 것을 확인할 수 있다. Test의 최대 증가는 그림 8의 H1-DNN(128)에서 7.02%이고, 최소 증가는 그림 9의 H2-DNN(128-64)의 1.37%이다.

V. 결 론

전기신호에서 발생하는 아크신호의 검출은 화재의 위험 때문에, 높은 수준의 검출률이 필요하다. 기존의 아크 검출 기법들은 다양한 특징을 사용하지만, 완벽한 성능을 얻는 것이 어렵다. 본 논문에서는 전기신호의 통계적 특징을 이용하여 아크 검출을 하는 기법에 VMD를 추가하여 검출 성능을 개선할 수 있음을 신경망 기반으로 증명하였다. 다양한 깊이와 폭을 가지는 신경망 모델에 적용한 결과 모델 구조에 따라 약간의 차이는 있지만, 평균적으로 (Train, Test)=(4.44%, 3.97%)의 성능 향상 결과를 얻었다. VMD가 성능 향상에 도움이 되는 것을 알 수 있다.

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] 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.
- [8] 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.
- [9] S. Bang, J. Park, M. Jang, and W. Choi, "Analysis of series arc-fault signal using wavelet transform form non-linear loads". *Trans. Korean Institute of Electrical Engineers*, Vol. 57, No. 8, 2008.
- [10] G. Yunmei, W. Li, W. Zhuoqi, and J. Bin Feng, "Wavelet packet analysis applied in detection of low-voltage DC arc fault", *IEEE Industrial Electronics and Applications*, 2009.
- [11] K. Dragomiretskiy and D. Zosso, "Variational Mode Decomposition", *IEEE Tran. Signal Processing*, Vol. 62, No. 3, Feb. 2014.
- [12] T. Chakravortil and P. Dash, "Multiclass power quality events classification using variational mode decomposition with fast reduced kernel extreme learning machine-based feature selection", *IET Sci. Meas. Technol.*, Vol. 12, Iss. 1, pp. 106-117, 2018.
- [13] L. Maaten and G. Hinton, "Visualizing Data using t-SNE", *Journal of Machine Learning Research*, Vol. 9, pp. 2579-2605, 2008.

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



이 승 수

- 2017년 8월 : 강원대학교 IT대학 컴퓨터정보통신공학과 학사
- 2017년 9월 ~ 현재 : 강원대학교 컴퓨터정보통신공학과 석사과정
- 주관심분야 : 점유센서, 딥러닝, 머신러닝



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 : <https://orcid.org/0000-0002-4702-8276>
- 주관심분야 : 컴퓨터비전, 3D영상처리, 머신러닝응용