

일반논문 (Regular Paper)

방송공학회논문지 제26권 제5호, 2021년 9월 (JBE Vol.26, No.5, September 2021)

<https://doi.org/10.5909/JBE.2021.26.5.566>

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

로지스틱 회기를 이용한 아크 검출

김만배^{a)‡}

Arc Detection using Logistic Regression

Manbae Kim^{a)‡}

요약

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. 그러나, 딥러닝의 문제는 연산 복잡도가 높다는 것이다. 이 문제는 단말기에 딥러닝 연산 모듈을 넣기가 어렵게 한다. 따라서 본 논문에서는 복잡도가 상대적으로 낮은 기계학습 기법중에 로지스틱회기 (logistic regression)를 이용하여 아크 검출을 하는 기법을 제안한다.

Abstract

The 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. On the contrary, Deep neural network (DNN) directly utilizes raw data without feature extraction, based on end-to-end learning. However, a disadvantage of the DNN is processing complexity, posing the difficulty of being migrated into a terminal device. To solve this, this paper proposes an arc detection method using a logistic regression that is one of simple machine learning methods.

Keywords : arc detection, logistic regression, frequency spectrum, FFT

a) 강원대학교 컴퓨터정보통신공학과(Kangwon National University, Dept. of Computer & Communications Engineering)

‡ Corresponding Author : 김만배(Manbae Kim)

E-mail: manbae@kangwon.ac.kr

Tel: +82-33-250-6395

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

※ This research was supported by the MSIT(Ministry of Science and ICT), Korea, under the ITRC (Information Technology Research Center) support program (IITP-2021-2018-0-01433) supervised by the IITP (Institute for Information & Communications Technology Promotion)

· Manuscript received May 17, 2021; Revised July 19, 2021; Accepted August 11, 2021.

1. 서론

2014년 소방방재청의 화재 통계연감에 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 전기 화재 원인의 공통점은 아크(arc)를 동반하는 것이다. 그림 1은 정상 신호와 아크 신호의 한가지 예를 보여준다.

아크 신호 검출은 가정, 공장, 스마트 공장, 스마트 팜에서 중요한 사안이다^[1,2]. 예를 들어 스마트팜에서 아크로 화재 또는 온도, 습도, CO2 등의 공급이 중단되면 한해 농사를 모두 망치게 되는 큰 손실이 발생한다. 또한 가정의 화재, 공장 화재 등도 물질적, 금전적으로 많은 손실이 발생한다. 따라서 아크 검출은 매우 중요한 기술이다.

아크 신호 검출을 위해 다양한 방법들이 사용되어왔다. 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. 신경망 모델로는 심층신경망(deep neural network)^[3,4,5], 자기부호화기(auto-encoder)^[6], 합성곱신경망(convolutional neural network)^[7] 등을 활용한다. 입력신호에서 아크 검출에 필요한 특징(feature)을 찾은 후에, 이 특징을 입력으로 분류 모델을 확

습하여 아크 신호를 검출하게 된다. 특징으로는 주로 주파수(frequency), 통계적 특징(statistical feature) 등을 사용한다. 푸리에변환^[8], 웨이블릿(wavelet)변환^[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.

상기 딥러닝 모델들은 계산 복잡도 때문에 단말기에 적용하는 것이 어려운 실정이다. 따라서 단말기에 아크 검출 모듈을 넣기 위해서는 계산 복잡도가 낮은 기계학습 방법을 이용한 고속 아크 검출이 필요함과 동시에, 아크 검출 성능도 만족스러워야 한다. 본 연구에서는 로지스틱 회기(logistic regression)로 아크 검출을 하는 방법을 제안한다. 제안 방법의 장점은 다음과 같다.

- 기존 딥러닝 모델들은 복잡도 때문에, 해결 방법으로 기계학습 기법중의 하나인 로지스틱회기를 사용한다. 따라서 상대적으로 고속 처리가 가능하다.
- 푸리에 변환으로 얻은 전체 주파수대역(frequency bandwidth)중 일부 대역 구간만 사용함으로써 속도 향상이 가능하다.
- 추론(inference)에서는 로지스틱 회기의 출력 데이터인 연속 ϕ 값에 이동평균(moving average)을 이용하여 노이즈에 강하게 되고, 성능을 개선한다.

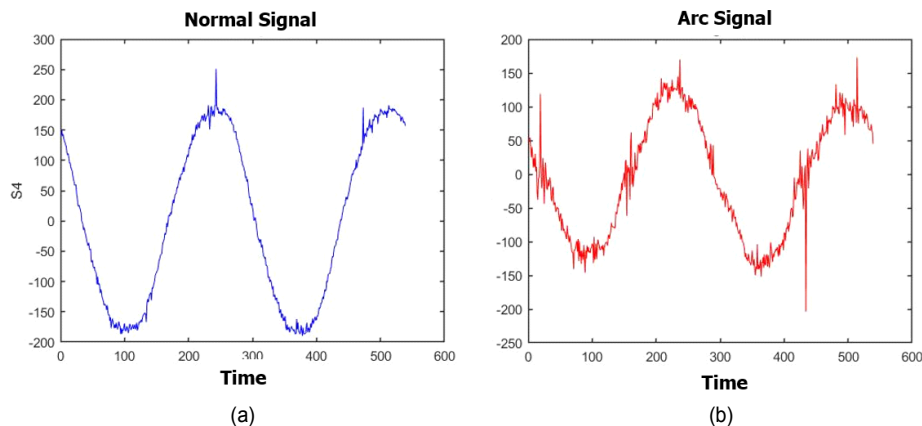


그림 1. 정상 신호와 아크 신호의 예. (a) 정상 신호 및 (b) 아크 신호
 Fig. 1. An example of normal and arc signals. (a) normal signal and (b) arc signal

II. 로지스틱 회귀

로지스틱 회귀(logistic regression)는 독립 변수의 선형 결합을 이용하여 사건의 발생 가능성을 예측하는데 사용되는 통계 기법이다. 로지스틱 회귀의 목적은 일반적인 회귀 분석의 목표와 동일하게 종속 변수와 독립 변수간의 관계를 함수로 나타내어 향후 예측 모델에 사용하는 것이다. 이는 독립 변수의 선형 결합으로 종속 변수를 설명한다는 관점에서는 선형 회귀 분석과 유사하다. 하지만 로지스틱 회귀는 선형 회귀 분석과는 다르게 종속 변수가 범주형 데이터를 대상으로 하며 입력 데이터가 주어졌을 때 해당 데이터의 결과가 특정 분류로 나뉘기 때문에 분류(classification) 기법에 해당된다.

일반적인 회귀 분석법은 독립 변수들에 의해서 종속 변수의 변화가 선형으로 변한다고 가정하기 때문에 아크, 정상 종속 변수가 아크의 발생 유무로 표시되는 이항적인 사건을 다루는 데에는 적합하지 않다.

이에 반하여 종속 변수와 독립 변수와의 관계를 비선형이라 가정하여 로지스틱 회귀 변수를 추정하는 로지스틱 회귀분석은 두 개의 값만 가지는 종속 변수와 독립 변수들의 관련성을 분석할 수 있다.

따라서 본 연구에서는 아크 검출을 위해 로지스틱 회귀 분석을 사용하며, 이를 위해 종속 변수로서는 아크 또는 정상 신호 여부, 독립 변수로는 주파수 대역(frequency bandwidth)을 사용하여 종속 변수와 독립 변수간의 관계를 추정한다.

일반적으로 회귀 분석에서의 모형은 주어진 독립 변수 x_1, x_2, \dots, x_k 하에서 종속 변수가 독립 변수에 대한 선형식으로 아래의 식 (1)과 같이 표현된다.

$$z = \beta_0 + \beta_1 x_1 + \dots + \beta_k x_k = [1 \ x_1 \ \dots \ x_k] \begin{bmatrix} \beta_0 \\ \beta_1 \\ \vdots \\ \beta_k \end{bmatrix} \quad (1)$$

여기서 $[\beta_0, \beta_1, \dots, \beta_k]$ 는 회귀 파라메타이다.

그러나, 아크, 정상의 이분형 종속 변수인 경우에 z 는 아크가 발생하게 되는 확률로의 변환이 필요하다. 여기서 z 의

범위가 $-\infty$ 에서 $+\infty$ 의 값을 가지면 값은 확률이므로 $[0,1]$ 의 확률값만을 가질 수 있으며, 확률은 S자형에 가까운 곡선의 모형을 가지게 되며 이러한 특성은 아크의 발생 유무를 확률로 변환시킬 수 있는 장점을 가진다. 따라서 식 (2)처럼 로지스틱 시그모이드 (sigmoid) 함수로 나타낼 수 있다. (그림 2)

$$\phi(z) = \frac{1}{1 + e^{-z}} \quad (2)$$




그림 2. 로지스틱 시그모이드 함수 $\phi(z)$. 입력값 $z=0$ 일때 ϕ 는 0.5이다.
Fig. 2. Logistic sigmoid function $\phi(z)$. ϕ is 0.5 at $z=0$

로지스틱 회귀는 감독학습(supervised learning)에 속해서, 학습 데이터마다 레이블(label)이 있다. 예를 들어 레이블은 아크=0, 정상=1로 해서 학습하게 된다. 식 (2) 및 그림 2를 보면 $\phi \geq 0.5$ 이면 정상, 반대이면 아크로 판정한다.

III. 로지스틱 회귀 학습

그림 3은 로지스틱 회귀의 학습단계의 흐름도를 보여준다. P 주기(cycle) 시간신호 $x(t)$ 가 주어지면 주파수 변환 방법인 푸리에변환(Fourier Transform)으로 주파수 스펙트럼(spectrum)을 얻는다. P는 일반적으로 1, 2이다. 스펙트럼의 주파수는 $[f_0, f_1, \dots, f_N]$ 이다. 아크와 정상신호는 특정 주파수 대역폭(bandwidth)에서 다른 특징을 가지고 있다. 따라서 $[f_0, f_N]$ 의 범위에서 분류 성능이 가장 우수한 최적 대역을 찾는 것이 학습의 주 목적이다. 이를 위해서 학습 데

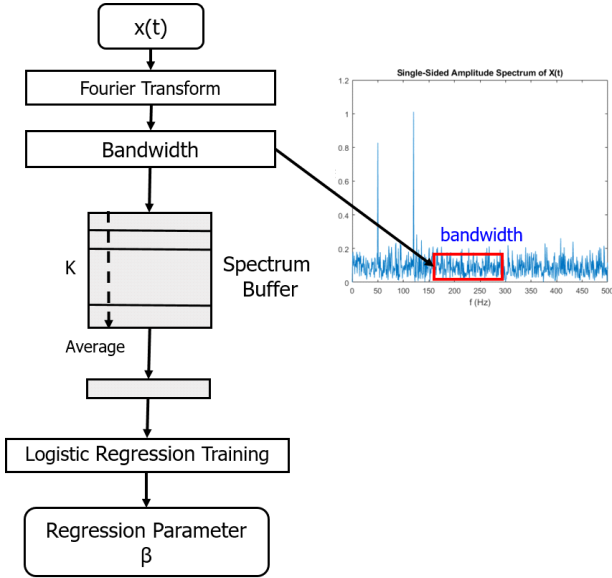


그림 3. 로지스틱 회기 학습
Fig. 3. Training of Logistic regression

이터가 주어지면 대역폭의 구간 범위를 그림 4처럼 설정한다. L개의 구간을 사용하면, 1개의 구간 범위 Δf 는 다음과 같이 계산된다.

$$\Delta f = \frac{f_N - f_0}{L} \quad (3)$$




그림 4. $[f_0, f_N]$ 을 L개의 구간으로 분할함
Fig. 4. Decomposing $[f_0, f_N]$ with L intervals

따라서 L개의 구간 범위는

$$[f_0, f_0 + \Delta f], [f_0 + \Delta f, f_0 + 2\Delta f], [f_0 + 2\Delta f, f_0 + 3\Delta f], \dots, [f_0 + (L-1)\Delta f, f_0 + L\Delta f] \quad (4)$$

이다.

각 주파수 구간에서의 주파수 스펙트럼은 $[0,1]$ 로 정규화된다.

여기서 단일 신호별로 처리하면, 잡음 등의 영향으로 데이터의 신뢰도가 낮아지기 때문에, 연속 신호의 스펙트럼 평균을 구한 후에 활용한다. 이를 위해서 스펙트럼 버퍼 (spectrum buffer)를 사용한다.

버퍼 크기(buffer size)는 K이고, 연속으로 입력되는 스펙트럼은 버퍼에 저장된다. 버퍼에는 최근 K개의 스펙트럼이 저장된다. 그림 5는 스펙트럼 버퍼의 구조를 보여준다. 입력 주파수 스펙트럼은 K개를 저장할 수 있는 버퍼에 입력 순서대로 저장된다.




그림 5. K개의 스펙트럼을 저장하는 스펙트럼 버퍼
Fig. 5. Spectrum buffer containing K spectrms

스펙트럼 버퍼에 저장된 K개의 주파수 스펙트럼은 다음과 같다.

$$\begin{aligned} & [f_i^1, f_{i+1}^1 \dots f_{i+\Delta f-1}^1] \\ & [f_i^2, f_{i+1}^2 \dots f_{i+\Delta f-1}^2] \dots \\ & \dots \\ & [f_i^K, f_{i+1}^K \dots f_{i+\Delta f-1}^K] \end{aligned} \quad (5)$$

여기서 f_i^k 에서 i 는 대역폭의 첫 번째 주파수, k 는 스펙트럼 버퍼의 라인 번호이다. $k \in \{1, K\}$

스펙트럼 버퍼에 저장된 K개의 스펙트럼의 평균 X 을 계산한다.

$$X = [1 \ x_0, x_1, x_2, \dots, x_{\Delta f-1}] \quad (6)$$

X 의 첫 번째 원소인 1은 식 (1)의 회기식에서 절편 (offset)인 β_0 때문에 필요하다.

$x_0, x_1, \dots, x_{\Delta f-1}$ 는 다음과 같이 수직 성분의 평균값이다.

$$\begin{aligned}
 x_0 &= \frac{1}{\Delta f} \sum_{k=1}^K f_i^k \\
 x_1 &= \frac{1}{\Delta f} \sum_{k=1}^K f_{i+1}^k \\
 x_2 &= \frac{1}{\Delta f} \sum_{k=1}^K f_{i+2}^k \\
 &\dots \\
 x_{\Delta f-1} &= \frac{1}{\Delta f} \sum_{k=1}^K f_{i+\Delta f-1}^k
 \end{aligned} \tag{7}$$

로지스틱 회기 모델의 입력은 X 이다.

학습에서는 먼저 회기 파라메타 β 의 초기값을 설정한다. 일반적으로 정규분포, $[0,1]$ 분포 또는 모두 0으로 초기화한다. β 의 크기는 $(\Delta f + 1) \times 1$ 이다.

학습에서 갱신 회수인 에폭(epoch)에 따라 다음 식 (8), (9)를 이용하여 경사 하강법(gradient descent)으로 계속 z, β 를 갱신한다.

$$\phi(z) = \frac{1}{1 + \exp(-X\beta)} \tag{8}$$

$$\beta = \beta + \alpha X^T (Z - \phi(z)) \tag{9}$$

여기서 α 는 학습률(learning rate), Z 는 실제 신호의 레이블로 아크 신호이면 0, 정상 신호이면 1이다. $Z \in \{0,1\}$. $(\cdot)^T$ 는 (\cdot) 의 전치행렬(transpose)이다.

에폭만큼 갱신이 완료되면 최종 β 값인 β^* 가 구해진다. 이 β^* 값은 다음 장에서 추론에 활용된다. 또한 분류 정확도(classification accuracy)가 가장 높은 구간 $[f_s^*, f_e^*]$ 을 탐색한다. $f_e^* = f_s^* + \Delta f$. 즉, 식 (4)의 주파수 구간에서 가장 분류 정확도가 높은 구간을 선택한다. n 번째 구간에서 정확도가 가장 높으면, 최종 선택한 구간은

$$[f_s^*, f_e^*] = [f_0 + (n-1)\Delta f, f_0 + n\Delta f] \tag{10}$$

이다.

IV. 로지스틱 회기 추론

학습 단계에서 최적의 대역폭 식 (10)의 $[f_s^*, f_e^*] = [f_0 +$

$(n-1)\Delta f, f_0 + n\Delta f]$ 와 식 (9)의 회기 파라메타 β^* 가 얻어지면 이를 이용하여 입력신호의 추론(inference)을 수행한다. 이 추론과정은 실제 아크 검출 단말기에 탑재될 기계학습 모듈이다.

그림 6은 추론 단계의 흐름도이다.

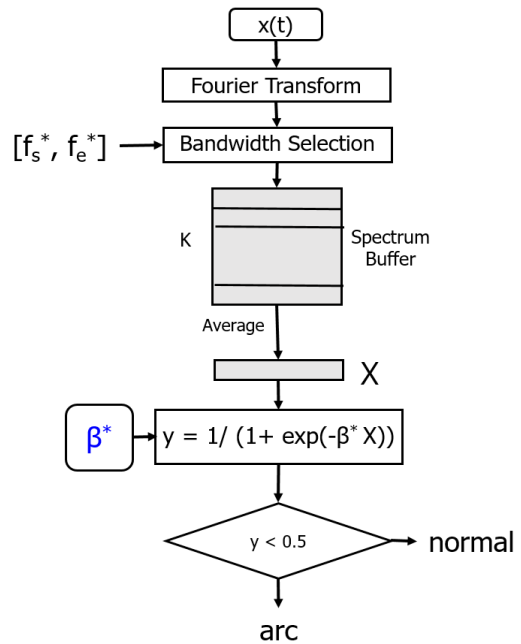


그림 6. 추론 엔진의 흐름도
Fig. 6 Flow diagram of the inference engine

입력으로 시간신호 $x(t)$ 가 입력되면 푸리에변환으로 주파수 스펙트럼을 얻는다. 이 스펙트럼에서 최적 대역폭인 $[f_s^*, f_e^*]$ 구간의 스펙트럼만을 추출한다. 이 스펙트럼은 스펙트럼 버퍼에 저장하고, 이 버퍼의 크기는 K 이다. 즉 K 개의 최근 스펙트럼이 저장된다.

버퍼에 저장된 K 개의 스펙트럼은 다음과 같다.

$$\begin{aligned}
 &[f_i^1, f_{i+1}^1 \dots f_{i+\Delta f-1}^1] \\
 &[f_i^2, f_{i+1}^2 \dots f_{i+\Delta f-1}^2] \\
 &\dots \\
 &[f_i^K, f_{i+1}^K \dots f_{i+\Delta f-1}^K]
 \end{aligned} \tag{11}$$

$i = f_s^*, i + \Delta f - 1 = f_e^*$ 이다.

스펙트럼 버퍼에 저장된 K개의 스펙트럼의 평균 X를 계산한다.

$$X = [x_0, x_1, x_2, \dots, x_{\Delta f-1}] \quad (12)$$

$x_0, x_1, x_2, \dots, x_{\Delta f-1}$ 는 다음과 같이 수직 성분의 평균값이다.

$$\begin{aligned} x_0 &= \frac{1}{\Delta f} \sum_{k=1}^K f_i^k \\ x_1 &= \frac{1}{\Delta f} \sum_{k=1}^K f_{i+1}^k \\ x_2 &= \frac{1}{\Delta f} \sum_{k=1}^K f_{i+2}^k \\ &\dots \\ x_{\Delta f-1} &= \frac{1}{\Delta f} \sum_{k=1}^K f_{i+\Delta f-1}^k \end{aligned} \quad (13)$$

다음에 로지스틱회기에 다음 신호가 입력되면

$$X = [1, x_0, x_1, x_2, \dots, x_{\Delta f-1}] \quad (14)$$

로지스틱 함수인 $\phi(z)$ 를 구한다.

$$\phi(z) = \frac{1}{1 + e^{-X\beta}} \quad (15)$$

$\phi(z)$ 가 구해지면, 다음 식을 이용하여 아크 또는 정상 신호를 결정하게 된다.

$$\text{레이블} = \begin{cases} \text{아크} & \text{if } \phi(z) \leq 0.5 \\ \text{정상} & \text{otherwise} \end{cases} \quad (16)$$

V. 실험 결과 및 분석

1. 아크 데이터 획득

정상신호와 아크신호 데이터는 한국전기안전공사 전기 안전연구원에서 아크 생성기(arc generator)를 이용하여 제

표 1. 아크 데이터의 부하 종류

Table 1. Load types of arc data

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)

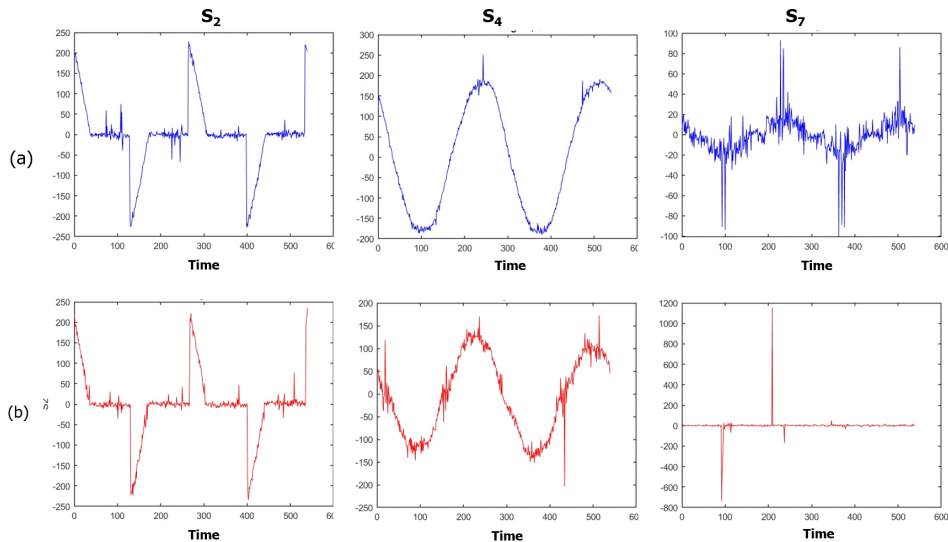


그림 7. 정상 및 아크 신호의 예. (a) 정상 신호 및 (b) 아크 신호

Fig. 7. Examples of normal and arc signals. (a) normal signals and (b) arc signals

작하였다. 총 7개의 부하(load) S_i ($i \in 1, \dots, 7$)가 있으며, S_i 는 각각 정상신호와 아크신호의 데이터로 구성된다. 표 1은 데이터의 7가지 부하 종류를 보여준다. 부하별 정상신호 및 아크신호를 생성하였다. S_1 는 부하로 조광기(dimmer)와 백열등(incandescent lamp)을 사용하여 얻은 신호이다, 샘플링 주파수는 16KHz이다. 따라서 신호의 한 주기에서 200개의 샘플을 얻는다. 각 신호 데이터에는 아크(0), 정상(1)으로 해당 레이블이 할당된다.

그림 7은 표 1의 S_2, S_4, S_7 의 정상 신호와 아크 신호의 예를 보여준다. 각 학습 데이터는 정상이면 레이블을 1, 아크이면 0으로 클래스를 할당하여, 지도학습 이진 분류 로지스틱 회기로 학습한다.

2. 분류 성능

주파수 대역 $[f_0, f_N]$ 은 $L=5$ 의 구간으로 분리한다. 최대 주파수 f_N 이 500이면, $[0, 100], [100, 200], [200, 300], [300, 400], [400, 500]$ 으로 분리한 후에 각각 얻은 분류 정확도는 표 2에서 보여진다. 분류 정확도는 각 대역에서 96.25%, 96.41%, 94.89%, 96.14%, 90.04%인데, 이중 $[100, 200]$ 에서 최대 정확도인 96.41%을 얻는다.

표 2. 주파수 대역별 분류 정확도
Table 2. Classification accuracy with respect to frequency bandwidth

번호	주파수 대역 (Hz)	분류 정확도 (%)
2	[0, 100]	96.25
3	[100, 200]	96.41
4	[200, 300]	94.89
5	[300, 400]	96.14
6	[400, 500]	90.64

따라서 추론 단계에서는 입력으로 $x(t)$ 가 입력되면, 푸리에 변환 후에 얻은 주파수 스펙트럼에서 $[100, 200]$ 의 구간 데이터를 추출한다. 추출된 데이터에 로지스틱 회기를 구한다.

$$X = [1, f_{100}, f_{101}, \dots, f_{200}] \quad (17)$$

$z = X\beta^*$ 이므로

$$z = [1, f_{100}, f_{101}, \dots, f_{200}] \begin{bmatrix} \beta_0 \\ \beta_1 \\ \vdots \\ \beta_{101} \end{bmatrix} \quad (18)$$

로지스틱 함수인 $\phi(z)$ 를 구한다.

$$\phi(z) = \frac{1}{1 + e^{-X\beta}} \quad (19)$$

$\phi(z)$ 가 구해지면, 마지막으로 다음 식을 이용하여 아크 또는 정상 신호를 결정한다.

$$\text{레이블} = \begin{cases} \text{아크} & \text{if } \phi(z) \leq 0.5 \\ \text{정상} & \text{otherwise} \end{cases} \quad (20)$$

표 3은 16 KHz 샘플링률의 신호에 대한 로지스틱회기의 분류성능을 보여준다. 주파수 대역과 스펙트럼 버퍼 크기 K에 따라 성능의 변화가 관찰된다. 같은 주파수 대역에서 버퍼 크기를 증가하면, 일반적으로 더 우수한 분류 성능을 얻을 수 있다. 가장 우수한 분류 성능은 $f=[1,200], K=40$ 일 때 99.03%이다. K를 20으로 줄이면 98.56%로 소폭 감소한다. K=1이면 대체적으로 93~94%을 보여주고 있다. 이 결과는 스펙트럼 버퍼 활용의 중요성을 보여준다. 주파수 대

표 3. 로지스틱 회기를 이용한 16 KHz 신호의 아크 성능
Table 3. Arc classification of 16KHz signals by logistic regression

Bandwidth	Spectrum Buffer Size	Classification Accuracy
[1, 100]	1	92.21
[1, 100]	20	97.03
[1, 100]	40	96.32
[1, 200]	1	93.12
[1, 200]	20	98.56
[1, 200]	40	99.03
[1, 300]	1	96.34
[1, 300]	20	98.12
[1, 300]	40	96.53
[1, 500]	1	94.71
[1, 500]	20	96.54
[1, 500]	40	97.33




그림 8. 입력층, 은닉층, 출력층으로 구성된 DNN 모델
 Fig. 8. DNN model being composed of input, hidden, and output layers

역 [1, 100], [1, 300]에서는 버퍼크기가 20일때가 분류 성능이 가장 우수하다. 반면에 [1, 200], [1, 500]에서는 40에서 좋은 성능을 보여주고 있다. 버퍼 크기를 증가하면 노이즈의 영향이 감소하기 때문에 1개만 사용한 것보다는 성능이 향상된다. 그렇지만 주파수 대역마다 최적 버퍼 크기는 다르기 때문에, 실제 활용에서는 사용하려는 대역에 맞추어 크기를 결정하게 된다.

그림 8은 사용한 완전연결층 DNN(deep neural network) 모델인데, 로지스틱 회귀와 성능 비교를 위해 사용한다. 한주기의 입력신호는 푸리에변환을 통해서 주파수로 변환한다. 이 주파수에서 특정 주파수 대역을 선택한 후에, 해당 주파수 성분만 추출해서 입력층으로 보내진다. 은닉층은 1개, 2개로 실험한다. 뉴런의 개수는 50~200의 범위에서 선택한다. 출력층에는 아크/정상 2개의 노드가 있다.

표 4는 DNN의 분류 성능을 보여준다. 표에서 뉴런 개수가 60-60이면 은닉층은 2개이고 각각 뉴런의 개수는 60, 60을 의미한다. $f=[1,100]$, 60개의 뉴런에서 97.27%의 성능을 보여준다. 주파수= $[1,100]$, 60-60일 때 99.14%의 분류 성능이 가장 좋다. 은닉층 개수를 증가하면 상대적으로 성능은 조금 개선된다. 이경우에 성능은 97~99%의 분포를 가지므로, 딥러닝의 분류 성능을 알 수 있다. 로지스틱 회귀에서는 최대 분류성능이 99.0%이므로, DNN 처럼 로지스틱 회기도 만족스러운 아크 분류성능을 가질수 있음을 알 수 있다. 또한 SVM(Support Vector Machine)으로 분류 성능을 조사했는데, 분류 정확도는 전체적으로 80% 정도로 낮게 얻어진다.

표 4. 완전연결층 DNN을 이용한 16 KHz 신호의 아크 성능
 Table 4. Arc classification of 16 KHz signal of fully-connected DNN

Bandwidth	Buffer Size	No. of Neurons	Classification Accuracy
[1, 100]	1	60	97.27
[100, 200]	1	60	92.67
[200, 300]	1	60	93.28
[300, 400]	1	60	90.78
[1, 200]	1	60	98.29
[1, 100]	1	60-60	99.14
[1, 100]	1	160-160	97.34
[100, 200]	1	60-60	97.18
[100, 200]	1	160-160	98.95
[200, 300]	1	60-60	98.36
[200, 300]	1	160-160	98.74
[200, 300]	1	400-400	99.41
[300, 400]	1	60-60	98.57
[300, 400]	1	160-160	99.31
[300, 400]	1	300-300	99.41

표 5에서는 DNN과 로지스틱 회귀의 처리속도를 비교한다. DNN은 0.089ms, 로지스틱 회귀는 0.009ms이다. 이 시간은 한 개의 입력 데이터의 추론 시간이다. 상대적으로 로지스틱 회귀가 10배 정도 속도가 향상되는 것을 알 수 있다.

표 5. 추론 처리 속도 비교
 Table 5. Comparison of the processing time of inference (unit:ms)

DNN	Logistic Regression
0.089	0.009

VI. 결 론

전기신호에서 발생하는 아크신호의 검출은 화재의 위험 감지하기 위해서, 높은 수준의 검출률이 필요하다. 본 연구에서는 기계학습 방법 중의 하나인 간단한 로지스틱 회귀를 활용하는 아크 검출 방법을 제안하였다. 다양한 부하의 전기신호를 실험에 이용하여 제안 방법을 검증하였고, 또한 완전연결층 DNN도 구현하여 성능 비교를 하였다. 최대 분류 성능은 99.03%로, 99.14%을 보여준 DNN보다 다소 낮지만, 만족스러운 성능을 얻었다. 복잡도를 줄이기 위해서 전체 스펙트럼을 사용하지 않고, 일부 스펙트럼을 사용하여 좀더 처리 속도를 개선하였다. 또한 스펙트럼 버퍼를 사용하여 노이즈의 영향을 줄여서 성능도 개선하였다.

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. Lee, S. Kang, T. Kim, S. Lee and M. Kim, "Electrical arc detection using artificial neural network", *Journal of Broadcast Engineering*, Vol. 24, No. 5, Sep. 2019.
 [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] S. Lee, S. Kang, T. Kim and M. Kim, "Electrical arc detection using convolutional neural network", *Journal of Broadcast Engineering*, Vol. 25 No. 4 pp. 274-282, July 2020.
 [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] 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.
 [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.

저 자 소 개



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, 데이터분석, 영상처리