

# 실 고장 데이터를 고려한 MODWT 기반 전력계통 선로고장 분류모델

김태근, 임세헌, 윤성국\*

송실대학교

[taegeun1520@gmail.com](mailto:taegeun1520@gmail.com), [seheon0223@naver.com](mailto:seheon0223@naver.com), [\\*sgyoon@ssu.ac.kr](mailto:*sgyoon@ssu.ac.kr)

## MODWT-based Power System Line Fault Classification Considering Real Fault Data

Tae-Geun Kim, Se-Heon Lim, Sung-Guk Yoon\*

Soongsil Univ.

### 요약

전력 계통에서의 선로고장은 주로 낙뢰, 수목접촉, 동물접촉과 크레인 접촉 등으로 인해 발생한다. 이때 발생한 선로고장은 종류 및 원인에 따라 고장 전류가 다르게 나타난다. 고장전류는 연결된 전력 계통에 악영향을 미치기 때문에 고장 발생 시 빠르게 고장을 탐지하고, 분류하여 전력 계통으로부터 분리하고 재정비를 하는 것이 중요하다. 이를 위해 본 논문에서는 전력 계통에서 발생 가능한 선로고장 유형을 시뮬레이션으로 모델링하고 고장유형을 분류하는 모델을 제안하였다. 시뮬레이션 기반의 고장파형과 실전력 계통의 고장파형은 차이가 있을 수 있음을 고려하여 시뮬레이션으로부터 생성한 데이터에 잡음(Noise)을 추가하여 분류 정확도를 분석하였다. 고장 데이터의 고조파가 포함된 특성을 고려하기 위해 이산 웨이블릿 변환(Discrete Wavelet Transform, DWT)의 변형모델인 최대 중첩 이산 웨이블릿 변환(Maximal Overlap Discrete Wavelet Transform, MODWT)를 사용하여 에너지를 계산하였다. 랜덤포레스트(Random Forest, RF), 인공신경망(Artificial Neural Network, ANN) 기법을 사용하여 고장분류모델을 훈련하고 분류 정확도를 비교 분석하였다.

## I. 서론

전력 계통의 송전선 또는 배전선에서 고장이 발생하는 것을 선로고장이라 하고, 주된 원인으로는 낙뢰, 수목접촉, 동물접촉, 크레인 접촉 등이 있다[1]. 선로고장 발생 시, 고장유형과 고장원인 분석이 올바르게 이루어지면 적절한 인력과 장비가 투입되어 빠른 복구가 이루어질 수 있다. 관련 연구로, 선로고장 시 고장전압 및 고장전류를 사용하여 고장유형을 분류한 연구[2], 고장원인을 분류한 연구[1] 등 다양한 연구가 진행되었다. 고장유형 분류 및 고장원인 분류에 사용된 기법으로는 퍼지로지 기반의 기법[3], 트리기반의 기법[4], 인공신경망을 활용한 기법[5] 등 다양한 기법이 활용되었다.

선로고장 발생 시 고장전류는 정상상태의 전류에 고조파가 더해진 형태로 나타나기 때문에 고장탐지, 고장분류를 진행한 다양한 사전연구에서 웨이블릿 변환(Wavelet transform, WT)을 활용하였다. 주로 사용되는 웨이블릿 변환으로는 이산 웨이블릿 변환(Discrete Wavelet Transform, DWT) 단시간 푸리에 변환(Short Time Fourier Transform, STFT) 등이 있다.


선로고장의 유형으로는 1선지락(Single line to ground, SLG), 2선지락(Double line to ground fault, DLG), 선간단락(Line to line fault, LL) 3상 단락(Three phase fault, LLL), 3상 단지락(Three phase to ground, LLLG) 고장으로 분류되고, 본 논문에서는 각각 A, B, C상의 고장을 고려하여, 고장유형을 총 11개로 분류하였다.

## II. 본론

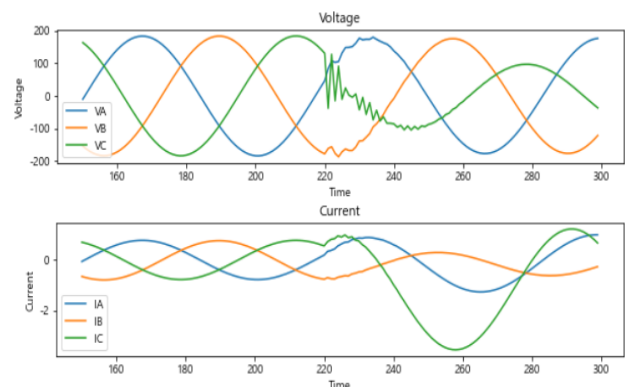
### 2-1. 선로고장 시뮬레이션 및 데이터 추출

전력 계통의 선로고장 시뮬레이션 데이터는 PSCAD 프로그램을 통해 11개의 고장유형별로 45개씩 추출하였다. 이때 고장저항, 고장 발생위치,

측정지점은 동일하게 설정하였고, 고장 발생시점을 변경하여 데이터를 추출하였다. 시뮬레이션 계통은 <그림 1>과 같이 설계하였다. <그림 2>는 추출한 데이터 중 CG고장 파형 예시를 나타낸다.



<그림 1> 선로고장 시뮬레이션 계통도



<그림 2> CG 고장파형(시뮬레이션) 예시


시뮬레이션으로부터 추출한 데이터는 실 고장파형과 차이가 존재하므로, 본 논문에서는 시뮬레이션 데이터와 실제 데이터와의 차이를 고려하기 위해 시뮬레이션으로부터 추출한 데이터에 신호 대 잡음비(Signal to Noise Ratio, SNR)를 고려하여 잡음을 더하여 훈련하고 분류 정확도를 분석하였다.

## 2-2. MODWT 기반 고장파형 웨이블릿 에너지 추출

최대 중첩 이산 웨이블릿 변환(MODWT) 기법은 기본적인 이산 웨이블릿 변환과 달리, 다운 샘플링(down sampling) 과정이 없어 입력 파형과 동일한 길이의 출력 파형을 얻을 수 있어, 실시간 고장탐지, 분류가 가능한 특징이 있다[6]. 본 논문에서는 MODWT 기법을 사용하여 고장파형의 웨이블릿 에너지를 계산하였다. 웨이블릿 에너지는 다음과 같이 계산하였다.

$$E_i = \sum_{k=1}^n (w_{i,c})^2$$

이때  $E_i$  는  $i$  번째 샘플의 웨이블릿 에너지를 의미하고, 본 논문에서는 고장파형의 한주기의 웨이블릿 에너지를 계산하였다.  $w_c$  는 웨이블릿 계수,  $n$  은 한주기당 샘플 수를 의미한다. 고장파형의 웨이블릿 에너지의 파형은 <그림 3>과 같이 고장 발생 시 커지는 형태로 나타난다.



<그림 3> CG 고장파형 웨이블릿 에너지

## 2-3. 고장분류모델 학습 및 성능 비교

본 논문에서는 선로고장 분류 모델을 랜덤포레스트 기법과 간단한 인공신경망을 훈련하여 성능을 비교하였다. 각 모델의 입력데이터는 각 상의 전류와 중성 전류의 고장 전 2주기 파형과 고장 후 2주기 파형을 사용하여 계산한 웨이블릿 에너지를 사용하였다. 훈련 데이터는 전체 데이터의 70%를 무작위로 선택하였다. 랜덤포레스트 모델은 사이킷런(sklearn) 라이브러리에서 제공하는 기본값을 사용하였고, 인공신경망은 은닉층을 2개로 구성하여 100회 훈련하였다. 시뮬레이션 데이터의 경우, 랜덤포레스트 모델은 100%, 인공신경망 모델은 97.30%의 분류 정확도를 나타내어 랜덤포레스트 모델이 인공신경망 모델에 비해 높은 성능을 보였다.

## 2-4. 잡음 데이터 생성 및 고장분류모델 학습 및 성능 비교

실 계통의 취득시 잡음을 고려하여 시뮬레이션 데이터에 신호 대 잡음비(Signal to Noise Ratio, SNR)를 고려하여 잡음데이터를 생성하였다. 본 논문에서는 신호 대 잡음비[dB] 30dB, 40dB, 50dB을 사용하여 잡음데이터를 생성하고 각 모델을 훈련하였다. 신호 대 잡음비는 다음과 같이 계산된다. 이때  $P$  는 전력을 의미한다.

$$SNR_{dB} = 10 \log_{10} \left( \frac{P_{signal}}{P_{noise}} \right)$$

각 신호 대 잡음비 별 랜덤포레스트 모델과 인공신경망 모델의 분류 정확도는 <표 1>과 같이 나타났다. 랜덤포레스트 모델의 경우 잡음이 적게 포함된 데이터에서 높은 분류 정확도를 보인 반면, 잡음이 포함될수록 인공신경망 모델보다 현저히 낮은 성능을 보였다. 인공신경망 모델은 신호 대 잡음비 40과 50에서 준수한 분류 정확도를 보였다. 랜덤포레스트 모델은 학습 시 입력데이터의 값을 기반으로 분기하는 특성으로 인해 변수 간 상관관계의 학습이 인공신경망 모델에 비해 어려운 것으로 분석된다.

<표 1> 신호 대 잡음 비에 따른 분류 정확도

SNR[dB]	분류 정확도	
	랜덤포레스트	인공신경망
20	30.40%	44.59%
30	68.91%	76.35%
40	87.83%	94.59%
50	95.94%	96.62%
원 데이터	100.00%	97.30%

## III. 결론

본 논문은 전력 계통에서 발생할 수 있는 선로고장의 유형을 시뮬레이션으로 모델링하여 데이터를 추출하고, 고장 유형 분류모델을 랜덤포레스트 기법과 인공신경망 기법을 사용하여 훈련하였다. 실 고장 데이터의 측정시 잡음을 고려하여 시뮬레이션 데이터에 잡음을 추가한 데이터를 생성하고 분류모델의 성능을 비교하였다. 잡음이 추가된 데이터에서는 인공신경망 모델이 랜덤포레스트 모델에 비해 높은 성능을 보이는 것을 확인하였다. 향후 연구로 고장 시 고장전류와 고장 위치 등 시뮬레이션 파라미터를 다양하게 사용하여 다양한 경우의 고장유형을 분류하는 연구를 진행할 계획이다.

## ACKNOWLEDGMENT

이 성과는 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원(No. 2020R1F1A1075137)과 한국전력공사의 2022년 착수 기초연구개발과제의 지원(과제번호: R22X002-19)을 받아 수행된 연구임.

## 참고 문헌

- [1] Asman, S. H., Ab Aziz, N.F., Ungku Amirulddin, U. A., & Ab Kadir, M. Z. A. "Decision tree method for fault causes classification based on RMS-DWT analysis in 275 kV transmission lines network". *Applied Sciences*, 11(9), 4031. 2021.
- [2] Jamehbozorg, A., & Shahrtaash, S. M. "A decision-tree-based method for fault classification in single-circuit transmission lines." *IEEE Transactions on Power Delivery*, 25(4), 2190-2196. 2010.
- [3] Pardhan, A. K., Routray, A., Pati, S., & Pradhan, D. K., "Wavelet fuzzy combined approach for fault classification of a series-compensated transmission line." *IEEE Transactions on Power Delivery*, 19(4), 1612-1618. 2004.
- [4] Chakraborty, D., Sur, U., & Banerjee, P. K. "Random forest based fault classification technique for active power system networks." *2019 IEEE International WIE Conference on Electrical and Computer Engineering (WIECONECE)*, (pp. 1-4), IEEE, 2019
- [5] Fahim, S. R., Sarker, Y., Islam, O. K., Sarker, S. K. Ishraque, M. F., & Das, S. K. "An Intelligent approach of fault classification and localization of a power transmission line.", *2019 IEEE International Conference on Power, Electrical, and Electronics and Industrial Applications (PEEIACON)*, (pp. 53-56). IEEE, 2019.
- [6] Costa, F. B., B. A. Souza, and N. S. D. Brito. "Real-time classification of transmission line faults based on maximal overlap discrete wavelet transform." *PES T&D 2012*. IEEE, 2012