

# 고장파형 전처리 기법별 실계통 고장유형 분류 모델 정확도 비교 및 분석

임세헌, 김태근, 이경영, 송경민, 윤성국

송실대학교

seheon0223@naver.com, taegeun1520@gmail.com, dlru7755@naver.com, songkl111@naver.com, sgyoon@ssu.ac.kr

## Comparison and analysis of fault type classification accuracy by fault waveform preprocessing methods based on field data

Se-Heon Lim, Tae-Geun Kim, Kyeong-Yeong Lee, Kyung-Min Song, Sung-Guk Yoon

Soongil University

### 요약

현존하는 송전선로의 고장유형 분류 연구는 대부분 시뮬레이션 데이터를 기반으로 진행되어 실계통에서 발생하는 고장 파형에 적용하는 경우 성능 저하가 예상된다. 실계통 고장데이터의 고장유형 분류 정확도 향상을 위해서는 실계통 고장데이터를 통한 실질적인 분류 모델 평가를 통한 입력데이터의 영향 분석이 선행되어야 한다. 본 논문은 고장데이터의 전처리 기법별 실계통 데이터의 고장유형 분류 정확도 분석을 통해 실계통 고장데이터의 고장유형 분류에 적합한 입력데이터를 도출하였다. 본 논문에서는 인공신경망(Artificial Neural Network, ANN) 기반 고장분류모델을 사용하여 다섯가지에 대해 유형분류 모델의 분류정확도를 비교·분석하였다. 결과를 통해 실계통 고장데이터 고장 유형분류에 적합한 전처리 기법은 RMS(Root Mean Square)와 MODWT-E(Maximal overlap discrete wavelet transform energy)인 것을 확인하고 원인을 분석하였다.

### I. 서론

3상 시스템인 송전선로에서 발생 가능한 선로고장유형은 총 10가지로, 평형 고장인 3상 단락(Three phase to ground fault, LLL) 유형 1개와 불평형 고장인 1선 지락(Single line to ground fault, SLG) 유형 3개, 2선 지락(Double line to ground fault, DLG) 유형 3개, 선간 단락(Line to line fault, LL) 3개로 구성된다[1]. 고장 유형에 따라 복구방법과 필요한 조치가 다르기 때문에 고장 후 전력선을 복구하기 위해 정확한 유형 분류가 필요하다.

선행연구에서는 고장유형 분류에 이산 웨이블릿 변환(Discrete wavelet transform, DWT)[2], 최대 중첩 이산 웨이블릿 변환(Maximal overlap discrete wavelet transform, MODWT)[3], 연속 웨이블릿 변환(Continuous wavelet transform, CWT)[4] 등 다양한 전처리 기법이 사용되었지만 대부분 시뮬레이션 데이터를 사용하여 성능을 검증하여 실계통 적용에 어떤 성능을 보일지는 확신할 수 없다.


본 논문에서는 이러한 사실을 바탕으로 실계통 고장데이터에 적합한 분류모델의 입력 구성을 도출하기 위한 실험을 진행하였다. 전처리 기법별 다섯가지 입력데이터를 구성하고 입력데이터 구성별 실계통 고장데이터의 분류 정확도 비교·분석을 통해 실계통 고장데이터분류에 적합한 입력데이터를 확인하였다.

### II. 본론

#### 2. 1. 데이터 구성

송전선로의 선로 고장을 모의하기 위해 PSCAD 프로그램을 사용하여 국내 345-154kV 계통을 단순화하여 [그림 1]과 같이 구성하였다. 다양한 고장 데이터를 확보하기 위해 고장유형, 송전선로 길이, 위상각을 [표 1]과 같이 구성하여 총 700(7(위상)×10(고장위치)×10(고장유형))개의 고장 데이터를 생성하였다. 생성한 고장 파형은 한 주기 당 64 샘플

데이터로 분류모델 입력으로 사용하기 위해 고장 전 1 주기와 고장 후 2 주기를 추출하여 사용하였다.



[그림 1] 시뮬레이션 계통도

[표 1] 시뮬레이션 파라미터 요약

고장유형	AG, BG, CG, ABG, ACG, BCG, AB, AC, BC, ABC (10가지)
송전선로길이 (km)	10 ~ 100km (10km 간격, 10가지)
위상(°)	0 ~ 180° (30° 간격, 7가지)

추출된 시뮬레이션 데이터를 훈련:검증:시험 = 8:1:1로 구성하였고 39개 실계통 고장데이터를 추가로 시험에 사용하였다. 실계통 고장데이터의 고장 유형 정보는 [표 2]와 같다.

[표 2] 실계통 고장데이터 고장 유형 정보

고장 유형	AB	ABC	ABG	ACG	AG	BC	BG	CG
개수	2	8	1	3	1	6	11	7

#### 2. 2. 전처리 기법을 통한 입력데이터 구성

본 논문에서는 [표 3]과 같이 순시치를 기본 입력으로 하고, RMS와 웨이블릿 변환 기법인 MODWT[3], MODWT-E(Maximal overlap discrete wavelet transform energy)[3], CWT[4]의 네가지 전처리 기법을 통해 산정된 특성을 분류모델의 입력으로 선정하였다. 기본 입력인 순시치는 3상 전압, 3상 전류 파형의 고장 전 1 주기 및 고장 후 2 주기를

사용하였기에 순시치, RMS(Root mean square), MODWT, MODWT-E의 입력 크기는 192(3주기×64샘플)×6(3상 전압, 3상 전류)에 의해 1,152로 계산되고, CWT는 9(스케일 개수)×192(파형길이)×6(전압 3상, 전류 3상)/10(샘플링 변환 비율)에 의해 계산된다.

[표 3] 입력 종류별 입력데이터 정보

Case	구성요소	입력 크기
1	순시치(기본)	1,152
2	RMS	1,152
3	MODWT	1,152
4	MODWT-E	1,152
5	CWT	1,037

### 2. 3. 분류 모델

실험에 사용된 고장유형 분류모델은 인공신경망(Artificial Neural Network, ANN)기반 고장분류 모델을 사용하였는데 ANN은 층과 뉴런 수 구성에 따른 성능 영향을 최대한 배제하기 위해 ANN 모델을 간단하게 설계하였다. ANN의 입력층, 은닉층(1층), 출력층 뉴런수는 각각 [표 3]의 입력크기, 128, 10(고장 유형 개수)로 구성하였다.

### 2. 4. 결과 분석


입력데이터의 구성에 따른 모델 평가를 위해 Case 별로 10번의 훈련을 진행하여 10가지 모델에 대한 평균 정확도를 평가지표로 사용하였다. [표 4]의 결과에 의하면 시뮬레이션 시험데이터를 통한 모델의 분류 정확도는 모두 80% 이상을 보였다. 그러나 실계통 시험데이터에서는 전체적으로 분류정확도가 저하 되었으며 입력별로 분류정확도의 편차가 발생하였다. 이를 통해, 시뮬레이션 데이터와 실계통 데이터 간 데이터 특성이 상이하다는 것을 확인할 수 있다. 또한 입력데이터 별로 실계통 데이터를 분류하는데 유의미한 분류 정확도 차이가 존재하는 것을 확인하였다.

평균적으로 Case 2과 Case 4에 해당하는 RMS와 MODWT-E를 입력으로 했을 때 분류정확도가 기본 입력인 순시치에 비해 각각 87.58%, 18.18% 성능 개선율을 보였다. 반면, WT 기반의 입력에 해당하는 Case 3, 5는 실계통 고장데이터 시험에서 현저히 낮은 성능 보였다. 본 결과는 잡음에 의한 영향을 비교적 덜 받는 RMS와 MODWT-E가 실계통 고장 데이터의 유형분류에 강인하다고 해석 될 수 있다.

[표 4] 입력 종류별 모델 정확도 (Case 1~5)

시험데이터	Case 1	Case 2	Case 3	Case 4	Case 5
시뮬레이션	1.000	0.982	0.816	0.989	0.977
실계통	0.451	0.846	0.103	0.533	0.113

전처리 기법 중 최고 성능을 보였던 RMS에 해당하는 Case 2에 대해서 실계통 시험데이터별 정답 및 예측을 추가로 분석하였다. [그림 2]의 x축 및 y축은 각각 실계통 시험데이터 번호 및 고장 유형 번호를 의미하며 이에 대한 정보는 [표 5]와 같다.



[그림 2] Case 3 결과: 실계통 시험데이터별 정답 및 예측

[그림 2]의 예측값은 5개 예측 모델의 결과중 가장 빈도가 높은 유형을

의미한다. [그림 2]에 의하면 예측 모델의 오답의 경우 ABG 고장을 BG 고장으로, ACG 고장(3건)을 AC 고장으로 예측하였다. 오답은 모두 DLG 고장에서 발생하였으며 DLG 고장을 LL 고장 또는 SLG고장으로 예측하는 것을 확인하였다.

[표 5] 그림 2 설명: 고장 유형 번호-고장유형 정보

번호	유형	번호	유형	번호	유형	번호	유형
0	AB	1	ABC	2	ABG	3	AC
4	ACG	5	AG	6	BC	7	BCG
8	BG	9	CG	-	-	-	-

DLG 고장은 LL 고장의 특성과 SLG 고장의 특성을 모두 포함하기 때문에 시뮬레이션 데이터와 상이한 실계통 DLG 고장 데이터를 분류했을 때 오답을 예측할 확률이 높아지는 것으로 추측된다. 예를 들어, DLG 고장의 경우 고장 난 두 상의 크기의 차이가 크면(작으면) SLG(LL)로 예측할 수 있다. 따라서 DLG 고장과 LL 고장을 구분하기 위한 순시치와 DLG와 SLG를 구분하기 위한 웨이블릿 기반의 입력을 잘 활용해야 할 것으로 분석된다.

### III. 결론

본 논문은 전처리 기법별 실계통 데이터의 고장 유형 분류 성능 분석을 통해 실계통 데이터의 고장유형 분류에 적합한 입력데이터를 도출하고 이를 분석하였다. 결과에 의하면 평균적으로 RMS와 MODWT-E를 입력으로 했을 때 성능이 기본 입력인 순시치에 비해 각각 87.58%, 18.18% 개선되었다. 반면, WT 기반의 입력은 사용하였을 때에는 시뮬레이션 및 실계통 고장데이터 시험에서 낮은 성능을 보였다. 이는 잡음에 의한 영향을 비교적 덜 받는 RMS와 MODWT-E가 WT 기반 입력에 비해 잡음이 포함된 실계통 고장 데이터의 유형분류에 강인하기 때문이라고 해석한다.

### ACKNOWLEDGMENT

본 연구는 한국전력공사의 2022년 착수 기초연구개발과제 연구비에 의해 지원되었음(과제번호: R22XO02-19).

### 참고 문헌

- [1] A. Yadav and Y. Dash, "An overview of transmission line protection by artificial neural network: fault detection, fault classification, fault location, and fault direction discrimination," *Advances in Artificial Neural Systems*, 2014.
- [2] X. G. Magagula, Y. Hamam, J. A. Jordaan and A. A. Yusuff, "A fault classification and localization method in a power distribution network," *2017 IEEE AFRICON*, pp. 1337-1343, 2017.
- [3] F. B. Costa, B. A. Souza, and Brito, N. S. D., "Real-time classification of transmission line faults based on maximal overlap discrete wavelet transform," *PES T&D 2012*, pp. 1-8, 2012.
- [4] D. Paul and S. K. Mohanty, "Fault Classification in Transmission Lines Using Wavelet and CNN," *2019 IEEE 5th International Conference for Convergence in Technology (I2CT)*, Bombay, India, pp. 1-6, 2019.