

랜덤 포레스트 특징 선택을 활용한 딥러닝 기반 전력 시스템 이상탐지 기법

*이동혁,*박준형,*정남준,**고영준

한국전력공사, 충남대학교

leedh8036@kepc.co.kr, junhyeong47@kepc.co.kr, namjoon.jung@kepc.co.kr, yjkoh@cnu.ac.kr

Deep Learning - Based Anomaly Detection Exploiting Random Forest Feature Selection for System Monitoring

*DongHyuk Lee, *JunHyeong Pak, *NamJoon Jung, **YeongJun Koh

*KEPCO, **Chungnam National University

요 약

이상탐지(Anomaly Detection) 기법이란 설비 또는 대형시스템의 상태 모니터링을 위해 활용되는 핵심 기술로서, 대상 설비에서 취득한 로그데이터 분석을 통해 다양한 모델로서 구성될 수 있다. 본 논문에서는 다변량 시계열 데이터의 특징 선택(Feature Selection)을 위해 랜덤 포레스트(Random Forest)를 적용한 딥러닝 기반 이상탐지 기법을 제안한다. 실험을 통해 데이터 셋의 특징 간 상관관계(Correlation)이나 중요도(Importance)를 기반으로 특징 선택을 수행하는 방식이, 기존 데이터 셋을 그대로 이상탐지 딥러닝 모델에 그대로 적용하는 경우에 비해 이상탐지 정확도를 개선할 수 있음을 확인하였다.

I. 서 론

인공지능(AI) 기술이 발전함에 따라 산업에서 생성되는 대량의 데이터를 기반으로 업무에 딥러닝 모델을 활용하는 사례가 많아지고 있다. 기업은 사익 증대와 조직의 효율적인 운영을 위해 장애 예측과 원인 분석 등의 목표를 달성하기 위하여 모델의 성능을 향상하고자 노력하고 있다. 이러한 딥러닝 모델의 성능을 향상시키는 방법으로는 목적에 부합한 최적의 알고리즘을 채택하거나 모델의 하이퍼 파라미터 등의 설정값을 조정하는 방법 등이 있지만, 기업에서 활용하는 대부분의 산업 데이터의 특징상, 다수의 특징으로 구성되고 전처리라 되어 있지 않은 무분별한 원천 데이터(Raw Data)를 그대로 훈련 데이터셋(Train Dataset)으로 활용하였을 시, 모델의 조정을 통해서만 성능을 향상하기란 쉽지 않으며, 모델의 목적에 부합한 데이터로 가공하여 활용할 필요성이 있다.[1] 본 논문에서는 22개의 특징으로 구성된 전력 설비 데이터터를 활용하여 딥러닝 모델의 매개변수 조정을 통한 성능 개선이 아닌 데이터 전처리 과정에서 데이터 특징 간 상관관계나 중요도 등을 기반으로 설비 이상탐지의 유효한 특징을 적극적으로 선택하여 모델의 정확도를 향상시키는 방안을 제안한다.

II. 본론

본 논문에서는 모델 성능의 향상을 위한 특징 선택 방법을 실증하기 위해 한국지능정보사회진흥원(NIA)에서 제공하는 서비스인 'AI Hub'에 등록되어 있는 '전력설비 고장대응을 위한 전력품질 분류 모델' 데이터를 활용하였다.[2] 해당 데이터셋은 전력설비의 센서로부터 측정된 에너지 사용 패턴 로그와 해당 설비의 각 도메인별 품질상태를 분류한 학습용 데이터이다. 데이터의 구성은 <표 1>과 같이 불량 여부 판정을 위해 측정된 22개의 특징과 3개의 도메인(역률평균, 전류고조파평균, 전압고조파평균)

에 대한 불량 여부(정상(0),주의(1),경고(2))의 값으로 구성되어 있으며 총 2,420,565건의 데이터가 등록되어있다.

#	특징(Feature)	샘플 값(Sample Value)	비고
1	주파수	59.854076	센서 측정 값
2	온도	24.3750	
3	S상전압	125.250	
(생략)			
20	R상무효전력	6170.00	
21	T상무효전력	7887.00	
22	무효전력평균	482.75930	
23	역률평균(label 1)	주의(1)	불량 여부
24	전류고조파평균(label 2)	경고(2)	
25	전압고조파평균(label 3)	정상(0)	

<표 1> 전력설비 품질 분류 모델 데이터셋 구성

센서 측정값인 22개의 특징을 모두 학습 데이터로 사용하여 3개의 도메인에 대한 불량 여부를 다층 퍼셉트론(Multi-Layer Perceptron, MLP) 딥러닝 모델로 예측한 결과, 각각의 정확도는 0.9649, 0.9794, 0.8401로 도출되었다. 본 연구에서는 비교적 정확도가 낮게 나온 전압고조파평균의 예측 정확도인 0.8401을 개선 시켜보고자 한다. 앞서 언급한 바에 따라, 모델을 직접 조정하는 것이 아닌, 22개의 특징 중 모델의 성능 개선에 유효한 특징만을 추출하기 위해 특징 간 상관관계를 파악할 필요성이 있다. 22개의 특징 간 상관계수(correlation coefficient)를 파악 하기 위해 임의의 특징 X의 샘플값이 $x = (x_1, x_2, \dots, x_n)$ 이고 특징 Y의 샘플 값이 $y = (y_1, y_2, \dots, y_n)$ 라고 하면 이 두 개의 특징 간 상관계수 r_{xy} 는 아래와 같이 구해진다.

$$r_{xy} = \sqrt{\frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}}$$

위의 식에 의해 각각의 상관계수를 구한 상관관계 매트릭스(Correlation Matrix)는 아래의 <그림 1>과 같다.

<그림 1> 22개 특징에 대한 상관관계 매트릭스

상관계수가 ±0.9이상이면 두 확률변수는 상호 의존성이 아주 높다고 간주되며 상호 의존성이 높은 특징을 하나의 그룹으로 구성하고 각 그룹별 대표 특징을 선정하여 학습에 사용하고자 <표2>와 같이 분류하였다.[3]

#	그룹	대표 특징
1	S상전압, R상전압, T상전압, 상전압평균	상전압평균
2	S상선간전압, R상선간전압, T상선간전압, 선간전압평균	선간전압평균
3	S상전류, R상전류, T상전류, 전류평균	전류평균
4	S상무효전력, R상무효전력, T상무효전력, 무효전력평균	무효전력평균
5	S상유효전력, R상유효전력, T상유효전력, 유효전력평균	유효전력평균
6	상호연관이 없는 나머지 특징 : 주파수, 온도	주파수, 온도

<표 2> 상호 의존성 기반 그룹별 대표 특징 분류표

최종 선정된 대표 특징 7개를 기존 딥러닝 모델을 통해 학습한 결과, 전압고조파평균(label 3)의 장애여부 예측 정확도는 0.4754로 기존 22개 특징을 모두 사용했을 때 보다 현저히 낮은 것을 확인할 수 있다. 상관관계 매트릭스 기반의 특징 선택 방법은 구현이 쉽고, 특징 간 상관관계를 파악하기에 빠르고 직관적이지만, 전력설비 품질 분류 모델 데이터셋과 같이 설비의 품질을 판단하는데 여러 특징에 대한 영향력이 동시에 존재하거나 데이터에 이상치가 포함되어 있을 시, 상관계수에 악영향을 미쳐 품질 판단에 영향력이 큰 특징이 오히려 중요도가 낮게 식별되어 모델의 정확도를 저하시킬 수 있는 것을 확인할 수 있었다. 이 단점을 보완하고자 특징 선택의 두 번째 방법으로 랜덤 포레스트(Random Forest)를 채택하였다. 랜덤 포레스트는 주어진 학습 데이터셋에서 무작위로 중복을 허용해서 n 개를 선택한 후, 선택한 n개의 데이터 샘플에서 데이터 특징값을 중복 허용 없이 d개를 선택한다.[4] 이 과정을 k번 반복하여 생성된 k개의 의사결정트리(Decision Tree)를 이용해 각 특징의 중요도(Feature Importances)를 계산할 수 있다. 여기서 k는 본 실험에서 'estimator'라는 변수로 정의되며, 랜덤 포레스트 안에 만들어지는 의사결정트리 개수로 그 수가 많아지면 연산량이 많아지고 과적합(Overfitting) 방지에 유리하지만, 연산속도가 느려지고 리소스가 많아져 적절한 상충관계(Trade-off)를 고려해야 한다. estimator 값을 조정하여 특징별 중요도를 산출할 수 있으며, 특징들의 평균 중요도보다 높은 특징들을 선별하여 모델의 성능을 개선할 수 있는 최적의 집합을 구성할 수 있었다. estimator 값이 400일 때, 전체 평균 중요도보다 높은 특징의 수는 9개로, 이 구성에서 모델의 정확도가 가장 높게 측정되었으며, <표 3>은 최종 선별된 특징들의 순위와 중요도를

나타낸다.

순위	특징	중요도
1	주파수	0.168
2	선간전압평균	0.163
3	온도	0.103
4	R상무효전력	0.101
5	R상전압	0.089
6	R상선간전압	0.082
7	S상무효전력	0.079
8	S상선간전압	0.078
9	T상선간전압	0.072

<표 3> 랜덤 포레스트 기반 특징별 중요도 순위

각 특징의 중요도는 [0 - 1] 범위의 수로 구성되어있으며 1.0에 가까울수록 설비의 품질을 분류하는 트리를 분할하는 데 큰 영향을 미쳤다는 것을 의미하며, 전체 22개 특징의 중요도의 합은 1이다. [5] <표 3>은 전체 특징의 평균 중요도인 0.071보다 높은 특징들이며, 전체 특징을 모델학습에 활용했을 경우의 탐지 정확도인 0.8401보다 위의 선별된 특징만을 모델에 적용했을 시 0.9622로 더 높은 예측 정확도를 도출할 수 있음을 알 수 있었다.

III. 결론

본 논문에서는 다수의 특징으로 구성된 전력설비 품질 분류 데이터셋을 이용하여 딥러닝 모델의 성능 개선에 유효한 특징을 선택하기 위한 방법으로 상관관계 매트릭스를 사용하여 상호 의존성이 높은 특징을 그룹으로 분류하여 선택하는 방법과 랜덤 포레스트 기반으로 특징 중요도를 산출하여 평균 중요도보다 높은 특징을 선택하는 방법을 비교하였다. 이러한 방법으로 최적의 특징 집합을 구성하였을 시, 전체 특징을 모두 모델 학습에 사용하였을 때보다 탐지 정확도를 개선할 수 있음을 확인할 수 있었다. 이는 향후 전력설비 품질 분류 데이터셋과 같이 다양하고 복잡한 산업 데이터를 딥러닝 모델에 적용하면, 데이터 특징에 적합한 특징 선택 방법을 사용하여 딥러닝 기반의 이상탐지 성능을 제고할 수 있을 것으로 기대된다.

Acknowledgement

본 연구는 한국전력공사 전력연구원 연구과제(R21IA05)의 지원을 받아 수행되었습니다.

참고 문헌

- [1] 이창희, "A Study on the important variable Selection Method by Feature Selection", 중앙대학교, pp. 3, Dec. 2007
- [2] AIHub "전력설비 고장 대응을 위한 전력품질 분류 모델", May. 2022 <https://www.aihub.or.kr/aihubdata/data/view.do?currMenu=115&topMenu=100&dataSetSn=455>
- [3] 김장훈, "A Study on Feature selection method for Anomaly detection based on Learning of Normal behavior in Industrial Control System", 순천향대학교 pp. 10, Feb. 2021
- [4] 이진이, "Feature Selection Algorithm for Machine Learning Based Security System", 건국대학교 pp. 14-18, Aug. 2017
- [5] 김민규, "A Study on Predicting TDI in tributaries of Han river basin using Correlation-based Feature Selection technique and Random Forest algorithm", Sep. 2019