

잔차 학습 기반 전기모터 이상상태탐지

이준석, 전창재*
세종대학교

wnstjr1193@naver.com, *cchun@sejong.ac.kr

Residual Learning-Based Electric Motor Anomaly Detection

Jun Seok Lee, Chang-Jae Chun*
Sejong University

요 약

본 논문에서는 간단한 구조로 탐지 성능을 높일 수 있는 잔차 학습(Residual Learning)을 기반으로 한 심층신경망을 활용하여 전기모터 이상상태를 탐지하는 방법을 제안한다. 특히 제안하는 방법에서는 설치가 간단한 전류센서로부터 수집한 데이터를 활용하여 이상상태를 탐지했다. 모델 성능을 검증하기 위한 데이터셋으로 Paderborn University의 전류 데이터를 사용했으며, 기존 방법에 비해 제안하는 방법이 더 나은 성능을 보임을 확인했다. 또한 설명 가능한 인공지능(Explainable AI, XAI) 방법을 활용하여 모델 출력에 영향을 주는 입력 특징 값을 확인했다.

I. 서 론

통계에 따르면, 전자 기계 구동 시스템과 모터 고장의 40~70%는 베어링 손상에 의해 발생한다. 이러한 고장은 downtime의 증가로 이어져 높은 비용이 들게 한다 [1]. 이러한 베어링 손상을 사전에 탐지할 수 있다면 장비의 downtime을 감소시켜 생산 비용을 줄일 수 있기 때문에 매우 중요하다. 베어링 손상을 탐지하기 위해서는 주로 진동 센서와 전류 센서를 통한 진동 신호 및 전류 신호를 많이 활용한다. 하지만 진동 센서는 대상기에 접촉식으로 설치해야 하며, 작업장에서 알 수 없는 비 주기적 진동 요인이 발생할 수 있어 데이터 수집 환경에 민감하다. 이에 반해, 전류 센서는 비 접촉식으로 설치가 가능하며, 기계의 작동 및 다른 외부적 요인에 의해서 큰 영향을 받지 않기 때문에 이상 탐지에 활용하기가 매우 유용하다. 연구 [3]에서는 전류 신호와 진동 신호 각각에 대해 Classical Machine Learning (ML) 기반 앙상블 알고리즘을 사용한 이상 탐지 모델을 제안했다. 연구 [4]에서는 두가지의 전류 신호를 사용해서, 1D-CNN (Convolution Neural Network)과 LSTM (Long short-term Memory) 모델의 학습을 통한 특징 추출 후에 과적합을 줄여주는 가중치 앙상블(Weight Ensemble) 학습을 하는 이상 탐지 모델을 제안했다. 하지만 연구 [3]의 결과는 정확도 기준 93.3%로 실제 시스템에 적용하기에는 성능이 너무 낮았다. 또한 연구 [4]에서도 연구 결과가 98.8%로 이상치를 완벽하게 탐지하지 못했다. 따라서 본 논문에서는 이상탐지 성능 향상을 목적으로 연구 [5]에서 제안한 잔차 학습 (Residual Learning)과 DNN (Deep Neural Network) 모델을 기반으로 한 앙상블 학습 방법을 제안한다. 모델 성능 검증은 전기 모터에서 수집한 공개 데이터셋을 활용하였으며, 본 연구의 결과가 기존의 이상 탐지 모델 [3] 및 [4]보다 더 좋은 정확도를 보이는 것을 확인했다. 또한 설명 가능한 인공지능(Explainable AI, XAI) 방법을 활용하여 모델 출력에 영향을 주는 입력 특징 값을 분석했다.

II. 본론

2.1. Residual Learning 기반 DNN 모델 및 학습환경

본 논문에서는 정확한 이상치 탐지를 위해서 잔차 학습 기반 DNN 모델을 활용하였다. 제안하는 모델에 잔차 학습을 활용함으로써, Layer가 깊어져도 이전 Layer가 학습했던 가중치를 가져오게 되면서 역전과 과정에서 최적의 기울기를 찾기 수월해진다. 이를 통해 Layer가 깊어져도 기울기 소실과 과적합의 문제를 어느 정도 해소시켜주어 모델 성능이 향상된다. 제안하는 모델 각각의 Layer가 가지는 노드의 개수는 순서대로 64, 128, 256, 256, 256, 512, 512, 512, 256, 512, 256, 128, 64, 3이다. 첫번째 Layer부터 하나의 Layer를 건너뛰어 연결하여 Residual 구조를 설계했다. 함수는 Adamax를 사용하였으며, clipnorm을 1.0으로 적용하여서 기울기 폭주를 방지했다. 학습률은 0.01로 설정하였으며, ReduceLROnPlateau 함수를 사용하여 Validation Loss가 감소하지 않으면, 학습률을 낮춰가며 훈련이 진행되도록 했다. 또한 활성화함수는 swish, 출력함수는 Softmax, 손실함수는 Categorical Cross Entropy를 사용했다. 모델 학습 및 테스트는 Python 3.10.6, TensorFlow 2.9.1로 진행했다.

2.2 시뮬레이션 결과

2.2.1 데이터

데이터 [2]의 베어링 데이터의 Class는 정상상태(Normal)와 이상상태 2가지(Inner Race Fault, Outer Race Fault)가 존재한다. 데이터는 구간별 효과적인 특징 추출을 위해서 20,480S/s로 다운 샘플링 및 특징 추출을 진행했다. 특징 추출 후 구성된 Feature 들은 최댓값, 최솟값, 평균, 표준편차, 제곱평균제곱근, 왜도, 첨도, 파고율, 절댓값 평균, Peak to peak, 형상계수, 물리적 배열, 제곱근 합으로 총 13개의 Feature로 구성되어 있다. 시뮬레이션을 위해 실제로 생성 및 수집된 정상과 이상 데이터를 활용했으며,

정확한 성능 비교를 위해서 데이터 구성은 연구 [3], [4]에서 사용한 데이터셋과 동일하다.

2.2.2 전류 데이터 사용 별 이상치 탐지 결과

데이터 [2]에는 전류 신호 데이터 두 가지가 (current u, current v) 존재한다. 그래서 본 연구에서 두 가지 데이터를 같이 사용하였을 때와 각각의 전류를 사용하여 학습했을 때를 비교하여 연구를 진행했다. 그 결과 각각의 전류를 사용하여 10 번의 시뮬레이션 한 결과의 평균인 표 1 을 기준으로 current u 는 정확도 기준 96.73%를 기록했으며, current v 는 96.54%를 기록했다. 반면에, 두 가지 신호를 앙상블 하여서 예측했을 때, 99.25%라는 결과를 볼 수 있었으며, 전류 신호 두 개를 같이 썼을 때, 이상치 탐지에 더 효과적인 것을 확인할 수 있었다. 앙상블을 활용한 예측 결과는 그림 1 의 혼동 행렬에서 좀 더 구체적으로 확인할 수 있다.

표 1. 전류 사용 별 이상치 탐지 결과

Data type	Ensemble	Current u	Current v
정확도 평균	99.25%	96.73%	96.54%



그림 1. 본 논문의 Ensemble Learning 혼동행렬 결과

2.2.3 벤치마크 연구와 본 연구 결과 비교

표 2 는 각 연구의 정확도에 대한 성능지표이다. 표 2 를 통해서 연구 [3]의 결과와 본 연구의 결과를 비교하였을 때, 본 연구의 결과가 5.95 % 더 높았으며, 연구 [4]의 결과와 비교를 하였을 때는 본 연구의 결과가 0.45 % 더 높았다.

표 2. 벤치마크 와 본 논문 연구결과비교

연구 [3] 결과	연구 [4] 결과	본 연구 결과
93.3 %	98.8 %	99.25 %

2.2.4 이상치 탐지 결과에 대한 XAI 분석

표 2 에서와 같이 본 논문의 이상치 탐지에 대한 결과는 기존 연구결과에 비해 좋았다. 하지만 딥러닝은 이러한 예측 값이 나온 것에 대한 설명이 부족하기 때문에 XAI 를 위한 SHAP 알고리즘을 활용하여 분석을 진행했다. 그림 2 에서, Outer Race Fault 데이터를 표본으로 분석을 진행했을 때, Outer Race Fault 가 발생할 확률이 0.63 으로 shape factor, Mean, Max, Min, Form Factor, RSS 순으로 Outer Race 예측하는데 효과적인 Feature 인 것을 확인할 수 있었으며, Std, Abs Mean, kurtosis, Skewness, RMS 가 Outer Race 를 예측하는데, 비효율적인 Feature 인 것을 알 수 있었다. Normal 상태의 베어링 경우에는 그림 3 에서 볼 수 있듯이 Outer Race Fault 와 다르게 Form Factor 가

Outer Race Fault 를 예측할 때는 효과적인 Feature 였지만, Normal 상태를 예측할 때는 비효율적인 Feature 인 것을 확인했다. 이를 통해서 베어링의 상태마다 어떠한 Feature 가 효율적인지, 비효율적인지 확인했다.




그림 2. Outer Race Fault 상태의 XAI 분석 결과



그림 3. Normal 상태의 XAI 분석 결과

III. 결론

본 논문에서는 두개의 전류 신호를 같이 사용하는 것이 더 효과적인 이상치 탐지 방법인 것을 확인했으며, 잔차 학습 기반의 DNN 의 결과와 벤치마크 논문의 결과와 비교하여서 모델의 타당성 검증했다. 그리고 XAI 알고리즘을 활용하여, 이상 탐지에 중요 Feature 들을 확인했다.

ACKNOWLEDGMENT

이 논문은 2022 년도 정부(중소벤처기업부)의 재원으로 중소기업기술정보진흥원-제조데이터 공동 활용 플랫폼 기술개발(인공지능비전 기반, 데이터 증강 및 결함 탐지 플랫폼 개발)사업의 지원을 받아 수행된 연구임(RS-2022-00156456). 이 연구는 2022 년도 정부(과학기술정보통신부)의 재원으로 국가과학기술 연구회의 지원을 받아 수행된 한국전기연구원 기본 사업임 (No. 22A01019).

참 고 문 헌

- [1] A. H. Bonnett and C. Yung, "Increased Efficiency versus Increased Reliability," in *IEEE Industry Applications Magazine*, vol. 14, no. 1, pp. 29-36, 2008.
- [2] Paderborn University Dataset; 2016, <<http://mb.uni-paderborn.de/kat/datacenter>>
- [3] C. Lessmeier, J. Kimotho, D. Zimmer and W. Sextro, "Condition Monitoring of Bearing Damage in Electromechanical Drive Systems by Using Motor Current Signals of Electric Motors: A Benchmark Data Set for Data-Driven Classification," in *Proc. Eur. Conf. Prognostic Health Manage. Soc.*, Bilbao, Spain, 2016, pp. 1-17.
- [4] T. Wagner and S. Sommer, "Bearing fault detection using deep neural network and weighted ensemble learning for multiple motor phase current sources," in *Proc. International Conference on Innovations in Intelligent SysTems and Applications (INISTA)*, 2020, pp. 1-7.
- [5] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," in *Proc. IEEE Conf. Comput. Vision Pattern Recognit. (CVPR)*, Jun. 2016, pp. 770- 778.