

전류 센서 데이터를 활용한 기계 시설물 고장 진단에 관한 연구

성상하* · 최형림** · 박도명*** · † 김상진

*동아대학교 경영정보학과 박사과정생, **동아대학교 스마트물류연구센터 연구교수, ***동아대학교 스마트물류연구센터 책임연구원
† 동아대학교 경영정보학과 교수

요 약 : 산업 현장의 기계 시설물 고장 문제는 큰 인명피해와 경제적 손실을 초래할 수 있기 때문에, 기계 시설물의 상태를 기반으로 고장을 진단하는 것은 대단히 중요하다. 따라서, 본 연구에서는 전류 센서 데이터를 활용하여, 시설물의 고장 여부를 진단할 수 있는 알고리즘을 제안한다. 본 연구에 활용된 전류 센서 데이터는 x, y, z축을 가진 3상 전류 데이터로 구성되어 있으며, 2kHz로 1초간 샘플링 되어 있다. 본 연구에서는 2차원적 특성을 가지는 전류 센서 데이터를 분석하기 위해 CNN(Convolution Neural Network)을 활용한다. 시설물의 고장진단에 가장 적합한 모델을 선정하기 위해 CNN의 대표적인 백본 네트워크를 활용하여, 결과를 비교하였다. 실험 결과, 본 연구에서 구성한 후보 백본 네트워크 중 ResNet의 분류 정확도가 98.5%로 가장 높게 나타났다.

핵심용어 : 고장진단, 센서데이터, 전류데이터, CNN

1. 서 론

최근 IoT 장비와 통신기술의 발달로 기계 시설물의 모니터링 및 관리의 중요성이 점차 강조되고 있다. 미흡한 시설물 관리로 인해 산업 생산성 감소 및 경제적 손실 등 다양한 문제점이 발생할 수 있기 때문이다. 이러한 문제를 해결하기 위해 최근에는 다양한 센서를 활용하여 기계 시설물의 상태를 모니터링하고 진단하는 연구가 수행되고 있다[1-3].

본 연구에서 시설물의 고장진단을 위해 활용한 데이터는 AIHub에서 제공되는 ‘기계시설물 고장 예지 센서’의 일부 데이터이다[4]. 모터를 구동하는 인버터에 전류 센서를 연결하여 전류 데이터를 측정하였다. 본 데이터는 x, y, z 축을 통해 수집된 2차원 데이터로 구성되기 때문에 일반적인 통계 기법이나 단순한 머신러닝 기법으로 분석하기에는 어려움이 있다. 따라서, 본 연구에서는 다양한 CNN(Convolutional Neural Network) 후보 백본 네트워크 간 성능 비교를 통해 기계 시설물의 고장 진단에 가장 적합한 백본 네트워크를 제시한다. 본 연구를 통해 2차원으로 구성된 전류 데이터에 대한 분석을 수행할 수 있으며, 기계 시설물의 고장 진단에 가장 적합한 CNN 백본 네트워크를 제시할 수 있다.

2. 연구방법론

CNN의 백본 네트워크는 이미지 분류 및 객체 인식을 위해 연구된 대표적인 아키텍처들이다. 대부분 이미지 처리 영역에 특화되어 있지만, 일부 레이어의 변경을 통해 다양한 데이터를 처

리할 수 있다. 본 연구에서는 다양한 백본 네트워크 중 많은 연구에서 활용되고 있는 VGGNet(Visual Geometry Group Net), ResNet(Residual Net), DenseNet을 대표적인 백본 네트워크를 선정하여, 기계시설물 고장 진단을 수행한다.

VGGNet은 다양한 컨볼루션 레이어를 깊게 쌓아 구성된 백본 네트워크이다[5]. 유사한 구조의 블록을 여러 번 중첩해서 사용하며, 이러한 구조로 인해 더욱 다양한 특성맵을 추출할 수 있다는 특징이 있다.

ResNet(Residual Net)은 깊은 신경망에서 발생하는 Gradient Vanishing 문제를 해결하기 위해 제안된 백본 네트워크이다[6]. ResNet은 레이어 간 입력값을 더하여 전달하는 Shortcut Connection을 사용하여, Gradient를 효율적으로 관리한다. 이를 통해 기존에 비해 더욱 깊은 네트워크를 구성할 수 있다.

DenseNet은 ResNet과 유사한 Shortcut Connection을 사용하지만, 모든 출력 값을 현재 레이어의 입력 값으로 사용한다는 차이점이 있다[7]. 이러한 구조로 인해 더 적은 매개변수로 더 깊은 모델을 만들어낼 수 있는 특징이 있다.

3. 실험

3.1 Data

AIHub에서 제공되는 ‘기계시설물 고장 예지 센서’ 데이터는 기계 시설물의 정상 상태와 고장 상태에서 수집된 전류, 전동 센서 데이터로 구성되어 있으며, 본 연구에서는 전류 데이터를

† 교신저자 : skim10@dau.ac.kr 051-200-7484
* sangha@donga.ac.kr 051-200-8437
** hrchoi@dau.ac.kr 051-200-5611
*** home21cc@dau.ac.kr 051-200-5614

활용하여 실험을 진행하였다.

본 연구에서 활용한 데이터는 모터출력 2.2kW 기준에서 수집된 데이터로, 정상 상태와 측정렬불량 상태로 구분된다. 3상 유도전동기 속도를 제어하기 위한 인버터에 전류 센서를 연결하여 일정 시간 단위로 모터에 공급되는 전류 값을 2kHz로 샘플링하여 데이터를 측정한다. 따라서 본 데이터는 측정된 장비의 상태에 따라 라벨링을 구분하며, 각 3상의 전류 값이 1초 동안 측정된 테이블을 가진다. Fig. 1은 3상 전류 값의 일부 데이터를 시각화한 예시를 나타낸다.

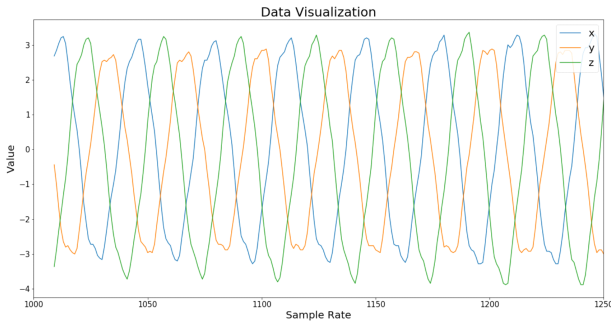


Fig. 1 3상 전류 데이터의 시각화 예시

본 연구에서 활용된 정상 데이터는 964개이며, 측정렬불량 데이터는 3,635개이다. 즉, 4,599개의 데이터를 활용하였으며, 이 중 80%는 학습 데이터, 20%는 테스트 데이터로 구축하였다. 또한, 학습 시, 모델의 일반화 성능을 평가하기 위해 학습 데이터 중 20%를 검증 데이터로 활용하였다.

3.2 Modeling

본 연구에서는 수집된 2차원 테이블 데이터를 CNN에 입력하기 위해 입력(Input) 레이어 형태를 측정된 3상의 전류 값의 형태와 동일하도록 전처리를 수행했다. 또한, 입력 레이어의 채널 값을 1로 변경하고, Pooling 레이어의 Padding 함수 및 일부 Convolution 레이어의 노드 수를 조정하여, 전류 데이터에 적합한 형태로 백본 네트워크를 변경하였다. 최종적으로 입력 레이어는 (4599, 2000, 3, 1)의 형태로 나타난다.

4. 실험결과

본 연구의 실험결과는 Table 1과 같다. 3개의 백본 네트워크의 성능을 테스트 데이터를 통해 비교한 결과, ResNet의 결과가 가장 우수하게 나타났다. ResNet은 검증데이터 기준 98.5%의 분류 정확도를 기록하였으며, 이는 VGGNet의 92.4%, DenseNet의 80.7%보다 우수하게 나타났다. 따라서, 본 연구에서 활용한 3상 전류 데이터의 분류 백본 네트워크는 ResNet이 가장 적합하다.

Table 1 후보 백본 네트워크의 성능 비교

성능지표 \ 모델	VGGNet	ResNet	DenseNet
Accuracy	92.4%	98.5%	80.7%

5. 결 론

본 연구는 기계시설물의 고장 진단을 위해 AIHub에서 제공하는 ‘기계 시설물 고장 예지 센서’의 전류 데이터를 활용하여 분석을 진행했다. 해당 전류 데이터는 2차원으로 수집되었기 때문에 일반적인 통계기법과 머신러닝 적용에 어려움이 있다. 따라서, 본 연구에서는 고장여부를 분류하기 위해 CNN을 적용하였다. 분류를 위한 다양한 후보 백본 네트워크에 대한 성능을 확인하였으며, 실험결과, ResNet이 검증 데이터 기준 98.5%의 분류 정확도를 기록하여, 3상 전류 데이터 기반 기계 시설물 고장진단에 가장 적합한 CNN 백본 네트워크로 확인되었다.

본 연구는 2차원으로 구성된 전류 데이터에 대한 분석을 CNN을 통해 수행하였으며, 기계시설물의 고장 진단에 적합한 백본 네트워크를 제시한 점에 의의가 있다.

사 사

이 논문은 2023년 해양수산부 재원으로 해양수산과학기술진흥원의 지원을 받아 수행된 연구임(스마트항로표지 현장시설 고도화, 20210636)

참 고 문 헌

- [1] 장현준, 김광주, 김상훈 (2022), 기계 시설물 고장 여부 및 고장 범주 분류 기법 비교, 한국통신학회 학술대회논문집, pp.942-943.
- [2] 안동주, 신재광, 이수안 (2022), 전동기 기계시설물 고장 분류를 위한 이미지 인코딩 기반 경량화된 딥러닝 모델, 전자공학회논문지, 59권 5호, pp.57-63.
- [3] 서재홍, 박준성, 유준우, 박희준 (2021), LSTM-VAE를 활용한 기계시설물 장치의 이상 탐지 시스템, 품질경영학회지, 49권 4호, pp. 581-594.
- [4] AIHub (2020), 기계시설물 고장 예지 센서, <https://aihub.or.kr/aihubdata/data/view.do?currMenu=115&topMenu=100&aihubDataSe=realm&dataSetSn=238>
- [5] Karen Simonyan, Andrew Zisserman (2014), Very Deep Convolutional Networks for Large-Scale Image Recognition, arXiv:1409.1556
- [6] Kaiming He, Xiangyu Zhang, Shaoqing Ren, Jian Sun (2015), Deep Residual Learning for Image Recognition, arXiv:1512.03385
- [7] Gao Huang, Zhuang Liu, Laurens van der Maaten, Kilian Q. Weinberger (2018), Densely Connected Convolutional Networks, arXiv:1608.06993