

LSTM Autoencoder를 활용한 전동기 이상 탐지

박준석⁰, 하유진^{*}, 유재천^{**}

⁰성균관대학교 전자전기공학부,

^{*}성균관대학교 컴퓨터교육과,

^{**}성균관대학교 전자전기공학부

e-mail: qwt1597@naver.com⁰, hujhuj0110@gmail.com^{*}, yoojc@skku.edu^{**}

Motor Anomaly Detection Using LSTM Autoencoder

Jun-Seok Park⁰, Yoo-Jin Ha^{*}, Jae-Chern Yoo^{**}

⁰School of Electronic and Electrical Engineering, Sungkyunkwan University,

^{*}Dept. of Computer Education, Sungkyunkwan University,

^{**}School of Electronic and Electrical Engineering, Sungkyunkwan University

● 요약 ●

본 논문에서는 LSTM Autoencoder를 활용한 전동기의 Anomaly Detection을 제안한다. 전동기의 Anomaly Detection를 통해 전동기보드의 고장을 예방하여 이용자의 안전을 보장한다. 전동기로부터 얻은 시계열 진동 데이터와 시계열 데이터 분석에 유의미한 LSTM을 활용한 Autoencoder를 통해 Anomaly Detection을 구현했다. 그 결과 99.9%의 정확도를 기록하였다.

키워드: 딥러닝(Deep Learning), 이상 탐지(Anomaly Detection), 비지도학습(Unsupervised Learning), Autoencoder, LSTM, LSTM Autoencoder

I. Introduction

전동기는 전동기보드의 핵심 부품으로 전동기의 고장은 경제적 손실과 인명 피해를 발생시킬 수 있다. 그렇기에 설비의 고장을 정확하게 감지하고 이를 빠르게 유지보수하는 것이 중요하다. 이러한 문제에 딥러닝을 활용한 설비의 이상 탐지의 한 방법을 제안한다.

이상 탐지란 데이터에서 이상 패턴과 이상 개체 등을 찾아내는 것을 말한다. 본 연구에서는 시계열 데이터를 다루는데, 이상이 있으면 이상 패턴이 발생하여 이를 감지한다. 고장이 나기 전에도 서서히 이상 패턴을 보이므로, 장비가 완전히 고장나기 전에 이를 감지하여 사전에 방지할 수 있다.

기계 설비의 이상 탐지를 위해 지도학습과 비지도 학습을 사용할 수 있다. 지도학습은 정상과 비정상 데이터를 모두 사용하여 모델 학습 시 정확도가 높게 나오나, 두 가지 단점으로 인해 비지도 학습이 활발히 연구되고 있다. 지도학습의 단점은, 충분한 양의 비정상 데이터를 구하기 힘들다는 것과 새로운 이상 패턴이 발생하게 되면 새로 학습을 진행해야 한다는 것이다. 반면 비지도 학습은 다양한 유형의 예외 상황을 전부 탐지할 수 있을 뿐만 아니라 정상 데이터의 확보가 쉽다는 장점이 있어서 이상 탐지에 적합하다.[1]

본 연구에서는 전동기 데이터의 시간적 흐름을 고려하기 위해 sequence 데이터를 다루는 LSTM과 정상 데이터의 특징을 학습하는

Autoencoder를 합친 LSTM Autoencoder 알고리즘을 사용한다. 이상 탐지 모델을 생성하기 위해 LSTM Autoencoder 알고리즘에 정상 전동기 데이터를 학습시키고, 마지막으로 성능 평가와 결과 분석을 시행하였다.

II. Preliminaries

1. Autoencoder

Autoencoder는 입력을 encoder와 decoder를 거쳐 입력을 재구축한다. 입력과 출력의 차이를 손실 함수로 학습이 진행된다. 인코더를 거치면서 노이즈를 제거한다거나 차원이 축소되는 점을 이용하기도 하며, 디코더를 이용해 샘플을 만드는 데도 사용된다. 본 연구에서는 Autoencoder가 입력을 그대로 재구축한다는 점을 이용해 인코더와 디코더를 전부 활용하여 이상 탐지를 하는 데 활용하였다.[2]

2. LSTM

LSTM은 RNN의 한 종류로 길이가 길어졌을 때도 정보를 덜 잃어버린다는 장점이 있다. 이를 포함하여 LSTM은 대부분의 문제에

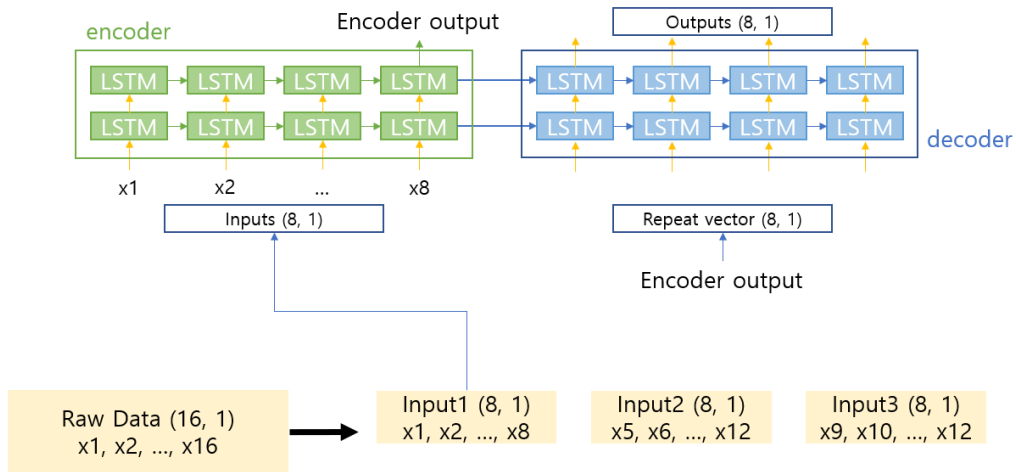


Fig. 1. System Architecture

대해서 RNN보다 좋은 성능을 보이므로 본 연구의 인코더와 디코더에 활용하였다.[3]

3. LSTM Autoencoder

LSTM Autoencoder는 Autoencoder의 encoder와 decoder로 LSTM을 사용한다. Autoencoder의 기능을 수행하면서 입력의 순서를 반영할 수 있다.[4]

3. 모델 구조

연구에서 사용한 LSTM Autoencoder 모델은 2개의 인코더 계층과 2개의 디코더 계층으로 구성되어 있다. 은닉층 개수는 각각 인코더 계층에 32, 16개, 디코더 계층에 16, 32개로 설정하였다.

Table 1. Hidden Layers 수

Layer	Hidden Layers
Encoder Layer	32
	16
Decoder Layer	16
	32

III. The Proposed Scheme

1. 학습 환경

본 연구는 NVIDIA GeForce RTX 3090 GPU 환경에서 수행되었다. 연구에 사용한 전동기 데이터는 대전 도시철도 역사에서 AI HUB에 제공한 데이터이다. 전동기에 부착된 진동 감지 센서로, 단축으로 가속도를 측정하여 기록한 데이터이다. Training Set은 3초 동안 초당 4000회 측정되어 총 12,000개의 수치가 기록된 15,290만 개의 정상 데이터를 사용하였다. 추후 테스트를 위해 정상 데이터와 측정될 불량 상태인 데이터가 섞여 있는 테스트 데이터를 추가로 사용하였다.

시스템의 전체적인 모습은 Fig 1.과 같다.

2. 데이터 전처리

본 연구에서는 데이터의 형태를 적절하게 변환하고, 효율적인 학습을 위해 scaler를 사용했다. 우선 LSTM 모델에 학습시키기 위해 원래 샘플의 개수와 특성 개수로 이루어졌던 2차원 데이터를 한번에 처리할 데이터의 개수까지 포함하는 3차원 데이터로 변경했다. 원본 데이터의 경우 단위 시간마다 기록된 12000개의 수치가 있는데, 한번에 처리할 수치를 8개로 정하고 한 번에 4개씩 데이터를 건너뛰도록 하여 한 개의 원본 데이터로부터 2998개의 학습 데이터를 생성해낼 수 있었다. 그 후 scaler를 이용해 데이터의 평균을 0, 분산을 1로 조정하여 학습을 진행하였다.

4. 학습

모델의 optimizer는 Adam을 사용하였고, 손실 함수는 MSE를 사용한다.[5] 파라미터는 배치 사이즈를 4096으로 설정하고, learning rate는 0.0001로 설정하였다. 그 결과 에포크가 60회일 때, 모델의 검증 손실 값이 0.0008을 기록하였다. 모델의 학습 결과는 Fig 2. 과 같다.




Fig. 2. Learning Curve of Model

5. 분류




Fig. 3. Prediction

위 자료는 5개의 정상 데이터와 5개의 이상 데이터로 shuffle 없이 예측을 한 결과이다.

본 연구에서 사용한 데이터에는 3초간 12000개의 수치가 기록되어 있다. 12000개의 수치로부터 2998번의 예측을 진행하고 2998개의 MSE 값이 생성된다. Fig 3.처럼 이상 개체라고 2998개의 모든 구간에서 높은 MSE값을 가지지는 않기 때문에 추가적인 방식으로 이상 탐지를 수행해야 한다.

본 연구에서는 데이터에서 나온 다수의 MSE 값의 상위 0.5%에 해당하는 값의 평균을 활용하였다. 이를 통해 정상 데이터에서 소수의 값이 튀어 이상으로 식별되는 현상을 방지해 Model의 Sensitivity를 개선했다. 또한, Precision, Recall 곡선을 활용해 Threshold를 설정하여 Model의 전체적인 정확도를 개선했다.




Fig. 4. Random Prediction

Fig 4.는 본 논문에서 제안하는 분류방식을 쓰지 않을 경우 생길 수 있는 문제점을 보여준다. 임계값을 설정하여 그 값을 넘는 구간을 이상 개체라고 판단할 경우, 정상 개체 중에서 극소수의 값이 튀었을 때 이상 개체라고 판단할 가능성도 있다. 또한, 이상 개체의 수많은 구간이 정상의 범위에 속하기도 하므로 모델의 정확도가 매우 낮게

측정될 것이다.

IV. Conclusions

		Predicted	
		Abnormal	Normal
Actual	Abnormal	499	1
	Normal	0	500

완성된 모델은 99.9%의 정확도를 보여줬다. 또한, True Positive Rate(TPR)가 0.998, True Negative Rate(TNR)가 1로 뛰어난 성능을 보여준다. 특히 TNR이 1이므로 정상적인 개체를 모델이 오분류하여 재산 낭비가 일어나는 일이 매우 적을 것이다. 이것으로 기업은 사고를 예방하고, 기기의 유지보수에 큰 도움을 얻을 수 있다.

ACKNOWLEDGEMENT

"본 연구는 과학기술정보통신부 및 정보통신기획평가원의 대학ICT연구센터지원사업의 연구결과로수행되었음" (IITP-2022-2018-0-01798)

REFERENCES

- [1] Chandola, Varun, Arindam Banerjee, and Vipin Kumar. "Anomaly detection: A survey." ACM computing surveys (CSUR) 41.3 (2009): 1-58.
- [2] Bank, Dor, Noam Koenigstein, and Raja Giryes. "Autoencoders." arXiv preprint arXiv:2003.05991 (2020).
- [3] Hochreiter, Sepp, and Jürgen Schmidhuber. "Long short-term memory." Neural computation 9.8 (1997): 1735-1780.
- [4] Lee, Jong-Hyeon, and Jung-Mo Sohn. "Escalator Anomaly Detection Using LSTM Autoencoder." Proceedings of the Korean Society of Computer Information Conference. Korean Society of Computer Information, 2021.
- [5] Kingma, Diederik P., and Jimmy Ba. "Adam: A method for stochastic optimization." arXiv preprint arXiv:1412.6980 (2014).