딥러닝 기반의 기계 잔존 수명 예측 시스템

이세훈*, 김한솔O, 정찬영*, 이태형*, 김지태*, 송경환**, 손정모***
O인하공업전문대학 컴퓨터시스템과,
*인하공업전문대학 컴퓨터시스템과,
**한국콘베어공업(주),
***이포즌(주)
e-mail: seihoon@inhatc.ac.kr*, doctorsol@naver.comO, gook3427@naver.com*, thlee0700@gmail.com*,
jitae0401@naver.com*, khsong@conveyor.co.kr**, msohn@epozen.com***

Deep Learning based Machine Remaining Useful Life Prediction System

Se-Hoon Lee*, Han-Sol KimO, Chan-Young Jung*, Tae-Hyeong Lee*, Ji-Tae Kim*,
Kyung-Hwan Song**, Jung-Mo Sohn***
ODept. of Computer Systems, INHA Technical College,
*Dept. of Computer Systems, INHA Technical College,
**R&D Center, Korea Conveyor Ind. Co., LTD.,
***EPOZEN. Co., LTD.

● 요 약 ●

본 논문에서는 산업 현장에서 사용되는 기계들의 건전성을 유지하고 예측하는 시스템을 개선할 수 있는 연구 결과를 비교하고 설명한다. 이번 연구에서는 딥러닝 기술을 이용함으로서 특정장치에 종속되지 않고 범용적으로 수집된 소음데이터를 사용하여 현장 적용의 유연성을 높이고, 딥러닝 모델 중 GRU를 이용하여 기존 연구 결과와 비교 실험을 하여 더 우수한 결과를 얻었다.

키워드: 잔존 수명(Ramaining Useful Life), 딥러닝(Deep Learning), GRU(Gate Recurrent Unit)

I. Introduction

머신러닝 기반 잔존 수명 예측 시스템은 산업현장에서 사용되는 기계 주요 부품들의 성능 저하로 인한 문제를 방지하고자 AI가 예측하는 수명 곡선을 통하여 잔존 수명을 예측(RUL, Remaining Useful Life)하고 기계의 건전성을 유지한다[1]. 산업 현장에서는 이를 적용하는 것으로 인력 및 비용절감을 기대 할 수 있으며 잔존수명 예측을 통하여 기간별 유지보수 계획을 세우는데 활용할 수 있다.

본 논문에서는 이포즌에서 제공한 자원들을 바탕으로 구축한 시스템 전반의 아키텍처를 설명하고 현장에서 사용되는 에스컬레이터의 소음 데이터를 푸리에 변환과 포락선 분석으로 건전성 인자에 해당하는 신호를 분리하고 GRU를 사용하여 수명 예측을 수행하는 기법을 제안한다[2].

II. The Proposed Scheme

1. System Architecture

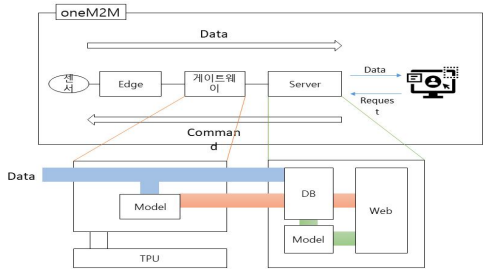

Fig. 1. System Architecture

제안하는 시스템은 Fig. 1 과 같이 IoT 국제 표준인 oneM2M을 기반으로 구성되어 있다.

센서에서 측정된 소음 데이터는 게이트웨이를 통해 서버로 전달되

고 서버에서는 푸리에 변환 등의 전처리 과정을 거쳐 기어와 베어링의 신호로 데이터를 분리시킨다[3].

이후 분리된 데이터에서 건전성 인자(Health Index)를 얻은 뒤 이를 딥러닝 모델로 학습시켜 HI 그래프를 얻은 후[4] 최종적으로 잔존 수명을 예측한다.

예측한 수명 정보는 웹 인터페이스를 통해 사용자에게 전달되며 사용자는 이를 통해 부품에 전반적인 유지보수 계획을 수립할 수 있다.

2. GRU(Gate-Recurrent-Unit)

선행 연구에서의 RNN은 장기 의존성 문제로 타임 스텝이 길어질수록 앞쪽의 영향력이 줄어드는 문제가 있기 때문에 본 연구서는 GRU 네트워크를 사용한다.

GRU 네트워크는 같은 시계열 예측 네트워크인 LSTM과 비교하여 적은 데이터로 우수한 성능을 나타낸다.

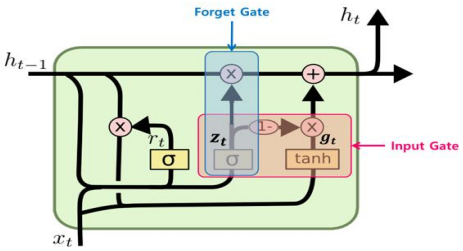

Fig. 2. Gate-Recurrent-Unit

따라서 본 연구에서는 푸리에 변환과 포락선 통해 획득한 신호의 건전성 인자를 Fig. 2 의 GRU 모델의 입력 데이터로 사용한다[4]. 이후 GRU 모델로 얻은 HI 그래프를 잔존 수명 예측에 활용한다.

III. Experiment

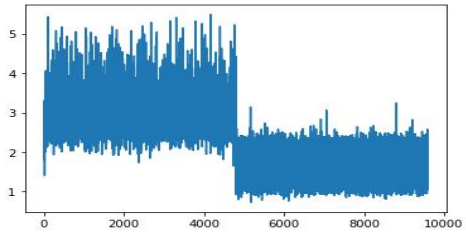

Fig. 3. HI Graph

Fig. 3 은 기계 부품의 건전성 인자를 얻기 위해 그린 HI 그래프다. 해당 그래프는 한국콘베어공업에서 제공한 에스컬레이터의 소음데이터를 사용하였다. 소음데이터를 Fig. 4 와 같이 푸리에 변환과 포락선 분석을 통하여 각각 기어와 베어링 신호로 분리한 뒤 결함 주파수대역을 GRU로 학습시키고 이 후 HI그래프를 얻는다[4].

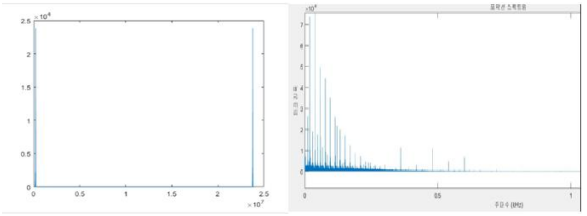

Fig. 4. Fourier Transform and Envelope Analysis

최종적으로는 HI 그래프를 이용하여 건전성 인자를 취득하고 RUL을 예측하는 그래프를 그리고 기존의 연구에서 사용된 RNN과의 결과를 비교한다.

IV. Conclusions

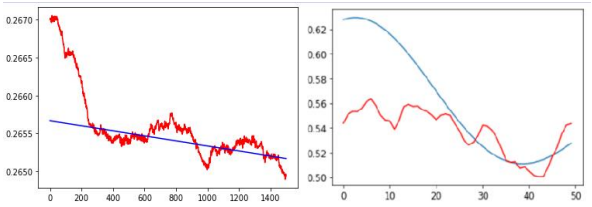

Fig. 5. RUL Graph

본 연구에서 Fig 5 와 같이 기존 연구에서 사용된 RNN 방식의 RUL예측 그래프보다 실제 RUL에 근접한 결과를 얻을 수 있었다.

REFERENCES

[1] S.Xingjian, Z.Chen H.Wang D.Y.Yeung, "Convolutional LSTM network: A machine learning approach for precipitation nowcasting," Advances in neural information processing systems, pp. 802-810, 2015.

[2] P.P.Adhikari, H.V.Rao, and M.Buderath, "Machine Learning based Data Driven Diagnostics & Prognostics Framework for Aircraft Predictive Maintenance," 10th International Symposium on NDT in Aerospace Dresden, Germany, Oct. 2018.

[3] Hyeon-Jung Kim, Byeong-Hyun Ahn, Dong-Hee Park, Byeong-Keun Choi, "Feature Analysis for Fault Diagnosis according to Gearbox Failure," Transactions of the Korean Society for Noise and Vibration Engineering 27(3), pp. 312-317, Jun. 2017.

[4] Tae-wan Hwang, Keun-su Kim, Su-ji Kim, Byung-joo Jeon, Byeng-Dong Youn, “Health index extraction for ball bearing using defect frequency,” Korean Society for Precision Engineering, pp. 1428-1430, Dec. 2016.