

논문 2022-59-1-14

Convolutional LSTM 모델 기반의 짧은 지연 시간을 갖는 베어링 결함 진단

(Low-latency Bearing Fault Diagnosis based on
Convolutional LSTM Model)

김 지 호*, 신 지 훈*, 김 태 환**

(Ji-Ho Kim, Ji-Hoon Shin, and Tae-Hwan Kim[©])

요 약

본 논문은 짧은 지연 시간을 갖는 베어링 결함 진단을 위한 convolutional LSTM (ConvLSTM) 모델 기반의 진단 예측 방법을 제안하고 이에 대한 진단의 지연 시간 및 정확도를 평가한다. 제안하는 방법은 일반적인 결함 진단의 절차 중 입력의 취득에 소요되는 시간을 효과적으로 감소시키기 위해 순차적으로 입력되는 데이터를 짧은 벡터로 분할하여 처리한다. 짧은 벡터의 입력에서 시간적 특징을 효과적으로 찾기 위해 ConvLSTM 모델을 사용하며 ConvLSTM 모델은 many-to-many 구조로 설계하여 연속된 진단의 예측 결과가 고장 조건에 해당하는 즉시 고장을 진단하는 방법이 적용되었다. 제안된 방법은 case western reserve university 베어링 데이터셋으로 실험되었으며, 결함 진단의 정확도는 유지하면서 예측 시간을 2D-CNN 모델에 비해 99.3%, 1D-CNN 모델에 비해 50.7% 감소시켰다.

Abstract

This paper presents a novel approach of bearing fault diagnosis based on convolutional LSTM (ConvLSTM) model to reduce the latency. Time-series sensor data are segmented into short vectors that are fed sequentially into a ConvLSTM model to find the spatio-temporal features effectively. The model is devised to a many-to-many structure by which the failure can be diagnosed as soon as several consecutive prediction results correspond to the failure condition. The proposed approach reduces the latency by up to 99.3% and 50.7% compared to the 2D-CNN-based and 1D-CNN-based approaches, respectively, without any degradation of the diagnosis accuracy.

Keywords : Fault diagnosis, Neural networks, Embedded systems, Low-latency monitoring systems

I. 서 론

베어링은 기계의 내부에서 회전하는 샤프트를 지지하여 물체의 회전을 보조하는 회전체 장비로서 대부분의 기계에서 사용되는 필수 구성요소이다. 베어링의 경

우 지속적인 마찰로 인한 마모가 발생하게 되어 결함이 생기기 쉬우며, 이는 전체 기계 고장 원인의 30-40%를 차지하는 기계의 주요한 고장 원인이다^[1]. 자율 주행, 스마트 팩토리 등 기계의 역할이 확대됨에 따라 기계의 고장으로 인해 생길 수 있는 피해와 손실의 정도가 커

*학생회원, **평생회원, 한국항공대학교(School of Electronics & Information Engineering, Korea Aerospace University)

[©] Corresponding Author(E-mail : taehwan.kim@kau.ac.kr)

※ 본 연구는 경기도의 경기도 지역협력연구센터 사업의 일환으로 수행하였고 [GRRC항공2017-B02, 3차원 공간 데이터 처리 및 응용 기술 연구], 2021년도 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 기본연구사업임 (2021R1F1A1059536).

EDA 도구는 IDEC의 지원을 받았음.

Received : October 22, 2021

Revised : November 4, 2021

Accepted : November 9, 2021

졌기 때문에 기계 설비의 상태를 분석하고 고장을 사전에 예측하는 시스템이 필요하다. 이에 기계 고장의 주요 원인인 베어링의 상태를 진단하여 전체 기계 고장으로 이어지기 전에 결함을 예측할 수 있다면 기계 고장으로 인한 치명적인 피해를 대비할 수 있다.

베어링의 결함에 따른 고장을 예측하여 사고를 미연에 방지하기 위해서는 결함에 대한 지속적인 모니터링이 필요하다. 측정된 데이터를 기반으로 기계의 상태를 수학적으로 모델링하여 잔여 수명을 예측하기도 하지만, 전문가가 수집된 신호를 분석하고 판단하는 과정을 거쳐야 할 뿐만 아니라 환경 변화에 따라 모델링을 새로 해야 한다는 단점이 있다. 또한 지속적으로 기계를 모니터링 하는 데에는 인력 적으로 한계가 있기 때문에 기계의 상태를 모니터링 하는 자동화 시스템이 필요하다^[8]. 자동화된 모니터링 시스템은 일반적으로 센서를 통해 취득한 데이터로 기계의 상태를 지속적으로 모니터링 한다. 베어링은 기계 내부에 내장되어 성능 저하를 육안으로 관찰하여 판단할 수 없기 때문에 부착된 센서를 통해 측정된 진동 데이터로 결함을 진단한다.

머신 러닝 기법 중 신경망을 기반으로 베어링의 결함을 진단하는 방법에 대한 연구가 활발히 진행되고 있다. 초기에는 진동 데이터를 이미지로 해석하여 데이터의 공간적 특징을 추출하는 2차원 합성곱 신경망(2D-CNN)을 기반으로 결함을 진단하는 방법을 중심으로 연구가 이루어졌다^[2~4]. 2D-CNN 모델의 높은 연산량을 줄이기 위해 일부 논문에서는 전처리 없이도 원시 데이터를 효과적으로 처리할 수 있는 1차원 합성곱 신경망(1D-CNN) 기반의 결함 진단 방법을 제안하였다^[5~8]. 이후 진단의 정확도를 높이기 위해 RNN(Recurrent Neural Network)을 기반으로 순차적인 데이터의 시간적 특징을 추출하여 결함을 진단하는 방법이 제안되었으며^[9, 10], 두 신경망의 장점을 모두 활용하여 시공간 특징을 효과적으로 추출하기 위해 CNN 모델과 RNN 모델을 결합하여 사용한 방법도 제안되었다^[9]. 이전 연구들은 결함 진단의 정확도 또는 연산량을 중심으로 연구가 진행되어 왔으며, 입력 데이터의 취득부터 결함 진단 결과의 도출까지 걸리는 진단의 지연 시간을 크게 고려하지 않았다.

본 논문에서는 convolutional LSTM (ConvLSTM) 모델을 기반으로 짧은 진단 지연 시간을 보이는 베어링 결함 진단 방법을 제안한다. 긴 입력 데이터를 얻기 위해 생기는 입력 데이터 취득 시간을 줄이기 위해 짧은 원시 벡터로 결함을 진단하며 입력의 시공간적 특징을

효과적으로 추출하기 위해 many-to-many 구조의 ConvLSTM 모델이 사용된다. 시간별로 들어오는 짧은 원시 벡터의 진단 결과가 연속적으로 결함을 예측한다면 이후의 입력을 더 이상 처리하지 않고 그 즉시 결함을 진단할 수 있는 방법을 적용하였다. 해당 방법은 case western reserve university (CWRU) 베어링 데이터를 사용하여 실험되었으며 1D-CNN 모델과 2D-CNN 모델 기반의 접근 방식에 비해 각각 50.89%, 99.3%의 진단 지연 시간을 감소시키면서도, 결함 진단의 정확도는 유지하였다.

본 논문의 나머지 부분은 다음과 같이 구성된다. II장에서는 기존의 베어링 결함 진단 절차와 신경망 기반의 결함 진단 방법에 대해 분석한다. III장에서는 ConvLSTM 모델 기반의 결함 진단 방법을 설명하고, 진단 지연시간을 줄일 수 있는 진단 예측 방법을 제안한다. IV장에서는 제안하는 방결함 진단 방법의 진단 정확도 및 지연 시간을 보이고, 이를 다른 신경망을 기반으로 한 결함 진단 방법과 정량적으로 비교한다. 마지막으로 V장에서는 본 논문의 결론을 도출한다.

II. 기존의 결함 진단 방법

1. 결함 진단 절차

신경망을 기반으로 한 결함 진단의 절차는 크게 1) 데이터 취득, 2) 데이터 가공, 3) 가공된 데이터를 사용한 결함 진단의 세 단계로 구성된다^[3]. 그림 1에 신경망을 사용한 결함 진단의 절차를 도시하였다. 데이터 취득 단계에서는 적절한 크기의 입력이 얻어질 때까지 순차적으로 들어오는 진동 데이터를 취득하고 메모리에 축적한다. 데이터 가공 단계에서는 신경망의 입력 포맷에 맞도록 데이터를 재배열하거나 시간-주파수 축의 스펙트로그램을 생성하여 입력 데이터를 가공해주고, 결함 진단 단계에서는 신경망을 기반으로 결함을 진단한다.

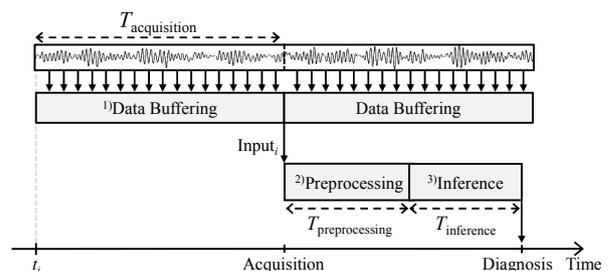


그림 1. 기존 결함 진단 방법의 전반적인 처리 흐름
Fig. 1. Overall processing flow of the conventional fault-diagnosis method.

결함 진단의 지연 시간은 입력 데이터가 들어오기 시작한 시점부터, 해당 데이터가 결함인지에 대한 진단이 이루어지는 시점까지 소요된 시간을 의미한다. 결함 진단의 지연 시간은 결함 진단 절차에 따라 데이터의 취득, 가공, 진단 각 단계에 소요되는 시간의 합으로 정의할 수 있다. 결함 진단의 지연 시간은 $T_{\text{diagnosis}}$ 로 표기하며 아래와 같은 수식으로 표현할 수 있다.

$$T_{\text{diagnosis}} = T_{\text{acquisition}} + T_{\text{preprocessing}} + T_{\text{inference}} \quad (1)$$

여기서, $T_{\text{acquisition}}$ 는 데이터 취득 시간으로 첫 번째 데이터의 취득을 시작한 시점부터 원하는 입력 크기의 데이터를 취득하기까지 소요된 시간을, $T_{\text{preprocessing}}$ 은 데이터를 가공하는 데에 소요된 전처리 시간을, $T_{\text{inference}}$ 는 신경망의 추론 과정을 통해 최종적으로 결함을 진단하는 데에 소요된 시간을 나타낸다.

데이터 취득 시간은 신경망의 입력 크기에 의해 결정되며, 입력의 크기는 진단 정확도와 진단 지연 시간을 모두 고려하여 최적화시킬 필요가 있다. 입력의 크기에 따른 진단 정확도와 진단 지연 시간은 trade-off 관계를 가지고 있으며, 그림 2에서 해당 관계에 대한 실험 결과를 보인다. 더 긴 취득 시간동안 데이터를 취득하면 짧은 시간동안 취득한 데이터보다 더 많은 정보를 담고 있기 때문에 진단 정확도가 높아질 것이라고 기대할 수 있지만, 긴 데이터를 축적하기 위해 기다려야 하는 $T_{\text{acquisition}}$ 또한 증가한다는 단점이 있다. 뿐만 아니라, 입력 데이터가 길어지면 해당 데이터를 전처리 하고 추론하는 과정에 걸리는 시간 또한 증가하여 결국 $T_{\text{diagnosis}}$ 가 증가하게 된다.

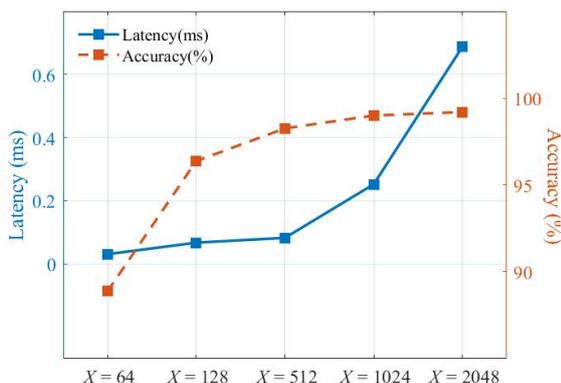


그림 2. 입력의 크기(X)에 따른 진단 정확도와 진단 지연 시간

Fig. 2. Diagnosis accuracy and latency for the input size denoted by X.

전처리 과정은 원시 데이터를 신경망의 입력 크기에 맞게 변형하거나 효과적인 특징 추출을 위해 데이터를 미리 가공해주는 과정이다. 2D-CNN 모델의 경우 2차원 형태의 데이터를 입력으로 사용하기 때문에 취득된 1차원 형태의 진동 데이터를 2차원으로 가공해 주어야 한다^[7]. 최근 연구에서는 푸리에 변환을 통해 스펙트로그램을 생성하여 2차원 데이터로 가공하며, 이 경우 전처리 과정에 걸리는 시간이 추론 과정에 걸리는 시간과 비슷하게 소요될 수 있다^[8]. 가공된 데이터로 결함을 진단하는 마지막 과정은 신경망의 추론 과정으로, 2D-CNN, 1D-CNN, fully-connected LSTM (FC-LSTM) 등의 모델을 사용하여 결함을 진단한다.

2. 뉴럴 네트워크 기반의 결함 진단

2차원 CNN과 1차원 CNN 모델은 각각 2차원과 1차원 벡터의 입력을 받아 여러 개의 합성곱 레이어를 거쳐 완전 연결 레이어 (fully-connected layer; FCL)를 통해 최종 결함 진단 결과를 도출하는 구조를 가진다. CNN 모델은 하나의 입력 데이터에 존재하는 공간적인 특징의 추출에 뛰어나지만 다수의 입력 데이터 간의 시간적인 특징을 추출하지 못하는 구조적인 단점을 가지고 있다. 이에 따라, CNN 모델을 사용해서 입력 데이터 간의 시간적인 특징을 파악하기 위해서는 다수의 입력 데이터를 연결시켜 하나의 거대한 입력 데이터로 가공하여 사용하게 되며, 이 경우 $T_{\text{acquisition}}$ 과 $T_{\text{preprocessing}}$ 증가하여 진단 지연시간이 증가하는 문제가 있다.

RNN은 입력에 대한 정보를 내부의 상태 메모리에 저장하고 다음 입력이 들어왔을 때 상태 메모리에 저장된 정보를 고려하여 추론하기 때문에 입력 데이터 간의 시간적인 특징을 추출하기 유리한 구조를 가지고 있다. 베어링의 진동 데이터는 근본적으로 시간에 따라 취득된 것이기 때문에 취득된 데이터 간의 시간적인 특징 추출이 중요하다. 따라서 공간적 특징의 추출에 뛰어난 CNN 모델보다 시간적 특징의 추출에 뛰어난 RNN을 사용하여 데이터를 진단하는 것이 더 적합하다. CNN 모델과 달리 RNN 모델은 모델 내부의 상태 정보를 이용하여 입력 데이터 간의 시간적인 특징을 효과적으로 추출할 수 있지만 공간적 특징을 추출하기 어렵다는 단점이 존재한다. 결과적으로, 최근 연구에서는 추론 성능을 높이기 위해 서로 다른 특징을 가지는 신경망을 (예: CNN + RNN) 결합하여 사용함으로써, 각 신경망의 단점을 보완하고 진단 정확도를 높인다^[11, 12].

III. 제안하는 결함 진단 방법

지속적으로 모니터링을 해야 하는 시스템의 경우, 시간이 흐를수록 진단의 지연 시간이 누적되어 결국 결함에 해당하는 데이터가 입력으로 들어와도 빠른 시간 내에 결함으로 진단하지 못하게 된다. 따라서 결함을 진단하는 데에 걸리는 지연 시간을 줄여야만 결함을 진단하여 고장을 예측하는 모니터링 시스템이 제대로 된 역할을 할 수 있게 된다. 하지만 기존의 신경망을 기반으로 한 결함 진단은 성능 개선을 중심으로 연구가 진행되어 왔으며, 진단의 지연 시간이 크게 고려되지 않았다. 예를 들어, 성능을 향상시키기 위해 입력 받은 데이터로 스펙트로그램을 생성한 후에 분석하는 과정을 한 단계 추가하거나^[3, 4], 다른 종류의 신경망을 결합하여 추론 과정에 사용하였다^[11, 12].

제안하는 결함 진단 방법은 $T_{acquisition}$ 을 감소시키고 $T_{preprocessing}$ 을 제거하기 위해 짧은 시간에 취득한 진동 신호 그대로를 입력 데이터로 사용한다. ConvLSTM 모델은 LSTM의 수식에서 각 게이트의 곱셈 연산을 합성곱 연산으로 대체했기 때문에, 필터링 기법을 적용함으로써 입력의 공간적인 특징을 추출할 수 있게 된다. 또한 ConvLSTM 모델은 RNN 모델을 기반으로 한 신경망이기 때문에 RNN의 특징인 내부 메모리를 사용하여 이전에 얻은 입력과 현재 입력 간의 시간적인 특징을 추출할 수 있다. 따라서, 하나의 신경망으로 시공간적인 특징을 모두 추출이 가능하기 때문에 짧은 데이터로도 진단의 정확도를 유지할 수 있으며, 별도의 전처리 과정이 필요하지 않다. 아래에 ConvLSTM 모델의 게이트 연산 수식을 보면, FC-LSTM 모델의 게이트 연산 수식에서 행렬곱 연산이 합성곱 연산으로 대체된 것을 확인할 수 있다.

$$\begin{aligned}
 f_t &= \sigma(\mathbf{W}_{xf} * x_t + \mathbf{W}_{hf} * h_{t-1} + b_f) \\
 i_t &= \sigma(\mathbf{W}_{xi} * x_t + \mathbf{W}_{hi} * h_{t-1} + b_i) \\
 o_t &= \sigma(\mathbf{W}_{xo} * x_t + \mathbf{W}_{ho} * h_{t-1} + b_o) \\
 g_t &= \tanh(\mathbf{W}_{xg} * x_t + \mathbf{W}_{hg} * h_{t-1} + b_g)
 \end{aligned}
 \tag{2}$$

ConvLSTM 모델은 many-to-many 구조로 설계하여 짧은 진단 지연 시간을 달성하기 위한 방법으로 결함을 모니터링 한다. RNN의 many-to-many 구조 특성 상 순차적으로 입력 받은 데이터를 기반으로 현재까지 받은 입력에 대한 결함 감지 결과를 도출할 수 있다. Many-to-one 구조와 같이 마지막 타임 스템프의 FCL의 결과만 결함 진단 결과로 사용하는 대신,

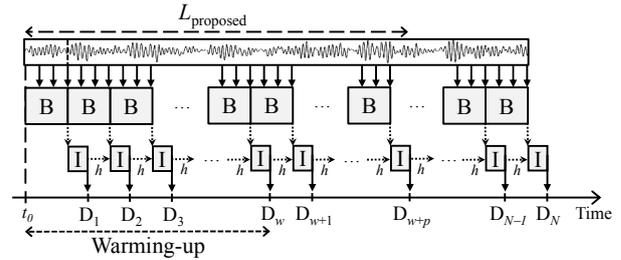


그림 3. 제안하는 짧은 지연시간을 갖는 베어링 결함 진단 방법의 처리 흐름
Fig. 3. Processing flow of the proposed fault-diagnosis method.

ConvLSTM 모델의 모든 타임 스템프에서 FCL을 거쳐 현 시점까지의 진단 결과를 도출한 뒤 이 값들을 진단의 예측 값으로 전부 고려한다. 입력의 초기 상태에서는 충분한 데이터가 입력으로 들어오지 않아 분석 정확도가 떨어지기 때문에 ConvLSTM 모델이 최소한의 데이터를 받아 워밍업 할 시간이 필요하다. 이에 워밍업 파라미터 (w)를 설정하여 w 이전까지는 최종적인 진단의 결과를 내지 않고, w 이후에 동일한 예측 결과가 연속으로 나오는 개수를 인내 파라미터 (p)로 설정하여 w 와 p 를 통해 분석 정확도와 지연 시간을 조정할 수 있게 된다. 그림 3에서 D_n 은 각각 각 입력에 대한 결함 예측 결과가 도출되는 시점이며, N 은 입력의 총 개수,

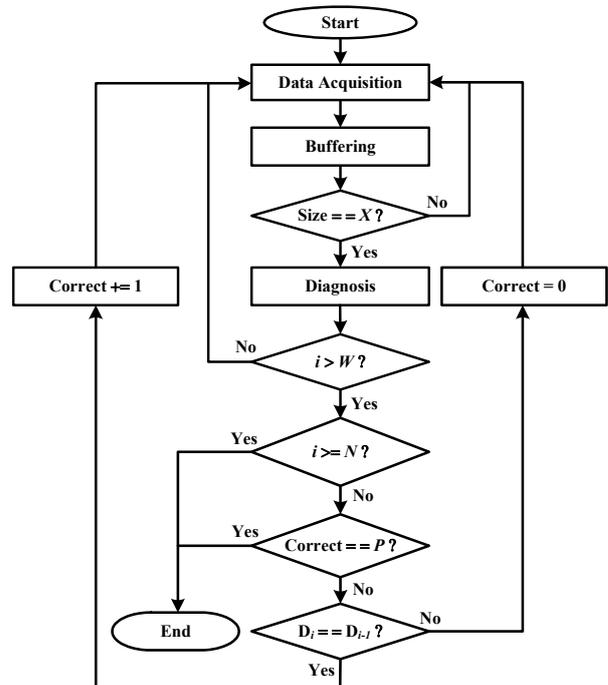


그림 4. 제안하는 짧은 지연 시간을 갖는 베어링 결함 진단 방법의 처리 절차
Fig. 4. Procedure of the proposed fault-diagnosis method.

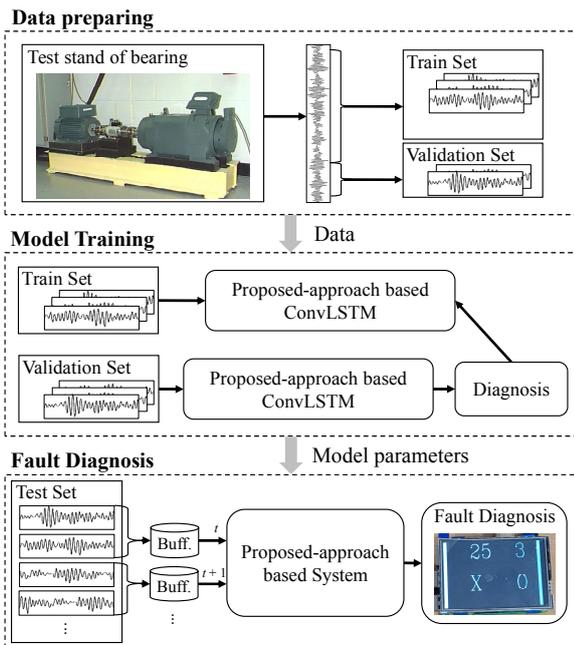


그림 5. 제안하는 결함 진단 방법에 기반한 모니터링 시스템과 시연 절차 및 환경
 Fig. 5. Bearing fault monitoring system based on the proposed method, its demonstration flow, and environment.

ConvLSTM 모델에서 이전 입력을 기억하는 메모리 역할을 하는 state는 h , B와 I는 각각 데이터 취득 단계와 데이터 추론 단계를 나타낸다.

제안하는 방법에서의 진단 절차는 아래와 같은 흐름으로 진행된다. 그림 4에 제안하는 방법의 처리 절차를 도시하였다. 먼저, 입력의 최소 크기인 만큼의 입력을 받을 때까지 데이터 축적 (data buffering)을 진행한다. 이후 원하는 크기의 입력을 취득하였다면 (data acquisition) 진단 (diagnosis) 단계로 진입하여, 워밍업 파라미터인 w 타임 스템프만큼 데이터를 입력 받아 진단하며 워밍업 한다. 이후 인쇄 파라미터인 p 개의 연속적인 결과가 예측될 때까지 데이터를 입력 받아 결함을 진단하는 것을 반복하며 입력의 총 개수인 N 개를 처리할 때까지 p 개의 연속적인 결과가 나오지 않는다면 마지막 타임 스템프의 예측 결과로 최종 결함을 진단한다. 최소 지연 시간은 w 시간 이후에 바로 개의 예측 결과가 연속으로 나오는 경우에 발생하고 최대 지연 시간은 p 개의 연속 결과 예측이 마지막 타임 스템프까지 발생하지 않아 모든 타임 스템프를 계산해야 할 때 발생한다.

IV. 결과 및 분석

제안하는 지연시간 감소를 위한 결함 진단 방법에 기반한 모니터링 시스템은 1.2GHz로 동작하는 ARM Cortex-A53 프로세서를 기반으로 하는 임베디드 시스템에서 구현되었다. 데이터를 순차적으로 신경망의 입력으로 공급하기 위해 sampling rate를 12kHz로 가정하여 8192개의 sampling 결과를 입력의 크기로 정하고, RNN을 기반으로 결함을 진단할 경우 하나의 입력을 128개의 sampling 결과로 작게 분할하여 처리한다. 제안하는 방법에서 사용한 ConvLSTM 모델은 16 state 크기를 가지며, w 와 p 는 각각 8과 4로 설정하였다. 학습에는 adam 옵티마이저 (optimizer)를 통해 배치 사이즈 128로 총 500 epoch 동안 학습시켰으며, 학습률은 초기 값 0.001로 시작하여 200 epoch 이후부터 0.0001로 줄여 학습을 진행하였다.

제안하는 결함 진단 방법에 기반한 모니터링 시스템의 시연 절차는 다음과 같다. 우선 데이터를 순차적으로 신경망에 공급하기 위하여 1차원 데이터를 시간에 따라 배열하였고 이 중 80%를 학습 데이터셋으로, 나머지 20%를 테스트 데이터셋으로 사용하였다. 짧은 지연 시간을 갖는 결함 진단 방법이 적용된 ConvLSTM 모델을 학습 데이터셋으로 학습시키고, 파라미터인 w 와 p 를 변경해가며 성능 저하가 적으면서도 지연 시간을 효과적으로 줄일 수 있는 파라미터를 결정한다. 이후 학습된 파라미터를 모니터링 시스템 내의 메모리에 저장

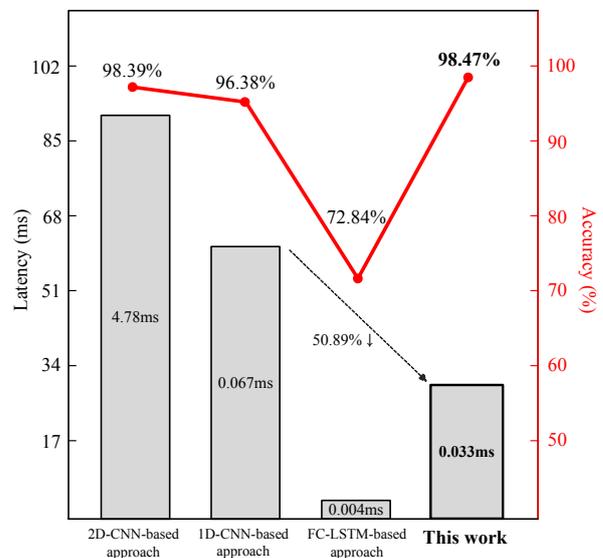


그림 6. 결함 진단 방법들의 지연 시간과 정확도
 Fig. 6. Latency and accuracy of the fault-diagnosis methods.

표 1. 그림 6의 결함 진단 방법들을 위해 사용된 신경망 모델의 구조와 파라미터 수

Table 1. Structures and number of parameters of the neural network models employed for the fault-diagnosis methods, whose performances are shown in Fig. 6.

Layer	2D-CNN-based approach	1D-CNN-based approach	FC-LSTM-based approach	ConvLSTM-based proposed approach
1	¹⁾ Conv2d/(3x3)/16	Conv1d/(3x1)/8	²⁾ FC-LSTM/(8x1)/(8x1)/22	ConvLSTM/(5x1)/(3x1)/16
2	AvgPool2d/(2x2)/16	AvgPool1d/(2x1)/16	FC-LSTM/(22x1)/(22x1)/2 2	ConvLSTM/(5x1)/(3x1)/16
3	Conv2d/(3x3)/16	Conv1d/(3x1)/16	-	AvgPool2d/(2x1)/16
4	Conv2d/(3x3)/32	Conv1d/(3x1)/30	-	-
5	AvgPool2d/(2x2)/32	AvgPool1d/(2x1)/30	-	-
6	Dense/12	Dense/12	Dense/12	Dense/12
³⁾ Parameters	52K	53K	53K	49K

¹⁾Type of Layer/(Kernel size)/Output channel size

²⁾Type of Layer/(Input kernel size)/(State kernel size)/Output channel size

³⁾The parameters are based on 32-bit floating point number system

하고, 입력 데이터를 순차적으로 진단 모델의 입력으로 전달한 뒤, 진단 결과를 모니터에 띄운다. 시연 절차와 환경은 그림 5에 나타내었다.

제안하는 방법과 다른 신경망 기반의 방법을 비교하기 위해 각 신경망이 비슷한 메모리 사용량을 갖도록 모델의 구조를 설정하였다. CWRU 베어링 데이터셋을 사용하여 11개의 결함 상태와 1개의 정상 상태로 구성된 12개의 결과 중 현재 베어링의 상태를 진단하고, 진단 정확도로 각 방법의 성능을 평가하였다. 표 1에 제안하는 ConvLSTM 모델 기반의 결함 진단 방법과 비교한 2D-CNN, 1D-CNN, FC-LSTM 모델 기반의 결함 진단 모델의 자세한 구조 및 파라미터의 수를 나타내었다. 2D-CNN 모델과 1D-CNN 모델 기반의 방법은 합성곱 레이어 3개와 평균 풀링 레이어 2개, FCL 구조로 설계하였으며 FC-LSTM 모델과 ConvLSTM 모델 기반의 결함 진단 모델은 두 개의 RNN 레이어와 평균 풀링 레이어로 설계하였다.

지연 시간은 하나의 입력 크기를 8192로 설정하고 모니터링 시스템에 입력 데이터를 순차적으로 공급하여 입력이 들어간 시점부터 최종 진단 결과가 나오는 시점까지의 시간으로 측정하였다. 그림 6에는 제안하는 방법과 다른 신경망 기반의 결함 진단 방법의 지연 시간과 정확도를 비교 결과를 보여준다. 제안하는 방법은 0.033ms의 지연 시간을 가졌으며 98.47%의 진단 정확도를 보였다. 2D-CNN 모델과 1D-CNN 모델기반의 방법은 각각 4.78ms, 0.067ms의 지연 시간을 가졌으며 98.39%, 96.38%의 진단 정확도를 보였다. FC-LSTM 모델 기반의 방법은 0.004ms의 최저 지연 시간을 갖지

만 72.84%의 낮은 진단 정확도를 보인다. 제안하는 방법은 진단의 정확도는 유지하면서 1D-CNN 모델과 비교하였을 때 50.89%의 지연 시간의 감소를 달성하였으며 2D-CNN 모델과 비교하였을 때는 99.3%의 지연 시간의 감소를 달성하였다.

V. 결 론

본 논문에서는 베어링 결함 진단의 지연 시간을 ConvLSTM 모델을 통해 감소시키는 방법을 제안한다. 제안한 방법은 입력의 크기를 작게 받아도 시공간적 특징을 효과적으로 추출할 수 있도록 ConvLSTM 모델을 사용하였으며, 입력을 얻기 위한 과정에 걸리는 지연 시간을 효과적으로 줄였음에도 결함 진단의 정확도는 유지하였다. 결함의 진단 단계에서도 지연 시간을 줄이기 위해 워밍업 파라미터인 w 와 인내 파라미터 p 를 설정하여 w 이후에 인내 p 만큼의 연속된 예측이 발생할 경우 남은 입력을 분석하지 않고도 그 즉시 결함을 진단한다. 제안하는 방법은 CWRU 데이터셋으로 실험되었으며 정확도 저하 없이 1D-CNN 모델과 비교하였을 때는 50.89%, 2D-CNN 모델과 비교하였을 때는 99.3%의 진단 지연 시간 감소를 달성했다.

REFERENCES

- [1] C. Heising, et al., "IEEE recommended practice for the design of reliable industrial and commercial power systems," IEEE Std 493-2007 (Revision of IEEE Std

- 493-1997) – Redline, pp. 1-426, 25 June 2007.
- [2] Z. Li, T. Zheng, W. Yang, H. Fu, and W. Wu, "A robust fault diagnosis method for rolling bearings based on deep convolutional neural network," in Proc. Prognostics and System Health Management Conf., pp. 1-6, Qingdao, China, Oct 2019.
- [3] P. Liang, C. Deng, J. Wu, Z. Yang, and J. Zhu, "Intelligent fault diagnosis of rolling element bearing based on convolutional neural network and frequency spectrograms," in Proc. IEEE Int'l Conf. on Prognostics and Health Management, pp. 1-5, San Francisco, CA, USA, June 2019.
- [4] L. Wen, X. Li, L. Gao, and Y. Zhang, "A new convolutional neural network-based data-driven fault diagnosis method," IEEE Trans. Ind. Electron., vol. 65, no. 7, pp. 5990-5998, July 2018.
- [5] H. Kong, Q. Yang, Z. Zhang, Y. Nai, D. An, and Y. Liu, "One dimensional convolutional neural networks based on exponential linear units for bearing fault diagnosis," in Proc. Chinese Automation Congress, pp. 1052-1057, Xi'an, China, Dec. 2018.
- [6] Y. Li, L. Zou, L. Jiang, and X. Zhou, "Fault diagnosis of rotating machinery based on combination of deep belief network and one-dimensional convolutional neural network," IEEE Access, vol. 7, pp. 165710-165723, Nov. 2019.
- [7] C. Li, L. Yu, A. Zhang, Q. He, W. Yang, and Z. Duan, "A novel bearing fault diagnosis of raw signals based on 1d residual convolution neural network," in Proc. Int'l Conf. on High Performance Big Data and Intelligent Systems, pp. 1-6, Shenzhen, China, May 2020.
- [8] J. Shin, C. Kim, T. Kim, "Mechanical status monitoring based on sound event detection," Journal of The Institute of Electronics and Information Engineers, vol. 55, no. 11, pp. 84-91, Nov. 2018.
- [9] X. Li, H. Jiang, Y. Hu, and X. Xiong, "Intelligent fault diagnosis of rotating machinery based on deep recurrent neural network," in Proc. Int'l Conf. on Sensing, Diagnostics, Prognostics, and Control, pp. 67-72, Xi'an, China, Aug. 2018.
- [10] D. Qiu, Z. Liu, Y. Zhou, and J. Shi, "Modified bi-directional LSTM neural networks for rolling bearing fault diagnosis," in Proc. IEEE Int'l Conf. on Communications, pp.1-6, Shanghai, China, May 2019.
- [11] M. Qiao, S. Yan, X. Tang, and C. Xu, "Deep convolutional and LSTM recurrent neural networks for rolling bearing fault diagnosis under strong noises and variable loads," IEEE Access, vol. 8, pp. 66257-66269, Apr. 2020.
- [12] H. Qiao, T. Wang, P. Wang, S. Qiao, and L. Zhang, "A time-distributed spatiotemporal feature learning method for machine health monitoring with multi-sensor time series," MDPI Sensors., vol. 18, no. 9, pp. 2932, Sep. 2018.

— 저 자 소 개 —



김 지 호(학생회원)
2021년 한국항공대학교 항공전자
정보공학과 학사 졸업.
2021년~현재 한국항공대학교
항공전자 및 정보통신
공학부 석사 과정.

<주관심분야: 회로 및 시스템, 임베디드 시스템,
VLSI 설계, ASIC 설계>



신 지 훈(학생회원)
2018년 한국항공대학교 항공전자
정보공학과 학사 졸업.
2020년 한국항공대학교 항공전자
및 정보통신공학부
석사 졸업.

<주관심분야: 회로 및 시스템, VLSI 설계, ASIC
설계>



김 태 환(평생회원) - 교신저자
2005년 연세대학교 전기전자공학과
학사 졸업
2007년 한국과학기술원 전기 및
전자공학과 석사 졸업.
2010년 한국과학기술원 전기 및
전자공학과 박사 졸업.

2011년~현재 한국항공대학교 항공전자정보공학부
교수.

<주관심분야: 회로 및 시스템, VLSI 설계, ASIC
설계>