

Seq2Seq 모델 기반의 로봇팔 고장예지 기술

이영현*, 김경준*, 이승익**, 김동주***

Seq2Seq model-based Prognostics and Health Management of Robot Arm

Yeong-Hyeon Lee*, Kyung-Jun Kim*, Seung-Ik Lee**, Dong-Ju Kim***

요약 본 논문에서는 인공신경망(Artificial Neural Network) 모델 중, 시계열 데이터의 변환을 위한 모델인 Seq2Seq(Sequence to Sequence) 모델을 이용한 산업용 로봇 고장 예지 기술에 대하여 제안한다. 제안 방법은 고장 예지를 위한 추가적인 센서의 부착 없이 로봇 자체적으로 측정 가능한 관절 별 전류와 각도 값을 데이터로 사용하였고, 측정된 데이터를 모델이 학습할 수 있도록 전처리한 후, Seq2Seq 모델을 통해 전류를 각도로 변환하도록 지도 학습 하였다. 고장 진단을 위한 이상 정도(Abnormal degree)는 예측 각도와 실제 각도 간의 단위시간 동안의 RMSE(Root Mean Squared Error)를 사용하였다. 제안 방법의 성능평가는 로봇의 정상 및 결함 조건을 달리한 상태에서 측정된 테스트 데이터를 이용하여 수행되었고 이상 정도가 임계값 넘어가면 고장으로 분류하게 하여, 실험으로부터 96.67% 고장 진단 정확도를 보였다. 제안 방법은 별도의 추가적인 센서 없이 고장 예지 수행이 가능하다는 장점이 있으며, 로봇에 대한 깊은 전문지식을 요구하지 않으면서 수행할 수 있는 방법으로 높은 진단 성능과 효율성을 실험으로부터 확인하였다.

Abstract In this paper, we propose a method to predict the failure of industrial robot using Seq2Seq (Sequence to Sequence) model, which is a model for transforming time series data among Artificial Neural Network models. The proposed method uses the data of the joint current and angular value, which can be measured by the robot itself, without additional sensor for fault diagnosis. After preprocessing the measured data for the model to learn, the Seq2Seq model was trained to convert the current to angle. Abnormal degree for fault diagnosis uses RMSE (Root Mean Squared Error) during unit time between predicted angle and actual angle. The performance evaluation of the proposed method was performed using the test data measured under different conditions of normal and defective condition of the robot. When the Abnormal degree exceed the threshold, it was classified as a fault, and the accuracy of the fault diagnosis was 96.67% from the experiment. The proposed method has the merit that it can perform fault prediction without additional sensor, and it has been confirmed from the experiment that high diagnostic performance and efficiency are available without requiring deep expert knowledge of the robot.

Key Words : Deep Learning, PHM(Prognostics and Health Management), Robot, Seq2Seq(Sequence to Sequence), Time Series Data Prediction

This paper was supported by Creative Economy Leading Technology Development Project(No.SF317003A) funded by Gyeongbuk-do and Gyeongbuk Science & Technology Promotion Center in 2017, and basic research project(No.2016R1D1A1B01014776) funded by the government(Ministry of Education) in 2016.

* Information Research Laboratories, Pohang University of Science and Technology

** Department of Smart Software, Yonam Institute of Technology

*** Corresponding Author : Information Research Laboratories, Pohang University of Science and Technology (kkb0320@postech.ac.kr)

Received May 06, 2019

Revised May 28, 2019

Accepted May 29, 2019

1. 서론

공장 내의 기계시스템들은 하중이 계속 작용하는 환경에서 마모(Wear), 균열 결함(Fault), 성능 저하(Degradation)로 인한 손상(Damage)이 필연적으로 발생하게 된다. 이들을 제대로 관리하지 못하여 한계 수준을 넘어가게 되면 치명적인 사고나 사용 중단 상태를 일으키게 되고, 막대한 피해와 비용 손실이 발생한다. 이를 막기 위해 기존에는 운용 중 철저한 예방정비에 의존하며 고가/고안정성 시스템을 운용하고 있다. 하지만 정비가 실제 결함 유무와 관계없이 일정한 주기마다 실시되므로 정상 부품의 불필요한 교체 및 정비시간 동안의 운용 중단으로 인한 비용 손실을 발생시키는 문제점이 있고, 갑작스런 시스템 고장을 예방하는 데에 한계가 있다. 최근에는 이런 문제점들을 해결하기 위해 기계시스템의 이상을 조기에 감지하고 고장을 미리 예측하는 고장 예지 및 건전성 관리(PHM: Prognostics and Health Management)기술들이 연구되고 있다.

고장 예지 및 건전성 관리 기술에는 크게 두 가지 방법이 있는데, 첫째로 모델 기반 방법(Model based approach)은 고장이 진행되어 가는 과정을 모델링한 물리적 고장 모델을 기반으로 고장을 진단 및 예지한다. 이 방법은 정확도가 높으며 적은 양의 데이터로도 고장 진단이 가능하고, 모델의 변수를 바꿔줌으로써 다양한 운행 환경에서도 적용 가능하다. 그러나 공정 자동화 기술의 발전으로 인해 시스템 복잡도가 크게 증가하고 고장 메커니즘 파악이 어려워져, 모델을 완전히 구현하기 힘들다. 또한 모델링 과정에 해당 분야 전문가의 도움이 필요하여, 모델을 구성하고 유지하는데 많은 비용이 든다. 이러한 요인들로 인해 현재 모델 기반 방법은 적용 분야가 매우 한정적이다.

다음으로 데이터 주도 방법(Data driven approach)은 데이터에서 고장과 관련된 중요한 인자를 찾아내어 통계적 방법, 기계학습, 딥러닝 기법으로 시스템의 신뢰성, 건전성 정보를 추론하는 것이다. 이중 기계학습과 딥러닝 기법은 건전성 인자와 고장 여부의 관계를 학습을 통해 스스로 배움으로써

미래고장을 예측할 수 있다. 이 방법은 물리적 손상 모델을 구현하기 어려운 다변량·비선형 시스템에 적용이 가능하지만, 예측 모델의 훈련을 위해서는 많은 데이터가 필요하다.

이러한 고장 예지 및 건전성 관리 기술을 기계시스템들에 적용한 많은 연구들이 진행되었다. 복사기의 고장을 규칙 기반 방법으로 진단한 연구(Lee et al., 1998)[1]와 머신러닝 기법을 통해 납축전지의 열화현상을 예측한 연구(Choi et al., 2018)[2], 설비의 관측되지 않은 고장에 대해서도 클러스터링 기법으로 고장을 진단한 연구(Lee et al., 2000)[3], 등이 있다. 공장 내부 설비에 대해서는 딥러닝 기반 밀링 기계의 마모도를 예측 하는 연구(Zhao et al., 2017)[4], 딥러닝 기반 회전기기의 고장을 예측하는 연구(Jeong et al., 2016)[5] 등이 있다.

다양한 기계시스템에 대한 고장 예지 및 진단 연구는 상당수 존재하지만, 로봇 분야의 경우에는 산업현장의 스마트화에 따라 중요성이 더 커지고 있음에도 불구하고 진행된 연구가 거의 없다. 국내 사례로는 가속도 센서를 통해 측정된 진동 데이터에서 건전성 인자를 추출하여 고장을 진단한 연구(Kim et al., 2016)[6]와 전류 신호의 주파수 분석을 통해 고장을 진단하는 방법(Lee et al., 2018)[7] 등이 연구되었다. 국외 사례로는 로봇에 부착된 공간 감지 센서에서 측정된 로봇 자세의 정확도를 기준으로 고장을 진단한 연구(Qiao et al., 2018)[8]와 진동 센서를 통해 측정된 데이터에 이산 웨이블릿 변환을 적용하고 인공신경망을 통해 고장을 진단한 연구(Jaber et al., 2016)[9]가 있다.

본 논문에서는 다변량·비선형 기계시스템인 산업용 로봇팔의 이상 징후를 진단하기 위해 딥러닝 모델인 Seq2Seq를 적용하는 방법을 제안한다. 현재 로봇 고장 예지 분야에 딥러닝을 적용한 사례는 국내적으로 거의 없으며, 유사 연구로 진동 센서 등을 부착하고 측정된 데이터로 고장 예지를 수행하는 연구가 일부 수행되었다. 하지만, 이러한 방법들은 추가 센서로 인한 비용문제로 실제 산업현장에 적용하기 어려운 부분이 있다. 이에, 본 논문에서는 산업용 로봇팔에서 자체적으로 수집 가능한 시계열 데이터

만으로 모델을 학습시키고, 시스템의 출력과 모델 출력의 차이가 특정 임계값을 넘으면 고장으로 분류하는 방법을 제안한다. 제안 방법의 성능평가는 로봇의 정상 데이터와 주요 결함 조건에서 측정된 이상 데이터를 이용하여 수행하였다.

2. 본론

본 논문에서는 로봇팔에서 측정되는 데이터를 수집하여, 전처리 및 데이터 분석을 수행하고, 딥러닝 모델 중 시계열 데이터 변환 모델인 Seq2Seq 모델을 학습하여 고장 예지 및 진단을 수행한다.

2.1 데이터셋

고장 예지를 위한 딥러닝 모델의 학습 및 검증을 위하여, 본 논문에서는 특정 행동이 티칭(Teaching)된 6축 로봇팔에서 데이터를 수집하였다. 결함 데이터를 측정하기 위한 결함 조건 부위는 (5)번 축의 타이밍 벨트로 선정하였다. 이는 타이밍 벨트에 로봇의 반복 운동으로 인한 마모 및 외부 온도 변화에 의한 텐션 저하 등의 요인들이 작용하여 수명 감소 및 결함이 발생할 가능성이 다른 축들에 비하여 상대적으로 높기 때문이다. 데이터 측정을 위한 실험 환경은 그림 1과 같이 구성하였다. 산업용 로봇팔에서 측정된 센서 데이터의 구성은 표 1과 같으며, (5)번 축 타이밍 벨트의 결함 조건은 표 2와 같다. 이상 1 상태의 경우 타이밍 벨트의 옆면 및 축의 기어와 맞물리는 톱니 부분을 마모시킨 상태로 데이터를 측정하였고, 이상 2 상태는 타이밍 벨트가 동력을 전달하는 두 축 간의 거리를 가깝게 조정함으로써 텐션 저하 상황을 가정하여 데이터를 측정하였다. 로봇의 각 관절(Joint) 별 각도(Angle)와 전류(Current)는 로봇 내부에서 측정된 값이다.



그림 1. 산업용 6축 로봇팔
Fig. 1. Industrial six-axis robot arm

표 1. 데이터 구성
Table. 1. Data organization

Data name	Description	Data name	Description
J1	Angle of joint (degree)	I1	Current of joint (%)
J2		I2	
J3		I3	
J4		I4	
J5		I5	
J6		I6	

표 2. (5)번 축 결함 조건
Table. 2. Axis 5 defect condition

State	normal	abnormal1	abnormal2
Fault		Axis 5 Timing belt Wear	Axis 5 Timing belt Lower tension

2.2 데이터 전처리

로봇으로부터 측정된 데이터에는 결측 및 오측정, 잡음이 존재하였으며, 센싱부터 데이터를 전송받는 과정의 네트워크 환경이 변화됨에 따라 샘플링 데이터 간의 주기가 10~40ms로 일정하지 못한 문제점들이 있었다. 이러한 데이터를 딥러닝 모델의 학습 데이터로 사용하기 위해서는 데이터에 존재하는 상기 요인들의 영향을 제거하여야 한다. 이에 본 논문에서는 데이터 특성에 맞는 전처리를 수행하였다. 비정상적으로 큰 잡음 데이터(Outlier)는 임계치를 설

정하여 그림 2와 같이 제거하였고, 임계치 범위 안의 잡음은 Median 필터를 적용하였다.




그림 2. 큰 잡음 데이터(Outlier) 제거
Fig. 2. Remove outlier

또한 필터링으로 공백이 된 데이터와 샘플링 주기가 일정하지 않은 문제를 해결하기 위해 리샘플링(Resampling) 과정을 통해 데이터를 재구성하였다. 10~40ms 샘플링 주기의 데이터들을 10ms 기준으로 업샘플링할 경우 업샘플링 오차로 인하여 모델의 성능이 저하될 수 있으므로 40ms를 기준으로 다운샘플링 과정을 거쳤다. 데이터 전처리과정의 예를 그림 3에 나타내었으며, 전처리 후 데이터 샘플의 수는 표 3과 같다.




그림 3. Median 필터 적용 및 리샘플링
Fig. 3. Applying median filters and resampling

표 3. 데이터 샘플 수
Table. 3. Number of data samples

	normal	abnomal1	abnomal2
Data samples	1,078,519	102,026	80,619

전처리 된 데이터 샘플들은 모델의 학습, 검증, 테스트를 위한 시퀀스 데이터로 구성할 필요가 있다. 시퀀스 데이터의 길이는 로봇의 동작을 고려하여

100개(4초 간의 데이터)로 결정하였으며, 로봇의 가동 초기 샘플 및 측정 구간이 불연속적인 부분은 제외하였다. 최종 데이터셋 구성은 아래의 표 4와 같다. 데이터셋의 정규화는 학습 데이터들의 변수들이 0~1의 동일한 범위가 되도록 최대-최소 정규화를 적용하였으며, 같은 기준을 검증 및 테스트 데이터에 적용하였다. 검증용 데이터셋은 학습 과정을 평가하여 모델의 파라미터를 조정하기 위해 사용되었으며, 조정이 끝난 후에는 학습 데이터에 포함시켜 모델 학습을 진행하였다. 테스트 데이터셋은 학습하지 않은 상태별 데이터에 대한 진단 성능을 확인하기 위해 상태별로 동일한 수로 구성하였다.

표 4. 데이터셋 구성
Table. 4. Dataset configuration

	normal	abnomal1	abnomal2
Train Data	450,000		
Validation Data	50,000		
Test Data(Sample)	500	500	500

2.3 데이터 분석

로봇팔로부터 수집된 각 관절 별 데이터 간의 관계를 파악하기 위하여, 본 논문에서는 정상 데이터의 각 측정값들에 대한 피어슨 상관분석(Pearson correlation analysis)을 수행하였고, 그 결과를 그림 4에 나타내었다.




그림 4. 공분산 행렬
Fig. 4. Covariance matrix

(1)번 축과 (4)번 축의 데이터가 높은 양의 상관 계수, (1, 4)번 축과 (6)번 축이 높은 음의 상관 계수를 나타내는데 이는 로봇의 동작에 의한 결과이며 설정된 동작에 의해 변화되므로 유효한 상관관계는 아니다. 전류-각도의 상관계수를 보면 (2)번 축을 제외한 각 축은 양의 상관계수를 보였다.

측정된 전류-각도 간의 인과관계를 확인하기 위해 그레인저 인과관계 검정(Granger causality test) (Granger et al., 1980)[10]을 실시하였다. 그레인저 인과관계 검정은 두 변수 x, y 간의 영향을 주는 관계가 있음을 알고 있을 때 원인-결과 관계를 검정할 수 있는 방법으로 아래와 같은 절차를 가진다.

i. $x \rightarrow y$ (x =원인 변수, y =결과 변수)를 검정할 경우 아래와 같은 회귀식을 모델링

$$y_t = \sum_{i=1}^p a_i \cdot x_{t-i} + \sum_{j=1}^q \beta_j \cdot y_{t-j} + \epsilon_t$$

ii. 원인변수가 결과변수에 영향을 주지 않는다는 귀무가설(H_0)과 영향을 준다는 대립가설(H_1)을 수립

$$H_0 : \sum_{i=1}^p a_i = 0 \quad H_1 : \sum_{i=1}^p a_i \neq 0$$

iii. 귀무가설(H_0) 상의 회귀모형을 추정

$$y_t = \sum_{i=1}^p a_i \cdot x_{t-i} + \epsilon_t$$

iv. 대립가설(H_1) 상의 회귀모형을 추정

$$y_t = \sum_{i=1}^p a_i \cdot x_{t-i} + \sum_{j=1}^q \beta_j \cdot y_{t-j} + \epsilon_t$$

v. F검정 수행

표 5는 전류-각도 데이터에 대해 그레인저 인과관계 검정한 결과이다. 더불어, 전류-각도의 경우 그림 5의 로봇 구동 메카니즘을 고려하여 양측으로 검정을 진행하였다.

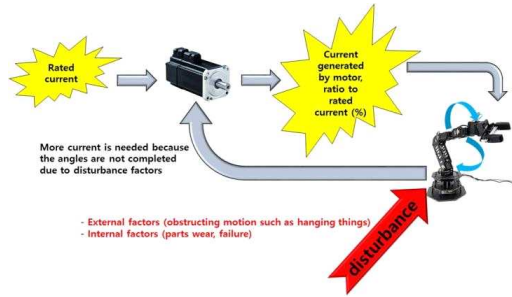


그림 5. 산업용 로봇팔의 작동원리
Fig. 5. Operation principle of industrial robot arm

표 5. 그레인저 인과관계 검정 결과
Table. 5. Result of granger causality test

value	F-test		value	F-test	
	F	p		F	p
11→11	33.79	0.000	11→11	21.93	0.000
12→12	8.59	0.000	12→12	20.09	0.000
13→13	15.67	0.000	13→13	11.15	0.000
14→14	12.98	0.000	14→14	5.17	0.006
15→15	23.01	0.000	15→15	16.91	0.000
16→16	17.64	0.000	16→16	9.67	0.000
set	time difference 2				

유의수준 5%의 F검정에 대해, 전류-각도의 경우 양측 모두 P-value가 0.05 미만의 값이므로 원인변수가 결과변수에 영향을 주지 않는다는 귀무가설을 기각하고 통계적으로 유의미한 영향을 끼친다는 대립가설을 채택할 수 있다. 전류-각도는 서로에게 그레인저 인과관계가 성립하며 서로에게 영향을 주지만, F통계값이 (2)번 축을 제외한 모든 축에서 전류→각도 방향이 크기 때문에 전류가 먼저 선행된다고 간접적으로 유추해볼 수 있다. 이는 그림 6과 같은 그래프를 통해 확인하거나 로봇의 구동 과정을 보면 논리적으로 타당하다 할 수 있다.




그림 6. (5)번 축 전류-각도 그래프
Fig. 6. Axis 5 current-angle graph

2.4 제안 모델

LSTM(Long Short Term Memory)(Hochreiter et al., 1997)[11] 모델은 RNN(Recurrent Neural Network) 모델의 학습 과정 중 기울기(Gradient)가 소실되거나(Vanishing) 매우 큰 값을 가지게 되는(Exploding) 문제를 해결하기 위해, RNN의 기억을 담당하는 Hidden state에 장기기억 정보를 지니는 Cell state 개념을 추가하고, State 계산에 필요한 데이터들을 어느 정도 반영할지 Gate 연산을 통해 정함으로써 오래된 정보를 유지할 수 있도록 개선한 모델이다. 그림 7은 LSTM 모델의 구조이다.




그림 7. LSTM 모델 구조
Fig. 7. Structure of LSTM

각각의 LSTM 블록은 장기기억을 저장하는 Cell state(C_t)와 단기기억을 저장하는 Hidden state (H_t), 3개의 Gate(f_t, i_t, o_t)들로 이루어져 있다. Forget gate(f_t)는 이전 Cell state(C_{t-1})로부터 현재 Cell state(C_t)로의 기억 정도를 결정하고, Input gate(i_t)는 현재 State로 입력되는 정보를 현재의 Cell state(C_t)에 저장할 정도를 결정하며, Output gate(o_t)는 현재 Cell state(C_t)에서 다음 Hidden state(H_t)로 정보를 전달할 정도를 결정한다. 수식은 아래와 같다.

$$f_t = \sigma(W_{xf}x_t + W_{hf}h_{t-1} + b_f)$$

$$i_t = \sigma(W_{xi}x_t + W_{hi}h_{t-1} + b_i)$$

$$o_t = \sigma(W_{xo}x_t + W_{ho}h_{t-1} + b_o)$$

$$C_t = f_t \circ C_{t-1} + i_t \circ \tanh(W_{xc} * X_t + W_{hc} * H_{t-1} + b_c)$$

$$H_t = o_t \circ \tanh(C_t)$$

Seq2Seq(Sequence to Sequence)(Sutskever et al., 2014)[12] 모델은 LSTM 모델을 포함한 RNN 계열의 모델을 결합한 형태로, 입력 부분은 시계열 데이터를 벡터로 압축하는 인코더 역할을 하고, 출력 부분은 압축된 벡터를 다시 시계열 데이터로 변환하는 디코더 역할을 한다. 변환하는 과정에서 모델은 잠재된 벡터 공간 상의 데이터 분포를 학습하게 된다. 이러한 Seq2Seq 모델은 언어 번역이나 음성인식 등 주로 언어 데이터를 다룰 때 사용되고 있으며, 시계열 데이터의 이상치 탐지에도 사용되고 있다. Seq2Seq 모델의 구조는 그림 8과 같다.




그림 8. Seq2Seq 모델 구조
Fig. 8. Structure of Seq2Seq

본 실험에서 다루는 전류 및 각도 데이터는 서로 다른 도메인의 데이터이므로, 특정 도메인의 시계열 데이터를 다른 도메인의 시계열 데이터로 변환하는 Seq2Seq 모델이 모델링에 적합하다.

그러므로 본 논문에서는 로봇팔 동력 전달부 결함을 예측하기 위해, 신호를 변환하는 모델로서의 Seq2Seq 모델을 제안한다. 그레인저 인과관계 분석 결과 및 실제로도 산업용 로봇팔이 전류를 입력으로 받아 출력인 각 관절의 각도를 만들어내는 기계시스템인 부분에 착안하여, Seq2Seq 모델을 정상 전류 데이터를 입력받고 정상 각도 데이터로 변환하도록 모델링 하였다. Seq2Seq 모델의 학습 방법은 각 축에서 측정되는 6차원 전류 데이터 샘플 100개(4초간의 데이터)를 측정된 6차원 각도 데이터로 변환하도록 하는 지도 학습이다. Seq2Seq 모델의 학습 개요도는 그림 9에 나타나 있다.




그림 9. Seq2Seq 모델의 전류-각도 변환 학습
Fig. 9. Seq2Seq model learning current-to-angle conversion

3. 실험 및 결과

제안하는 산업용 로봇팔 고장 예지 및 진단 방법의 성능평가는 학습에 사용되지 않은 정상 데이터와 결함 조건을 달리한 이상 데이터로 구성된 테스트 데이터셋을 이용하여 수행하였다. 고장 예지 및 진단을 위한 이상 정도(Abnormal degree)는 제안 모델의 각도 예측값과 실제 값의 RMSE(Root Mean Squared Error)를 20초 간격으로 구한 값으로 규정하였다. 테스트 데이터에 대한 6개축의 이상 정도는 그림 10과 같다.

모든 조건에서 (5)번 축의 이상 정도가 다른 축에 비해 높은 것은 결함 조건을 가할 (5)번 축의 움직임이 다른 축보다 많도록 로봇 동작이 설정되어 있기 때문이다. 그림 10에서 이상 1, 2 조건의 경우,

모든 축이 정상 조건보다 이상 정도가 크게 측정되었으며, 약한 결함 조건인 이상1(타이밍 벨트 마모)이 이상2(타이밍 벨트 텐션 저하)보다 이상 정도가 비교적 작게 측정되었다.

정상 데이터와 비정상 데이터를 구분하기 위한 임계값은, 정상 데이터 각 축의 이상 정도 평균값에 1.3을 곱한 값으로 설정하였다. 이를 초과한 데이터에 대해서는 이상 상태로 분류하도록 시스템을 구성하였다. 성능평가는 분류된 예측 상태에 대한 정확도를 측정함으로써 수행되었고, 이를 그림 11에 나타내었다.

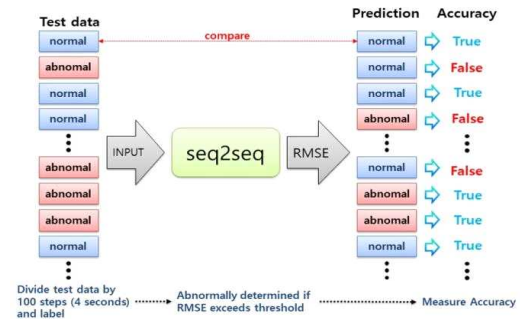


그림 11. 성능 평가 방법론
Fig. 11. Performance evaluation methodology

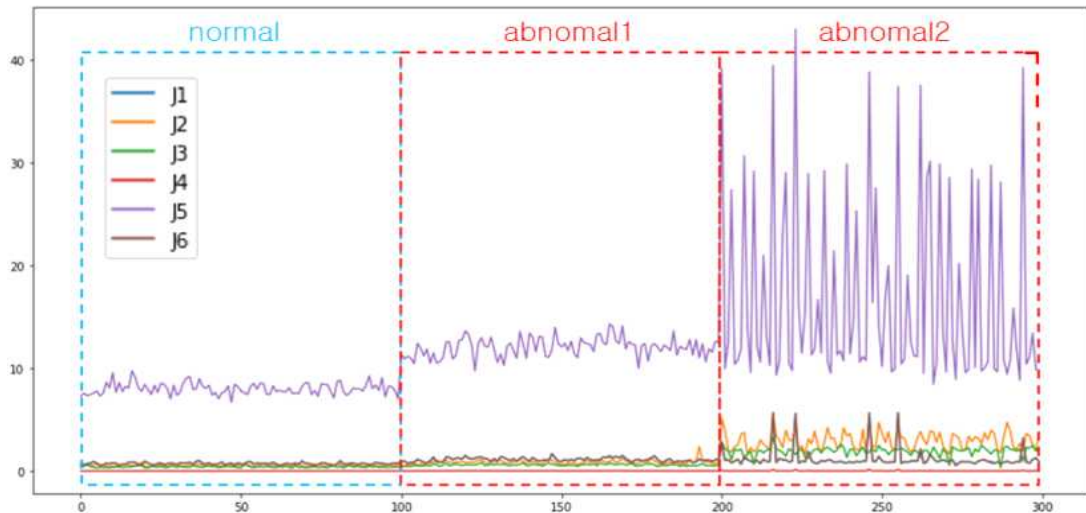


그림 10. 로봇 상태별 이상 정도 비교
Fig. 10. Comparison of abnormal degree for each state of robot

성능평가 실험 결과는 혼동행렬(Confusion Matrix)로 나타내었다. 혼동행렬은 모델의 예측 값과 실제 값을 비교하는 표로써, 알고리즘 및 머신러닝 모델의 성능을 평가하기 위한 일반적인 성능지표로 사용되며, 혼동행렬을 이용한 정확도 계산 방법을 그림 12에 나타내었다. 이와 같은 성능평가 기준에 의한 제안 기술의 성능평가 결과는 표 6과 같다.




그림 12. 혼동 행렬 및 정확도
Fig. 12. Confusion matrix and accuracy

표 6. 실험 결과
Table. 6. Experiment result

Actual \ Predicted	Abnormal (P, Positive)	Normal (N, Negative)
Abnormal (T, True)	198	2
Normal (F, False)	8	92

실험에서 고장예측 정확도는 96.67% ($\{(198+92) / (198+8+2+92)\} * 100$)를 보였으며, 이로부터 제안 방법의 효용성을 확인할 수 있었다. 일반적으로 산업용 로봇은 실제 산업현장에서 고장 날 확률이 상당히 낮으며, 이에 본 논문에서는 로봇의 결함 환경을 인위적으로 구성하여, 이로부터 측정된 데이터를 이용하였다. 이러한 점을 감안하여, 향후 로봇을 오랜 시간 운용하면서 자연스러운 성능 저하 과정에서 수집된 데이터를 활용한 로봇 고장 예지 기술 연구를 지속할 계획이다.

4. 결론

본 논문에서는 딥러닝 알고리즘 중 기계변역에서

주로 사용된 Seq2Seq 모델을 로봇 팔에서 측정되는 데이터에 적용하여 로봇 동력 전달부 고장을 예측할 수 있는 시스템을 제안하였다. 수집 데이터의 통계적 분석결과와 로봇의 구동 방식에 착안하여, 정상 전류 시퀀스가 입력되면 정상 각도 시퀀스가 출력되도록 제안 모델을 학습시켰으며, 이를 통해 예측 정확도가 낮을 경우 이상 상태로 분류하도록 알고리즘을 구성하였다. 정상 및 결함 조건을 설정한 테스트 데이터셋을 사용하여 실험을 수행한 결과, 제안 모델은 96.67%의 고장예측 정확도를 보였다. 제안 방법은 추가적인 센서의 부착 없이 로봇 자체적으로 측정되는 데이터만을 사용하여 고장을 예측할 수 있다는 장점을 가지며, 이를 통해 현재 로봇을 운용 중인 다양한 산업군에 비교적 쉽게 적용 가능할 것으로 사료된다.

REFERENCES

- [1] Lee J., Y. Kim, "A Hybrid Malfunction Diagnostic System using Rules and Cases", Journal of Korea Expert System, vol.4, no.1, pp.115-131, 1998.
- [2] Choi G., G. Kim, "Building battery deterioration prediction model using real field data", Journal of Intelligence and Information Systems, vol.24, no.2, pp.243-264, 2018.
- [3] Lee J., J. Kang, "Performance Improvement of Malfunction Diagnostic System by Developing Case-based Reasoning Systems for Individual Clusters", Proceedings of Spring, the Korea Intelligent Information System Society Conference, pp.427-434, 2000.
- [4] Zhao R., R. Yan, J. Wang, K. Mao, "Learning to Monitor Machine Health with Convolutional Bi-Directional LSTM Networks", Sensors, vol.17, no.2, 273, 2017.
- [5] Jeong H., S. Woo, S. Kim, S. Park, H. Kim, S. Lee, "Deep Learning Based Diagnostics of Orbit Patterns in Rotating Machinery", Annual Conference of the Prognostics and Health Management Society, vol.7, 2016.
- [6] Kim Y., J. Park, J. Ha, B. Yoon, J. Park, "Robust Fault Detection Method of an Industrial Robot

under Various Operating Conditions", Proceedings of Spring, Korean Society of Mechanical Engineers Conference, pp.1536-1539, 2016.

[7] Lee J., C. Park, G. Ahn, M. Yoon, B. Yoon, "Current Signal Characteristic Frequency-Based Motor Fault Diagnosis for Collaborative Robot", Proceedings of Korean Society of Mechanical Engineers Conference, pp.1600-1602, 2018.

[8] Qiao G., B. A. Weiss, "Quick health assessment for industrial robot health degradation and the supporting advanced sensing development", Journal of Manufacturing Systems, vol.48, pp.51-59, 2018.

[9] Jaber A., R. Bicker, "Fault Diagnosis of Industrial Robot Bearings Based on Discrete Wavelet Transform and Artificial Neural Network", Insight - Non-Destructive Testing and Condition Monitoring, vol.58, no.4, pp.179-186, 2016.

[10] Granger C. "Testing for causality: A personal viewpoint", Journal of Economic Dynamics and Control, vol.2, pp.329-352, 1980.

[11] Hochreiter S., J. Schmidhuber, "Long short term memory", Journal of Neural Computation, vol.9, no.8, pp.1735-1780, 1997.

[12] Sutskever I., O. Vinyals, Q. V. Le, "Sequence to Sequence Learning with Neural Networks", Technical report, arXiv preprint arXiv:1409.3215, 2014.

저자약력


이 영 현 (Yeong-Hyeon Lee) [정회원]



- 2017년 : 부경대학교 건축공학과 공학사
- 2018년~현재 포항공과대학교 정보통신연구소 연구원

〈관심분야〉 기계학습 및 딥러닝, 이상탐지, 시계열 데이터 예측, 데이터 마이닝

김 경 준 (Kyung-Jun Kim) [정회원]



- 2005년 : 경북대학교 정보통신학과 공학박사
- 2006년 : 호남대학교 전파이동통신공학과 전임강사
- 2009년 : 한국과학기술원 전산학과 연구부교수
- 2012년 : 대구디지털산업진흥원 책임연구원
- 2013년 : 포항공과대학교 정보통신연구소 연구기획실장

〈관심분야〉 통신 프로토콜, 무선센서 네트워크, 멀티미디어 통신

이 승 익 (Seung-Ik Lee) [정회원]



- 1994년 : 경북대학교 전자공학과 공학사
- 1997년 : 경북대학교 대학원 전자공학과 공학석사
- 2006년 : 경북대학교 대학원 전자공학과 공학박사
- 2006년~현재: 연암공업대학교 스마트소프트웨어공학과 교수

〈관심분야〉 얼굴인식, 영상신호처리, 디지털 신호처리

김 동 주 (Dong-Ju Kim) [정회원]



- 1998년 : 충북대학교 전파공학과 학사
- 2000년 2월: 충북대학교 전파공학과 석사
- 2010년 : 성균관대학교 전기전자 및 컴퓨터공학과 박사
- 2011년~2015년 : 대구경북과학기술원 IT융합연구부 선임연구원
- 2016년~현재 : 포항공과대학교 정보통신연구소 책임연구원

〈관심분야〉 얼굴인식, HCI, 컴퓨터비전, 인공지능