

# Gear Fault Diagnosis Based on Residual Patterns of Current and Vibration Data by Collaborative Robot's Motions Using LSTM

Baek Ji Hoon<sup>†</sup> · Yoo Dong Yeon<sup>††</sup> · Lee Jung Won<sup>†††</sup>

## ABSTRACT

Recently, various fault diagnosis studies are being conducted utilizing data from collaborative robots. Existing studies performing fault diagnosis on collaborative robots use static data collected based on the assumed operation of predefined devices. Therefore, the fault diagnosis model has a limitation of increasing dependency on the learned data patterns. Additionally, there is a limitation in that a diagnosis reflecting the characteristics of collaborative robots operating with multiple joints could not be conducted due to experiments using a single motor. This paper proposes an LSTM diagnostic model that can overcome these two limitations. The proposed method selects representative normal patterns using the correlation analysis of vibration and current data in single-axis and multi-axis work environments, and generates residual patterns through differences from the normal representative patterns. An LSTM model that can perform gear wear diagnosis for each axis is created using the generated residual patterns as inputs. This fault diagnosis model can not only reduce the dependence on the model's learning data patterns through representative patterns for each operation, but also diagnose faults occurring during multi-axis operation. Finally, reflecting both internal and external data characteristics, the fault diagnosis performance was improved, showing a high diagnostic performance of 98.57%.

Keywords : Gear Fault Diagnosis, Correlation Analysis, LSTM, Collaborative Robot, Prognostics and Health Management

## LSTM을 이용한 협동 로봇 동작별 전류 및 진동 데이터 잔차 패턴 기반 기어 결함진단

백 지 훈<sup>†</sup> · 유 동 연<sup>††</sup> · 이 정 원<sup>†††</sup>

## 요 약

최근에는 협동 로봇의 데이터를 활용한 다양한 결함진단 연구가 수행되고 있다. 협동 로봇의 결함진단을 수행하는 기존 연구들은 기존 연구의 학습 데이터는 미리 정의된 기어의 동작을 가정하고 수집한 정적 데이터를 사용한다. 따라서 결함진단 모델은 학습한 데이터 패턴에 대한 의존성이 높아지는 한계가 있다. 또한 단일 모터를 사용한 실험으로 다관절이 동작하는 협동 로봇의 특성을 반영한 진단이 이루어지지 못했다는 한계가 있다. 본 논문에서는 앞서 언급한 두 가지 한계점을 해결할 수 있는 LSTM 진단 모델을 제안한다. 제안하는 방법은 단일 축 및 다중 축 작업 환경에서의 진동 및 전류 데이터의 상관분석을 사용하여 정상 대표 패턴을 선정하고, 정상 대표 패턴과의 차이를 통해 잔차 패턴을 생성한다. 생성된 잔차 패턴을 입력으로 축별 기어 마모 진단을 수행할 수 있는 LSTM 모델을 생성한다. 해당 결함진단 모델은 동작별 대표 패턴을 통해 모델의 학습 데이터 패턴에 대한 의존성을 낮출 수 있을 뿐 아니라 다중 축 동작 수행 시 발생하는 결함을 진단할 수 있다. 마지막으로, 내부 및 외부 데이터의 특성을 모두 반영하여 결함진단 성능을 개선한 결과 98.57%의 높은 진단 성능을 보였다.

키워드 : 기어 결함진단, 상관분석, LSTM, 협동로봇, 건전성 예측 및 관리

## 1. 서 론

최근 Industry 4.0로 인해, 공장의 생산 공정에서도 스마트

화가 가속화되고 있다[1]. 스마트팩토리는 제품의 생산 과정에서 설비에 부착된 센서를 통해 데이터를 실시간으로 수집하고 수집된 데이터를 분석하여 제품의 생산성 및 품질을 향상시키는 공장이다. 기존 공장 자동화를 위한 단순 작업에 특화된 산업용 로봇은 인간이 필요한 섬세하고 유동적인 작업을 수행하기는 어렵다. 이러한 작업에는 사람과 같은 공간에서 상호작용을 하며 작업을 수행하도록 고안된 협동 로봇이 효과적이다[2]. 또한 협동 로봇이 공정 내에서 섬세하고 중요한 작업을 수행하기 때문에 작업 중 결함은 생산 효율성의 저하와 경제적 손실을 크게 일으킬 수 있으므로, 협동 로봇의 유지보수는 매우 중요하다.

※ 이 논문은 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(No. 2023R1A2C1006332).

† 준 회 원 : LIG넥스원 드론개발단 연구원

†† 준 회 원 : 아주대학교 AI융합네트워크학과 전자공학전공 박사과정

††† 종신회원 : 아주대학교 전자공학과/AI융합네트워크학과 교수

Manuscript Received : December 14, 2022

First Revision : April 12, 2023

Second Revision : July 5, 2023

Accepted : July 12, 2023

\* Corresponding Author : Lee Jung Won(jungwon@ajou.ac.kr)

스마트팩토리의 기기 유지보수 방법은 사후정비방식(Corrective Maintenance, CM), 예방정비방식(Preventive Maintenance, PM), 그리고 예지보전방식(Predictive Maintenance, PdM)의 세 단계로 나뉜다[3]. 먼저, 사후정비방식(CM)은 기기 결함이 발생한 후에 기기를 정비하는 방식으로, 정비 후 재가동에 시간이 소요되는 문제가 존재한다[4]. 예방정비방식(PM)은 정기적으로 기기의 유지보수를 수행하는 방식으로, 사후정비방식보다 효율적이지만, 주기적으로 정비에 시간이 소요되는 단점이 존재한다. 마지막으로, 예지보전 방식(PdM)은 기기의 상태 데이터를 분석하여, 기기의 결함을 사전에 예측하는 방식이다. 이 방식의 경우, 추가적으로 기기의 데이터 수집, 데이터 분석, 그리고 결함 예측이 수행되어야 하는 단점이 있다. 그러나 예지 보전방식은 추가적인 작업 수행의 단점보다 예측을 통해 효율적인 유지보수가 가능한 이점이 더 크기 때문에, 최근에는 협동 로봇 및 기기의 예지보전에 관한 연구가 확대되고 있다[5].

산업용 로봇의 결함은 센서, 엔코더, 그리고 컴퓨터 제어 시스템과 같은 전기 부품에서 발생 가능하며 감속기, 모터로 구성된 기계 부품에서도 발생한다[6]. 또한 약 45%의 결함이 대부분 이러한 기계 부품 결함에서 발생한다[7]. 다음 Fig. 1은 모터 부품의 결함 비율을 나타낸 그림으로 베어링 및 기어, 스테이터, 로터 및 샤프트 순으로 결함이 발생하며, 베어링 및 기어 결함의 발생 비율이 41%로 가장 높다[8].

한편, 산업용 로봇의 예지 보전을 위해서는 요구 기능을 수행하지 못하는 고장의 원인이 되는 결함을 진단해야 한다. 결함진단에 활용되는 데이터에 따라 기기 내부 데이터인 전류 및 토크 데이터[9-11], 그리고 외부 데이터인 진동 데이터[12-14]를 사용한 연구가 대표적이다. 전류 및 토크 데이터를 사용한 결함진단연구 중 [9]는 샤프트 결함을 주파수 영역에서 토크 데이터의 변화 폭을 분석하고, [10]은 로터 결함을 웨이브릿 변환을 사용하여 전류 데이터의 결함 유무에 따른 분해 단계의 차이를 분석하여 결함을 진단한다. [11]은 볼 스�크류 결함을 전류 데이터를 입력으로 웨이브릿 패킷 변환과 선형 회귀기법을 사용하여 진단한다. 진동 데이터를 사용한 결함진단연구 중 [12]은 기어박스 결함을 진동 데이터를 PTDA

(Phase-based Time Domain Averaging)을 사용하여 분석하고, [13]는 베어링 및 기어 결함을 진동 데이터를 입력으로 합성곱 신경망(CNN)을 사용하여 진단하며, [14]은 감속기의 기어 결함을 진동 데이터를 입력으로 오토 인코더(Auto-Encoder) 및 SVM(Support Vector Machine)을 사용하여 진단하였다. [15]은 기어 결함을 진동 데이터를 입력으로 합성곱 신경망(CNN)을 사용하여 진단한다. 이러한 기존 결함진단 연구들은 협동 로봇이나 기기의 결함을 진단하는데 다음과 같은 한계점을 지니고 있다.

첫째, 협동 로봇이 수행한 동작 데이터 패턴에 대한 학습 모델의 의존성이 높다. 협동 로봇은 정해진 프로세스에서 고정된 작업을 하는 일반적인 산업용 로봇과는 달리, 사용자 정의 프로그램을 통해 다양한 작업을 수행하는 특성이 있어, 수집 데이터 역시 다양한 패턴을 지닌다. 하지만 기존의 연구에서는 실험 환경에서 수행한 작업에서 수집된 데이터를 학습하여 진단 모델을 생성하기 때문에, 수집 데이터 패턴에 의존성을 가지게 된다[14]. 따라서 기존에 생성된 데이터만을 가지고 만든 진단 모델이 협동 로봇의 다양한 동적 실행 상황에 대한 범용성을 지니기 어렵다.

둘째, 단일 축이 아닌 다관절이 동작하는 작업에서 발생하는 결함을 진단하기 어렵다. 협동 로봇은 보통 6축 혹은 7축으로 구성되며, 각 관절은 모터에 의해 구동되기 때문에 특정 구동부 모터에 결함이 발생할 수 있다. 그러나 [15]와 같은 연구에서는 단일 모터에서 수집된 데이터를 사용하여 분석을 수행하기 때문에, 다관절 협동 로봇의 구동 상황을 고려한 결함진단 모델을 생성하기 어렵다는 한계가 있다.

따라서 본 논문에서는 협동 로봇의 기어 마모 결함진단에 있어 상기 언급한 두 가지 문제점을 해결하기 위해 전류와 진동, 두 가지 센서 데이터 잔차 패턴 기반의 LSTM 모델을 제안한다. 제안하는 방법은 단일 축 및 다중 축 작업 환경에서의 진동 및 전류 데이터에 피어슨 상관분석을 적용하여 정상 동작의 대표 패턴을 선정하고, 정상 대표 패턴과의 차이를 통해 잔차 패턴을 생성한다. 또한 생성된 잔차 패턴을 입력으로 축별 기어 마모 진단을 수행할 수 있도록 장기 시계열 데이터 학습에 유리한 LSTM(Long Short-Term Memory) 모델을 학습한다. 모델 학습 결과, 생성된 대표 패턴을 기반으로 잔차 패턴을 학습한 LSTM 모델은 협동로봇의 기어 마모 실험에 98.57%의 정확도의 높은 성능을 확인하였다.

제안하는 방법은 저비용의 센서를 사용하여 실제 공정 도입 시 경제성 측면에서 효율적이며, 내부 데이터인 각 축별로 인가된 전류 데이터와 외부 데이터인 6축 진동 데이터를 사용하여 다양한 결함 특성을 분석에 사용하여 진단 성능을 향상시켰다. 또한 정상 데이터들의 대표 패턴과 데이터 사이의 잔차를 사용하여, 협동 로봇의 다양한 동작별 데이터 패턴에서 결함 특성 정보를 추출하여 동작 데이터 패턴에 대한 모델의 의존성을 낮출 수 있었다. 결과적으로, 6축 협동 로




Fig. 1. Causes of Faults in the Motor Parts [8]

봇을 사용한 단일 축 및 다중 축이 동작하는 작업 환경에서 수집된 전류 및 진동 데이터를 사용하여, 단일 축 동작 데이터와 복합 동작 데이터의 시계열 특성을 반영 가능한 LSTM 모델을 활용하여 다중 축 동작 수행 시 발생하는 결함을 진단할 수 있다.

## 2. 관련 연구

협동 로봇의 부품 결함을 진단하기 위해 내부 및 외부에 부착된 센서에서 수집된 데이터를 통계적으로 분석하거나 학습 모델을 활용하고 있다. 프로그래머블한 동작을 수행하는 다관절 협동 로봇의 기어 결함진단을 위해서는 내외부 센서를 모두 활용하여 진단 성능을 높이고 로봇 동작의 의존성을 낮출 필요가 있다.

### 2.1 센서 데이터 관점에서의 결함진단

협동 로봇의 결함진단은 일반적으로 내부 데이터와 외부 데이터를 사용하여 결함을 진단한다.

먼저, 내부 데이터인 토크 데이터를 사용한 결함진단 연구로 [9]는 산업용 로봇의 주요 구성요소인 액추에이터의 감속기 축 정렬 결함을 액추에이터에서 수집된 토크 데이터를 분석하여 진단한다. 결함으로 인해 발생하는 토크 리플을 FFT(Fast Fourier Transform)와 Power Spectrum 분석을 사용하여 결함을 진단한다. [11]은 내부 데이터인 전류 데이터를 사용한 결함진단연구로 협동 로봇의 모터의 볼 스크류 결함을 전류 데이터를 분석하여 진단한다. 전류 데이터를 STFT(Short-Time Fourier Transform)와 WPD(Wavelet Packet Decomposition)를 사용하여 분석한다. 또한 Fisher score를 사용해 추출된 통계적 특성을 입력으로 로지스틱 회귀와 k-최근접 이웃 알고리즘을 사용하여 결함을 진단한다.

[12]는 외부 데이터인 진동 데이터를 사용한 결함진단 연구로 협동 로봇의 기어박스 결함을 기어박스에서 부착된 진동 센서의 데이터를 분석하여 진단한다. 진동 데이터를 PTDA(Phase-based Time Domain Averaging)를 사용하여 결함 특성을 가진 잔차 신호와 그렇지 않은 신호로 나눈다. 이렇게 얻은 결함 특성을 가진 잔차 신호를 분석하여 결함진단 성능을 향상시킨다.

이러한 내부 및 외부 데이터인 토크, 전류, 그리고 진동 데이터를 사용한 협동 로봇의 결함진단연구들은 협동 로봇의 결함 특성을 반영한 연구들이다. 내부 데이터는 개별 액추에이터의 결함 진단에 좋은 성능을 보인다. 외부 데이터는 다중 축이 동작하는 협동 로봇의 동작 중 결함을 진단할 때에 좋은 성능을 보인다. 따라서 본 논문에서는 협동 로봇의 기어 마모에 따른 동작 결함을 진단하기 위해 내외부 센서인 전류와 진동 데이터를 복합적으로 분석하는 방법을 제안한다. 이러한

다중 센서를 사용 시 결함에 대한 다양한 측면에서의 데이터 확보가 가능하여 진단 성능의 개선을 기대할 수 있으며, 진동 및 전류 센서 모두 저렴한 가격의 센서를 사용하여 공정 도입의 경제성 측면에서도 장점이 있다.

### 2.2 모델 관점에서의 결함진단 연구

산업용 로봇의 결함진단 연구는 수집된 센서 데이터를 사용한 머신러닝 및 딥러닝을 사용한 연구가 주로 수행되고 있다. 학습 기반 결함진단 연구는 ANN(Artificial Neural Network) 모델[22], CNN(Convolutional Neural Network) 모델[23], LSTM(Long Short-Term Memory) 모델[24] 그리고 LSTM-Autoencoder 모델[25] 등을 기반으로 기기의 결함 및 정상 상태 데이터를 학습하여 결함을 진단하는 연구들이 있다.

ANN(Artificial Neural Network) 모델을 사용한 결함진단 연구인 [22]은 로봇의 기어박스 결함을 인공신경망을 사용하여 진단하는 연구이다. 웨이블릿 변환을 사용하여 진동 데이터를 다중채널 주파수로 변환하여 입력으로 하여 인공신경망 모델을 통해 결함을 진단한다. 해당 연구에서는 모델 설계 시 로봇의 동작 특성을 고려하기 어려운 한계가 있다. CNN(Convolutional Neural Network) 모델을 사용한 결함진단인 [23]은 협동 로봇의 모터의 결함을 CNN 모델을 사용하여 진단하는 연구이다. 다양한 동작 환경에서 수집된 센서 데이터를 입력으로 사용하여 CNN 모델을 통해 결함을 진단한다. 해당 연구에서는 시뮬레이션을 기반으로 하여 데이터를 생성한다. 시뮬레이션 기반 데이터는 실제 센서 데이터가 아니어서 결함 및 정상 상태에서의 결함 특성을 반영하지 못한다는 단점이 있다. [24]은 모터의 베어링 결함을 EEMD(Ensemble Empirical Mode Decomposition)과 장단기 메모리 모델을 사용하여 진단한다. 해당 연구에서는 EEMD로 진동 신호를 주파수 특성에 따라 여러 신호로 나누어 준다. 이렇게 생성된 특성별 신호들을 이어서 LSTM 모델의 입력으로 넣어 결함을 진단한다. 해당 연구는 LSTM 모델을 사용하여 시계열 특성을 반영한 진단 모델이지만, 해당 연구에서는 하나의 모터를 사용한 결함진단 연구로 다관절이 동작하는 작업에서 발생하는 결함진단에는 한계가 있다. [25]는 고전압 변압기의 부상에 발생하는 결함을 전류의 위상각과 크기를 LSTM-Autoencoder의 입력으로 사용하여 MAE(Mean Absolute Error) 값을 통해 결함을 예측한다. 해당 연구는 결함 데이터가 적은 환경에 적합한 LSTM-Autoencoder를 활용하여 데이터 불균형 환경에서 특정 장비의 결함을 진단하는데 적합하다. 하지만 본 연구에서처럼 데이터의 불균형이 크지 않은 조건에서는 활용도가 높지 않다. 또한 로봇의 여러 관절에 다양한 결함이 발생 가능한 협동 로봇의 특성상 하나의 센서에서 발생하는 데이터로 다양한 결함을 분류하는 측면에서는 한계가 존재한다.

2.1과 2.2절에서 비교한 연구들의 사용 데이터, 결함 종류, 진단방법을 요약하면 다음 Table 1과 같다.

Table 1. Summary of Related Research

| Related studies | Data              | Fault                                  | Method                                |
|-----------------|-------------------|--|---------------------------------------|
| [9]             | Torque (Inner)    | Shaft misalignment in the gearbox      | Analysis using FFT and Power Spectrum |
| [11]            | Current (Inner)   | Ball screw fault in the motor          | Analysis based on STFT and WPD        |
| [12]            | Vibration (Outer) | Gearbox fault                          | PTDA and residual analysis            |
| [22]            | Vibration (Outer) | Gearbox fault                          | ANN                                   |
| [23]            | Position (Inner)  | Motor fault                            | CNN                                   |
| [24]            | Vibration (Outer) | Bearing fault in the motor             | EEMD and LSTM                         |
| [25]            | Current (Inner)   | High-voltage transformer bushing fault | LSTM-Autoencoder                      |

따라서 본 논문에서는 기존 모델 및 데이터 기반 결함진단 연구의 한계점을 다음과 같이 해결하고자 한다. 첫째, 동작 데이터 패턴에 대한 모델의 의존성을 낮추기 위해 정상 데이터들의 대표 패턴과 데이터 사이의 잔차를 사용하여, 협동 로봇의 다양한 동작별 데이터 패턴에서 결함 특성 정보를 추출하여 진단에 활용한다. 둘째, 다중 축 동작 수행 시 발생하는 결함의 높은 진단 성능을 위해 단일 축 및 다중 축이 동작하는 작업 환경에서 수집된 협동 로봇의 전류 및 진동 데이터를 사용하여 협동 로봇의 동작 특성을 내부 및 외부 두 측면에서 반영한다. 또한 LSTM 모델을 사용하여 단일 축 동작 데이터와 및 복합 축 동작 데이터의 시계열 특성을 반영한다.

### 3. 동작별 잔차 패턴 기반 LSTM 결함진단 모델

이 장에서는 Fig. 2와 같이 세 단계로 진단을 위한 학습 모델을 구축한다. 먼저, 협동 로봇에서 결함이 부여된 단일 축만을 구동시키는 작업과 결함이 부여된 축을 포함하는 다중 축을 구동시키는 작업(Task)에 대하여 정상 및 결함상태의 데이터를 수집한다(Step 1). 그리고 수집된 정상 데이터의 상관분석을 진행하였다(Step 2). 이를 통해 가장 높은 상관관계수 값을 가지는 정상 대표 패턴을 선정한다(Step 3). 선정된 정상 대표 패턴으로 결함 특징이 내재된 잔차 신호를 생성한다(Step 4). 마지막으로, 이렇게 생성된 잔차 신호를 입력으로 하여 LSTM 모델을 학습하여 단일 축 및 다중 축 작업의 결함진단 모델을 개발한다(Step 5).

#### 3.1 상관분석을 사용한 정상 대표 패턴 추출

이 절에서는 상관분석을 사용하여 정상 데이터 패턴 중 대표 패턴을 생성한다. 협동 로봇은 수행하는 동작에 따라 시계열 데이터인 진동 및 전류 데이터가 다양한 양상의 데이터 패턴을 보인다. 정상 상태의 협동 로봇이 같은 동작을 수행한 결과로 수집된 데이터일지라도 외부 환경적인 원인이나 로봇의 내부 원인으로 데이터가 다른 양상을 보일 수 있다. 따라서 본 논문에서는 내·외부 환경 요소를 고려한 정상 대표 패턴을 추출하여 결함진단에 활용한다.

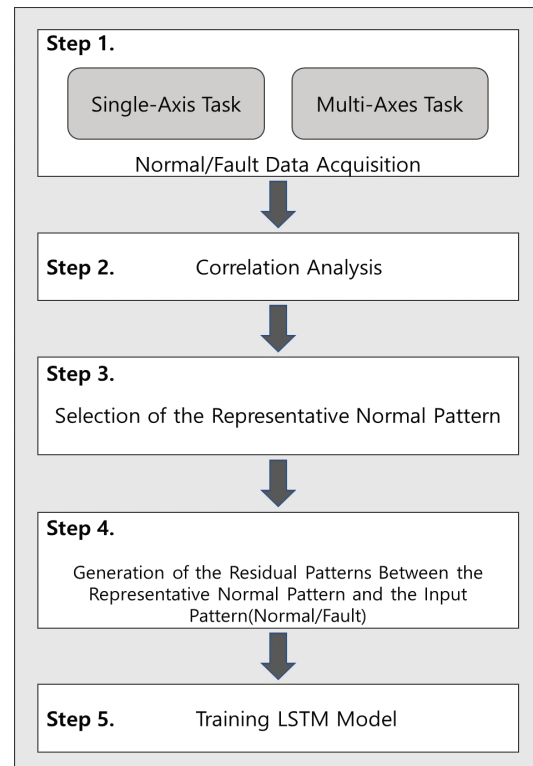


Fig. 2. Building LSTM Model using the Residual Patterns

데이터의 대표 패턴을 생성할 때는 평균, 제곱평균제곱근과 같이 기존 데이터들을 기반으로 새로운 데이터 패턴을 생성해주는 방식과 유클리디안 거리, 맨해튼 거리, 상관분석 등과 같이 데이터 패턴들 사이의 비교를 통해 대표 패턴을 선정하는 방식이 있다. 이러한 방식들 중 본 논문에서 상관분석을 사용하는 이유는 다음과 같다.

먼저, 평균 및 제곱평균제곱근과 같은 방법은 로봇의 동작으로 발생하는 변화량이 큰 센서 데이터 외에 내·외부 환경에서 발생하는 변화량이 작은 데이터는 필터링을 하게 된다. 하지만 변화량이 작은 데이터 요소도 결함진단 시에는 중요한 요소이기 때문에 해당 방법은 결함진단에 적합하지 않다.

다음으로 유클리디안 거리와 맨해튼 거리 등 데이터 사이의 거리 기반 대표 패턴 선정 방법은 일정 기준을 적용하여

기존 데이터 패턴에서 대표 패턴을 선정한다는 점에서 상관분석과 유사한 방법이다. 하지만 거리를 기반으로 대표 패턴을 선정하는 방법은 스케일이 큰 로봇의 동작 데이터에 영향을 많이 받는 특징이 있다. 따라서 스케일이 작은 환경 요소 데이터를 활용하는 본 논문에서는 적합하지 않다. 따라서 본 논문에서는 스케일이 작은 데이터에도 상관관계의 정량적인 비교에 장점이 있는 피어슨 상관분석을 수행한다.

Equation (1)에서  $n$ 개의 데이터 개수를 가지는 변수  $x$ 와  $y$ 에 대하여  $x_t$ 와  $y_t$ 는 두 변수  $x$ 와  $y$ 에서 각각의 개별 데이터를 의미한다.  $\bar{x}$ 와  $\bar{y}$ 는 각각  $x$ 와  $y$ 의 평균을 의미한다. 해당 수식을 통해 두 변수  $x$ 와  $y$  사이의 상관성( $C_{xy}$ )을 확인할 수 있다. 해당 수식에서  $x$ 양의 선형성이 클수록 상관계수 값이 1에 가깝게 나타나며, 음의 선형성이 클수록 상관계수 값이 -1에 가깝게 나타난다.

$$C_{xy} = \frac{\sum_{t=0}^n \frac{(x_t - \bar{x})(y_t - \bar{y})}{n-1}}{\sqrt{\sum_{t=0}^n (x_t - \bar{x})^2} \sqrt{\sum_{t=0}^n (y_t - \bar{y})^2}} \quad (1)$$

본 논문에서는 상관분석 방법을 협동 로봇의 시계열 데이터에 적용하여 Fig. 3의 알고리즘을 통해 분석을 수행한다. 단일 축 및 다중 축 동작 작업의 정상 데이터 패턴 사이의 상관 정도를 분석하여 정상 대표 패턴(RP, Representative Pattern)을 선정하는 알고리즘이다. 각 Task들에 대하여 정상 데이터 패턴들(Normal\_Patterns)들 사이에서 패턴 간 상관성 계수(PCC, Pearson Correlation Coefficient)를 계산하여 더한다. 이렇게 더해진 상관성 계수의 합이 가장 큰 정상 데이터 패턴을 RP로 선정한다.

Fig. 4는 센서로부터 수집된 데이터를 단일 축 및 다중 축 동작 작업의 정상 데이터 패턴 사이의 상관 정도를 분석하는 과정을 예시한다. 이때, 작업별 실험 횟수는  $n$ 번이다. 따라서  $n \times n$ 의 상관행렬로 나타내며, 각 행렬 성분은 연계된 데이터 간의 상관분석을 통해 획득한 상관계수를 나타낸다. 생성된 상관 계수들에 대하여 데이터별 총합을 구하여 가장 큰 값을 가지는 데이터 패턴을 RP로 선정한다. 예를 들어, 빨간색 상자로 표시된 상관계수는 대표 패턴과 Data  $n$  사이의 상관 분석 결과이다. 해당 상관계수 0.98은 양의 상관성이 있음을 나타낸다. 이런 방식으로 모든 데이터 사이의 상관계수를 구하고 각 행 및 열의 상관계수를 모두 더한 결과가 오른쪽 마지막 열의 Sum 열과 같이 나타난다. 21.12이 해당 Sum 열에서 가장 큰 값이며 해당 패턴을 대표 패턴으로 선정한다. Fig. 5에서 표시된 RP를 정상 대표 패턴으로 선정한다. 이처럼 데이터별 상관계수의 총합을 구하여 정상 대표 패턴을 선정하는 과정을  $n$ 개의 센서 데이터에 대해 수행하며, 각 데이터 타입에 따른 정상 대표 패턴이 생성된다. 정의된 정상 대표 패턴들은 수집된 데이터들의 동작 특성을 가장 잘 반영하는 대표 패

| Algorithm 1 : Representative Pattern Selection |  |
|--|--|
| 1  | Input : All Task's Normal Data Pattern                           |
| 2  | Output : RP  |
| 3  | <b>for</b> Task in Tasks <b>do</b> :                             |
| 4  | <b>for</b> Normal_Pattern in Normal_Patterns <b>do</b> :         |
| 5  | <b>for</b> Another_Normal_Pattern in Normal_Patterns <b>do</b> : |
| 6  | PCCs <- PCC(Normal_Pattern, Another_Normal_Pattern)              |
| 7  | PCCs_Sums <- Sum(PCC)  |
| 8  | RP <- Max(PCCs_Sums)   |
| * RP = Representative Pattern                  |  |
| * PCC = Pearson Correlation Coefficient        |  |

Fig. 3. Representative Pattern Selection Algorithm

|          | Data 1 | RP   | Data 3 | Data n-1 | Data n | Sum   |
|----------|--------|------|--------|----------|--------|-------|
| Data 1   | 1      | 0.95 |        | 0.73     | 0.79   | 10.34 |
| RP       | 0.95   | 1    |        | 0.97     | 0.98   | 21.12 |
| Data 3   |        |      |        |          |        | ⋮     |
| Data n-1 | 0.73   | 0.97 |        | 1        | 0.79   | 16.67 |
| Data n   | 0.79   | 0.98 |        | 0.79     | 1      | 13.32 |

Fig. 4. Selection of Normal Representative Patterns Using Pearson Correlation Analysis

턴이 되며, 결함 데이터와의 비교 분석 시 정상에 대한 일관된 비교 기준을 제시할 수 있다.

### 3.2 정상 대표 패턴을 사용한 잔차 신호 생성

3.2절에서는 각 동작 작업에 대하여 선정된 정상 대표 패턴을 사용하여 Fig. 5의 그림에서처럼 수행된 작업에서 수집된 모든 정상 및 결함 데이터에 대하여 정상 대표 패턴과의 잔차를 계산한다. 이때, 협동 로봇이 수행한 다양한 작업에서 수집된 데이터에 대해서 작업별로 Fig. 5처럼 잔차 신호를 생성한다.

(a)에서 결함이 부여된 협동 로봇의 데이터 패턴(Fault)과 정상 대표 패턴(RP)을 비교해 보면 결함 패턴이 정상 대표 패턴과 비교하여 두 패턴 사이의 차이가 크게 발생하는 것을 확인할 수 있다. (b)에서는 이러한 결함 데이터 패턴과 정상 대표 패턴 사이의 차이에 집중하기 위해 두 패턴 사이의 잔차를 나타낸다. 이렇게 생성된 잔차 패턴은 정상 대표 패턴과 결함 데이터 패턴 사이의 차이를 직관적인 분석이 가능케 하여 결함 특성에 집중된 분석이 가능하게 된다. (c)에서는 마찬가지로 정상 데이터 패턴(Normal)과 정상 대표 패턴(RP) 사이의 차이 또한 (d)에서와 같이 생성해준다. 이처럼 생성된 잔차 패턴은 협동 로봇의 동작 특성을 제거하여, 다양한 동작을 수행하는 협동 로봇의 분석 복잡도를 낮출 수 있다.



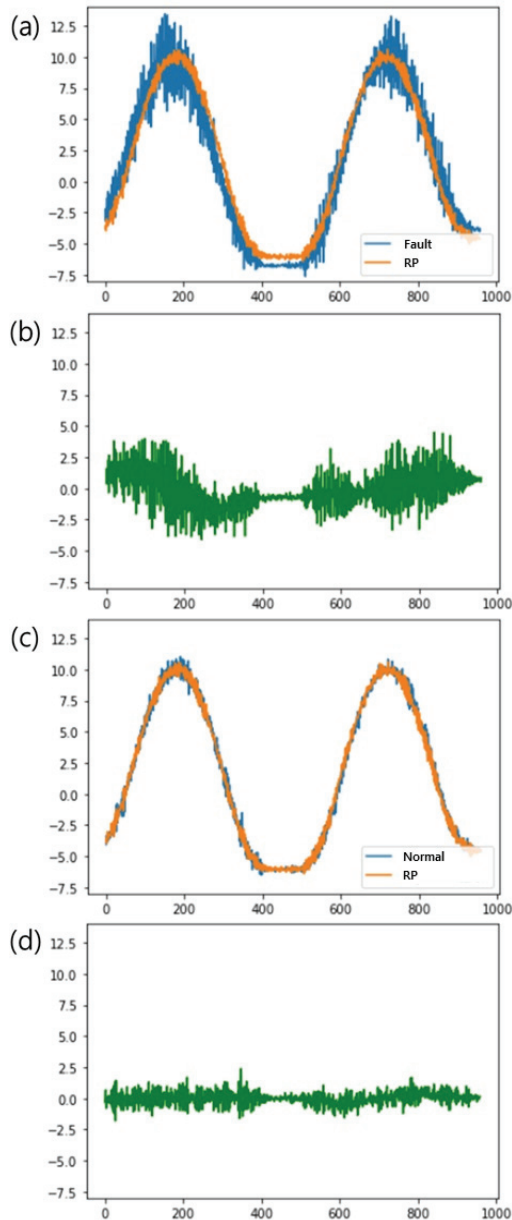


Fig. 5. Extracting the Residual Patterns (a) Fault and Normal Representative Data Pattern (b) Residual Data Pattern Between Fault Data Pattern and Normal Representative Data Pattern (c) Normal Data Pattern and Normal Representative Data Pattern (d) Residual Data Pattern of Normal Data Pattern and Normal Representative Data Pattern

### 3.3 결함진단 LSTM 모델의 설계

3.3절에서는 생성된 잔차 신호를 입력으로 하여 결함을 진단하는 LSTM(Long Short Term Memory) 모델[26]에 대하여 설명한다. 협동 로봇이 동작하면서 수집되는 데이터는 시간에 따른 변화를 보여주는 시계열 데이터이다. 이러한 시계열 데이터의 시간에 따라 연속적으로 변하는 특성을 반영하는 진단 모델을 설계하기 위하여 시계열 데이터의 분석에 이점이 있는 LSTM 모델을 진단 모델로 선정하였다.

- 입력층(Input layer) : 입력 데이터의 경우, 협동 로봇이 여러 작업을 수행하면서 수집된 전류 및 진동 데이터를 작업 단위마다 수집한다. 수집된 데이터들에서 피어슨 상관분석을 통해서 대표 패턴을 선정한다. 이렇게 선정된 대표 패턴을 사용하여 잔차 신호를 생성한다. 이렇게 생성된 잔차 신호를 Fig. 6의 입력층에서 볼 수 있듯이 각 특징별로 입력 타임 스탬프(Input Time Stamp)는  $n$ 개로 설정하며, 특징 개수  $m$ 개로 입력 차원(dimension)을 설정해 준다. 이렇게 설정된 슬라이딩 윈도우(Sliding Window)를 한 칸씩 옮기면서 생성된 윈도우 LSTM 유닛에 입력으로 넣어준다.
- 은닉층(Hidden layer) : 앞서 입력층(Input layer)에서 생성된 윈도우(window)를 각 LSTM 유닛에 시간 단위마다 윈도우(window)를 이동시켜주면서 각 LSTM 유닛으로 넣어준다. 다음으로 각 LSTM 유닛에 이전 LSTM 유닛에서 필요한 특성만을 선정하여 다음 LSTM 유닛으로 전달하며 학습을 진행한다.
- 출력층(Output layer) : 최종적으로 학습된 LSTM 모델은 Output layer에서 출력으로 해당 입력이 결함상태이면 1, 정상 상태이면 0으로 분류한 예측 결과를 출력한다.

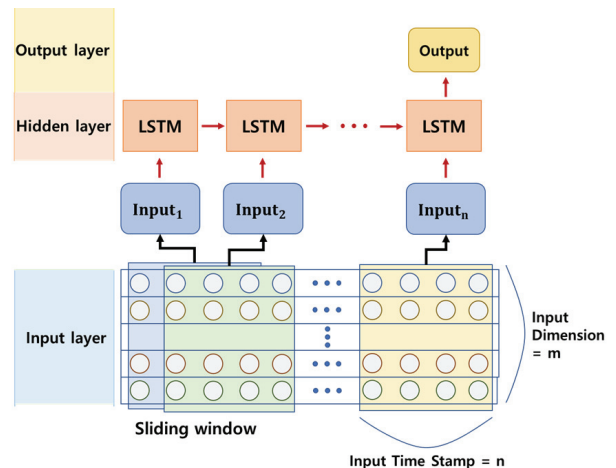


Fig. 6. Structure of Fault Detection LSTM Network

## 4. 실험

### 4.1 실험 환경

실험에는 Fig. 7과 같은 6축 협동 로봇인 Niryo One[27]을 사용하였다. 협동 로봇의 각 축에서 전류 데이터를 10ms 주기로 수집하였으며, 6축 진동 데이터를 10ms 주기로 수집하였다. Fig. 7의 협동 로봇에 대하여 정상 상태의 협동 로봇 및 4번 축 구동부에 기어 결함을 부여한 상태의 협동 로봇을 실험에 사용하였다. 해당 로봇이 수행한 작업은 Table 2에서처럼 결함이 부여된 단일 축 구동 작업은 로봇의 최대 동작 반경( $290^\circ$ )의 80% 정도의 범위로 구동하는 작업으로 설정하였




Fig. 7. Collaborative Robot Test Experimental Bench

Table 2. Range of Motion of Tasks

| Operation Scope | Single-axis motion operation |       | Multi-axes motion operation |       |       |
|-----------------|------------------------------|-------|-----------------------------|-------|-------|
| Joint 1         | 0°                           | 0°    | -20°                        | +20°  | 0°    |
| Joint 2         | 0°                           | 0°    | 0°                          | 0°    | 0°    |
| Joint 3         | 0°                           | 0°    | 0°                          | 0°    | 0°    |
| Joint 4         | -230°                        | +230° | -145°                       | +290° | -145° |
| Joint 5         | 0°                           | 0°    | +60°                        | -60°  | 0°    |
| Joint 6         | 0°                           | 0°    | +120°                       | -120° | 0°    |

으며 결함이 부여된 축을 포함하는 다중 축을 구동시키는 작업은 결함 축은 최대 동작 반경으로 설정하고 나머지 축들의 경우 결함 축에 무리한 부하를 주지 않는 정도의 구동 범위로 제한하는 동작으로 설정하였다. 작업별로 2000회씩 실험을 수행하였으며 수집된 데이터는 정상 및 결함의 상태에 따라 작업별로 2000개의 데이터가 생성되었다. 생성된 데이터를 학습, 검증, 그리고 테스트 데이터로 각각 6:2:2의 비율로 나누어주었다.

#### 4.2 모델 학습 및 평가

정상 상태의 협동 로봇에서 수집된 전류 및 진동 데이터에서 피어슨 상관분석을 사용하여 각 특성별 상관계수의 합이 가장 큰 패턴을 특성별 대표 패턴으로 선정하였다. 이렇게 선정된 특성별 정상 대표 패턴과 모든 데이터 사이에 잔차 패턴을 생성한다. Fig. 8은 단일 축 및 다중 축 동작 데이터 패턴에서 협동 로봇의 동작 특성이 제거되고, 결함 특성이 남은 것을 확인할 수 있다. 기존의 (a)와 (b)를 입력으로 사용하는 경우에는 진단 모델이 동작 특성까지 고려하여 결함을 진단하여야 하지만 잔차 패턴을 사용하는 경우에는 결함 특성에 집중한 진단이 가능하다. 따라서 협동 로봇이 수행한 동작 데이터 패턴에 대한 모델의 의존성을 낮출 수 있다.

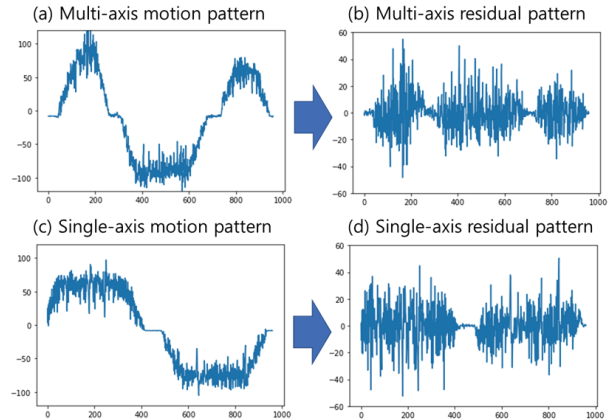


Fig. 8. Residual Pattern of Single-axis and Multi-axes Motion

Table 3. Test Accuracies of Different Preprocessing Methods

| Model                                    | Accuracy(%) |
|--|-------------|
| using mean value model                   | 96.12       |
| using euclidean distance model           | 97.31       |
| using pearson correlation analysis model | 98.57       |

Table 4. Test Accuracies of Different Methods

| Model                  | Accuracy(%) |
|------------------------|-------------|
| ANN model              | 80.05       |
| CNN model              | 93.45       |
| LSTM model             | 94.55       |
| LSTM-Autoencoder model | 96.74       |
| proposed model         | 98.57       |

Table 3은 본 논문에서 제안하는 피어슨 상관분석을 사용한 기법과 평균 및 유클리디언 거리를 사용한 LSTM 모델 사이의 성능을 비교한 결과이다. 피어슨 상관분석을 사용한 모델의 정확도가 98.57%로 평균을 사용한 모델과 비교하여 2.35%p, 유클리디언 거리를 사용한 모델과 비교하여 1.26%p의 성능 향상을 보였다.

Table 4는 본 논문에서 제안하는 잔차 패턴을 사용한 LSTM 모델과 다른 진단 모델과의 성능을 비교한 결과이다. 제안하는 모델의 정확도가 98.57%로 ANN 모델과 비교하여 18.52%p, CNN 모델과 비교하여 5.12%p, 잔차 패턴을 사용하지 않은 LSTM 모델과 비교하여 4.02%p 그리고 LSTM-Autoencoder 모델과 비교하여 1.83%p의 성능 향상을 보였다. 따라서 제안하는 방법이 단일 축 및 다중 축 동작을 수행하는 협동 로봇의 결함을 높은 성능으로 진단하는 것을 확인하였다.

Table 5는 내부 데이터인 전류 데이터, 외부 데이터인 진동 데이터, 그리고 전류 및 진동 데이터를 모두 사용한 세 가지 경우에 대한 성능을 비교한 표이다. 전류 및 진동 데이터를 모두 사용한 경우 전류 데이터만을 사용하여 결함을 진단한 경우와 비교하여 13.08%p의 성능 개선을 보였으며, 진동 데이

Table 5. Test Accuracies of Proposed Model Under Different Input Data

| Model          | Input Data          | Accuracy(%) |
|----------------|---------------------|-------------|
| proposed model | current             | 85.49       |
| proposed model | vibration           | 97.20       |
| proposed model | current & vibration | 98.57       |

Table 6. Structure of Current &amp; Vibration Data

| Data                 | Feature        | Feature number |
|----------------------|----------------|----------------|
| Current              | Axis_1         | 6              |
|                      | Axis_2         |                |
|                      | Axis_3         |                |
|                      | Axis_4         |                |
|                      | Axis_5         |                |
|                      | Axis_6         |                |
| Vibration            | Gyro_x         | 6              |
|                      | Gyro_y         |                |
|                      | Gyro_z         |                |
|                      | Acceleration_x |                |
|                      | Acceleration_y |                |
|                      | Acceleration_z |                |
| Total feature number |                | 12             |

터만을 사용하여 결함을 진단한 경우와 비교하여 1.37%p의 성능 개선을 보였다. 해당 결과를 통해 내부 및 외부 데이터의 분석을 통한 결함진단이 내부 및 외부 단일 데이터만을 통한 진단보다 더 높은 성능을 확인하였다.

Table 6은 전류 및 진동 데이터의 데이터 특성을 종류와 개수를 나타내는 표이다. 각 데이터는 6개의 특성으로 이루어져 있으며, 단일 데이터만 사용하여 진단하는 경우 해당 데이터의 6개의 특성만 사용하여 진단하게 된다. 하지만, 두 데이터를 사용하는 경우 12개의 특성을 모두 사용 가능하며, 이러한 다중 센서 데이터를 사용하여 결함에 대한 다양한 측면에서의 데이터 분석이 가능하여 진단 성능의 개선이 가능하였다.

## 5. 결론 및 향후 연구

본 논문에서는 협동 로봇의 기어 마모 결함을 진단하는 잔차 패턴을 사용한 LSTM 모델을 제안한다. 제안하는 진단 모델은 협동 로봇의 전류 및 진동 데이터를 사용하여, 로봇의 동작별로 정상 데이터의 특성마다 피어슨 상관분석으로 정상 대표 패턴을 선정한다. 선정된 정상 대표 패턴을 사용하여 잔차 데이터 패턴을 생성하고 잔차 데이터 패턴을 LSTM 모델의 입력으로 넣어주어 출력으로 결함 유무를 출력한다. 실험 결과, 제안하는 모델의 정확도는 98.57%로 LSTM 모델과 비교하여

약 4%p 높은 성능, LSTM-Autoencoder 모델과 비교하여 약 2%p 높은 성능을 보였다. 전류 및 진동 데이터를 개별로 입력으로 사용한 모델과 비교하여 각각 약 13%p와 약 1%p 높은 성능을 보였다.

해당 실험 결과를 통해 제안하는 결함진단 모델은 두 가지 기여점을 가진다. 첫째, 정상 대표 패턴과 데이터 사이의 잔차를 사용하여, 협동 로봇의 동작 데이터 패턴에서 동작 특성을 제거하고, 남은 결함 특성을 입력으로 사용하여 결함진단 모델의 학습 데이터 패턴에 대한 의존성을 낮출 수 있다. 이를 통해 산업현장에서 학습에 사용하지 않은 로봇의 동작에 대해서도 좋은 성능을 보일 수 있을 것이라 기대된다. 둘째, 전류 데이터와 진동 데이터를 사용하여 각 축별 데이터와 복합 동작 데이터의 시계열 특성을 LSTM 모델의 입력으로 활용하여 다중 축 동작 수행 시 발생하는 결함진단에 뛰어난 성능을 보였다. 이를 통해 복잡한 동작을 수행하는 실제 산업 로봇에 도입 시에도 우수한 진단 성능을 보일 것이라 기대된다.

## References

- [1] A. G. Frank, L. S. Dalenogare, and N. F. Ayala, "Industry 4.0 technologies: Implementation patterns in manufacturing companies," *International Journal of Production Economics*, Vol.210, pp.15-26, 2019.
- [2] A. Weiss and A. Huber, "User experience of a smart factory robot: Assembly line workers demand adaptive robots," *arXiv preprint arXiv:1606.03846*, 2016.
- [3] R. Ahmad and S. Kamaruddin, "An overview of time-based and condition-based maintenance in industrial application," *Computers & Industrial Engineering*, Vol.63, No.1, pp.135-149, 2012.
- [4] T. Gullledge, S. Hiroshige, and R. Iyer, "Condition-based maintenance and the product improvement process," *Computers in Industry*, Vol.61, No.9, pp.813-832, 2010.
- [5] S. Selcuk, "Predictive maintenance, its implementation and latest trends," *Proceedings of the Institution of Mechanical Engineers, Part B: Journal of Engineering Manufacture*, Vol.231, No.9, pp.1670-1679, 2017.
- [6] L. F. Villa, A. Reñones, and J. R. Perán, "Statistical fault diagnosis based on vibration analysis for gear test-bench under non-stationary conditions of speed and load," *Mechanical Systems and Signal Processing*, Vol.29, pp.436-446, 2012.
- [7] S. Vallachira, M. Orkisz, M. Norrlöf, and S. Butail, "Data-driven gearbox failure detection in industrial robots," *IEEE Transactions on Industrial Informatics*, Vol.16, No.1, pp.193-201, 2019.



- [8] D. A. Tobon-Mejia, K. Medjaher, and N. Zerhouni, "CNC machine tool's wear diagnostic and prognostic by using dynamic Bayesian networks," *Mechanical Systems and Signal Processing*, Vol.28, pp.167-182, 2012.
- [9] Z. Yu and Y. Zhang, "Diagnosis of the misaligned faults of the vertical test instrument of high-precision industrial robot reducer," *Shock and Vibration*, Vol.2021, pp.1-17, 2021.
- [10] A. Bonci, S. Longhi, and F. Verdini, "Predictive maintenance system using motor current signal analysis for industrial robot," *2019 24th IEEE International Conference on Emerging Technologies and Factory Automation (ETFA)*, IEEE, 2019.
- [11] Q. Yang, Xi. Li, Yi. Wang, and A. Ainapure, "Fault diagnosis of ball screw in industrial robots using non-stationary motor current signals," *Procedia Manufacturing*, Vol.48, pp.1102-1108, 2020.
- [12] Y. Kim, J. Park, K. Na, H. Yuan, B. D. Youn, and C. S. Kang, "Phase-based time domain averaging (PTDA) for fault detection of a gearbox in an industrial robot using vibration signals," *Mechanical Systems and Signal Processing*, Vol.138, pp.106544, 2020.
- [13] C. C. Lo, C. H. Lee, and W. C. Huang, "Prognosis of bearing and gear wears using convolutional neural network with hybrid loss function," *Sensors*, Vol.20, No.12, pp.3539, 2020.
- [14] J. Long, J. Mou, L. Zhang, S. Zhang, and C. Li, "Attitude data-based deep hybrid learning architecture for intelligent fault diagnosis of multi-joint industrial robots," *Journal of Manufacturing Systems*, Vol.61, pp.736-745, 2020.
- [15] L. F. Villa, A. Reñones, and J. R. Perán, "Statistical fault diagnosis based on vibration analysis for gear test-bench under non-stationary conditions of speed and load," *Mechanical Systems and Signal Processing*, Vol.29 pp.436-446, 2012.
- [16] Z. Gao, C. Cecati, and S. X. Ding, "A survey of fault diagnosis and fault-tolerant techniques—Part I: Fault diagnosis with model-based and signal-based approaches," *IEEE Transactions on Industrial Electronics*, Vol.62, No.6, pp.3757-3767, 2015.
- [17] L. Console and O. Dressler, "Model-based diagnosis in the real world: Lessons learned and challenges remaining," *IJCAI*, Vol.99, 1999.
- [18] A. Soualhi, M. Lamraoui, B. Elyousfi, and H. Razik, "PHM SURVEY: Implementation of diagnostic methods for monitoring industrial systems," *International Journal of Prognostics and Health Management*, Vol.10, No.2, pp.6909-6932, 2019.
- [19] D. U. Campos-Delgado and D. R. Espinoza-Trejo, "An observer-based diagnosis scheme for single and simultaneous open-switch faults in induction motor drives," *IEEE Transactions on Industrial Electronics*, Vol.58, No.2, pp.671-679, 2010.
- [20] Z. W. Huang, Y. Z. Yang, J. Wang, and Y. Li, "Parity space-based fault diagnosis of CCBII braking system," *Journal of Central South University*, Vol.20, No.10, pp.2922-2928, 2013.
- [21] A. T. James, O. P. Gandhi, and S. G. Deshmukh, "Fault diagnosis of automobile systems using fault tree based on digraph modeling," *International Journal of System Assurance Engineering and Management*, Vol.9, No.2, pp.494-508, 2018.
- [22] A. A. Jaber and R. Bicker, "Industrial robot backlash fault diagnosis based on discrete wavelet transform and artificial neural network," *American Journal of Mechanical Engineering*, Vol.4, No.1, pp.21-31, 2016.
- [23] J. Pan, L. Qu, and K. Peng, "Sensor and actuator fault diagnosis for robot joint based on deep CNN," *Entropy*, Vol.23, No.6, pp.751, 2021.
- [24] P. Zou, B. Hou, J. Lei, and Z. Zhang, "Bearing fault diagnosis method based on EEMD and LSTM," *International Journal of Computers Communications & Control*, Vol.15, No.1, 2020.
- [25] I. Mitiche, T. McGrail, P. Boreham, A. Nesbitt, and G. Morison, "Data-driven anomaly detection in high-voltage transformer bushings with lstm auto-encoder," *Sensors*, Vol.21, No.21, pp.7426, 2021.
- [26] S. Hochreiter and J. Schmidhuber, "Long short-term memory," *Neural Computation*, Vol.9, No.8, pp.1735-1780, 1997.
- [27] "Niryo One - An accessible educational 6 axis robotic arm, just for you - Niryo," Niryo, 2020. [Internet], <https://niryo.com/niryo-one/>. [Accessed: 15 Oct 2019].



백 지 훈

<https://orcid.org/0009-0006-9200-2346>

e-mail : jihoon.baek@lignex1.com

2021년 아주대학교 전자공학과(학사)

2023년 아주대학교 AI융합네트워크학과  
전자공학전공(석사)

2023년 ~ 현 재 LIG넥스원 드론개발단  
연구원

관심분야 : Collaborative Robot, Predictive Maintenance



유 동 연

<https://orcid.org/0000-0002-5780-0661>

e-mail : dongs0125@ajou.ac.kr

2019년 아주대학교 전자공학과(학사)

2021년 아주대학교 전자공학과(석사)

2021년 ~ 현 재 아주대학교

AI융합네트워크학과

전자공학전공 박사과정

관심분야 : Data Analysis, Machine Learning, Deep Learning,  
Collaborative Robot, Predictive Maintenance



이 정 원

<https://orcid.org/0000-0001-8922-063X>

e-mail : jungwony@ajou.ac.kr

1993년 이화여자대학교 전자계산학과(학사)

1995년 이화여자대학교 전자계산학과(석사)

1995년 ~ 1997년 LG종합기술원 주임연구원

2003년 이화여자대학교 컴퓨터학과(박사)

2003년 ~ 2006년 이화여자대학교 컴퓨터학과 BK교수, 전임강사  
(대우)

2006년 ~ 현 재 아주대학교 전자공학과/AI융합네트워크학과 교수

관심분야 : Context Awareness, Big Data Analysis, Predictive  
Maintenance, Collaborative Robots, Intelligent  
Embedded Software