

Real-time Fault Detection System of a Pneumatic Cylinder Via Deep-learning Model Considering Time-variant Characteristic of Sensor Data

Byeong Su Kim · Geun Myeong Song · Min Jeong Lee · Sujeong Baek[†]

Department of Industrial & Management Engineering, Hanbat National University

센서 데이터의 시계열 특성을 고려한 딥러닝 모델 기반의 공압 실린더 고장 감지 시스템 구현

김병수 · 송근명 · 이민정 · 백수정[†]

국립한밭대학교 산업경영공학과

In recent automated manufacturing systems, compressed air-based pneumatic cylinders have been widely used for basic perpetration including picking up and moving a target object. They are relatively categorized as small machines, but many linear or rotary cylinders play an important role in discrete manufacturing systems. Therefore, sudden operation stop or interruption due to a fault occurrence in pneumatic cylinders leads to a decrease in repair costs and production and even threatens the safety of workers. In this regard, this study proposed a fault detection technique by developing a time-variant deep learning model from multivariate sensor data analysis for estimating a current health state as four levels. In addition, it aims to establish a real-time fault detection system that allows workers to immediately identify and manage the cylinder's status in either an actual shop floor or a remote management situation. To validate and verify the performance of the proposed system, we collected multivariate sensor signals from a rotary cylinder and it was successful in detecting the health state of the pneumatic cylinder with four severity levels. Furthermore, the optimal sensor location and signal type were analyzed through statistical inferences.

Keywords : Pneumatic Cylinders, Fault Detection, Deep Learning, Multivariate Sensor Data

1. 서론

현대 제조 산업 분야에서 높은 생산성과 고품질이 요구됨에 따라 이산 생산 시스템의 자동화가 보편적으로 이루어지고 있다[3, 9, 20]. 이산 생산 시스템은 Programmable Logic Controller(PLC)를 이용하여 사전에 동작 및 작업을 정의한 후 현재의 센서 값 변화에 맞춰 공압 실린더, 리니

어 모터, 파워 스크루 등의 기계 장치가 움직이는 형태로 자동화를 구현한다[4, 21, 23]. 다양한 기계 장치 중 공압 실린더는 압축된 공기에 의해 작동하며, 실린더의 끝에 설치되는 엔드 이펙터(End effector)에 따라 다양한 형태, 강도의 제품을 손쉽게 다룰 수 있기에 여러 자동화 생산 시스템의 기본 기계 장치로 많이 활용된다. 예를 들어 Lee et al.[15]은 농장에서 생산되는 식품의 품질을 향상하고자 온실의 층고를 자동으로 조절하고자 하였다. 온실 내 사용되는 에너지 등을 고려하여 일반적으로 국내에서는 3m 정도의 층고를 유지하나, 작물이 성장함에 따라 층고를 높여 작물이 수평으로 자랄 수 있도록 하여야 한다. 이를 위해

Received 23 May 2024; Finally Revised 16 June 2024;
Accepted 17 June 2024

[†] Corresponding Author : sbaek@hanbat.ac.kr

온실 천장의 무게를 버티면서도 자동으로 조절하기 위하여 공압식 격막 실린더를 사용하는 유리 온실 및 플라스틱 온실을 위한 자동 기동 상승 장치를 제안하였다. Jeong et al.[5]은 6개의 선형 액추에이터에 적용되는 12개의 유니버설 조인트(Universal joint)를 이용하여 상단의 평판 각도를 조정하는 스투어트 시스템(Stewart system)의 정밀 제어를 위하여 공압 실린더를 적용하였다. 그 결과 기존의 유압 및 전기 모터 기반의 액추에이터와 비교하였을 때 저 부하의 중량물을 적은 오차 범위 내에서 고속으로 움직일 수 있었다. Jimenez et al.[6]의 경우 Automated Guided Vehicle(AGV) 및 Autonomous Mobile Robot(AMR)에서 공압식 복동 실린더의 사용이 적합한지 실험을 통해 검증하였다. 먼저 복동 실린더가 지면으로부터 일정 각도 이상 기울어져 있을 때 전진, 후진 동작을 위해 필요한 공기의 압력을 수학 모델로 정의하였다. 이후 실린더의 놓여있는 자세(수평, 수직) 및 움직이는 물체(피스톤 로드, 실린더 몸체), 가해지는 압력에 따라 움직이는 데 걸리는 시간 및 힘을 측정하여 분석하였다. 그 결과 AGV, AMR 등에서 복동 실린더를 사용 시 중력의 영향은 미미하므로 놓이는 실린더의 자세는 주어진 작업을 수행하는 데 중요하지 않음을 발견하였다.

위의 연구들과 같이 공압 실린더는 상대적으로 작은 기계 장치로 간주하며 대부분의 공압 실린더 고장은 나사 풀림 같은 작은 증상에서부터 시작되기에 실린더의 유지 보수는 주기적인 점검에 따른 예방정비로 많이 이루어졌다. 그러나 전체 자동화 생산 시스템에서 많이 사용되는 기계 장치임에 따라, 공압 실린더가 고장을 일으켜 전체 생산 시스템의 작동이 갑작스레 중단되는 경우 수리 비용, 생산량 변동 등 경제적 손실과 더불어 작업 환경에서의 안전이 위협받을 수 있다. 예를 들어, 실린더를 구성하는 부품 중 하나인 나사가 느슨하게 체결되어 있거나, 완전히 풀림이 발생할 경우, 초기 작동에서는 큰 문제가 되지 않을 수 있다. 그러나 작은 고장 원인이 계속 누적될 경우 결과적으로는 전체 생산 시스템의 안정성과 안전성을 해칠 수 있는 중대한 원인으로 발전하게 된다. 이러한 문제를 해결하기 위하여 다양한 선행 연구들이 수행되었다. 예를 들어 Kim et al.[10]은 주조 공정에서 사용되는 금형 틀을 여닫기 위해 사용되는 실린더의 이상을 감지하고자 하였다. 금형 틀을 여닫는 작업은 순서가 정해져 있으므로, 주조 공정 제어용 PLC로부터 실린더의 이동 시작 및 종료 시점을 확인한 후 해당 시간의 금형 온도, 냉각 온도를 이용하여 미래의 센서 값을 예측할 수 있는 딥러닝 모델을 Long-Short Term Memory(LSTM)를 이용해 구축하였다. Yoo et al.[24]의 연구에서도 주조 과정에서 생산되는 제품의 품질을 높게 유지하기 위해서는 실린더의 온도 데이터를 관리하는 것이 중요하다고 판단하였다. 이를 위해 주조

에 사용되는 전면의 온도를 수집한 후 1-dimensional Convolution neural network를 이용하여 현재 상태가 정상인지 고장인지 감지하였다. 그 결과 약 99.5%의 F1 Score를 보여 실제 현장에서 실린더 온도 값을 통해 주조 사이클의 정상 및 이상을 판단할 수 있음을 알 수 있었다. 또한 Kang et al.[8]의 연구에서는 자동차 엔진에 들어가는 실린더의 이상 상태를 감지하고자 하였다. 특히 자동차 엔진에서는 실린더 헤드 볼트가 주 기능인 체결 기능 이외에도 개스킷의 밀폐 기능 유지에 중요한 역할을 함에 따라 실린더 헤드 볼트의 수명을 예측하였다. 이를 위해 실린더 내부에 반복적으로 압력을 가할 수 있는 테스트베드를 구축한 후 헤드 볼트의 수명을 다양한 시험 압력 조건에서 따라 가속수명시험을 통해 측정하였다. 측정된 데이터를 역송 모형에 적용하여 실린더 헤드 볼트의 특성 수명을 계산하였다.

위와 같이 실린더를 포함한 대다수의 기계 이상 감지 연구는 수행하는 특정 작업에 대한 배경지식 또는 전문가의 경험을 응용하여 수행된다[7]. 예를 들어, K 대학교의 스마트팩토리 패키징 공정의 예지보전을 위해서도 전진 및 후진 작업을 수행하는 실린더의 경우 해당 정보를 사용하여 왕복 운전 시의 힘의 크기, 속도, 위치값을 측정하여 고장 감지를 하였다[14]. 그러나 실린더의 작업 조건 등과 같은 정보가 고장 감지 모델에 사용되는 경우, 실린더의 응용 방식이 달라질 때마다 추가적인 보정이 필요하므로 일반적인 실린더 시스템의 이상을 포괄적으로 감지하기 위해 사용하기에는 어려움이 있다. 그러므로 본 연구에서는 공압 실린더의 Extension 및 Retraction과 같은 기본 동작을 수행할 때와 정지하여 있을 때를 구분하지 않고 센서 데이터를 수집한 후 현재 어떤 동작을 수행하는지에 대해서 고장 모델에 정보를 제공하지 않음에 따라 범용적인 고장 감지에 사용할 수 있게 하고자 한다. 다시 말해 실린더가 특정 작업을 위해 움직이고 있는 상태와 더불어 움직임이 완료된 후 일정 시간 정지해 있는 상태에서도 설비의 건전성에만 초점을 맞춰 고장 감지를 가능하게 한다는 점에서 기존 연구들과의 차별성을 가진다. 또한 실린더의 현재 상태를 정상과 고장으로 구분하는 것에서 더 나아가 열화 정도에 주목하여 최종 고장 감지 결과를 고장 상태를 4단계로 분류하였다.

제안된 고장 감지 모델을 더욱 효율적으로 사용하기 위해서는 부착되는 아날로그 센서의 수가 적을수록 좋다. 이러한 관점에서 각 센서의 부착 위치와 센서 유형이 고장 감지에 미치는 영향을 통계적으로 분석하였다. 추가적으로 해당 고장 감지 모델을 통해 작업자가 공압 실린더의 현재 운영 상태를 제조 현장 및 원격 상황과 관계없이 즉시 인지할 수 있도록 아두이노 기반의 알림 시스템과 Graphic User Interface(GUI) 시스템을 설계 및 제작하여


효용성을 검증하였다.

본 논문의 구성은 다음과 같다. 제2장에서는 공압 실린더의 고장 감지를 위하여 정의한 정상 및 고장 상태와 데이터 수집 방법에 대해 설명하였다. 제3장에서는 수집된 센서 데이터를 기반으로 고장 감지를 위한 딥러닝 모델을 구축하는 과정을 서술하고 제안하는 모델의 성능을 제시하였다. 제4장에서는 제안한 고장 감지 모델을 이용한 실시간 고장 감지 시스템의 구현 방법을 설명하였으며, 마지막으로 제5장은 본 연구의 요약과 향후 연구 방향으로 구성되어 있다.

2. 공압 실린더의 정상 및 고장 상태 정의 및 센서 데이터 수집

2.1 연구 대상: 자동화 생산 시스템의 공압 실린더

본 연구에서는 H 대학교의 스마트팩토리 테스트베드에 설치된 공압형 복동 실린더를 활용하였다. H 대학교의 스마트팩토리 테스트베드는 USB를 상자에 포장하는 공정으로 실제 산업 환경에서의 자동화 및 생산 최적화 전략을 연구하기 위해 설계되었다. 팔레트 배급부터 제품 삽입, 레이저 마킹, 비전 검사, 제품 조립, 창고 저장까지 총 7개의 공정으로 구성되어 있으며, 전체 자동화 생산 시스템에서 대상 제품 또는 부품을 잡고, 위치를 옮기기 위한 공압 실린더는 총 31개가 존재한다. 모든 실린더는 Extension 및 Retraction을 통해 좌우 또는 상하 운동을 하거나, 시계 방향 또는 반시계 방향으로의 회전 운동을 하는 형태이다. 또한 공압 실린더의 끝에 부착된 엔드 이펙터의 형상에




<Figure 1> Used Pneumatic Cylinder and the Three Attached Multivariate Sensors (1, 2 and 3)

따라 대상 제품을 진행 방향 또는 반대 방향으로 밀거나 제품을 파지하거나, 부착된 센서의 위치를 이동시키는 역할을 수행하고 있다.

본 연구에서는 4번째 순서인 비전 검사 공정에서 회전 동작을 통해 대상 제품을 생산 작업대로 옮기는 공압 실린더를 대상으로 하였다. 해당 실린더는 본 테스트베드에서 사용되는 다른 실린더들과 동일한 스펙을 가지고 있으며 다양한 제조 공정에 폭넓게 적용할 수 있는 기본 작업을 위한 범용 장치로서의 역할을 하고 있다. 이 실린더는 압축된 공기의 압력을 통해 회전 동작을 수행하며 공압 회전 실린더의 형상은 <Figure 1>과 같다.

2.2 공압 실린더의 정상 및 고장 상태 정의

공압 실린더의 고장 감지를 위하여 실린더의 정상 및 고장 상태에 대해 명확하게 사전에 정의하고자 하였다. 실린더의 정상 상태는 제조사가 제공한 매뉴얼에 따라 설치한 후 유지보수 절차에서 문제점을 발견하지 못한 경우로 정의하였다. 데이터 수집을 위하여 공압 실린더의 고장 상태의 경우 임의로 발생시켜야 하였다. 여러 가지 고장 원인과 모드를 조사한 후 그 중 계속 반복 실험을 할 수 있고 보편적으로 발생하는 체결 나사의 풀림을 본 연구의 고장 상태로 결정하였다. 또한 얼마나 많은 체결 나사가 풀리느냐에 따라 고장의 심각도가 달라지므로 <Figure 2>에 표시된 바와 같이, 실린더 A와 B 두 위치에 설치된 나사의 제거 개수에 따라 고장 상태의 심각도(고장 정도)를 구분하였다.



<Figure 2> Two Different Locations (A and B) of Used Screws for Manipulating Fault States

기계 시스템의 건강(건전) 상태는 일반적으로 초기에는 정상 상태에서 시작하여 사용함에 따라 열화가 점진적으로 진행되며, 최종적으로 시스템의 사용이 불가해지 고장 상태에 도달하게 된다[19, 25]. 이를 기반으로, 구체적으로 정의하자면, 본 연구에서의 정상 상태는 공압 실린더의 모든 체결 나사가 완전히 고정된 상태로 유지된 상태를 의미한다. 고장 단계1은 낮은 심각도를 보이는 것으로 <Figure


2>의 A 위치의 체결 나사 두 개가 풀려서 제거된 상태를 의미하며, 고장 단계2는 A 위치의 나사가 한 개 더 제거되어 조금 더 체결의 정도가 낮아짐을 의미한다(총 세 개의 나사 풀림). 마지막으로 고장 단계3은 B 위치의 나사가 약간 풀린 상태와 A 위치의 나사가 세 개가 완전히 제거된 상태로 정의하였다. 고장 상태를 정의함에 있어 하나의 나사를 더 제거한 것은 공압 실린더를 구성하는 전체 나사 중 체결이 풀린 나사의 총 길이가 더 길어지는 효과로 간주되므로 조작한 세 가지 고장 상태의 열화 정도는 풀린 나사의 개수와 비례한다. 이에 따라, 더 많은 나사가 풀린 경우를 더 심각한 고장 상태로 정의하였고, 이 후 고장 단계 1, 2 및 3을 ‘증상 1’, ‘증상 2’, ‘고장’이라 명명하였다. 또한 B 위치의 나사 풀림의 경우, A 위치의 나사 풀림보다 실린더의 안정성과 작동 정확성에 더 미쳐 외관으로 확인하였을 때 정상 상태 대비 작업 동작과 관계없는 흔들림이 더 명확히 관찰되었다.

2.3 다변량 아날로그 센서 데이터 수집

공압 실린더의 작업 특성 등에 무관하게 고장 감지를 하기 위하여 본 연구에서는 다양한 아날로그 센서를 사용하고자 하였다. 이를 위하여 모션 센서를 이용하여 다변량 센서 데이터를 수집하였다. 사용된 모션 센서는 3축 자기장 신호, 3축 가속도 신호 및 3축 각속도 신호 및 온도 신호를 측정할 수 있는 센서이다. 실린더의 움직임과 위치 변화에 따라 이러한 아날로그 센서값들이 변화할 것이라 가정하였으며, <Figure 1>에서 묘사되는 바와 같이 실린더의 세 가지 위치에 부착하여 실시간으로 시계열 데이터를 수집하고자 하였다. 다만 온도 값의 경우 실제 실린더를 사용함에 따라 변화하는 것보다 외부 환경인 계절적 요인에 더 큰 영향을 받았음에 따라 분석에 사용하지 않았다.

데이터 수집은 다음과 같은 규칙에 따라 진행되었다. 각각의 센서로부터 동시에 신호 데이터를 수집하기 위하여 하나의 데이터 수집 모듈(Data acquisition system)을 사용하여 약 1초마다 새로운 측정치를 수집하였다 (Sampling frequency = 1Hz). 또한 실린더의 동작 주기에 따라 데이터 세트를 형성한 것이 아니라, 약 1분 동안 연속적으로 센서 신호를 수집하여 하나의 데이터 세트를 구축하였다. 1분의 시간 동안 작업자는 수동 제어 명령을 통해 실린더를 시계 방향 또는 반시계 방향으로 회전시키는 작업을 계속하여 진행하였다. 이는 실린더의 건강 상태와 관계없이 움직임을 정지, 가속, 감속 등으로 다양하게 하여 어떠한 작업을 하더라도 고장 감지를 가능하게 하기 위하여 고안된 방법이다. 예를 들어 <Figure 3>을 살펴보면, 약 12초 동안 2번의 공압 실린더의 Extension 및 Retraction이 발

생하였으며 움직임을 유지하는 상태가 작업자의 수동 제어에 달려있기에 매번 다소 달라진다. 이러한 특징이 추후 서술될 Sliding window 등의 기법에 의해 다양한 형태로 고장 감지 모델에 입력될 것이므로 최종적으로 개발될 고장 감지 모델이 특정 실린더 작업에 초점을 맞추지 않을 수 있을 것으로 기대한다. 최종적으로 각 상태 별로(정상, 증상 1, 증상 2 및 고장) 60개의 데이터 세트를 성공적으로 수집하였다. <Table 1>은 위의 과정을 통해 수집된 데이터 세트의 예시이다.



<Figure 3> Cylinder Displacement Graph During Sensor Data Collection

<Table 1> Example of the Collected Datasets with a Total of 28 Sensor Signals

Time	14:43:58	14:43:59	...	14:44:57
Acc_x0	1.00	1.00	...	1.00
Acc_y0	-0.02	-0.02	...	-0.03
Acc_z0	-0.00	-0.02	...	-0.01
Mag_x0	-4.57	-13.82	...	-5.14
Mag_y0	-49.43	10.40	...	-51.27
Mag_z0	-60.81	0.74	...	0.12
Roll0	-98.42	-87.83	...	-114.87
Pitch0	-88.59	-88.06	...	-88.28
Yaw0	179.25	-101.24	...	-105.67
...				
Roll2	-179.55	-179.53	...	-179.34
Pitch2	0.22	0.19	...	-0.00
Yaw2	179.69	179.70	...	-90.22


* Acc_x, y, z: Acceleration signals in x, y, z direction
 * Mag_x, y, z: Magnetic field signals in x, y, z direction
 * Roll, Pitch, Yaw: Angular velocity in roll, pitch, yaw direction
 * The number written behind the sensor signal type(0, 1, 2): The location index of the attached sensors

3. 공압 실린더의 고장 감지를 위한 센서 데이터 분석

3.1 센서 데이터 전처리

수집된 데이터는 시계열 데이터 형태로, 절대 시간이 포함된 28개의 변수로 구성되어 있다. 데이터 전처리 과정에서, 모든 데이터 세트의 첫 번째 행에서 결측치가 발견되었다. 이는 데이터 수집 모듈의 작동 초기화와 실제 센서의 데이터 수집 시작 시 수동으로 기기를 켜는 과정 사이의 작동 차이로 인해 발생한 것으로 파악되었다. 또한 절대 시간에 따라 해당 시간에 실린더의 움직임 상태가 달랐을 수 있으나, 본 연구에서는 해당 부분에 특정하여 분석을 수행하지 않기 위하여 데이터의 첫 행에 존재하는 결측치를 포함한 모든 행을 제거하는 조치를 하였다.

또한 본 연구에서 시계열 데이터를 효과적으로 분석하기 위해 슬라이딩 윈도우 기법을 도입하였다. 예를 들어 수집한 원본 센서 데이터 전체를 X 라고 하면, 현재 <Figure 4>의 경우 약 7초 동안 수집한 데이터가 된다. 이때 슬라이딩 윈도우 크기(l)가 3초라면, 초기 1초에서 3초까지 수집된 데이터를 첫 번째 입력 데이터 군집으로 사용한다. 이후, 슬라이딩 윈도우는 사전에 정의된 스텝(Step) 크기에 따라 최신 데이터 방향으로 이동하게 된다. 만약 스텝의 크기가 1초라면, 두 번째 입력 데이터 군집은 2초에서 4초까지의 센서 데이터가 되는 것이다. 이러한 방식은 각 데이터 포인트가 여러 데이터 군집에 걸쳐 사용될 수 있게 하므로, 데이터의 최대 활용과 함께 더 넓은 시간 범위의 패턴을 파악할 수 있는 장점을 제공한다[11].



<Figure 4> Example of the Sliding Window Technique

또한 슬라이딩 윈도우 기법은 연속적인 데이터의 시간적 연속성을 유지하면서 동시에 데이터 세트를 효율적으로 처리할 수 있도록 한다[2, 17]. 슬라이딩 윈도우를 사용하지 않고 단일 하나의 시점(타임 스템프)에 대한 데이터만을 사용할 경우, 해당 데이터 수집된 시점에 공압 실린더가 멈추었거나, 시계 방향으로 회전하거나, 반시계 방향으로 회전하거나 등의 작업에 종속적인 결과를 도출할 확

률이 높다. 그러나 슬라이딩 윈도우를 사용할 경우, 근접한 과거 데이터부터 현재까지의 데이터를 동시에 고려하는 것이므로 해당 슬라이딩 윈도우 내에 다양한 실린더의 작업 상황이 포함될 수 있어 실제 수행하고 있는 작업에 영향을 받지 않고 설비의 건전성(정상 또는 고장 상태) 판단만 하기에 유용하다.

본 연구에서 수집하여 분석에 사용된 데이터는 한 세트당 약 1분 단위로 수집되었으며, 각 데이터 세트는 대략 60에서 65개의 데이터 포인트로 구성되어 있다. 실험을 통해 관찰된 바에 따르면, 공압 실린더가 한 번 작동하여 다시 원위치로 복귀하기까지 평균적으로 약 7초가 소요되었다. 이러한 시간은 실린더의 회전 동작을 충분히 포착할 수 있는 중요한 기준점으로 작용한다. 따라서 이 정보를 바탕으로 슬라이딩 윈도우 크기를 7초로 설정함으로써, 각 윈도우가 실린더의 전체 작동 주기를 포괄할 수 있도록 하였다. 이는 실시간 이상 감지의 효율성을 극대화하면서 동시에 필요한 정보를 충분히 수집할 수 있는 최적의 균형을 찾는 데 중점을 두었다. 그러나 본 연구에서는 실제 공압 실린더의 작동 현황과 관련 없이 고장 감지를 하는 것이 목적이므로 모든 입력 데이터 군집이 실린더의 작동 처음과 끝을 포함하지 않도록 슬라이딩 윈도우의 스텝의 크기는 윈도우 크기와 다르되, 실시간 고장 감지가 가능하도록 1초로 설정하였다. 이에 따라 학습에 사용될 데이터의 개수는 결정된 슬라이딩 윈도우의 개수에 따라 다음과 같은 수식으로 계산될 수 있다. 본 연구에서는 슬라이딩 윈도우의 크기가 7초이며, 각각의 데이터 세트의 크기는 평균적으로 약 60초였다. 이에 따라 딥러닝 모델 학습 및 테스트를 위해 사용된 입력 슬라이딩 윈도우의 개수는 12,803개이다.

$$sw = \sum_{i=1}^m [n_i - l + 1] \tag{1}$$

sw 는 수집한 데이터에서 슬라이딩 윈도우 기법을 통해 얻은 입력 데이터 군집의 수이며, i 는 수집한 데이터 세트의 번호를 의미한다. m 은 수집된 데이터 세트의 총 개수이다. n_i 는 i 번째 수집된 데이터 세트의 전체 길이(크기)를 의미하며, l 은 입력 데이터 군집 추출을 위한 슬라이딩 윈도우 크기이다. 위 수식에서의 스텝의 크기는 1이다.

추가로 수집된 센서 데이터들의 특성을 표준화하는 작업을 진행하였다. 이 과정은 각 센서 데이터의 평균을 0, 표준편차를 1로 조정하는 것이다[1]. 이러한 표준화는 수집된 데이터 간의 값의 범위가 다르더라도 동일한 규격 내로 변환함에 따라 데이터 간의 비교를 용이하게 하며, 센서 간의 차이를 보정 하는 효과가 있다. 또한, 수집된 시계열 데이터에 포함된 절대 시간 정보의 경우 상대 시간

으로 변환하여 분석에 사용하였다. 고장 감지에 있어 실제 수집된 절대적 시간 정보보다는 데이터 포인트의 선후 관계 또는 상대적 시간 간격이 더 중요한 변수로 작용할 것으로 판단하였기 때문이다. 이에 따라 실제 공압 실린더가 작동할 때의 일시 및 시간과 같은 정보가 아니라 기기가 켜지고 나서 얼마나 작동하였는가와 같은 정보로 변환하기 위하여 각각의 데이터 수집이 시작될 때를 시간 0으로 설정하고, 시간이 1초 증가할 때마다 시간을 +1씩 증가시키는 방식을 채택하였다.

3.2 고장 감지 및 분류를 위한 LSTM 기반 딥러닝 모델 구축

본 연구에서는 딥러닝 기반 모델로서 LSTM 구조를 기본으로 채택하여 구축하였다. LSTM은 시계열 데이터와 같이 데이터 내에 포함된 선후 관계 정보 및 시퀀스를 효과적으로 다루는 방법이다. 특히 기존의 Recurrent neural network가 가지는 장기의존성 문제를 해결하기 위하여 입력 게이트, 망각 게이트, 출력 게이트 개념을 도입하여 장기간에 걸쳐 제공되는 데이터의 중요한 특성을 학습할 수 있다[22, 26]. 본 연구에서 다루는 다변량 센서 데이터는 시간에 따른 센서의 다양한 측정값을 포함하고 있으므로 시계열 데이터로 볼 수 있다. 이러한 특성을 고려할 때, LSTM 구조가 공압 실린더의 작동에 있어 고장 감지를 하는 데 이상적인 기본 모델 구조라 판단하였다. 그러므로 LSTM 레이어를 기본으로 하여 고장 감지를 위한 효율적인 딥러닝 모델을 구축하기 위하여 Greedy search를 기반으로 최적화를 진행하였으며, 최종 고장 감지 모델은 <Table 2>와 같다. 입력 계층은 슬라이딩 윈도우와 수집된 센서 데이터의 수에 따라 7×28의 행렬 형태이며, 출력 계층은 네 가지 건강 상태 중 한 가지를 결정할 수 있게 One-hot encoding 형태의 1×4 벡터 형태이다.

Greedy search는 각 단계에서 최적이라고 생각되는 것을 차례대로 선택하여 최종적인 해답에 도달하는 근사적인 알고리즘이다. 이는 전역 최적해를 항상 보장하지는 않지만 단순하고 빠르다는 장점이 있어 많은 연구에서 사용되고 있다. Kim et al.[13]은 순회 외판원 문제에서의 파라미터 최적화를 위한 방법을 비교 분석하였다. 그 결과 Greedy search 기반의 방법이 기존의 다른 무작위 기반의 최적화 및 지역 탐색 기법들보다 우수한 성능을 나타냄을 증명하였다. 또한, Kim et al.[12]의 경우에도, 블록 대각화 프리코딩 기법의 성능을 향상시키기 위하여 Greedy search를 활용하였다. 송신 및 수신 안테나 개수, 사용자의 수, 안테나 각도, 안테나 간의 거리에 대해 Greedy search를 적용하여 전체 시스템 용량을 향상시킬 수 있었다. 본 연구

에서는 이러한 Greedy search 기반의 접근 방식을 참고하여 제안한 고장 감지 모델의 하이퍼파라미터 최적화를 진행하였다. 이 과정에서 하이퍼파라미터 최적화 과정에서 상대적으로 크지 않은 은닉층의 수 및 노드 개수로도 높은 정확도를 얻을 수 있었기에 추가적인 탐색은 진행하지 않았다.

<Table 2> The Specification of the Developed Fault Detection Model for a Pneumatic Cylinder Via Multivariate Sensor Data

Input Layer	LSTM(7, 28)
Hidden Layer 1	LSTM(300, 7)
Hidden Layer 2	LSTM(150)
Output Layer	LSTM(4)
Hidden Layer Activation	Hyperbolic tangent (tanh)
Output Layer Activation	softmax
Optimizer	Adaptive moment estimation (Adam)
Loss	Categorical cross entropy

* LSTM(a, b): LSTM layer with a unit as a 2-dimensional array whose number of rows and columns are 'a' and 'b'.
 * LSTM(a): LSTM layer with units whose the number is 'a'.

본 연구에서 구축한 딥러닝 모델의 고장 감지 성능을 확인하기 위하여 수집한 전체 데이터 세트를 학습 데이터, 검증 데이터, 평가 데이터로 나누어 분석을 수행하였다. 구체적으로 전체 데이터 세트의 20%는 평가 데이터로 사용하였으며, 나머지는 학습 단계에서 사용하였다. 모델 학습 단계에서의 성능 향상을 위하여 학습 단계의 데이터의 80%는 순수 학습 데이터로, 나머지 20%는 검증 데이터로 할당하여 모델의 일반화 능력과 최종 성능을 평가하였다. 이에 따라 전체 12,803개의 데이터 중 순수 학습 데이터는 8,193개(전체 데이터 대비 약 64%), 검증 데이터는 2,049개(전체 데이터 대비 약 16%), 평가 데이터는 2,561개(전체 데이터 대비 약 20%)로 분할되었다. 또한 수집한 데이터를 학습, 검증, 평가 데이터로 구분함에 있어 전체 데이터 중 상대적으로 과거의 데이터만이 학습에 사용되고 상대적으로 최신의 데이터만이 평가에 사용되는 현상을 방지하고자 하였다. 이를 위해 일반적으로 딥러닝 모델에서 적용하는 방법과 동일하게 임의적으로 데이터를 섞은 후 비율에 맞춰 나누었다[16, 18]. 다시 말해 각 데이터를 구성하는데 있어 전체 데이터 세트에서 중복 추출하지 않았으므로, 평가에 사용된 데이터는 고장 감지 모델이 학습 데이터가 아닌 새로운 데이터임을 보장한다. 이러한 데이터 분할 방식은 모델이 학습 과정에서 과적합을 방지하고, 실제 운영 환경에서의 성능을 신뢰성 있게 평가할 수 있도록 한다. 그 결과, <Table 3> 및 <Table 4>와 같이 학습

<Table 3> Confusion Matrix of the Fault Detection in a Training Phase

		Actual health state			
		Normal	Symptom 1	Symptom 2	Fault
Predictive health state	Normal	1938	10	0	0
	Symptom 1	27	2000	2	0
	Symptom 2	7	10	2057	3
	Fault	8	28	1	2102

<Table 4> Confusion Matrix of the Fault Detection in a Test Phase

		Actual health state			
		Normal	Symptom 1	Symptom 2	Fault
Predictive health state	Normal	634	5	0	0
	Symptom 1	12	631	0	0
	Symptom 2	3	4	638	0
	Fault	2	5	0	627

및 평가 단계에서 모두 높은 고장 감지 정확도를 보였다 (학습 정확도: 98.83%, 평가 정확도: 98.79%). 이러한 결과는 본 연구에서 개발된 모델이 실제 애플리케이션에 효과적으로 적용될 수 있음을 보여주며, 장기적인 운영에서도 안정적인 성능을 제공할 것으로 기대할 수 있다.

공압 실린더의 건강 상태를 이산적으로 분류하는 것에서 높은 성능을 확인하였으므로 본 연구에서는 추가로 동일한 설비의 상태를 연속적인 수치의 형태로 예측할 수 있다면 설비의 잔존 수명과 연계하여 유지보수에서 더 효과적으로 활용할 수 있을 것으로 기대하였다. 다시 말해 구축한 회귀 모델이 0을 출력한다면 현재 공압 실린더의 상태는 정상 상태로 볼 수 있으며 0보다 큰 값을 출력할수록 공압 실린더에 고장이 발생하고 있을 확률이 높다고 해석하는 것이다. 수집된 데이터가 총 고장의 심각도에 따라 총 4단계로 구분할 수 있음에 따라 증상1은 1, 증상 2는 2, 고장은 3의 숫자를 넣어 총 0에서부터 3까지의 연속된 숫자를 출력하도록 모델을 설계하였다. 또한 기존 분류 모델 구축 시 사용한 동일한 데이터와 모델의 구조를 활용하되 최종 출력 계층의 형태만 회귀 모델의 형태로 변경하고자 하였으며 최종적으로 <Table 5>와 같이 구축되었다. 다만 Optimizer 및 Loss의 경우 분류 모델과 달라져야 함에 따라 Root mean square propagation과 Mean square error로 변경하였다. 그 결과 모델의 결정계수(R^2) 값이 98.8%로 높은 고장 감지 정확도를 보였다. 이는 모델이 수집된 데이터를 바탕으로 공압 실린더의 건강 상태를 연속적인 수치로도 매우 정확히 예측함을 의미한다.

<Table 5> Specification of the Developed Regression Model for a Pneumatic Cylinder's Fault Detection Via Multivariate Sensor Data

Input Layer	LSTM(7, 28)
Hidden Layer 1	LSTM(300, 7)
Hidden Layer 2	LSTM(150)
Output Layer	LSTM(1)
Hidden Layer Activation	Hyperbolic tangent (tanh)
Optimizer	Root mean square propagation (RMSProp)
Loss	Mean square error

* LSTM(a, b): LSTM layer with a unit as a 2-dimensional array whose number of rows and columns are 'a' and 'b'.

* LSTM(a): LSTM layer with units whose the number is 'a'.

3.3 고장 감지 성능 향상을 위한 차원 축소

높은 고장 감지 성능을 보이더라도 수많은 아날로그 센서가 설치되고 방대한 양의 데이터가 항상 수집되어야 한다면 해당 고장 감지 모델의 효율성은 실제로 높다고 보기 어렵다. 이에 따라 본 연구에서는 고장 감지의 효율성을 최대화하기 위해 센서의 부착 위치와 유형에 따른 최적화 분석을 추가로 수행하였다. 독립 변수로 센서 설치 위치와 아날로그 센서 신호의 종류를 선정하였으며 종속변수로는 기존 구축된 고장 감지 모델의 정확도를 설정하였다. 센서의 부착 위치는 앞에서 언급한 <Figure 1>에 표기된 바와 같이 세 군데이며, 센서 신호의 종류 역시 자기장, 각속도, 가속도로 총 3가지로 구분할 수 있다. 다시 말해 이는 3^2 완전 요인 배치법 설계에 해당하므로 총 9가지 경우에 대해 3번

<Table 6> Fault Detection Performance According to the Location of Sensor Installation and Sensor Signal Type


		Location of sensor installation		
		Location 1	Location 2	Location 3
Signal type	Acceleration	70.6%	52.3%	55.1%
		70.9%	51.3%	53.5%
		69.5%	52.0%	54.7%
	Magnetic field	94.2%	89.0%	92.2%
		93.3%	91.2%	91.5%
		91.0%	92.3%	90.6%
	Angular velocity	98.0%	91.4%	90.4%
		97.5%	89.9%	92.1%
		97.6%	89.7%	91.2%

의 반복 실험을 통해 <Table 6>과 같은 실험 데이터를 얻었다. 2원 분산분석(Two-way analysis of variance(ANOVA))을 통해 각 변수의 영향력을 정량적으로 평가한 결과는 <Table 7>과 같다. 모든 주 효과와 상호작용 효과에 해당하는 모든 *p*-value 값이 0.05보다 작으므로 센서의 부착 위치와 신호 유형, 그리고 위치와 신호종류에 따른 교호작용에 따라 고장 감지 성능에 통계적으로 유의미한 차이가 있다는 것을 의미한다. 이러한 유의미한 결과는 센서 배치와 유형 선택이 고장 감지 성능에 결정적인 영향을 미칠 수 있음을 시사한다.

이어서 어떤 위치와 어떤 센서 종류가 가장 고장 감지 성능에 긍정적인 효과를 미치는지 확인하기 위하여 Tukey-HSD 방법을 이용한 사후 검정을 수행하였다. 이 방법은 모든 그룹 쌍 간의 평균 차이를 비교하여, 어떤 그룹 조합에서 유의미한 차이가 발생하는지를 명확하게 밝힐 수 있도록 한다. 분석 결과를 요약하자면 <Figure 5>와 같다. 1번 위치에 부착된 각속도 센서(1 Gyro)가 약 97.7%로 고장 감지 성능이 가장 우수하였다. 상대 시간과 27개의 아날로그 센서를 모두 사용하였을 때의 고장 감지 성능과 비교한 결과 (98.8%) 큰 차이를 보이지 않았음에 따라 공압 실린더의 고장 감지를 위해서는 실린더 몸통의 상단에 각속도 센서를 평행하게 부착하는 것으로도 충분하다고 볼 수 있다.

<Table 7> ANOVA Result: Fault Detection According to the Location of Sensor Installation and Sensor Signal Type

	df	SS	MS	F-value	<i>p</i> -value
Location	2	452.0	226.0	217.6	0.000
Type	2	6748.9	3374.4	3249.3	0.000
Location:Type	4	251.6	62.9	60.6	0.000
Error	18	18.7	1.0	-	-




<Figure 5> Tukey-HSD Result: Fault Detection Performance According to the Location of Sensor Installation and Sensor Signal Type (Red Circle Indicates the Highest Accuracy)

4. 실시간 고장 감지 시스템 구현

본 연구에서는 H 대학교의 스마트팩토리 테스트베드에 설치된 공압 실린더의 상태 이상을 실시간으로 감지하고 관리하기 위한 시스템을 개발하였다. 해당 테스트베드에는 총 31개의 공압 실린더가 존재함에 따라 다음과 같은 상황을 가정하였다: 1) 각각의 실린더에 설치된 아날로그 센서 데이터는 무선 통신(블루투스 또는 Wifi)을 통해 전체 자동화 이산 생산 시스템을 제어, 관리하는 서버에 저장되고 있다. 2) 현장 작업자의 경우 실린더와 인접하게 설치된 경고 시스템을 통해 실시간으로 각각의 실린더의 상태 확인이 가능해야 한다. 3) 원격 관리자의 경우 GUI를 통해 전체 실린더에 대해 동시에 여러 실린더에 대한 건강 상태 확인을 수행할 것이다.

현장 작업자의 경우 다양한 실린더를 동시에 관리함과 동시에 직관적으로 현재 어떤 실린더에 고장이 발생하였는지 확인할 수 있어야 한다. 이에 따라 소형 임베디드 제

여기인 아두이노를 이용하여 4색 LED와 스피커를 통한 경고 시스템을 설계하였다. 각 LED 색상은 공압 실린더의 상태를 나타낸다. 정상 상태는 파란색, 초기 이상 증상은 초록색, 중간 단계의 경고는 노란색, 그리고 심각한 고장 상태는 빨간색으로 설정하였다. 추가로 실린더 상태의 변화에 따라 스피커에서는 주파수가 변하는 경고음을 발생시키도록 하여 시각적 신호와 함께 청각적 알람도 제공한다. 이러한 경고 시스템은 <Figure 6>과 같다. 이 시스템은 공장 내 작업자가 실린더의 상태를 직관적으로 신속하게 인지할 수 있도록 설계되었다. 이를 통해 잠재적인 문제가 발생했을 때 즉시 대응할 수 있어, 설비의 효율성을 높이고 유지보수 비용을 절감할 수 있다.



<Figure 6> Developed Alarm System Operated by the Proposed Fault Detection Model in Actual Shop Floor



<Figure 7> Developed GUI Interface for Applying the Proposed Fault Detection Model in Remote Management Situation

원격 관리자를 위한 GUI 시스템은 <Figure 7>과 같이 구축하였다. 자동화 생산 시스템을 제어하는 서버 컴퓨터에 위치한 데이터베이스에 유선 또는 무선 인터넷망을 통해 접근하여 실시간으로 현재 센서 데이터값을 추출한다. 추출된 값을 사전에 학습된 고장 감지 모델에 입력하여 출력값을 도출한 후 이를 화면으로 나타내도록 구축하였다. 서버의 데이터베이스에는 각 실린더에서 수집되는 센서 데이터별로 테이블을 구축함에 따라 원하는 실린더에 대한 고장 감지 결과를 선택해서 볼 수 있다. 현재 날짜와 시간과 함께 실시간 설비의 상태 값을 글자 및 색상으로 전달할 뿐만 아니라, 직전 과거의 설비 상태에 대한 로그 데이터도 제공한다.

5. 결 론

본 연구는 범용 공압 실린더의 고장 감지와 실시간 모니터링을 위한 통합 시스템의 개발에 초점을 맞추었다. 공압 실린더로부터 수집된 다변량 센서 데이터를 기반으로 딥러닝 기반 분류 모델을 구축하여 실린더의 점진적 고장 상태를 정밀하게 분류하였다. 이후 분류 모델을 기반으로 공압 실린더의 건강 상태를 연속적인 수치로 예측하는 회귀 모델을 추가로 구축하였다. 또한 센서의 설치 위치와 분석에 사용하는 아날로그 신호 유형에 따른 고장 감지 성능 최적화 분석을 진행하여 각 센서 유형과 위치가 고장 감지 성능에 미치는 영향을 통계적으로 평가하였다. 그 결과 공압 실린더 몸통의 상단에 각속도 센서를 평행하게 부착한 후 고장 감지에 사용할 경우 가장 효율적이었다. 마지막으로 아두이노 기반의 실시간 경고 시스템과 GUI를 통한 원격 모니터링 시스템을 구축하여, 공장 내외의 관리자 및 작업자가 설비의 상태를 실시간으로 파악하고, 적절한 대응을 취할 수 있도록 하였다. 이 시스템들은 효과적인 데이터 시각화 및 알람 기능을 제공하여 설비 관리의 신속성과 정확성을 향상시켰다.

그러나 제안한 시스템은 전문가가 사전에 정의한 고장의 심각성을 기반으로 단계를 이용하여 현재 실린더의 상태 변화를 감지하는 데 초점을 맞추고 있다. 하지만 전문가의 의견은 주관적일 수 있으므로, 실린더의 상태를 실제 부품의 열화 정도를 기반으로 한 수학 모델로 표현할 수 있다면 고장을 미리 예방하는 데 도움이 될 것이다. 예를 들어 공압 실린더의 나사가 점차 풀리는 것은 점진적인 열화를 나타내므로 이를 예측하는 모델을 만들 경우 나사의 풀림을 수치로 나타냄으로써, 점진적인 기계적 열화를 직관적으로 파악하여 예방적 유지보수를 가능하게 할 것이다.

Acknowledgement

This work was supported by the National Research Foundation of Korea (NRF) grant funded by the Korea government (MSIT) (No. 2022R1F1A1069296). This work was also supported by Korea Institute for Advancement of Technology (KIAT) grant funded by the Korea Government (MOTIE) (P0012744, HRD program for industrial innovation).

References

- [1] Ali, P.J.M. and Faraj, R.H., Data normalization and standardization: A technical report, *Mach Learn Tech Rep*, 2014, Vol. 1, No. 1, pp. 1-6.
- [2] Baek, S., Fault pattern extraction via adjustable time segmentation considering inflection points of sensor signals for aircraft engine monitoring, *J. Soc. Korea Ind. Syst. Eng.*, 2020, Vol. 44, No. 3, pp. 86-97.
- [3] Gupta, A.K. and Arora, S.K., Industrial automation and robotics. Laxmi Publications, 2011.
- [4] Hadi, H.H. and Sallom, M.Y., Pneumatic control system of automatic production line using SCADA implement PLC, *4th Scientific International Conference Najaf (SICN)*, 2019, pp. 37-42.
- [5] Jeong, J.H., Jang, J.S., and Ji, S. W., Analysis of the control performance of 6 DoF simulator with pneumatic cylinder, *Proceeding of the Korean Society of Power System Engineering*, 2006, pp. 278-281.
- [6] Jimenez, M., Kurmyshev, E., and Castaneda, C.E., Experimental study of double-acting pneumatic cylinder, *Experimental Techniques*, 2020, Vol. 44, pp. 355-367.
- [7] Kalsoom, T., Ramzan, N., Zhmed, S., and Ur-Rehman, M., Advances in sensor technologies in the era of smart factory and industry 4.0, *Sensors*, 2020, Vol. 20, pp. 6783:1-22.
- [8] Kang, B.S., Lee, C.S., and Chang, M.S., Life Prediction of Cylinder Head Bolt using Accelerated Life Testing, *Proceeding of 2012 Spring Conference of the Korean Society of Mechanical Engineers*, 2012, pp. 510-513.
- [9] Kim, D.H., Lee, I.S., and Cha, C.N., Development of cyber-physical production system based manufacturing control system for aircraft parts plant, *J. Soc. Korea Ind. Syst. Eng.*, 2020, Vol. 43, No. 1, pp. 143-150.
- [10] Kim, N.G., Kim, C.H., and Whang, G.N., Hydraulic cylinder abnormal detection by facility data analysis, *Proceeding of 2019 Autumn Conference of Korean Institute of Industrial Engineers*, 2019, pp. 3428-3432.
- [11] Kim, S.H., Jin, L., and Ryu, G.H., Incremental regression based on a sliding window for stream data prediction, *Journal of KIISS:Databases*, 2007, Vol. 34, No. 6, pp. 483-492.
- [12] Kim, S., Seo, W., Kwak, K., and Hong, D., Modified block diagonalization precoding with greedy approach, *The Journal of Korean Information and Communication Society*, 2008, Vol. 33, No. 1, pp. 79-85.
- [13] Kim, Y. and Hwang, J., Greedy-based neighbor generation methods of local search for the traveling salesman problem, *Journal of the Korea Society of Computer and Information*, 2022, Vol. 27, No. 9, pp. 69-76.
- [14] Kwon, D.-H. and Oh, C.-H., Predictive maintenance technology for smart factory, *Proceeding of 2021 Spring Conference of Korea Institute of information and Communication Engineering*, 2021, pp. 172-174.
- [15] Lee, H.J., Park E.M., Shin, D.C., Choe, J.S., and Kim, T.W., Development of raising device for greenhouse column using a pneumatic cylinder, *Protected Horticulture and Plant Factory*, 2018, Vol. 27, No. 3, pp. 206-212.
- [16] Lee, H.R. and Park, C., Comparative study of recommender systems based on deep learning algorithms, *Journal of the Korean Data & Information Science Society*, 2024, Vol. 35, No. 1, pp. 1-13.
- [17] Lee, J. and Kang, S., Analyzing extreme diurnal temperature range in spring on the South Korea using a sliding window approach, *Journal of the Korean Data & Information Sciences Society*, 2024, No. 35, No. 1, pp. 75-97.
- [18] Lee, K.J., Lee, H.J., and Oh, K.J., Using fuzzy-neural network to predict hedge fund survival, *Journal of the Korean Data & Information Science Society*, 2015, Vol. 26, No. 6, pp. 1189-1198.
- [19] Lee, Y.-B., Lee, G.C., Lee, J.J., and Lim, S.Y., A study on the accelerated life test of yaw gearbox for wind turbine, *Journal of Drive and Control*, 2024, Vol. 21, No. 1, pp. 16-21.
- [20] Na, K., Kim, M., and Lee, J., Real-time batch size determination in the production line, *J. Soc. Korea Ind. Syst. Eng.*, 2019, Vol. 42, No. 1, pp. 55-63.
- [21] Ramasamy, S., Kalaiarasan, A., Ajithvishva, M.S., Hemsri, M., Oorppan, G.M., Yasodharan, R., IoT visualization of smart factory for additive manufacturing System (ISFAMS) with visual inspection and material

- handling processes, *IOP Conference Series: Materials Science and Engineering*, 2020, Vol. 995. pp. 012027: 1-12.
- [22] Sherstinsky, A., Fundamentals of recurrent neural network (RNN) and long short-term memory (LSTM) network, *Physica D: Nonlinear Phenomena*, 2020, Vol. 404, pp. 132306:1-28.
- [23] Song, Y.-U. and Baek, S., Real-time fault detection in discrete manufacturing systems in via LSTM model based on PLC digital control signals, *J. Soc. Korea Ind. Syst. Eng.*, 2021, Vol. 44, No. 2, pp. 115-123.
- [24] Yoo, G.H., Yang, H.C., and Whang, G.N., Abnormal detection of the mold cylinder temperature cycle using 1D CNN, *Proceeding of 2021 Spring Conference of Korean Institute of Industrial Engineers*, 2021, pp. 5873-5878.
- [25] Yoon, Y.A., Jung, J.H., Lim, J.H., Chang, T.-W. and Kim, Y.S., A study on data preprocessing for developing remaining useful life predictions based on stochastic degradation models using air craft engine data, *J. Soc. Korea Ind. Syst. Eng.*, 2020, Vol. 43, No. 2, pp. 48-55.
- [26] Yu, Y., Si, X., Hu, C., and Zhang, J., A review of recurrent neural networks: LSTM cells and network architectures, *Neural Computation*, 2019, Vol. 31, No. 7, pp. 1235-1270.

ORCID

- Byeong Su Kim | <http://orcid.org/0009-0002-4811-8553>
Geun Myeong Song | <https://orcid.org/0009-0006-8392-3012>
Min Jeong Lee | <http://orcid.org/0009-0009-2926-4062>
Sujeong Baek | <http://orcid.org/0000-0002-9387-6217>