

Real-Time Fault Detection in Discrete Manufacturing Systems Via LSTM Model based on PLC Digital Control Signals

Yong-Uk Song · Sujeong Baek[†]

Department of Industrial Management Engineering, Hanbat National University

PLC 디지털 제어 신호를 통한 LSTM기반의 이산 생산 공정의 실시간 고장 상태 감지

송용욱 · 백수정[†]

한밭대학교 산업경영공학과

A lot of sensor and control signals is generated by an industrial controller and related internet-of-things in discrete manufacturing system. The acquired signals are such records indicating whether several process operations have been correctly conducted or not in the system, therefore they are usually composed of binary numbers. For example, once a certain sensor turns on, the corresponding value is changed from 0 to 1, and it means the process is finished the previous operation and ready to conduct next operation. If an actuator starts to move, the corresponding value is changed from 0 to 1 and it indicates the corresponding operation is been conducting. Because traditional fault detection approaches are generally conducted with analog sensor signals and the signals show stationary during normal operation states, it is not simple to identify whether the manufacturing process works properly via conventional fault detection methods. However, digital control signals collected from a programmable logic controller continuously vary during normal process operation in order to show inherent sequence information which indicates the conducting operation tasks. Therefore, in this research, it is proposed to a recurrent neural network-based fault detection approach for considering sequential patterns in normal states of the manufacturing process. Using the constructed long short-term memory based fault detection, it is possible to predict the next control signals and detect faulty states by compared the predicted and real control signals in real-time. We validated and verified the proposed fault detection methods using digital control signals which are collected from a laser marking process, and the method provide good detection performance only using binary values.

Keywords : Fault Detection, Digital Signal, LSTM, Discrete Manufacturing System, Sensor Data

1. 서 론

사물인터넷과 산업용 제어기 및 통신 장비가 발전함에 따라 다양한 센서 데이터 및 제어 신호를 기반으로 많은 생산 시스템들이 자동화되었다[4, 10]. 이산 생산 공정이란

셀 수 있는 제품을 생산하는 공정 시스템을 의미하며, 일반적으로 해당 공정은 이전 작업이 완료되면 정해진 작업 순서에 따라 다음 작업을 순차적으로 수행한다[11, 13]. 예, 스마트폰과 같이 1개씩 셀 수 있는 제품을 생산하는 공정이 이산 생산 공정의 대표적인 예시이며, 미리 주어진 순서대로 여러 액추에이터들이 동작을 하여 제품을 조립하게 된다. 이러한 이산 생산 공정을 자동화하기 위하여 디지털 제어 신호가 사용되고 있으며[8, 15], 이는 0 또는 1의 값을 갖는 이진수의 형태를 갖는다. 디지털 제어 신호는

Received 24 May 2021; Finally Revised 11 June 2021;
Accepted 18 June 2021

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

입력 값과 출력 값으로 구성되어 있으며, 입력 값은 센서의 작동 유무에 의해 수치가 결정되고, 출력 값은 액츄에이터의 동작 명령을 내리기 위해 생성된다. 아날로그 온도, 압력 센서와 같이 연속적인 수치를 측정하거나 서보 모터와 같이 상세한 동작 명령이 필요한 경우 아날로그 신호가 생성되기도 하나, 이산 생산 공정이나 단일 설비의 경우 시퀀스 기반의 운영으로 인해 디지털 제어 신호가 보다 많이 사용된다. 다시 말해, 시퀀스 기반으로 제조 시스템이 운영됨에 따라 현재 상태의 전후관계에 맞춰 디지털 신호 값의 다양한 조합이 모두 정상 상태를 의미하게 된다. 예를 들어, Seong et al.[19]은 Programmable logic controller(PLC)에서 수집된 신호 데이터를 비교하여 액츄에이터의 동작 수행 여부를 감지하여 예방할 수 있는 방법을 제안하였다. 수집된 PLC 신호 데이터는 공정을 제어하기 위해 일반적으로 입력과 출력 신호로 나뉘어져 있고, 시차에 따른 선후관계를 갖기에 작업의 순서를 확인하는 데 도움이 되었다.

이외에도 시스템을 안정적으로 운영하기 위하여 고장 감지 및 시스템 상태 예측 연구들이 많이 수행되고 있다 [2, 16]. 그러나, 센서 신호 분석을 기반으로 전통적인 고장 감지 기법을 이용할 경우, 아날로그 신호를 사용하는 경우가 많다[1, 3]. 예를 들어, 회전체 설비의 고장을 감지하는 경우[9, 17], 여러 위치의 진동 센서 데이터를 수집하여 하나의 정상 상태 모델을 생성하고 이와 현재 상태를 비교하여 고장을 감지한다. Hwang et al.[7]은 실제 제조 공정에서 생성되는 432개의 아날로그 센서 데이터를 활용하여 제품의 불량률을 개선하고자 하였다. 센서 데이터가 수집되는 시간 구간에 따라 각 데이터가 나타내는 바를 분류한 후, 불량률이 낮은 공정과 불량률이 높은 공정의 차이를 의사결정나무 분석을 통해 변수를 도출하였다. 또한, Kwon et al.[12]은 Laminator 설비의 온도를 측정하였으며, 측정된 데이터에서 유의미한 신호 패턴을 추출하여 도메인 지식에 의존하지 않는 이상 탐지 및 분류를 하고자 하였다. 시계열 신호에 대한 형태학적 특징을 추출하기 위해 양방향으로 데이터를 주고받을 수 있는 장단기 메모리(LSTM, Long short-term memory) 기반 오토 인코더(Autoencoder)를 제안하였으며, 밀도를 기반으로 데이터를 군집화 하였다. 특히, 순환신경망(RNN, Recurrent neural network), LSTM 및 양방향 LSTM을 이용하여 모델을 구축한 후, F1-score 값을 비교한 결과 제안한 양방향 LSTM 모델의 성능이 분류에 있어 가장 좋음을 확인하였다. Hong et al.[5]은 플랜트 공정의 주요 설비인 Forced Draft Fan에 8개의 센서를 설치하여 해당 설비의 이상 상태를 감지하고자 하였다. 수집되는 신호는 공기의 온도, 압력, 변위, 회전 속도와 같은 아날로그 신호였으며, 비선형 자기 회귀 신경망 기법을 사용하였다. 자기 회귀 신경망 기법

은 특히 다변량 데이터가 비선형 특징을 갖고 있고, 시간에 따라 변화하는 모습을 보일 때 다소 좋은 성능을 보여 해당 연구에서도 좋은 고장 감지 성능을 보였다. 이외에도 공정 설비에 부착된 압력, 온도, 유량, 분당 회전 횟수와 같은 센서 데이터와 과거 고장 이력을 비교하여 고장 상태를 판단하고자 하는 연구도 수행되었다[6]. 과거 고장 이력 정보를 학습시키기 위해 기계 학습 기법을 적용하였다. 먼저, 과거 운전 데이터를 고장 상태와 정상 상태 구간으로 분류한 후, 각각의 상태에 대한 특징 데이터를 추출하였다. 최종적으로 주성분 분석을 통해 두 상태를 구별할 수 있는 판단 기준을 생성하여 Fluid catalytic cracking 공정에서 운영되는 공기 송풍기의 고장 감지에 적용하였다.

그러나 시퀀스 기반의 제조 공정에서는 특정 액츄에이터의 가동으로 인해 생성된 디지털 제어 신호 값이 일정하지 않고 변화를 보일지라도, 전후 관계에 따라 상태 판단이 이루어질 필요가 있다. 다시 말해 이산 제조 공정의 운영을 통해 수집되는 디지털 제어 신호를 이용하여 현재 시스템의 상태를 판단하기 위해서는 내제된 시퀀스 패턴을 파악하여 이에 따른 상황 판단을 할 필요가 있다. 또한 해당 신호 정보는 이진수의 조합으로 이루어져 있어 아날로그 센서 데이터에 비하여 해석할 수 있는 정보가 매우 빈약하여, 기존의 아날로그 센서 데이터 분석 기반의 고장 감지 기법을 적용하는데 어려움이 있다.

그러므로 본 연구에서는 이러한 문제를 해결하기 위하여 이산 제조 시스템이 정상적으로 운행될 때의 다양한 시퀀스 패턴을 하나의 정상 모델로 구축하여 고장 감지를 위해 사용하고자 한다. 본 연구에서는 하나의 제조 주기동안의 시간 흐름을 고려할 수 있도록 순환신경망 기반의 고장 감지 모델을 구축하였다. 특히 정상 운영 상태에 대해 설명하기 위해 LSTM을 이용하였으며, 현재 디지털 제어 신호가 입력되면, 시스템이 정상적으로 운영된다는 가정하에 발생할 다음 디지털 제어 신호가 출력되도록 모델을 구축하였다. 제안한 방법의 성능을 검증하기 위해 실제 H대학교 스마트팩토리 센터에서 구동되고 있는 이산 제조 공정 중 하나인 레이저 마킹 공정의 데이터를 활용하였다.

2. 이산생산공정 및 디지털 제어 신호

2.1 이산 생산 공정의 디지털 제어 신호 구성

이산 생산 공정은 일반적으로 디지털 제어 신호를 통해 순차적으로 동작 및 작업을 수행한다. 해당 순차 작업을 자동으로 수행하기 위해서는 구성하고 있는 센서로부터 디지털 신호 값을 수집하고, 이에 따라 디지털 제어 값을

액추에이터에 전송하여 동작을 수행하여 한다. 이와 같은 디지털 제어 신호는 일반적으로 입력 신호와 출력 신호로 구분되며 입력 신호는 현재 시스템의 동작 여부를 확인하기 위한 센서 값들이다. 예를 들어 특정 위치에 대상 물체가 위치하였는지, 하지 않았는지 등의 정보를 입력 값으로 수집하여 다음 동작을 수행할 지 여부를 결정한다. 반면에 출력 신호의 경우 산업용 제어기의 판단에 따라 특정 액추에이터가 동작을 수행해야 할 경우 해당 값을 0에서 1로 변경하여 동작 수행에 대한 명령을 내린다. 그러므로 이와 같이 연관된 모든 센서, 액추에이터에 대해 1:1로 매칭되는 디지털 제어 신호 값이 존재하는 것이다. 예를 들어 <Table 1>과 같이 디지털 제어 신호가 존재한다면, 14개의 입력 신호를 생성하는 센서가 해당 이산 제어 공정에 설치되어 있고(DI0_0부터 DI1_7까지) 총 4개의 액추에이터가 산업용 제어기에 의해 동작 수행 여부를 변경할 수 있는 것(DQ4_2부터 DQ6_6까지)이다. 만약 DQ7.1이 1로 변경되었다면 다른 센서나 액추에이터에서는 변화가 없는 것이고, 이에 해당되는 액추에이터가 동작을 시작함을 의미한다.

2.2 H대 레이저 마킹 공정

본 연구를 위해서 H대학교 스마트팩토리센터 테스트 베드에 있는 자동 생산 설비 중 레이저 마킹 공정에서 데이터를 수집하였다. 레이저 마킹 공정은 앞서 설명한 바와 같이 디지털 제어 신호 기반으로 동작한다. 동작의 순


서는 다음과 같다 : 이전 공정에서의 작업이 끝난 후 레이저 마킹 공정의 컨베이어로 팔레트가 진입하게 된다. 컨베이어 벨트를 따라서 팔레트는 <Figure 1(a)>와 같이 움직여 스톱퍼(Stopper)에 의해 더 이상 전진하지 못한 채, 팔레트가 사전에 정의된 작업 위치에 정지하게 된다. 이에 따라 스톱퍼의 전면에 부착된 물체 감지 센서가 0에서 1로 디지털 신호 값을 변경한다. 이후, 제품을 이송하는 액추에이터(<Figure 1(b)>의 노란색 사각형으로 표기된 설비)가 하강하여 진공 그리퍼를 이용하여 제품을 흡착한다. 액추에이터 제품 흡착에 성공하면, 다시 상승한다. 이어서 액추에이터의 상승을 감지하는 센서가 점등되면 시계방향으로 90도 회전하고 제품을 작업대로 이동시키기 위해서 하강한다. 액추에이터의 하강을 완료하면 진공 흡착을 종료하여 <Figure 1(c)>와 같이 제품을 전용 작업대에 배치한다. 이송 액추에이터는 레이저 각인 작업에 방해가 되지 않도록 다시 원위치를 하게 되고, 작업대에 물체 감지 센서가 제품이 있는 것을 감지함에 따라 <Figure 1(d)>와 같이 제품 표면에 글자를 새긴다. 레이저 마킹 작업이 끝나면 이송 액추에이터는 전용 작업대에서 제품을 <Figure 1(e)>와 같이 상자 내에 다시 삽입한다. 이 때, 이송 액추에이터가 상자에 제품 삽입이 완료한 후, 원래의 제자리로 돌아오게 되면 해당 연관 신호의 변화에 따라, 상자의 전진을 방해하던 스톱퍼가 하강하여 팔레트가 다시 전진하게 된다. 최종적으로 팔레트는 <Figure 1(f)>와 같이 다음 공정으로 이동하게 된다. 위 내용을 요약하자면 <Table 2>와 같은 공정 개요로 나타낼 수 있다.

<Table 1> Digital Control Signal List Collected from the Laser Marking Process


Attribute	Explanation	Value
DI0_0	Emergency stop switch	Binary
DI0_1	External input signal 1 (connected to the previous process)	Binary
DI0_2	External input signal 2 (connected to the next process)	Binary
DI0_3	Detect a pallet inflow in front of the stopper	Binary
DI0_4	Detect a stopper extend	Binary
DI0_5	Detect a stopper retract	Binary
DI0_6	Detect a pallet go to the next processes	Binary
DI1_0	Detect a vacuum gripper turn on (suction on)	Binary
DI1_1	Detect a transfer actuator locate on the home position (at the 6o'clock)	Binary
DI1_2	Detect a transfer actuator locate on the rotated position (at the 9o'clock)	Binary
DI1_3	Detect the product located on the workbench	Binary
DI1_4	Detect a transfer actuator go downward (retract)	Binary
DI1_6	Detect a transfer actuator go upward (extend)	Binary
DI1_7	Detect a laser marking operation complete	Binary
DQ4_2	Start a laser marking operation	Binary
DQ6_4	Tower lamp (Red)	Binary
DQ6_5	Tower lamp (Yellow)	Binary
DQ6_6	Tower lamp (Green)	Binary

<Figure 2>는 레이저 마킹 공정의 실제 Human-machine interaction(HMI) 상의 화면이다. 공정 가동 시 HMI 화면을 통해 센서와 액추에이터의 상태를 실시간으로 확인할 수 있다. 이때, HMI 화면에서 'I'로 시작하는 요소들은 센서 또는 스위치로 분류되고, 'Q'로 시작하는 요소들은 액

추에이터로 분류된다. 이와 같이 실시간으로 확인 가능한 디지털 제어 신호를 데이터베이스에 1초 단위의 주기로 수집하였다[21]. 공정의 시작과 종료를 자동으로 감지하여 데이터를 수집하였으며 해당 레이저 마킹 공정에서 수집되는 디지털 제어 신호는 총 18개로 <Table 1>과 같다.




(a) Dispensing a pallet (with a product)




(b) Grasping the product by a vacuum gripper




(c) Placing the product on the dedicated workbench



(d) Laser marking



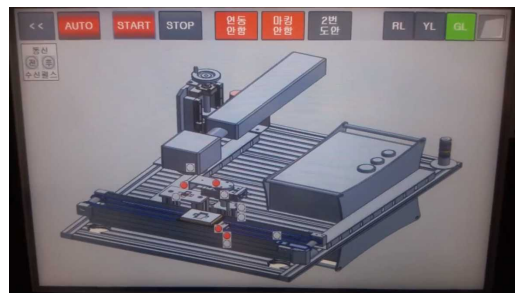
(e) Returning the product to the pallet



(f) Moving to the next process

<Figure 1> Normal Operations in Laser Marking Process

번호	상태	ID	비고	비고
01	비상정지 스위치	OK.0	비상정지 스위치 오프	비상정지 스위치 온
02	비상정지 버튼	OK.1	비상정지 버튼 누름	비상정지 버튼 해제
03	비상정지 릴레이	OK.2	비상정지 릴레이 온	비상정지 릴레이 오프
04	비상정지 릴레이	OK.3	비상정지 릴레이 오프	비상정지 릴레이 온
05	비상정지 릴레이	OK.4	비상정지 릴레이 온	비상정지 릴레이 오프
06	비상정지 릴레이	OK.5	비상정지 릴레이 오프	비상정지 릴레이 온
07	비상정지 릴레이	OK.6	비상정지 릴레이 온	비상정지 릴레이 오프
08	비상정지 릴레이	OK.7	비상정지 릴레이 오프	비상정지 릴레이 온
09	비상정지 릴레이	OK.8	비상정지 릴레이 온	비상정지 릴레이 오프
10	비상정지 릴레이	OK.9	비상정지 릴레이 오프	비상정지 릴레이 온
11	비상정지 릴레이	OK.0	비상정지 릴레이 온	비상정지 릴레이 오프
12	비상정지 릴레이	OK.1	비상정지 릴레이 오프	비상정지 릴레이 온
13	비상정지 릴레이	OK.2	비상정지 릴레이 온	비상정지 릴레이 오프
14	비상정지 릴레이	OK.3	비상정지 릴레이 오프	비상정지 릴레이 온
15	비상정지 릴레이	OK.4	비상정지 릴레이 온	비상정지 릴레이 오프
16	비상정지 릴레이	OK.5	비상정지 릴레이 오프	비상정지 릴레이 온
17	비상정지 릴레이	OK.6	비상정지 릴레이 온	비상정지 릴레이 오프
18	비상정지 릴레이	OK.7	비상정지 릴레이 오프	비상정지 릴레이 온



<Figure 2> The Corresponding HMI Screen of the Laser Marking Process

이러한 디지털 제어 신호가 자동화 시스템 운영을 위해서만 필요할 경우에는 별도로 해당 로그를 저장하지 않고 휘발적으로 해당 값이 변경되기만 한다. 그러나 본 연구에서는 정상 상태일 때의 디지털 제어 신호의 변화를 확인하기 위해서 해당 데이터들을 주기적으로 타임 스탬프와 함께 데이터베이스에 저장하였다. <Table 3>과 같은 히스토리 시계열 데이터 형태로 데이터베이스상에 수집하였다. 이때 저장되는 타임 스탬프의 경우, 실제 시간 정보가 아니라 현재 공정 사이클의 시작 시간과의 비교를 통한 상대 시간으로 기록되었다. 이는 해당 공정 사이클 상에서 특정 시간에 일어나는 디지털 제어 신호의 패턴을 밝혀내어 최종적으로 공장 사이클 동안의 제어 신호 상에서의 시퀀스를 알아내고자 하기 위함이다. 효과적인 히스토리 데이터 관리를 위하여 실제 운영 시간이나 공정 사이클 번호 역시 기록할 수 있으나, 본 연구에서는 해당 정보를 고장 감지를 위해 별도로 사용하지 않았다.

<Table 2> A Sequential Work Flow of the Laser Marking Process

ID	Explanation	The corresponding picture
1	Dispensing a pallet to the process	<Figure 1(a)>
2	Moving down an actuator	<Figure 1(b)>
3	Turning on a vacuum generator for grasping the product	
4	Moving up the actuator	<Figure 1(c)>
5	Rotating the actuator 90 degrees clockwise	
6	Moving down the actuator	
7	Turning off the vacuum generator for placing the product on the dedicate workbench	<Figure 1(d)>
8	Moving up the actuator	
9	Rotating the actuator 90 degrees counterclockwise	
10	Conducting laser marking on the product	<Figure 1(e)>
11	Rotating the actuator 90 degrees clockwise	
12	Moving down the actuator	
13	Turning on a vacuum generator for grasping the product	
14	Moving up the actuator	
15	Rotating the actuator 90 degrees counterclockwise	
16	Moving down the actuator	
17	Turning off the vacuum generator for placing the product in the box	<Figure 1(f)>
18	Moving up the actuator	
19	Moving down a stopper for stopping the pallet at the dedicate location	
20	(If the pallet goes to the next process,) Moving up the stopper	

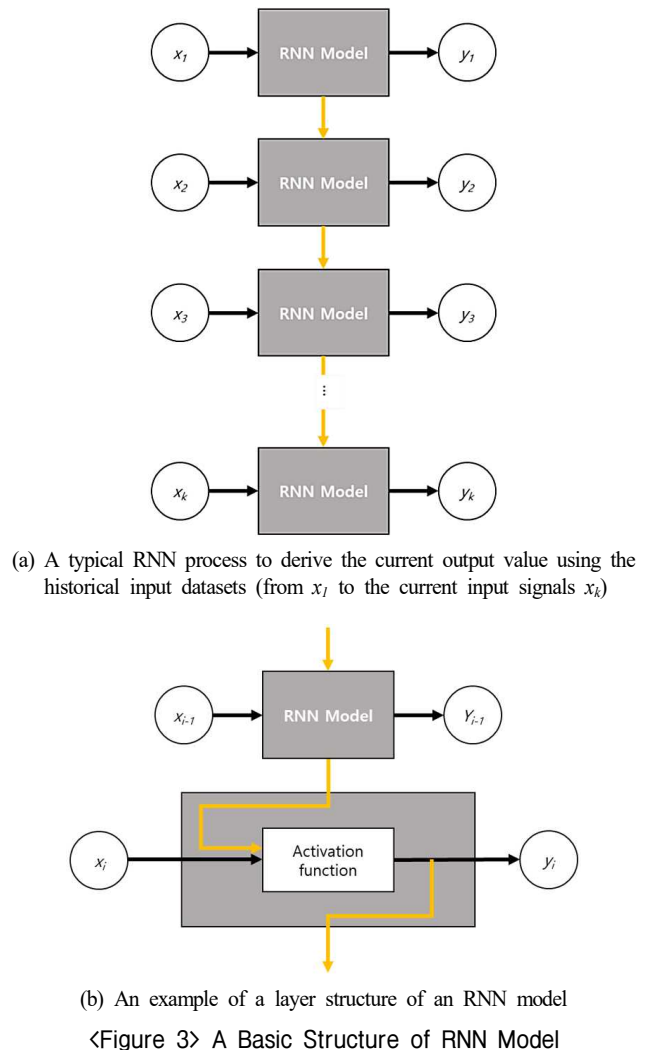
<Table 3> Example of a History Dataset which Consists of the Recorded Digital Control Signals

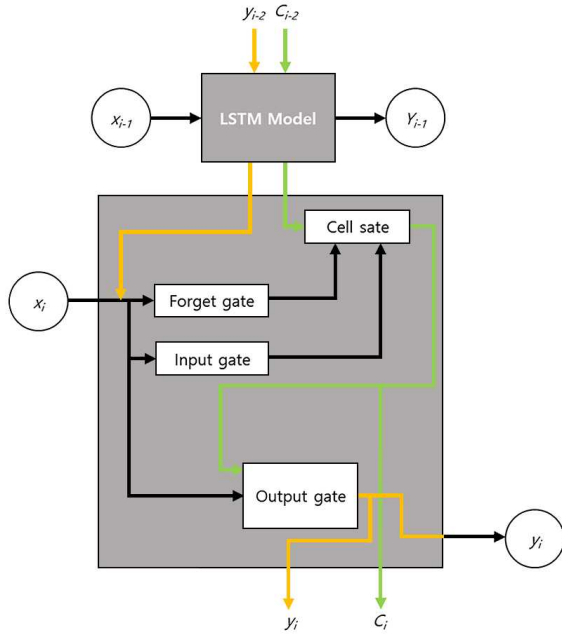
Time	DI0_0	DI0_1	...	DQ6_6
00:00:00	0	0	...	0
00:00:01	0	1		0
00:00:02	0	1	...	1
00:00:03	0	0		1
00:00:04	0	0		0
			...	

3. 고장 상태 감지를 위한 LSTM 구축 및 실험 결과

3.1 RNN 및 LSTM

본 연구에서는 RNN을 활용하여, 디지털 제어 신호 내의 시간에 따른 정상적인 변화와 시스템의 고장으로 인한 변화를 다르게 분류하고자 하였다. RNN은 일반적인 인공신경망에서 다루지 못하였던, 이전 입력 값과 현재 입력 값 간의 관계를 고려하여 현재의 출력 값을 계산하는 방법이다[18]. 입력 값과 출력 값의 형태에 따라 1:1, 1:n, n:1, n:n과 같이 다양하게 설정할 수 있어 시계열 데이터의 분류 및 회귀 문제를 다양한 구조로 적용 가능하다. 예를 들어 <Figure 3>과 같은 모델에 입력 값 x_n 이 하나의 수치 값이고, 얻으려는 값도 하나의 수치 값이라면 이는 Sequence-to-label 분류 또는 Sequence-to-one 회귀 RNN 형태로 모델을 구축할 수 있다. 또는 동일한 분류, 회귀 문제를 풀기 위하여 입력, 출력 값을 벡터 또는 행렬 형태로 입력할 수 있어, 음성 인식, 번역 등과 같은 연속된 데이터를 유기적으로 활용해야 하는 분야에서 많이 사용되고 있다[14, 22].





<Figure 4> A Basic Structure of LSTM Model

그러나 일반적인 구조의 RNN의 경우 학습 시 노드 가중치의 최적 값을 탐색하기 위해 수행하는 역전파 계산에서 시간 차이가 큰 과거 데이터에 대해서는 함수의 기울기가 매우 작아져 최적화 성능이 매우 저하되는 경우가 발생한다(기울기 소멸 문제, **Vanishing gradient problem**). 이러한 문제는 기본 RNN 형태에서 발전한 LSTM을 활용함으로써 해결할 수 있다. LSTM은 RNN의 한 종류로써, 일반적인 RNN에 비해서 오래된 이전 정보를 경우에 따라 단계적으로 판단하여 활용할 수 있다는 장점을 가지고 있다[18, 20]. 예를 들어 <Figure 4>에서 나타내는 바와 같이 **Forget gate**에서는 현재 입력 값 x_i 과 과거 출력 값 y_{i-1} 을 비교하여 이전 정보를 그대로 반영할지, 모두 무시할지를 결정한다. **Input gate**에서는 현재 레이어에서 입력 받은 두 값을 이용해 새로운 **Cell-state**를 만들어 내기 위한 은닉 값을 생성한다. **Forget gate**와 **Input gate**에서 생성된 변수와 이전 **Cell-state** 값을 이용하여 현재의 **Cell-state** 값 C_i 가 새롭게 생성된다. 최종적으로 현재의 **Cell state**와 현재 레이어의 입력 값들을 종합하여 **Output gate**에서는 현재 출력 값 y_i 를 계산한다. 요약하자면, 현재 입력 값과 과거에서 온 입력 정보를 항상 동일하게 반영하지 않고, **Forget gate**와 **Input gate**, **Output gate**를 통해 적절히 반영하여 사용할 수 있다.

3.2 LSTM 모델 구축 및 시간 공정 상태 감지 결과

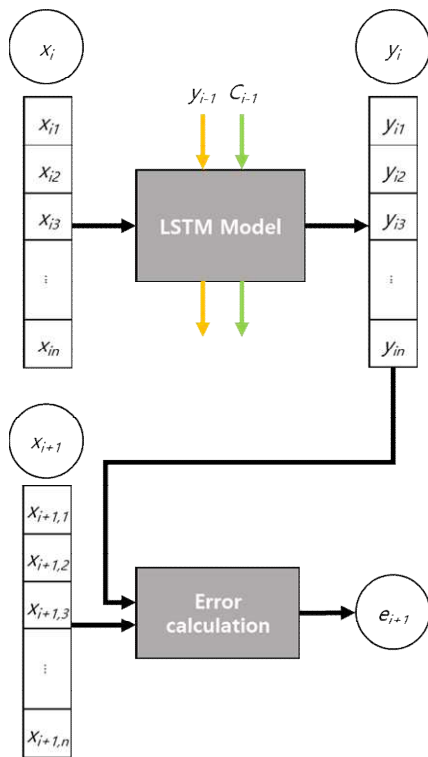
본 연구에서는 공정에서 수집되는 디지털 제어 신호를 사용할 수 있도록 LSTM 구조를 다음과 같이 설계하였다.

<Table 4> Layer Structure of the Developed LSTM Model for Fault Detection in a Discrete Manufacturing Process

Layer level	Type	The number of node units
Sequence input		The number of attributes in digital control signals
Hidden 1	LSTM	160
Fully connected		The number of attributes in digital control signals
Regression		The number of attributes in digital control signals

학습을 통한 정상 상태 모델 구축을 위하여 MATLAB 2021a를 이용하여 분석을 수행하였다. 분석에 사용된 LSTM 구조는 추후 다른 공정에 적용 시 별도의 전문가의 의견이 필요하지 않도록 경사 하강법(**Steepest-ascent method**)을 응용하여 주어진 학습 데이터에서 가장 좋은 고장 감지 성능을 보이는 모델 구조를 탐색하여 결정하였다. 항상 적용되어야 하는 **Sequence input**, **Fully connected**, **Regression layer**는 기본 레이어로 설정하여 별도의 변경을 하지 않았으나, 은닉 층(**Hidden layer**)의 수와 해당 은닉 층 내의 노드 수는 순차로 탐색하였다. 먼저 은닉 층의 수를 먼저 하나로 고정한 후, 해당 은닉 층의 노드 수를 초기 값 20에서 최대 200까지 20 단위로 증가시켜가며 성능을 확인하였다. 해당 단계에서 가장 최적의 노드 수를 도출한 후, 다시 은닉 층을 하나 추가하여, 해당 층에서의 최적 노드 수를 다시 발견하는 식으로 반복하였다. 해당 탐색 과정을 고장 감지 성능이 더 이상 향상되지 않을 때까지 반복하였으며, 그 결과 <Table 4>와 같이 모델이 최종적으로 결정되었다. 그 외 각 노드의 가중치와 같은 하이퍼 파라미터 (**Hyper-parameter**)는 Adam optimizer(초기 학습률 : 0.005, 최대 반복 횟수 : 300번)에 의해 최적 값이 도출되었다.

반면에 테스트 데이터를 이용하여 모델의 성능을 확인하는 과정(테스트 과정)에서는 실시간으로 실시간 제어 신호가 들어올 때에 대해 대응할 수 있도록 <Figure 5>와 같이 진행하였다. 현재 i 시점의 디지털 제어 신호 x_i 가 한 세트 수집되면 이를 구축된 LSTM 기반 고장 감지 모델에 입력하여 출력 값을 획득한다. 이렇게 계산된 출력 값 y_i 는 <Figure 5>에서 설명하는 바와 같이 입력 값과 동일한 크기의 벡터로 생성된다. 이후, 바로 다음 $i+1$ 시점의 입력 벡터 x_{i+1} 가 수집되면, 직전에 계산한 최신 출력 값 y_i 과 차이 비교를 통해 오차를 계산한다. 각각의 출력 노드는 디지털 제어 신호를 모사한 것이므로 0 또는 1의 값을 가지기에 오차 값의 범위는 0부터 최대 n (= 디지털 제어 신호의 수)이다. 해당 도출한 오차 값 e_{i+1} 이 사용자가 사전에 지정한 임계 값(**Threshold**) 이상으로 커질 경우 $i+1$ 시점에 고장이 발생한 것으로 간주하였다. 다시 말해, 임계 값은 사용자 정의 값으로 모델의



<Figure 5> LSTM based Fault Detection Using Digital Control Signals

예측과 다르게 작동한 센서 신호의 수와 일치한다. 이와 같은 형태로 고장 감지를 위한 모델이 학습되므로, 학습을 위해 사용되는 입력 데이터는 오로지 정상 공정 운영 일 때 수집된 값으로만 구성되었다. 그러므로 LSTM 모델을 사용하여 지도 학습 형태를 띄고 있으나, 실제로는 반지도형태의 학습을 수행하고 있다. 또한 본 연구에서는 학습 데이터를 통해 계산된 에러 값 중 가장 큰 값(= 5)을 임계 값으로 사용하여, 주어진 학습 데이터는 모두 정상 상태로 판단할 수 있도록 하였다(예 : 총 18개 중 최소 6개 이상의 디지털 신호가 예측 값과 다르게 작동한 경우 고장으로 감지). 추후 다른 공정에도 해당 고장 모델 구축을 손쉽게 적용하기 위하여, 별도의 전문가 지식을 활용하지 않고, 학습 데이터에만 의존하여 해당 임계 값을 결정하였다.

실시간 공정 상태 감지를 위하여 실험을 수행하여, 총 38번의 공정 운영을 통해 디지털 제어 신호를 수집하였다. 수집된 데이터 세트는 정상적으로 공정이 시작되어 종료된 30번의 공정 주기(정상 상태)와 8번의 비정상 종료된 공정 주기(고장 상태)로 구성되어 있다. 30번의 정상 상태 중 20번의 정상 상태에 대한 디지털 제어 신호를 학습 데이터로 사용하였으며, 나머지 10번의 정상과 8번의 고장 상태 데이터를 고장 감지 모델의 성능을 검증하기 위해 사용하였다. 구축된 고장 감지 모델의 성능을 확인

하기 위해서, 주어진 입력 데이터에 대해서 올바르게 현재 상태를 판단하였는가를 정확도로 측정하였다. 한 번 고장 상태가 판정되면 이후에 수집되는 디지털 제어 신호에 대해서는 추가 판정을 하지 않는 대신, 계속해서 고장 상태로 간주한다. 반면에 한 공정 사이클이 종료할 때까지 도출되는 에러 값이 임계 값을 초과하지 않는다면, 해당 공정은 시작부터 종료까지 모두 정상적으로 완수한 것으로 판단한다. 이와 같이 하나의 공정 사이클에 대해 정상 또는 고장으로 판단한 결과를 이용하여 최종적으로 정확도를 계산하여 전체 모델의 성능으로 사용하였다.

$$\text{정확도} = \frac{\text{고장 감지 모델이 올바르게 판단한 공정 사이클의 수}}{\text{주어진 데이터 내 공정 사이클의 수}}$$

분석 결과, 학습 성능(학습 데이터를 입력하였을 때의 정확도)과 테스트 성능(테스트 데이터를 입력하였을 때의 정확도)이 모두 100%로 도출되었다. 디지털 신호로만 구성된 입력 값만 활용함에도 불구하고, 주어진 LSTM 기반의 고장 감지 모델과 PLC로부터 수집된 디지털 제어 신호를 활용할 경우 올바르게 현재 상태를 판단할 수 있음을 확인하였다.

4. 결 론

본 연구에서는 이산 자동화 제조 공정에서 손쉽게 수집되는 디지털 제어 신호만을 이용하여 현재 공정 상태를 정상, 고장으로 판단하기 위한 고장 감지 모델을 구축하였다. 디지털 제어 신호는 아날로그 신호와 달리 각각의 센서 신호가 내포할 수 있는 정보는 매우 적으나, 자동화 공정의 움직임에 따라 센서 값이 변화함으로 시퀀스 정보를 직관적으로 확인할 수 있다는 특징이 있다. 이러한 시계열 데이터의 특징을 고려하기 위하여 LSTM 기반의 고장 감지 모델을 구축하였다. 현재 디지털 제어 신호 벡터를 입력하면 해당 LSTM 고장 감지 모델이 출력 값으로 다음 타임 스템프에 수집될 신호 벡터를 생성한다. 생성된 예측 값과 실제 수집되는 다음 디지털 제어 신호 값을 비교하여 일정 수준 이상이면 해당 타임 스템프에 이상 동작으로 인한 고장이 발생하였다고 간주하였다. 실제 레이저 각인 공정에서 수집된 데이터로 그 성능을 검증할 결과 모든 고장 상태에 대해 감지할 수 있음을 확인하였다.

그러나 해당 연구의 경우 하나의 이산 자동화 제조 공정에서만 성능을 검증하였으므로, 다른 형태의 작업이 이루어지는 공정으로부터 수집된 데이터를 이용하여 일반화된 성능에 대한 검증이 추가 필요하다. 본 연구에서는 은닉층 및 해당 은닉층의 노드 수에 대하여 경사 하강법을

이용하여 LSTM 모델의 최적화를 수행하였으나, 학습 데이터에 대한 과적합을 방지하기 위해서, 활성화 함수 등과 같은 다양한 하이퍼 파라미터에 대한 추가적인 최적화가 필요하다. 또한 이산 자동화 제조 공정의 유지보수에 도움이 되기 위하여 현재 고장을 감지하였던 시기가 실제 고장이 발생하고 나서 얼마 이후인지에 대한 추가 정보나 실제 수행하여야 할 동작 단계 등과 같은 설비 관리 적인 측면에서의 정보가 추가적으로 주어질 필요가 있다.

Acknowledgement

This work was supported by Korea Institute for Advancement of Technology (KIAT) grant funded by the Korea Government (MOTIE) (P0012744, The Competency Development Program for Industry Specialist), and was also supported by the research fund of Hanbat National University in 2020.

References

- [1] Cheon, K.M. and Yang, J., An Ensemble Model for Machine Failure Prediction, *J. Soc. Korea Ind. Syst. Eng.*, 2020, Vol. 43, No. 1, pp. 123-131.
- [2] Cho, S.-J., Jun, H.-B., Shin, J.-H., and Hwang, H.-J., A Study on Estimating the Next Failure Time of a Compressor in LNG FPSO, *J. Soc. Korea Ind. Syst. Eng.*, 2014, Vol. 37, No.4, pp. 12-23.
- [3] Fang, W., Guo, Y., Liao, W., Ramani, K., and Huang, S., Big Data Driven Jobs Remaining Time Prediction in Discrete Manufacturing System : A Deep Learning-based Approach, *International Journal of Production Research*, 2020, Vol. 58, No. 9, pp. 2751-2766.
- [4] Ghosh, A., Wang, G.-N., and Lee, J., A Novel Automata and Neural Network based Fault Diagnosis System for PLC Controlled Manufacturing Systems, *Computers and Industrial Engineering*, 2020, Vol. 139, pp. 1-16.
- [5] Hong, K., Heo, J., Hwang, S., and Lee, J., Analysis of Sensor Data for Detecting the Abnormal State of FD Fan, *Korean Journal of Computational Design and Engineering*, 2016, Vol. 23, No. 2, pp. 137-143.
- [6] Hwang, S., Heo, J., Hong, K., and Lee, J., Time Series Data Analysis and Fault Diagnosis of Plant Process Equipment Using Statistical Machine Learning Method, *Korean Journal of Computational Design and Engineering*, 2018, Vol. 23, No. 3, pp. 193-201.
- [7] Hwang, S., Kim, J., and Hwangbo, H., A Study of Sensor Data Analysis and Product Defect Improvement for Smart Factory, *The Journal of Bigdata*, 2018, Vol. 3, No. 1, pp. 95-103.
- [8] Ioannides, M.G., Design and Implementation of PLC-based Monitoring Control System for Induction Motor, *IEEE Transactions on Energy Conversion*, 2004, Vol. 19, No. 3, pp. 469-476.
- [9] Jung, H. and Kim, J.-W., A Machine Learning Approach for Mechanical Motor Fault Diagnosis, *J. Soc. Korea Ind. Syst. Eng.*, 2017, Vol. 40, No. 1, pp. 57-64.
- [10] Jung, T.-L., Choi, S.-W., Yoo, W., and Kim, B.S., A Real Time Temperature Monitoring System for Plating Process, *J. Soc. Korea Ind. Syst. Eng.*, 2015, Vol. 38, No. 4, pp. 72-79.
- [11] Kim, S. and Ryu, K., An AR based Monitoring System for Discrete Manufacturing, *Proceedings of 2018 Spring Korean Institute of Industrial Engineers*, Gyeongju, Republic of Korea, 2018, pp. 707-712.
- [12] Kwon, S., An, M., and Lee, H., Fault Detection and Classification of Process Cycle Signals Using Density-based Clustering and Deep Learning, *Korean Institute of Industrial Engineers*, 2018, Vol. 44, No. 6, pp. 475-482.
- [13] Lee, K., Ku, R., Choi, S., Park, C., Park, S., and Wang, J., PLC Code Generation for the Control of Production System, *Proceedings of 2008 Spring Korean Institute of Industrial Engineers*, Gwangju, Republic of Korea, 2008, pp. 128-134.
- [14] Miao, Y., Gowayed, M., and Metze, F., EESSEN : End-to-end Speech Recognition Using Deep RNN Models and WFST-Based Decoding, *Proceedings of 2015 IEEE Workshop on Automatic Speech Recognition and Understanding*, Scottsdale, AZ, U.S., 2015, pp. 167-174.
- [15] Murata, T., Komoda, N., Matsumoto, K., and Haruna, K., A Petri Net-Based Controller for Flexible and Maintainable Sequence Control and its Applications in Factory Automation, *IEEE Transactions on Industrial Electronics*, 1986, Vol. IE-33, No. 1, pp. 1-8.
- [16] Saez, M., Maturana, F.P., Barton, K., and Tilbury, D. M., Real-Time Manufacturing Machine and System Performance Monitoring Using Internet of Things, *IEEE Transactions on Automation Science and Engineering*, 2018, Vol. 15 No. 4, pp. 1735-1748.
- [17] Sameh, M., Tarek, A., and Yassine, K., Bearing and Rotor Faults detection and diagnosis of Induction Motors using Statistical Neural Networks, *Proceedings of 20th*

- International Conference on Sciences and Techniques of Automatic Control and Computer Engineering (STA)*, Monastir, Tunisia, 2020, pp. 77-81.
- [18] Selvin, S., Vinayakumar, R., Gopalakrishnan, E.A., Menon, V.K., and Soman, K.P., Stock Price Prediction Using LSTM, RNN and CNN-sliding Window Model, *Proceedings of 2017 International Conference on Advances in Computing, Communications and Informatics*, Udupi, India, 2017, pp. 1643-1647.
- [19] Seong, K., Han, K., Pyun, J., Wang, G., and Park, S., PLC Program Monitoring for Manufacturing Systems Using PLC Signal Time Difference, *Korean Journal of Computational Design and Engineering*, 2009, Vol. 14, No. 3, pp. 176-185.
- [20] Sherstinsky, A., Fundamentals of Recurrent Neural Network (RNN) and Long Short-Term Memory (LSTM) network, *Physica D : Nonlinear Phenomena*, Vol. 404, pp. 1-28.
- [21] Song, Y.-U. and Baek, S., Image Analysis based Data Pre-Processing of Digital Control Signals for Error Status Detection in Automatic Manufacturing System, *Proceedings of The Korean Society of Mechanical Engineers*, Pyeongchang, Republic of Korea, 2020, pp. 2075-2080.
- [22] Vathsala, M.K. and Holi, G., RNN based Machine Translation and Transliteration for Twitter Data, *International Journal of Speech Technology*, 2020, Vol. 23, pp. 499-504.

ORCID

Yong-Uk Song | <http://orcid.org/0000-0002-1821-8732>

Sujeong Baek | <http://orcid.org/0000-0002-9387-6217>