

설비 이상탐지를 위한 딥러닝 알고리즘 개발

김민희¹ · 진교홍^{2*}

Development of a Deep Learning Algorithm for Anomaly Detection of Manufacturing Facility

Min-Hee Kim¹ · Kyo-Hong Jin^{2*}

¹Graduate Student, Department of Smart Manufacturing Engineering, Changwon National University, Changwon, 51140 Korea

^{2*}Professor, Department of Electronic Engineering, Changwon National University, Changwon, 51140 Korea

요약

제품을 생산하는 설비의 고장이나 이상 현상은 곧 제품의 결함 및 생산라인 가동 중단으로 이어져 제조 업체의 막대한 경제적 손실의 원인이 된다. 스마트팩토리 서비스의 확산으로 공장에서 많은 양의 데이터가 수집됨에 따라, 이를 활용하여 제조 현장의 효율이나 제조 설비의 고장 예측 및 진단을 위한 인공지능 기반의 연구가 활발히 이어지고 있다. 하지만 정상과 이상을 구분 짓는 레이블 정보가 명확하지 않고 이상에 대한 극심한 클래스 불균형을 가지는 제조 데이터의 특징으로 인하여 분류 모델이나 이상탐지 모델의 개발에는 큰 어려움이 존재한다. 본 논문에서는 딥러닝 모델의 재구성 손실값을 이용하여 제조 설비의 이상탐지를 위한 딥러닝 알고리즘을 제안하고 성능을 분석하였다. 해당 알고리즘은 이상 데이터를 제외한 설비의 제조 데이터, 즉 정상 데이터에만 의존하여 이상을 감지한다.

ABSTRACT

A malfunction or breakdown of a manufacturing facility leads to product defects and the suspension of production lines, resulting in huge financial losses for manufacturers. Due to the spread of smart factory services, a large amount of data is being collected in factories, and AI-based research is being conducted to predict and diagnose manufacturing facility breakdowns or manufacturing site efficiency. However, because of the characteristics of manufacturing data, such as a severe class imbalance about abnormalities and ambiguous label information that distinguishes abnormalities, developing classification or anomaly detection models is highly difficult. In this paper, we present a deep learning algorithm for anomaly detection of a manufacturing facility using reconstruction loss of CNN-based model and analyze its performance. The algorithm detects anomalies by relying solely on normal data from the facility's manufacturing data in the exclusion of abnormal data.

키워드 : 스마트공장, 딥러닝, 제조 데이터, 이상탐지, 제조 설비

Keywords : Smart factory, Deep learning, Manufacturing data, Anomaly detection, Manufacturing facility

Received 30 November 2021, Revised 9 December 2021, Accepted 14 December 2021

* Corresponding Author Kyo-Hong Jin(E-mail:khjin@changwon.ac.kr, Tel:+82-55-213-3657)

Professor, Department of Electronic Engineering, Changwon National University, Changwon, 51140 Korea

Open Access <http://doi.org/10.6109/jkiice.2022.26.2.199>

print ISSN: 2234-4772 online ISSN: 2288-4165

© This is an Open Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License(<http://creativecommons.org/licenses/by-nc/3.0/>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.
Copyright © The Korea Institute of Information and Communication Engineering.

I. 서론

제조 업체의 가장 큰 자산이라 할 수 있는 생산설비의 고장이나 이상 현상은 제품의 품질 하락 및 전체 생산라인의 가동 중단을 초래해 막대한 손실을 초래할 수 있다. 이에 생산설비의 구성요소에 센서를 부착하여 수집된 센서 데이터와 생산관리시스템(Manufacturing Execution Systems)이나 전사적 자원관리(Enterprise Resource Planning) 시스템을 통하여 얻은 공정 데이터를 활용하여 제조 설비의 상태를 진단하거나 예측하는 인공지능 기반 이상탐지 모델의 개발이 활발히 진행되고 있다[1].

이러한 이상탐지 모델의 개발은 수집된 제조 데이터의 특성에 크게 좌우된다. 일반적으로 제조 데이터는 극심한 클래스 불균형(Class Imbalance)을 가진다[2]. 정상 상태 데이터에 비해 비정상 상태 데이터의 수는 분류 모델을 개발함에 있어 그 수가 현저히 부족하다[3]. 뿐만 아니라, 제조 데이터에는 생산설비의 정상 상태와 비정상 상태를 구분하는 레이블 정보가 포함되어 있지 않은 경우가 대부분이다. 따라서 지도학습(Supervised Learning)의 분류 모델을 통한 이상치 판별보다 GAN(Generative Adversarial Networks)[4]이나 오토인코더(Auto-encoder)와 같은 비지도학습(Unsupervised Learning) 모델을 통한 이상치 판별 방식이 더욱 적합하다[5].

본 논문에서 이상탐지의 대상으로 사용한 제조 설비는 Machining Center Tool이다. 이 설비는 여러 공구를 자동으로 교체하면서 고정된 제품을 가공하는 공작기계이다. 내장된 컴퓨터를 활용하여 프로그래밍된 가공 순서에 따라 면 깎기, 나사치기, 구멍뚫기, 홈파기 등의 작업이 진행된다. 머신 내부에 센서를 부착하여 작업 과정에서 발생하는 여러 데이터를 수집하고, 이상탐지 모델의 학습 데이터로 사용하였다.

본 논문에서는 설비의 이상탐지를 위한 딥러닝 알고리즘을 소개한다. 개발된 이상탐지 알고리즘은 CNN(Convolutional Neural Network)[6]을 기반으로 한 인코더와 디코더로 구성된 딥러닝 모델을 사용하며, 모델의 재구성 손실값(Reconstruction Loss)을 이용한다[7]. 여기서 재구성 손실값은 모델의 입출력 간 차를 의미한다. 학습에 용이하도록 단순이동평균(SMA: Simple Moving Average)을 활용한 기법을 적용하여 수집된 특정 설비의 제조 데이터를 변환한다. 변환된 데이터는 정상 상태 패턴 추출을 통해 분할되어 정상만이 담긴 학습 데이터

셋을 구성한 후 모델의 학습에 사용된다. 그리고 새로운 데이터를 모델의 입력으로 사용할 시 발생하는 재구성 손실값을 확인하여 설비의 이상을 탐지한다. 그리고 재구성 손실값에 대한 임계값(Threshold)을 설정하고 레이블 정보를 부여한 후 이상탐지율을 확인한다.

본 논문의 구성은 다음과 같다. 2장에서는 관련 연구 내용을 기술하고, 3장에서는 수집된 설비의 제조 데이터에 관한 내용과 이상탐지 알고리즘에 대하여 단계적으로 설명하였다. 4장에서는 개발한 알고리즘의 성능을 분석하였으며, 마지막으로 5장에서는 결론 및 향후 연구를 기술하였다.

II. 관련 연구

2.1. 이상탐지

정상의 분포에서 이탈된 데이터 샘플, 즉 이상치를 우리는 ‘Anomaly’, ‘Outlier’, ‘Novelty’ 등으로 다양하게 지칭한다. 이상치의 유형은 의도적인 유형과 의도적이지 않은 유형으로 나눌 수가 있다[8].




Fig. 1 Types of Anomalies

의도적인 유형에는 의도적으로 설계하여 DNN[9] 모델이 잘못된 결과를 도출하도록 의도하는 이상치인 적대적 예제(Adversarial Example)가 속한다. 적대적 예제가 정상 데이터로 위장하는 경향이 있을 시, 이는 이상탐지 시스템에서 해결하기 어려운 고난이도 문제에 속한다. 그러므로 이를 방어하기 위한 연구는 교란이나 해킹을 목적으로 만들어진 샘플에 대해 모델을 보다 강력하고 견고하게 발전시키기 위한 단계로 이어진다.

또한, 의도적이지 않은 유형은 신규성 이상치(Novelty)와 분포 외 예제(OOD: Out-Of-Distribution Example)로 분류되며, 이 유형은 DNN 모델과는 독립적이다. 신규성 이상치는 다수의 인스턴스와 본질적으로는 같지만,

종류가 다른 신규 또는 알려지지 않은 분포 내 데이터이다. 신규성 이상치는 이상탐지 시스템에서 정상 데이터로 분류되는 데이터지만, 분포 외 예제는 정상 분포에 속하지 않는 데이터를 가리키며 일반적으로 폐기된다. 그림 1에 이상치의 유형에 따른 예시를 나타내었다.

특징 공간에서 정상 상태의 영역을 정의하고, 이 영역을 벗어나는 경우를 비정상 상태로 정의하는 것이 이상탐지를 위한 기본적인 접근 방식이다. 하지만 정상 상태 영역과 비정상 상태 영역의 경계를 정의하는 것이 어렵고, 애플리케이션 유형에 따라 비정상 상태의 경계나 정의가 바뀔 수 있다. 또한, 정상 또는 비정상 상태에 대한 정보를 담고 있는 레이블 정보의 포함 유무는 활용 가능한 이상탐지 기법의 선택에 큰 부분을 차지한다. 이러한 고려사항들은 이상탐지 시스템 개발 방향을 결정하는 큰 요인이 되므로 해결하기 매우 어렵다[8, 10].

2.2. 이상탐지 애플리케이션

수집되는 데이터의 종류에 따라 다양한 분야에서 이상탐지를 위한 연구가 활발하게 진행되고 있다. 이상탐지가 적용된 실제 애플리케이션을 표 1에 나타내었다 [10].

Table. 1 Application Domains of Anomaly Detection

Application	Goal	Major Data-type
Intrusion Detection	Detecting malicious activity in a computer system	Time Series
Fraud Detection	Detecting fraud in many areas of e-commerce, such as banking, insurance or law enforcement	Tabular
Malware Detection	Detecting malicious code	Malware-Tabular Image
Medical Detection	Detecting diseases in medical data such as brain waves and medical images	Signal Image
Social Networks Anomaly Detection	Detecting spam emails or false information distributors	Text
Log Anomaly Detection	Tracking the cause of failure through the log recorded by the system	Text
IoT Big-Data Anomaly Detection	Detecting outliers in sensor data collected by IoT equipment	Time Series

Application	Goal	Major Data-type
Industrial Anomaly Detection	Detecting outliers in manufacturing data	Image Time Series
Anomaly Detection in Time series	Detecting outliers in process data, international oil prices, stock prices, and electricity demand	Time Series
Video Surveillance	Detecting abnormal behavior in the video	CCTV

컴퓨터 시스템의 이상 행위를 탐지하기 위한 침입탐지(Intrusion Detection), 보험이나 신용 및 금융과 관련하여 많은 전자상거래 영역에서 발생하는 불법 행위를 검출하기 위한 사기검출(Fraud Detection), 악성코드를 검출하기 위한 악성소프트웨어탐지(Malware Detection), 의학 데이터에서 기기의 오류나 환자 상태에 대한 이상을 검출하기 위한 높은 정확성을 요구하는 의료탐지(Medical Detection), 스팸 메일이나 허위 정보 유포자 등을 검출하기 위한 사회적 네트워크 이상탐지(Social Networks Anomaly Detection), 시스템상에 기록된 로그 기록을 통해 고장 원인을 검출하기 위한 로그 이상탐지(Log Anomaly Detection), 사물인터넷 장비가 수집한 센서 데이터에서 이상치를 검출하기 위한 IoT 빅데이터 이상탐지(IoT Big-Data Anomaly Detection), 제조 데이터에서 이상치를 검출하기 위한 산업적 이상탐지(Industrial Anomaly Detection), 공정 데이터나 주식 가격 및 전력 수요 등 시계열적 데이터에서 이상치를 검출하기 위한 시계열 이상탐지(Anomaly Detection in Time Series), CCTV와 같은 영상에서 이상 행위를 검출하는 비디오 감시(Video Surveillance) 등 다양한 데이터 유형(시계열, 표, 이미지, 텍스트, 신호, 영상 등)을 활용한 여러 도메인에서 이상탐지의 적용 사례를 찾아볼 수 있다 [10]. 이밖에도 이상탐지가 적용될 수 있는 분야는 무궁무진하며, 각 도메인의 특성을 반영하여 다양한 목적의 이상탐지 연구가 진행되고 있다.

III. 설비 이상탐지 알고리즘

3.1. 설비 제조 데이터

설비 제조 데이터는 머신의 내부에 부착된 전력, 온도, 진동, 압력, 습도 센서를 통하여 1초 단위로 수집되

는 센서 데이터와 공정 데이터이다. 공정 데이터는 설비명, 제품코드나 제품명, 생산 시작과 종료, 설비의 이상유무, 제품의 품질 등의 다양한 이벤트 정보를 기록한 데이터로 MES와 현장 작업자에 의해 기록된다. 표 2와 표 3에 센서 데이터와 공정 데이터의 예를 제시하였다.

Table. 2 Sensor Data Example of the Facility

	Date	Po	Te	Vi	Pr	Hu
1	2021-05-10 4:36:51 PM	2626.8	25.83	0.1	41.78	25.31
2	2021-05-10 4:36:52 PM	2414.7	25.82	0.1	41.02	25.33
3	2021-05-10 4:36:53 PM	2331.2	25.81	0.11	40.6	25.27
4	2021-05-10 4:36:54 PM	2440.2	25.83	0.12	40.2	25.28
5	2021-05-10 4:36:55 PM	2462	25.81	0.11	39.6	25.3

Table. 3 Process Data Example of the Facility

	Date	Status	Code	Name	Remarks
1	2021-05-10 7:09 AM	end	360	A	putting materials in
2	2021-05-10 7:28 AM	start	360	A	-
3	2021-05-11 17:40 PM	end	360	A	-
4	2021-05-11 19:46 PM	start	365	B	-

표 2에서의 Po, Te, Vi, Pr, Hu는 각각 전력(Power), 온도(Temp), 진동(Vibration), 압력(Press), 그리고 습도(Humidity)를 나타내며, 표 3에서의 Status, Code, Name, Remarks는 각각 설비상태(Manufacture status), 제품코드(Product code), 제품명(Product name), 그리고 기타사항을 나타낸다.

설비에서 생산되는 하나의 제품공정은 3가지 단계로 이루어지며, 총 720초의 공정시간을 갖는다. 센서 데이터를 상관분석하여 시간 단위를 증가시킬수록 전력과 진동 데이터의 상관관계가 증가함을 확인한 후, 공정 데이터에 포함된 제품생산 구간 정보와 센서 데이터에서 반복적으로 나타나는 유사 패턴의 비교분석을 통해 전력과 진동 데이터가 이상탐지 모델의 학습에 적합하다고 판단하였다.

3.2. 설비 이상탐지 알고리즘

설비 이상탐지 알고리즘은 단계적으로 크게 전처리, 학습, 이상탐지 순으로 진행된다.

전처리 단계는 센서를 통해 수집된 설비의 전력 및 진동 데이터를 딥러닝 모델의 입력에 맞게 분할하는 작업이다. 데이터 분할을 위해서는 데이터 값의 흐름과 시각적 특징을 파악하는 것이 중요하다.




Fig. 2 SMA-processed Power and Vibration Data

단순이동평균 기법을 이용하여 값의 변동성을 줄이고, 선형 보간을 통하여 시계열의 결측치를 제거한다. 이를 통해 학습 모델이 공통된 속성을 찾거나 일반화에 용이하도록 하여, 값의 변동성 및 무작위적인 변화량을 줄이는 동시에 시간 간격을 고정한다. 그림 2는 실제 데이터에 단순이동평균을 적용한 전력과 진동 데이터의 그래프이며, 특정한 패턴이 반복되고 있음을 확인할 수 있다. 이에 패턴 추출을 통하여 딥러닝 모델의 학습 데이터셋을 구성하고자, 유사 패턴들의 분포로부터 분포의 중심에 해당하는 대표 패턴을 생성하고, 그 패턴과 실제 패턴을 대조해보는 유사도 비교를 수행하였다.

유사도 비교는 대표 패턴과 실제 패턴과의 차이 계산을 통하여 낮은 측정치를 획득할 시 패턴 간의 높은 유사성을 가지는 것으로 판단한다. 일정한 시간 구간을 윈도우로 설정하여 그 구간동안 가장 차이가 적은 부분이 패턴의 시작점이며, 그림 3에 제시하였다. 그 시작점들로부터 720초의 공정시간을 추출하는 작업을 통하여 정상만이 담긴 유사 특정 패턴 문치를 확보하였다.




Fig. 3 Similarity Comparison

학습 단계에서는 CNN을 적용한 인코더와 디코더로 구성된 오토인코더 구조를 활용하였으며, 학습에 사용한 딥러닝 모델의 인코더와 디코더 계층 구조는 그림 4, 그림 5에 제시하였다. 각 레이어 사이에는 배치 정규화 (Batch Normalization)와 LeakyReLU 활성화 함수 (Activation Function)를 배치하였으며, 인코더의 마지막 계층에는 GlobalMaxPooling을 사용하여 모델을 구성하였다. 전처리 단계에서 획득한 720초 패턴 길이의 설비 전력 및 진동 데이터의 정상 데이터 집단을 인코더의 입력으로 사용하였으며, 제조 데이터의 특징을 추출하여 잠재 벡터(Latent Vector) Z 를 생성한다. 그리고 잠재 벡터 Z 를 통해 디코더는 인코더의 입력과 유사한 형태의 출력 데이터를 생성한다. 딥러닝 모델에 정상 패턴을 반복적으로 학습시키고, 출력이 입력과 비슷해질 수 있도록 손실값을 최소화하면서 복원율보다는 이상 탐지율에 초점을 두었다.

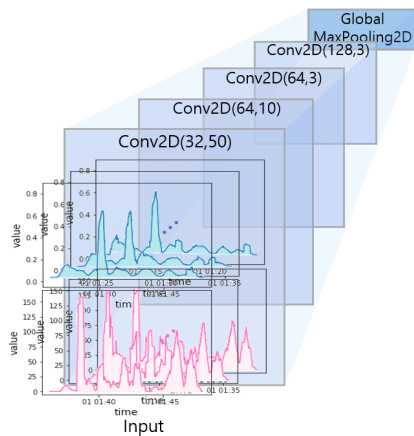


Fig. 4 Encoder

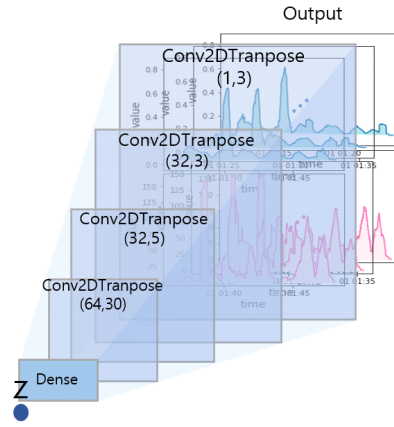


Fig. 5 Decoder

마지막으로 이상탐지 단계에서는 재구성 손실값을 확인하고 임계값을 설정하여 특정 임계값 초과일 시 이상, 미만일 시 정상으로 판단한다. 이상탐지 알고리즘의 최종 단계에서 사용한 테스트 데이터는 월별 제조 데이터이다. 모델의 입력과 크기가 동일하도록 분할하기 위하여 720초 크기의 윈도우를 1초 단위로 슬라이딩하면서 학습 단계를 거친 모델로 입력된다. 그림 6에서 비교적 낮은 차이 값을 보이는 구간이 정상 구간, 비교적 높은 차이 값을 보이는 구간이 이상 구간이다. 모델의 성능 평가를 위해 임계값을 기준으로 데이터에 대한 레이블 정보를 부여하였다.




Fig. 6 Reconstruction loss

다음 그림7은 제안된 알고리즘의 순서도이다. 전처리 단계(Preprocessing Step), 학습 단계(Learning Step), 그리고 이상탐지 단계(Anomaly Detection Step)를 화살표 방향으로 나타내었다.

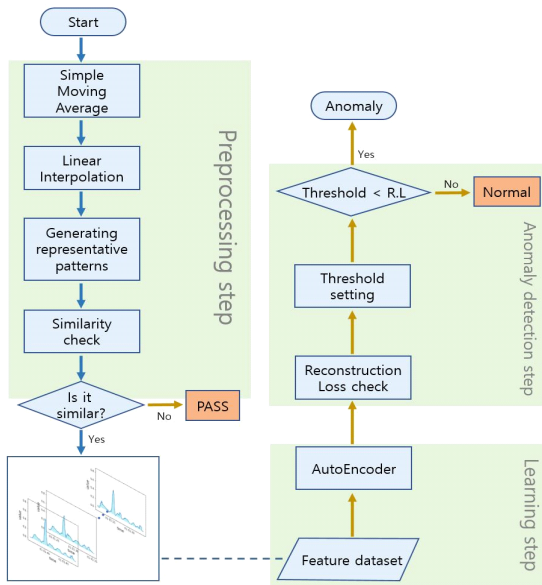


Fig. 7 Algorithm Flowchart

IV. 성능 평가

성능 평가 지표로는 재현율(Recall), 정밀도(Precision), 재현율과 정밀도의 조화평균인 F_1 -score, 그리고 재현율과 정밀도의 기중조화평균인 F_2 -score를 사용하였으며, 이상에 대한 성능 파악을 위한 재현율에 비중을 두 고자 최종 성능은 F_2 -score로 확인하였다.

단순이동평균을 적용할 시 설정하는 윈도우의 크기에 따른 성능의 차이를 표 4에 제시하였다. 윈도우는 한 번에 고려할 수 있는 데이터를 바라보는 창이며, 그 크기는 한 번에 고려할 수 있는 데이터의 범위를 나타낸다. 잠재 벡터의 차원을 일정하게 고정한 후 윈도우의 크기를 60초로 설정하여 진행하였을 경우 F_2 -score 92.89%의 가장 높은 성능을 보였다. 윈도우의 크기를 크게 설정할수록 설비 전력 및 진동 데이터 패턴의 형태를 단순하게 변화시켜 딥러닝 모델의 학습이 원활하게 진행되지만, 데이터가 가진 정보의 손실을 야기하므로 적절한 조절이 요구된다.

잠재 벡터에 따른 성능 차이는 표 5에 제시하였다. 표 5에서 윈도우 크기를 고정한 후 잠재 벡터 차원은 30으로 설정했을 때 F_2 -score 93.13%의 성능을 보였다. 차원이 커질수록 탐지에 불필요한 요소까지 포함시킬 수 있

으므로 차원에 따른 성능 차이가 발생하였다.

Table. 4 Comparison of performance according to window size of SMA-processing (Latent vector: 15)

SMA(s)	Recall	Precision	F_1 -score	F_2 -score
15	0.6796	0.8799	0.7669	0.7120
30	0.7702	0.8723	0.8180	0.7887
60	0.9388	0.8912	0.9143	0.9289
90	0.9642	0.8067	0.8784	0.9279
120	0.9674	0.2332	0.3758	0.5936

Table. 5 Comparison of performance according to latent vector dimension (Window size: 60 seconds)

Z	Recall	Precision	F_1 -score	F_2 -score
5	0.9335	0.8905	0.9115	0.9246
10	0.9369	0.8822	0.9087	0.9254
15	0.9388	0.8912	0.9143	0.9289
30	0.9417	0.8919	0.9161	0.9313
60	0.9441	0.8627	0.9015	0.9266

단순이동평균(SMA)의 윈도우 크기 설정 60초, 잠재 벡터 차원 30을 적용한 딥러닝 모델의 전체 기간에 대한 성능을 표 6에 제시하였다. 기간 A, B, C, D는 월별 데이터이며, 그 결과로 F_2 -score 96.37% 수준의 성능을 보였다.

Table. 6 Performance per period of the model applying window size of 60 seconds and latent vector dimension 30

Test	Recall	Precision	F_1 -score	F_2 -score
Period A	0.9834	0.9068	0.9436	0.9671
Period B	0.9417	0.8919	0.9161	0.9313
Period C	0.9874	0.9188	0.9519	0.9728
Period D	0.9891	0.8455	0.9116	0.9566
Total Period	0.9838	0.8913	0.9353	0.9637

V. 결론 및 향후 연구

제조 현장에서 수집되는 제조 데이터는 대부분 생산 설비의 정상 상태와 비정상 상태를 구분하는 레이블 정보가 없고, 정상 상태와 비정상 상태 데이터에 대한 극심한 클래스 불균형을 가진다. 이러한 특징을 지닌 제조 데이터를 이용하여 설비의 이상을 탐지하는 서비스를 개발하기 위해서는 정상 상태의 데이터만을 사용하여

모델을 학습시키는 비지도학습 기반의 딥러닝 모델의 사용이 요구된다.

본 논문에서는 설비에 관하여 수집한 제조 데이터와 대표적인 비지도학습 방법 중의 하나인 오토인코더 딥러닝 모델을 활용하여 설비의 이상 상태를 진단하는 알고리즘을 개발하고 성능을 평가하였다.

이상탐지 알고리즘은 크게 세 가지 단계로 나누어 서술하였으며, 전처리 단계에서는 데이터의 무작위적 변화량을 줄이는 단순이동평균 기법을 사용하여 값을 변화시켰다. 그리고 정상 대표 패턴을 생성한 후 실제 데이터와 유사도를 비교하였으며, 이를 통해 정상 대표패턴과 높은 유사성을 가지는 정상 패턴 데이터들만을 획득하였다. 이어서 학습 단계에서는 CNN 기반의 딥러닝 모델을 구성하고, 획득한 정상 패턴 특징을 사용하여 반복적으로 학습시켰다. 최종적으로 이상탐지 단계에서 재구성 손실값을 확인하여 제조 설비에 대한 F_2 -score 96.37%의 성능을 확인하였다.

개발한 이상탐지 알고리즘은 실제 설비에 적용해볼 예정이다. 또한, 랜덤 서치(Random Search)나 베이지안 최적화(Bayesian Optimization) 방식을 활용한 계층의 수, 필터의 크기, 드롭아웃(Dropout) 등 하이퍼파라미터 및 모델 구조의 최적화를 통해 비교적 낮은 정밀도를 향상시켜 현재보다 높은 F_1 -score 및 F_2 -score 도출을 목표로 발전시킬 계획이다. 또한, 실시간 이진분류만 가능한 현 개발 모델을 다중분류를 통한 제품 구분 및 고장 예측을 위한 딥러닝 모델로 발전시키고자 한다.

ACKNOWLEDGEMENT

This research was supported by Changwon National University in 2021~2022.

REFERENCES

- [1] J. H. Lee, J. H. Kim, J. B. Hwang, and S. S. Kim, "A Study on Fault Detection of Cycle-based Signals using Wavelet Transform," *Journal of the Korea Society for Simulation*, vol. 16, no. 4, pp. 13-22, Dec. 2007.
- [2] T. Lee, L. K. Lee, and C. Kim, "Performance of Machine Learning Algorithms for Class-Imbalanced Process Fault Detection Problems," *IEEE Transactions on Semiconductor Manufacturing*, vol. 29, no. 4, pp. 436-445, Nov. 2016.
- [3] S. Barua, M. Islam, X. Yao, and K. Murase, "MWMOTE-majority weighted minority oversampling technique for imbalanced data set learning," *IEEE Transaction on Knowledge and Data Engineering*, vol. 26, no. 2, pp. 405-425, Feb. 2014.
- [4] I. Goodfellow, J. P. Abadoc, M. Mirza, B. Xu, D. W. Farley, S. Ozair, A. Courville, and Y. Bengio, "Generative adversarial networks," *Communications of the ACM*, vol. 63, no. 11, pp. 139-144, Nov. 2020.
- [5] S. Akcay, A. A. Abarghouei, and T. Breckon, "GANomaly: Semi-supervised Anomaly Detection via Adversarial Training," *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, vol. 11363 LNCS, pp. 622-637, May. 2019.
- [6] R. Chauhan, K. Ghanshala, and R. Joshi, "Convolutional Neural Network (CNN) for Image Detection and Recognition," in *2018 First International Conference on Secure Cyber Computing and Communication (ICSCCC)*, pp. 278-282, Dec. 2018.
- [7] K. Qian, Y. Zhang, S. Chang, X. Yang, and M. H. Johnson, "AUTOVC: Zero-Shot Voice Style Transfer with Only Autoencoder Loss," in *International Conference on Machine Learning. PMLR*, pp. 5210-5219, May. 2019.
- [8] S. Bulusu, B. Kailkhura, B. Li, P. K. Varshney, and D. Song, "Anomalous Example Detection in Deep Learning: A Survey," *IEEE Access*, vol. 8, pp. 132330-132347, July. 2020.
- [9] J. Zhang, Y. Zheng, D. Qi, R. Li, and X. Yi, "DNN-Based Prediction Model for Spatio-Temporal Data," in *Proceedings of the 24th ACM SIGSPATIAL International Conference on Advances in Geographic Information Systems (SIGSPATIAL '16). Association for Computing Machinery*, New York: NY, pp. 1-4, Oct. 2016.
- [10] R. Chalapathy and S. Chawla, "Deep Learning for Anomaly Detection: A Survey," *arXiv preprint arXiv:1901.03407*, Jan. 2019.



김민희(Min-Hee Kim)

2019 창원대학교 전기전자제어공학부 전자공학전공 학사
2020-현재 창원대학교 대학원 스마트제조융합협동과정 제조시전공 석사과정
※관심분야: 제조 데이터 분석, 머신러닝, 딥러닝



진교홍(Kyo-Hong Jin)

1991 부산대학교 컴퓨터공학과 공학사
1993 부산대학교 컴퓨터공학과 공학석사
1997 부산대학교 컴퓨터공학과 공학박사
1997-2000 국방과학연구소 선임연구원
2000-2004 동의대학교 멀티미디어공학과 조교수
2004-현재 창원대학교 전자공학과 교수
※관심분야: 데이터통신, 제조 데이터 분석, 사물인터넷