

복합 임베디드 시스템 시계열 데이터를 활용한 딥러닝 이상 탐지 방법 비교 연구

임현재^{1,†} · 한성재¹ · 박주성¹ · 안기성¹ · 박주현¹

¹LIG넥스원

A Comparative Study of Deep Learning-Based Anomaly Detection Methods for Time-Series Data in Complex Embedded Systems

Hyun-Jae Im^{1,†}, Sung-Jae Han¹, Joo-Sung Park¹, Gi-Sung An¹ and Ju-Hyeon Park¹

¹LIG Nex1

Abstract

Complex embedded systems such as aircraft can lead to serious hazards when failures occur. This paper presents an anomaly detection model using deep learning techniques such as LSTM and 1D CNN on time-series datasets generated from complex embedded systems and compares inference results. Results showed that the 1D CNN model outperformed the LSTM model. Compared with the inference performance of a two-dimensional CNN model created in a previous study (Anomaly Detections Model of Aviation System by CNN), the two-dimensional CNN model had higher accuracy and recall. However, the 1-dimensional CNN model had faster inference speed. We can conclude that the 1D CNN model is more suitable than the LSTM model for anomaly detection in complex embedded systems that require real-time anomaly detection.

초 록

비행체 같은 복합 임베디드 시스템은 고장이 발생하면 심각한 위험을 초래할 수 있다. 본 논문에서는 복합 임베디드 시스템에서 출력되는 시계열 데이터 셋과 LSTM, 1차원 CNN과 같은 딥러닝 알고리즘을 활용하여 이상 탐지 모델을 생성하고 추론 결과를 비교했다. 그 결과 1차원 CNN 모델이 좋은 성능을 보였다. 이전 연구(합성곱 신경망을 활용한 항공 시스템의 이상 탐지 모델 연구)에서 생성한 2차원 CNN 모델의 추론 성능을 비교한 결과 정확도와 재현율은 2차원 CNN 모델이 높았지만, 추론 속도는 1차원 CNN 모델이 빨랐다. 실시간 이상 탐지가 필요한 복합 임베디드 시스템의 이상 탐지 모델에는 1차원 CNN 모델이 적합한 것으로 판단된다.

Key Words : Deep Learning(딥러닝), Anomaly Detection(이상 탐지), 1D CNN(1차원 CNN)

1. 서 론

비행체는 각종 센서류, 연산 컴퓨터, 엔진 등의 장치들이 유기적으로 연동되어 동작하는 복합 임베디드 시스템이다. 이러한 시스템은 한 가지 서브 시스템의 고장에도 임무 수행이 어려울 수 있다. 최악의 경우 비

행체가 추락하는 결과를 초래한다. 비행체와 같은 고장 시 위험을 초래할 수 있는 복합 임베디드 시스템은 개발, 생산, 운영의 모든 단계에서 품질 및 신뢰성 검증이 필요하다. 개발 단계에서는 비행시험, 각종 환경 시험 등을 통해 시스템의 신뢰성을 높이고 있으며 생산 단계에서는 스마트팩토리 구현으로 불량률을 줄이기 위한 노력을 하고 있다. 운영 단계에서도 통제 시스템을 통해 모니터링하고 진단한다.

에어버스사는 우주정거장에 장착된 컴퍼버스 모듈을 운영하며 탑승자와 시스템의 안정적 운영을 위해 데이

Received: Jul. 26, 2024 Revised: Sep. 09, 2024 Accepted: Sep. 29, 2024

† Corresponding Author

Tel: +82-031-5178-4559, E-mail: hyunjae.im@lignex1.com

© The Society for Aerospace System Engineering

터를 획득하고 지상에 전달하여 분석한다. 과거에는 운영자가 데이터를 확인하여 이상을 탐지하고 보고서를 작성했다. 현재는 인공지능을 활용한 우주정거장 분석 정보(ISS Analytics) 프로젝트를 통해 약 17,000 가지 종류의 텔레메트리(Telemetry) 데이터를 분석하여 이상을 탐지하고 해결하는 과정을 시스템화했다[1, 2].

일반 여객기, 도심항공교통(UAM), 운송용 소형 드론, 군용 무인기 등 다양한 비행체들이 개발되고 있으며 운영 예정이다. 이러한 비행체들이 안전사고 없이 안정적으로 운영되기 위한 이상 탐지가 필요하다. 본 연구는 시계열 데이터를 그래프 이미지로 생성한 데이터 셋과 2차원 CNN을 활용하여 이상 탐지를 수행한 연구의 후속 연구로 복합 임베디드 시스템에서 출력되는 전류 데이터에 대해 LSTM, 1차원 CNN(Convolutional Neural Network) 기법을 활용하여 이상 탐지 모델을 생성하고 결과를 2차원 CNN과 비교/분석했다. 정확도와 재현율을 모델의 성능 결과로 활용했으며 이상 탐지 시스템을 설계할 때 고려해야 하는 탐지 속도를 비교했다.

2. 이상 데이터 분석 및 전처리

2.1 이상 탐지 연구

이상 탐지(Anomaly Detection)는 정상과 이상을 구별하여 탐지하는 것을 의미하며 이상은 Novelty, Abnormality, Deviant, Outlier 등으로 표현하기도 한다[3, 4]. 이상 탐지는 금융, 의료, 제조 등의 분야에서 다양하게 활용되고 있다. 의료 분야에서는 질병을 진단하고, 금융 분야에서는 비정상 거래를 감지하고 제조 분야에서는 고장을 식별하는 데 활용되고 있으며 그 외에도 다양한 분야에서 활용되고 있다. 비행체와 같은 복합 임베디드 시스템은 제조 분야의 이상 탐지와 유사하게 시스템에서 출력되는 데이터 및 외부 점검 시스템에서 측정되는 데이터를 활용하여 이상을 탐지한다.

일반적인 시스템 이상 탐지 모델 생성은 데이터 불균형(Imbalance)으로 인해 어려움이 있다[5]. 고장 데이터는 전체 데이터의 1% 미만인 경우도 있다. 불균형을 해소하지 않고 사용하는 경우 모두 정상이라고

판단해도 99% 이상의 정확도를 출력한다. 예를 들어 캐글(Kaggle)에 공개된 신용카드 사기 거래는 Fig. 1과 같이 정상 284,807건 사기 거래는 492건으로 전체 거래의 0.2% 수준이다. 데이터 불균형 문제를 해소하는 방법으로는 언더샘플링과 오버샘플링 방법을 사용한다. 언더샘플링으로 정상 데이터를 줄이고 오버샘플링으로 이상 데이터를 증가시켜 정확한 학습이 되도록 균형을 맞춘다.

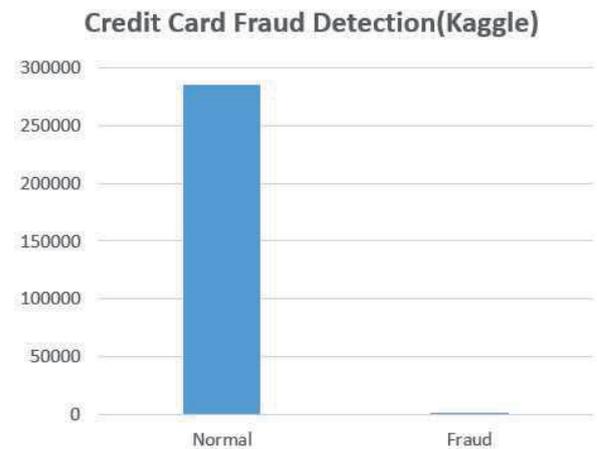


Fig. 1 Credit Card Fraud Detection Dataset

이상 탐지 연구의 경우 사용하는 데이터 및 활용 방법에 따라서 중요한 지표가 달라진다. 비행체와 같은 복합 임베디드 시스템의 경우에는 고장이 아닌데 이상이라고 판단하는 것(False Positive) 보다 고장인데 이상이 아니라고 판단하는 것(False Negative)이 더 치명적이기 때문에 학습 및 평가 지표 중 재현율(Eq. 1)이 중요하다. 본 연구에서도 모델에 대한 성능 평가 지표로 정확도와 재현율을 선정하여 비교했다.

$$Recall = \frac{TruePositive}{TruePositive + FalseNegative} \quad (1)$$

2.2 데이터 획득 및 전처리

본 연구에서는 복합 임베디드 시스템의 이상 탐지 모델을 생성하기 위해 전류 데이터를 활용했다. 전자/전기, 기계 구성품으로 구성된 비행체는 구성품 고장이 발생했을 때 전류 상태에 변화를 일으키기 때문이다. 데이터는 비행체의 전류 데이터 샘플을 참고하여

시뮬레이터를 만들고 데이터를 생성했다. 시스템에 전원을 2시간 공급하고 100msec 주기로 전류값을 출력하도록 했다. 정상 데이터는 약 8천 개, 고장 데이터는 약 3백 개를 생성했다. 정상 상태의 전류는 약 3.9~4.2A를 유지하는 것으로 설정했으며 고장은 시스템 운용 간 발생할 수 있는 경우를 모의했다. 형태는 Fig. 2의 첫 번째 그림과 같이 값의 변화율이 상대적으로 높은 경우, 두 번째 그림과 같이 변화율도 높고 순간적인 전류 상승을 나타내는 경우, 세 번째 그림과 같이 전류값이 일정 시간 동안 하락하는 경우, 마지막 그림처럼 전류값이 일정 시간 동안 급격히 상승하는 경우 등을 모의하여 데이터를 생성했다.

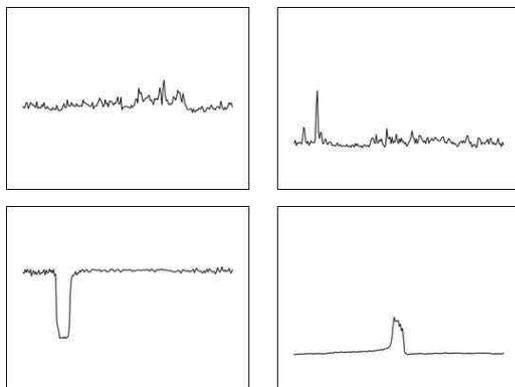


Fig. 2 Failure Data Shapes

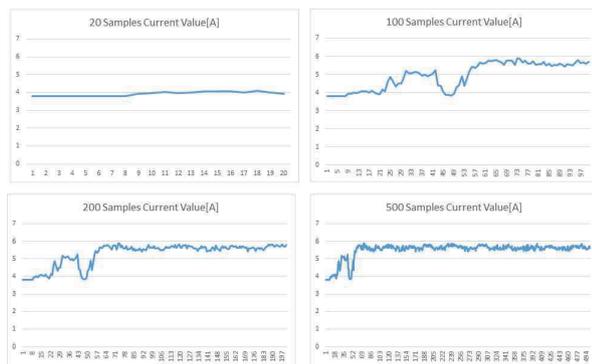


Fig. 3 Data Segmentation Comparison

시스템의 이상을 정확하고 빠르게 탐지하기 위해 생성한 데이터는 적절한 크기로 분할(Segmentation)이 필요하다. 2시간 동안의 데이터 하나의 데이터로 구분하여 이상을 탐지하는 경우 탐지 시점이 너무 늦다. 또한 데이터 분할은 고장의 형태가 잘 식별되도록 나

뉘야 한다. Fig. 3은 하나의 고장 데이터를 같은 시점부터 20, 100, 200, 500개 샘플로 분리하여 확인한 결과이다. 100개 이상의 샘플로 분할했을 때 고장의 형태를 식별할 수 있었다. 500개 샘플로 분할한 경우 50초 동안의 데이터로 이상을 판단하는 것으로 시스템의 판단이 늦어진다. 분할 크기 설정은 시스템의 특성과 데이터 모니터링 주기에 따라 다를 수 있다. 또한 실시간 판단이 필요한 경우에는 데이터의 분할 단위를 슬라이딩 방식으로 직전 데이터 N 개를 샘플로 설정할 수 있다. 데이터 분석 결과 본 연구에서 사용하는 데이터 세트는 100개, 200개 샘플 단위로 분할하는 것이 적합했다. 두 가지 분할 단위중 이전 연구와의 비교를 위해 데이터를 200개 샘플 단위(20초 단위)로 분할하여 전처리하였다. 데이터 세트는 언더샘플링으로 데이터 불균형을 해소하여 Table 1과 같이 정상 데이터와 고장 데이터를 각 50%의 균등한 비율로 구성했다.

Table 1 Data Set Size

Train set	Normal : 40,000
	Failure : 40,000
Test set	Normal : 10,000
	Failure : 10,000

3. LSTM을 활용한 이상 탐지

RNN(Recurrent Neural Network)은 임의 길이를 가진 시계열 데이터를 입력으로 받아 다음 값을 예측하는 모델로 가격 예측, 자연어 처리 등에 유용하게 사용된다. 본 연구에서 사용한 LSTM(Long Short-Term Memory)은 RNN의 일종으로 RNN의 장기 의존성 문제(Long-Term Dependency)를 해결하기 위해 나온 모델이다. LSTM은 중요한 정보를 장기적으로 기억하면서도 불필요한 정보를 효과적으로 잊을 수 있게 디자인되었다[6].

3.1 LSTM 네트워크 구성

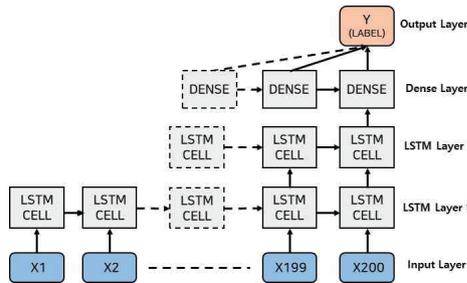


Fig. 4 LSTM Network

Table 2 LSTM Network Output Shape

Layer	output shape
Input Layer	200
LSTM Layer 1	200×128
LSTM Layer 2	64
Dense Layer	32
Output Layer(Dense)	1

LSTM을 활용한 딥러닝 네트워크는 Fig. 4와 같이 출력 모양은 Table 2와 같다. 입력 데이터는 200개의 샘플을 가지고 있는 CSV파일 형식이다. LSTM Layer 1은 시퀀스-투-시퀀스 형태로 128개의 뉴런으로 설정하였고 LSTM Layer2는 시퀀스-투-벡터 형태로 64개 뉴런을 설정했다. Dense Layer는 32개의 뉴런으로 설정했다. LSTM Layer의 깊이와 뉴런의 개수 등의 파라미터를 변화시키며 실험한 결과가 평균적으로 정확도가 잘 나오는 값으로 설정하여 실험했다. Dense Layer의 활성화 함수로 ReLU를 사용했고, 출력(Output) Layer는 활성화 함수로 Sigmoid를 사용했다.

3.2 LSTM 모델 학습과 결과

학습 반복 횟수 Epochs는 20으로 설정하고 학습률은 10^{-3} , 10^{-4} 두 가지로 설정하여 사전 실험을 수행했다. 학습률을 10^{-3} 로 설정하여 실험하였을 때 Fig. 5과 같이 학습 중 손실 값이 발산(Divergence)하는 경우가 약 50% 발생했다. 본 실험에서 학습률은 안정적인 결과를 출력하는 10^{-4} 로 설정하여 실험했다.

Epochs 20은 학습 결과가 안정적으로 출력되는 수준으로 설정했다. 다른 파라미터는 고정된 상태에서 실험 변수를 손실 함수와 Batch Size로 설정하고 독립적으로 10회씩 실험을 수행했다. 실험 결과는 Table 3과 같다. 손실 함수는 Binary Cross-Entropy와 MSE(Mean Square Error)가 비슷한 수준의 정확도와 재현율을 보였으며 Batch 크기를 조정해도 비슷한 결과를 나타냈다. 정확도는 90% 수준으로 양호했지만, 재현율은 81% 수준으로 활용하기 어려운 결과를 나타냈다.

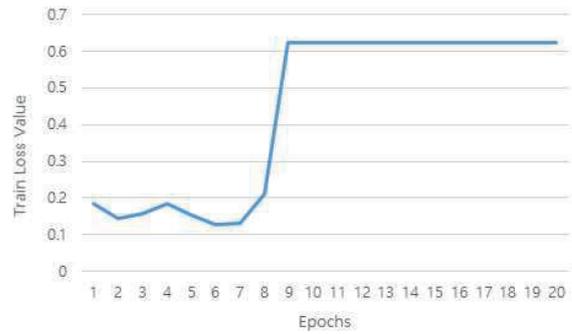


Fig. 5 Train Loss Value Divergence Graph

Table 3 LSTM Model Test Result

Loss Function	Batch Size	Accuracy	Recall
Binary Cross-Entropy	32	91%	82.1%
	64	90.5%	81.1%
MSE	32	90.5%	81.1%
	64	90.5%	81.1%

4. 1차원 CNN을 활용한 이상 탐지

1차원 CNN 모델은 이미지 데이터를 처리하는 2차원 CNN 모델과 유사한 방법과 절차로 학습을 수행한다. 1차원 시계열 데이터에 필터를 적용하여 특징을 추출한다. 가격 예측, 기상 데이터 분석, 오디오 신호 처리 등에 널리 사용된다. 1차원 CNN 모델은 2차원 CNN 모델과 비교해 상대적으로 학습 속도가 빠르고 메모리 사용량이 적은 특징이 있다[7].

4.1 1차원 CNN 네트워크 구성

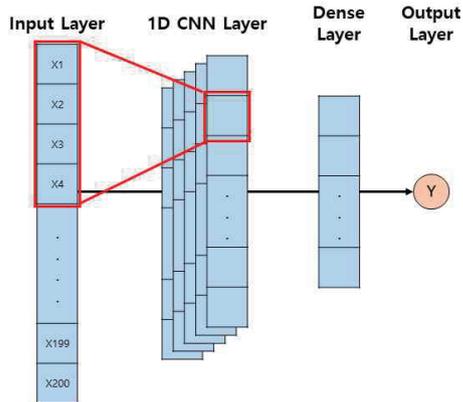


Fig. 6 1D CNN Network

Table 4 1D CNN Network Output Shape

Layer	output shape
Input Layer	200
1D CNN Layer	195×32
Dense Layer	128
Output Layer(Dense)	1

1차원 CNN을 활용한 네트워크 구성은 Fig. 6과 Table 4와 같다. 입력 데이터는 LSTM 네트워크에서 사용한 것과 같고 1차원 CNN Layer는 단층으로 구성하고 Dense Layer도 단층으로 구성했다. 1차원 CNN Layer를 단층으로 구성해도 파라미터에 따라 정확도와 재현율이 높게 나오는 경우가 있어 단층으로만 구성하고 파라미터를 변경하며 실험을 수행했다. 고정 파라미터로 1차원 CNN Layer의 필터 개수 32, 커널 크기 6으로 설정했다. Dense Layer는 128개 뉴런으로 설정했으며 1차원 CNN Layer와 Dense Layer 모두 ReLU를 활성화 함수로 사용했다. 출력 Layer는 활성화 함수로 Sigmoid를 사용했다.

4.2 1차원 CNN 모델 학습과 결과

Table 5 1D CNN Model Test Result

Loss Function	Batch Size	Accuracy	Recall
Binary Cross-Entropy	32	93.9%	88.1%
	64	95.8%	91.8%
MSE	32	96.5%	93.7%
	64	97.0%	94.5%

학습 반복 횟수 Epochs는 20으로 설정하여 학습을 수행했다. 파라미터를 변경하며 사전 실험을 수행한 결과 LSTM 모델과 같이 학습률 10^{-3} 보다 크게 설정하면 학습 중 발산하는 경우가 발생하여 10^{-4} 로 설정하고 학습을 수행했다. 다른 파라미터는 고정한 상태에서 실험 변수를 손실 함수와 Batch Size로 설정하고 10회씩 독립적으로 실험을 수행했다.

시험 결과는 Table 5와 같이 손실 함수를 MSE로 설정하였을 때 Binary Cross-Entropy의 결과보다 1.9% 높은 정확도를 보였으며 4.1% 높은 재현율을 보였다. 각 손실 함수에서 Batch 크기 32로 설정했을 때보다 64로 설정했을 때 정확도와 재현율이 모두 개선되는 것을 확인할 수 있었다. Batch 크기를 128로 설정하여 실험한 결과는 정확도와 재현율이 64로 설정한 결과 대비 차이가 1% 미만이었다.

5. 이상 탐지 방법 결과 분석 및 비교

5.1 이상 탐지 정확도 및 재현율 분석

Table 6 Anomaly Detection Results

Model	Accuracy	Recall
LSTM	91%	82.1%
1D CNN	97.0%	94.5%
2D CNN	99.7%	98.9%

Table 6은 같은 데이터 셋을 이용하여 이전 수행한 연구인 2차원 CNN을 활용한 모델에 적용하여 실험한 내용을 추가한 결과이다[8]. 같은 데이터 셋을 Fig. 2와 같은 그래프 이미지로 변환하여 2차원 CNN 모델에 적용했다. 2차원 CNN 모델은 2개의 2차원 CNN Layer와 1개의 Dense Layer를 갖는 모델로 다양한 실험을 통해 파라미터를 최적화한 모델이다.

LSTM 모델의 정확도와 재현율은 실제 시스템에 적용하기에는 낮은 정확도와 재현율을 나타냈지만 1차원 CNN과 2차원 CNN은 실제 시스템에 적용할 수 있는 90% 이상의 높은 정확도와 재현율을 나타냈다. LSTM 모델과 CNN 모델의 결과가 차이가 발생하는 이유로 LSTM 모델은 시계열 데이터의 시간적 장기

의존성 모델링에 강점이 있고 CNN 모델은 데이터에서 패턴을 감지하고 국소적 특징을 추출하는 데 강점이 있기 때문에 판단된다. 연구에 사용한 전류 데이터는 앞선 데이터와 뒤에 데이터의 장기 의존성이 크지 않고 국소적 패턴이 강한 형태를 나타낸다고 판단할 수 있다. LSTM 모델이 결과 지표가 상대적으로 낮은 다른 원인으로 충분한 양의 데이터가 없는 것도 이유가 될 수 있다.

5.2 이상 탐지 속도 분석

비행체와 같은 시스템의 이상 탐지는 정확도와 재현율만큼 탐지 속도가 매우 중요하다. 시스템 고장이 발생했을 때 실시간으로 대응해야 이후 발생할 수 있는 영향을 최소화할 수 있다. Table 7은 실험에서 사용한 모델을 정상 데이터와 고장 데이터 총 2만 개의 데이터 셋을 추론할 때 소요된 시간을 측정된 결과이다. 각 네트워크 구성 및 설계에 따라 결과가 변경될 수 있지만 실험에서 구축한 네트워크 기준으로 1차원 CNN이 가장 빠른 추론 속도를 보였다.

Table 7 Anomaly Detection Durations

Model	Evaluation Duration
LSTM	5.9 sec
1D CNN	2.2 sec
2D CNN	33.0 sec

2차원 CNN의 속도가 상대적으로 느린 이유는 1차원의 시계열 데이터를 이미지로 변형하여 데이터 셋으로 활용하여 실제 처리해야 하는 데이터 크기가 크기 때문이다. 시계열 데이터 원본은 200x1 데이터이지만 이미지는 160x120 픽셀로 입력 데이터 크기에 차이를 보인다. 또한 1차원 CNN 모델에서 사용하는 합성곱 연산과 풀링(Pooling) 연산이 LSTM 모델의 구조보다 병렬처리에 효율적으로 빠른 추론 속도를 보인다[7].

5. 결 론

본 연구는 시계열 데이터를 그래프 이미지로 생성한 데이터 셋과 2차원 CNN을 활용하여 이상 탐지를 수

행한 이전 연구의 후속 연구이다[8]. 이번 연구에서는 이미지 데이터가 아닌 시계열 데이터와 LSTM, 1차원 CNN을 활용한 이상 탐지 모델 생성하여 손실 함수, Batch 크기에 따른 성능 변화를 확인했다. 그 결과는 복합 임베디드 시스템의 전류 데이터를 활용한 이상 탐지에는 LSTM보다 1차원 CNN이 더 높은 정확도와 재현율을 보였다. 1차원 CNN 모델은 Binary Cross-Entropy보다 MSE를 손실 함수로 사용할 때와 Batch 크기를 64로 설정할 때 더 좋은 성능을 보였다. 1차원 CNN 모델은 2차원 CNN을 사용한 모델보다 정확도와 재현율은 낮지만, 추론 속도가 월등히 빨랐다. 여객용 비행체, 산업용 무인기, 스마트 팩토리과 같이 고장이 치명적인 위험 또는 손실이 될 수 있는 분야는 실시간으로 시스템의 상태를 모니터링하고 판단해야 한다. 이러한 시스템의 경우에는 높은 정확도와 재현율을 보이고 추론 속도가 빠른 1차원 CNN이 적합할 수 있다.

본 연구에서는 단순 LSTM 모델과 1차원 CNN 모델을 비교한 결과 LSTM 모델의 추론 성능이 낮게 측정되었다. 유사 시스템 이상 탐지 연구에서는 LSTM-AE(LSTM Auto Encoder)로 딥러닝 네트워크를 구성으로 실험하여 의미 있는 결과를 보였다[9]. 후속 연구로 LSTM-AE 모델을 사용하여 추가 실험을 수행할 계획이다. 또한 본 연구에서는 전류 데이터 한 가지 데이터만 사용하는 단변량 분석(Univariate Analysis) 방법을 활용했는데, 시스템의 다양한 데이터를 활용한 다변량 분석(Multivariate Analysis) 방법도 연구하고 실험할 계획이다[10].

이상 탐지 연구는 다양한 분야에서 활발히 이루어지고 있다. 하지만 2.1절 내용과 같이 데이터 불균형으로 인해 분석 및 딥러닝 모델 생성에 어려움이 있다. 적게는 1% 미만의 데이터를 구성하는 고장 데이터의 오버샘플링 방법에 대한 연구도 필요하다. 일반적으로 오버샘플링에 많이 사용하는 SMOTE(Synthetic Minority Over-sampling Technique) 방법과 생성형 인공지능 알고리즘인 GAN(Generative Adversarial Network)을 통한 데이터 증강(Augmentation)으로 고장 데이터를 오버샘플링 하여 실험한 결과가 원본 고장 데이터 대비 어떤 결과를 보이는지에 대한 연구도 필요하다.

References

- [1] How Airbus Detects Anomalies in ISS Telemetry Data Using TFX, <https://blog.tensorflow.org/2020/04/how-airbus-detects-anomalies-iss-telemetry-data-tfx.html>, April 2020.
- [2] L. Moddemann, H. Steude, O. Niggemann, P. Grashorn, "Automated Anomaly Detection and Diagnosis of the Environmental Control System of the ISS," the Helmut Schmidt University, dtec.bw - band 1, pp.123-128, 2022.
- [3] R. Chalapathy, S. Chawla, "Deep Learning For Anomaly Detection: A Survey," arXiv preprint arXiv:1901.03407, Jan 2019.
- [4] J. Seo, J. Park, J. Yoo, H. Park, "Anomaly Detection System in Mechanical Facility Equipment: Using Long Short-Term Memory Variational Autoencoder," *J Korean Soc Qual Manag*, vol. 49, no. 4, pp. 581-594, Dec 2021.
- [5] K. Choi, J. YI, C. Park, S. Yoon, "Deep Learning for Anomaly Detection in Time-Series Data: Review, Analysis, and Guidelines," *IEEE Access*, vol. 9, pp. 120043-120065, 2021.
- [6] Understanding LSTM Networks, <https://colah.github.io/posts/2015-08-Understanding-LSTMs>, Aug 2015.
- [7] J. Rostovski, M. Ahmadilivani, A. Krivosei, A. Kuusik, M. Alam, "Real-Time Anomaly Detection Using 1D-CNN and LSTM," *Nordic Conference NCDHWS 2024*, pp. 260-278, May 2024.
- [8] H. Im, T. Kim, J. Song, B. Kim, "Anomaly Detection Model of Aviation System by CNN," *Journal of Aerospace System Engineering*, vol. 17, No. 4, pp. 67-74, Aug 2023.
- [9] Y. Jung, E. Park, J. Kim, "Detection of Anomalities in Major Components of Unmanned Vehicles Using AI Algorithms Based on Autoencoder," *SASE 2023 Fall Conference*, pp. 43-45, Oct 2023.
- [10] K. Hundman, V. Constantinou, C. Laporte, I. Colwell, T. Soderstrom, "Detecting Spacecraft Anomalies Using LSTMs and Nonparametric Dynamic Thresholding," *24th ACM SIGKDD international conference on knowledge discovery & data mining*, pp 387-395, 2018.