

# 합성곱 신경망(CNN)을 활용한 항공 시스템의 이상 탐지 모델 연구

임현재<sup>1,†</sup> · 김태림<sup>1</sup> · 송종규<sup>1</sup> · 김범수<sup>1</sup>

<sup>1</sup>LIG넥스원

## Anomaly Detections Model of Aviation System by CNN

Hyun-Jae Im<sup>1,†</sup>, Tae-Rim Kim<sup>1</sup>, Jong-Gyu Song<sup>1</sup> and Bum-Su Kim<sup>1</sup>

<sup>1</sup>LIG Nex1

### Abstract

Recently, Urban Aircraft Mobility (UAM) has been attracting attention as a transportation system of the future, and small drones also play a role in various industries. The failure of various types of aviation systems can lead to crashes, which can result in significant property damage or loss of life. In the defense industry, where aviation systems are widely used, the failure of aviation systems can lead to mission failure. Therefore, this study proposes an anomaly detection model using deep learning technology to detect anomalies in aviation systems to improve the reliability of development and production, and prevent accidents during operation. As training and evaluating data sets, current data from aviation systems in an extremely low-temperature environment was utilized, and a deep learning network was implemented using the convolutional neural network, which is a deep learning technique that is commonly used for image recognition. In an extremely low-temperature environment, various types of failure occurred in the system's internal sensors and components, and singular points in current data were observed. As a result of training and evaluating the model using current data in the case of system failure and normal, it was confirmed that the abnormality was detected with a recall of 98 % or more.

### 초 록

최근 미래의 운송시스템으로 도심교통항공(Urban Aircraft Mobility)이 주목받고 있으며 소형 드론도 다양한 산업에서 역할을 하고 있다. 다양한 종류의 항공 시스템 고장은 추락으로 막대한 재산 및 인명 피해로 이어질 수 있다. 항공 시스템이 많이 활용되는 무기체계에서도 고장은 임무 실패의 결과를 유발한다. 본 논문에서는 항공 시스템의 이상(Anomaly)을 탐지하여 개발 및 생산 간 시스템의 신뢰도를 높이고 운용 중 사고를 예방할 수 있도록 딥러닝 기술을 활용한 이상 탐지 모델을 연구했다. 모델 훈련 및 평가 데이터로 극저온 환경에서 시스템의 전류 데이터를 활용하였으며 이미지 인식에 많이 활용되는 딥러닝 기법 합성곱 신경망(CNN; Convolutional Neural Network)을 활용하여 딥러닝 네트워크를 구현했다. 시험 대상 시스템은 극저온 환경에서 다양한 형태의 고장이 유발되었고 전류값의 특이점이 나타났다. 시스템 정상 및 고장 데이터를 활용하여 모델을 훈련 시키고 평가한 결과 98% 이상의 재현율(Recall)로 이상 탐지하는 것을 확인했다.

**Key Words** : Aviation System(항공 시스템), Artificial Intelligence(인공 지능), Anomaly Detection(이상 탐지), CNN(합성곱 신경망)

Received: May 25, 2023 Revised: Jun. 29, 2023 Accepted: Jul. 11, 2023

† Corresponding Author

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

© The Society for Aerospace System Engineering

## 1. 서 론

최근 미래 운송시스템으로 도심항공교통(UAM;

Urban Aircraft Mobility)이 주목받고 있으며 연구개발이 활발하게 이뤄지고 있다[1]. 소형 드론도 감시, 계측, 운송 등의 용도로 다양한 산업에서 활용되고 있다. 이러한 항공 시스템의 고장은 추락으로 이어져 인명 사고 또는 막대한 재산 피해를 초래한다. 국가적인 차원에서도 무인 항공 시스템이 기존 공역에서 안전하게 통합 운용될 수 있도록 K-UAM 운용개념서(1.0)을 발간했다[2]. 방위산업 분야에서도 무인항공기, 헬리콥터, 유도미사일 등의 다양한 항공 시스템이 이용되고 있는데 이러한 시스템의 고장은 임무 실패 및 인명 사고의 결과를 초래한다. 본 연구에서는 항공 시스템 개발 및 생산 간 출력하는 데이터를 딥러닝에 활용해 이상(Anomaly)을 탐지(Detection)는 연구를 수행했다. 항공 시스템의 이상 탐지는 신뢰도 높은 항공 시스템을 개발에 보조적인 역할을 할 수 있고 시스템 운용 간 항공사고 예방에 도움이 될 것이다.

이상 탐지 분야는 시스템의 정상적인 상태(Normal)와 구분되는 이상을 탐지하는 것으로 금융, 의료, 지능형 CCTV 등의 다양한 산업과 제품에서 활용되고 연구되고 있다[3]. 애플의 아이폰과 애플워치는 최근 충돌을 감지하여 긴급 구조서비스를 자동으로 요청하는 기능을 탑재했는데 이 또한 이상 탐지를 응용이라 할 수 있다. 제조업에서도 4차 산업혁명의 일환으로 제품 개발 및 생산 간 산출되는 데이터를 활용하여 이상 탐지 연구하며 생산성과 제품 신뢰도를 높일 수 있는 스마트팩토리를 구현하고 있다[4,5].

항공 시스템은 다양한 하위 시스템이 복합적으로 연동되어 있다. 하위 시스템에는 시스템의 종류에 따라 복수의 PCB(Printed Circuit Board) 모듈, 배선 장치, 모터 등이 있으며 PCB 모듈은 다수의 센서와 전자 소자를 포함한다. 일반적으로 항공 시스템은 자체점검(BIT; Built In Test) 기능이 있지만 센서와 전자 소자 단위에서 발생하는 다양한 형태의 고장 및 고장 징후를 모두 식별할 수 없다. 실제 고장이지만 자체점검은 정상으로 표시되는 사례가 종종 있다. 시스템의 자체점검은 개발자가 시스템 요구 조건, 하위 시스템의 특성 그리고 과거 개발 사례를 기반으로 논리를 구현한 것이다. 하지만 새로운 항공 시스템을 개발하며 내부 부품에서 발생하는 다양한 고장을 모두 식별하여 자체점검 기능에 포함하기는 어렵다. Figure 1과 같은 전

통적인 프로그래밍 접근으로는 복잡성과 다양성이 높은 시스템의 모든 고장을 식별하기 어렵다는 것을 의미한다[6]. Figure 2와 같이 인공지능 기술을 활용하는 접근 방식을 통해 전통적인 프로그래밍 접근 방식의 한계를 극복하는 것이 본 연구의 목표이다. 본 연구에서는 극저온 환경에서 항공 시스템 전류 데이터를 획득하고 데이터 전처리를 통해 시계열 데이터를 그래프 이미지로 변환하여 데이터 세트를 구축했다. 구축된 데이터 세트로 딥러닝 이상 탐지 모델을 생성하고 이를 평가했다.




Fig. 1 The Traditional Approach




Fig. 2 Machine Learning Approach

## 2. 시스템 및 데이터 획득 방법

### 2.1 시험 대상(Target) 시스템

항공 시스템은 그 사용 목적에 따라 다양한 하위 시스템으로 구성된다. 일반적으로 비행조종컴퓨터(FCC; Flight Control Computer), 복합항법장치(EGI; Embedded GPS/INS), 임무컴퓨터(MC; Mission Computer), 데이터링크장치(DLU; Datalink Unit), 영상획득장치(EOIR; Electro Optic Infra-Red)를 포함하고[7] 이외에 비행 방식 및 목적에 따라 엔진제어장치(Engine Control Unit), 레이더장치(Radar Unit), 라이더장치(Lidar Unit) 등 임무 수행을 위한 장치가 탑재된다. 각 장치는 내부적으로 PCB 모듈과 각종 센서 등이 탑재되어 있다. 실험에서 사용된 대상 시스템은

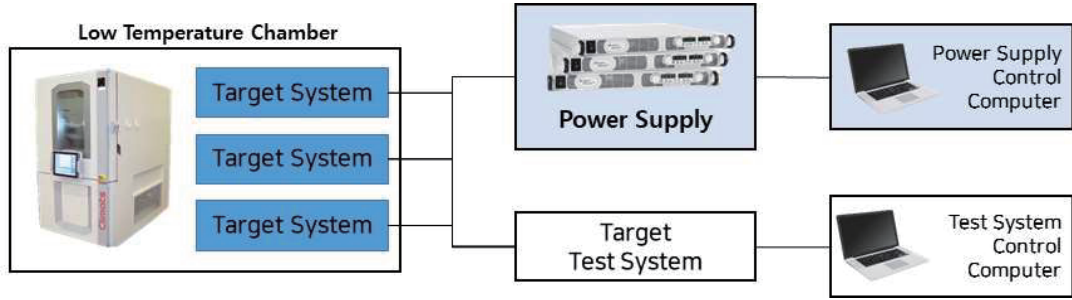


Fig. 3 Target System and Test System Configuration

위에 나열한 구성요소 대부분을 포함한 시스템으로 내부에 다수의 PCB 모듈과 센서류가 탑재되어 있다.

### 2.2 데이터 획득 방법

일반적인 항공 시스템이 운용될 수 있는 환경을 모의한 상태에서 고장을 유발하기 위해 대상 시스템을 저온 챔버(Chamber)에 넣고  $-40\text{ }^{\circ}\text{C}$  수준의 저온 시험을 진행했다. 시험 프로파일은 상온에서 시작하여  $-40\text{ }^{\circ}\text{C}$  수준으로 온도를 낮추어 일정 시간 유지하고 다시 상온으로 복귀하는 방식으로 진행했으며 300회 이상 시험하여 데이터를 획득했다. 시험의 구성은 Fig. 3과 같다. 대상 시스템 3조를 저온 챔버에 넣고 전원공급과 점검을 위한 시스템을 배치했다. 대상 시스템 점검장비를 통해 주기적으로 자체점검 결과를 수신하고 저장했다. 전원공급장치 제어 컴퓨터에서는 대상 시스템의 전원을 제어하고, 100 ms 주기로 3조의 대상 시스템의 전압과 전류 데이터를 수신하여 저장했다. 시험간 고장 발생 시 고장원인이 되는 부품을 수리 및 교체하며 시험을 계속 진행해 다양한 고장을 유발하고 출력 데이터를 획득했다.

### 3. 데이터 분석 및 전처리

Table 1 Failure Cases and Test Results

Failure Case	BIT Result	Current Singular Point
Comm. Module	Failure	X
PWR. Module	Failure	O
Element on Board	Pass	O
Sensor	Pass	O

### 3.1 고장 데이터 분석

시험이 진행되는 동안 다양한 부분에서 다양한 형태의 고장을 확인할 수 있었다. Table 1은 고장 발생 시 자체점검 결과, 전류 특이점의 일부 내용이다. 전자 소자 고장 사례와 센서 고장 사례의 경우 자체점검 결과는 정상이었지만 개발자가 고장을 식별하였고 전류 데이터에서 특이점을 확인했다. 서론에서 설명한 바와 같이 다양한 하위 시스템을 포함하고 복잡한 구성의 시스템은 자체점검 기능 구현에 있어 전통적인 프로그래밍 접근으로 한계가 있음을 시험 결과로 확인할 수 있었다.

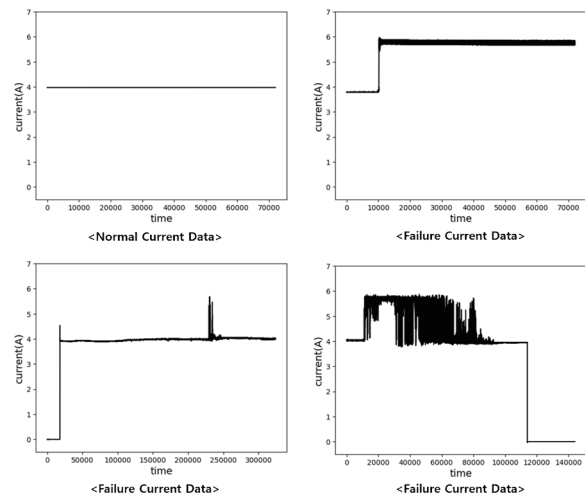


Fig. 4 Normal and Failure Current Data




Fig. 5 Normal and Failure Current Data(Enlarged)

Figure 4는 시험 중에 습득한 전류 데이터를 그래프로 나타낸 것이다. 좌상단 그래프는 정상일 때의 전류 중 하나를 그래프로 표현한 것이고 나머지 세 가지는 고장일 때 그래프의 일부이다. Fig. 5는 x축(시간)을 100배 이상 확대하여 표현한 그래프이다. 시스템에 고장이 발생했을 때 전류 데이터의 형태는 다양했지만 정상 전류 데이터와는 확연하게 구분되는 특징을 보였다. 전류가 1~2 A 정도 상승하는 경우, 기존 전류 수준에서 값이 불안정하게 흔들리는 경우, 두 가지 현상이 동시에 발생하는 경우 등 다양한 형태로 발생했다.

항공 시스템의 고장은 발생 후 최대한 빠르게 인지하고 대응하는 것이 항공사고 예방에 도움이 되기 때문에 긴 시간 동안 운용된 데이터를 하나의 데이터로 보는 것은 옳지 않다. 반면 너무 짧은 시간의 데이터로 고장을 판단하면 일시적인 오류를 고장으로 판단하여 이후 중요한 임무 수행을 못 하게 될 수 있다. 자체 점검을 판단하는 시간 기준은 시스템의 종류 및 목적에 따라 수 초 또는 수 분의 데이터 단위로 결정하여 고장 및 이상을 탐지해야 한다.

### 3.2 데이터 전처리

데이터는 시간 흐름에 따라 변화하는 전류값을 기록한 전형적인 시계열 데이터이다. 시계열 데이터는 신호 처리, 기상, 경제 등의 분야에서 데이터 분석을 통해 미래의 값을 예측하는 데 많이 활용되고 있다[4]. 이번 연구에서는 전류값 시계열 데이터를 활용하지만, 시스템의 미래 전류값을 예측하는 것이 아니라 일정 구간의 데이터를 Fig. 5와 같은 그래프 이미지로 변환하고 딥러닝 학습을 통해 항공 시스템의 이상을 탐지했다.

수집한 데이터는 3조의 시스템의 전압, 전류 데이터가 모두 포함된 raw 데이터이다. raw 데이터를 데이터 처리가 편리한 CSV 파일로 변환하고 시스템 3조의 데이터를 각각 분리하며 사용하지 않는 전압 데이터는 제거했다. 이 과정에서 과대적합(Overfitting)을 줄이기 위해 데이터 증식(Augmentation)을 수행했다[8]. 또한 데이터 변환 간 이상 탐지가 불필요한 전원을 공급하기 전 데이터를 필터링하였다. 데이터는 100 ms 주기로 수집된 데이터로 20초 단위(200개 데이터)로 구분하여 이미지를 생성했다. 데이터를 20초 단위로 분

리한 이유는 Fig. 5와 같이 그래프에 데이터의 특징이 잘 표현되었기 때문이다. 더 많은 데이터를 한 이미지에 그래프로 표현했을 때는 데이터의 특징이 누락되었고 적은 데이터 단위로 그래프를 표현했을 때는 시스템의 일시적인 오류도 고장으로 인식될 우려가 있었다. 이미지의 크기는 데이터의 특징 표현력과 모델 학습 및 평가 속도를 고려하여 너비 160 픽셀, 높이 120 픽셀로 설정했다. 이미지는 흰색 배경에 전류 데이터를 선 그래프로 나타낸 것이기 때문에 색상으로 표현할 수 있는 특징이 없어 회색조(Grayscale)로 이미지를 생성했다. Fig. 6은 데이터 전처리 과정을 도식화한 것이다.




Fig. 6 Data Pre-processing

수집된 데이터는 시스템 고장 발생 경우를 알고 있어 데이터 라벨링 작업은 필요하지 않았지만, 시험 중 인지되지 않은 특이 사항을 검수하는 작업을 수행했다. 데이터 전처리 프로그램은 Python으로 구현했으며 Numpy, Pandas 라이브러리를 활용하여 데이터 전처리를 수행하고 Matplotlib을 활용하여 그래프 이미지를 생성했다. 데이터 전처리 결과 고장 데이터 약 13만 개를 포함하여 전체 약 213만 개의 이미지 데이터를 준비했다.

## 4. 합성곱 신경망을 활용한 이상 탐지

연속적인 전류값과 같은 시계열 데이터를 통해 이상을 탐지하는 방법은 다양하다. 순환 신경망(RNN; Recurrent Neural Networks)의 일종인 LSTM(Long Short-Term Memory), 합성곱 신경망(CNN), 오토인코더(Autoencoder) 기법들을 활용한 방법과 이를 조합하여 모델을 생성하는 방법들도 연구되고 있다[4,9-13]. 본 연구는 데이터 전처리를 통해 전류값을 그래프로 표현한 이미지를 데이터로 활용했으며 합성곱 신경망 기법을 활용해 이상 탐지 모델을 훈련하고 성능을 평가했다.




Fig. 7 Typical CNN Architecture

### 4.1 합성곱 신경망(CNN)

합성곱 신경망은 생물의 시각 피질 구조 연구부터 시작되어 이미지 인식 분야 외 다양한 분야에 사용되고 있다. 합성곱 신경망의 구조는 Fig. 7과 같이 입력층, 몇 개의 합성곱층과 풀링(Pooling)층, 완전연결(Fully connected)층 그리고 출력층으로 이루어져 있다[6,14,15]. 입력된 데이터는 합성곱층에서 고유의 가중치를 갖는 합성곱 커널과 활성화(Activation)함수에 의해 특징이 추출된다. 풀링층은 의미상으로 유사한 특징들을 하나로 병합하는 층으로 최대나 평균 같은 합산 함수를 사용하여 축소본을 생성한다[14]. 또한 풀링층은 계산량과 메모리 사용량을 줄여주는 역할도 한다[6]. 완전연결층은 일반적인 신경망의 은닉(Hidden)층이며 데이터를 1차원 데이터로 평탄화한 후 최종 출력층에 연결된다.

### 4.2 이상 탐지 딥러닝 네트워크 구성

Table 2 Experiment Deep Learning Network

Layer	output shape
Input Layer	160×120
Conv2D Layer 1	160×120×64
Max Pooling Layer 1	80×60×64
Conv2D Layer 2	80×60×128
Max Pooling Layer 2	40×30×128
Flatten Layer	123600
Dense Layer	128
Dense Layer(Output)	1

본 연구에서 사용한 딥러닝 네트워크 구성은 Table 2와 같다. 입력 이미지는 160×120 크기의 회색조 이미지를 활용했으며 첫 번째 합성곱층(Conv2D Layer)은 5×5 크기의 합성곱 커널 64개로 설정하고 활성화함

수는 Eq. 1로 표현할 수 있는 ReLU(Rectified Linear Unit)를 사용했다. 두 번째 합성곱층은 커널 개수만 128개로 설정하고 나머지 첫 번째 합성곱층과 동일하게 설정했다. 입력된 크기의 이미지와 같은 크기의 층을 갖기 위해서는 입력의 주위에 값을 추가하는 패딩(Padding)이 필요한데 '0'으로 값을 채워 넣는 제로 패딩을 설정했다. 풀링층(Max Pooling Layer)은 두 개 층 모두 2×2 크기의 커널을 사용했으며 커널 안에 값 중 가장 큰 값을 뽑아내는 Max Pooling 방식을 사용했다. 완전연결층(Dense Layer)은 128개 유닛(뉴런), 활성화함수는 ReLU 함수를 사용했다. 출력층(Dense Layer)은 이상과 정상을 판별하는 1개의 유닛을 설정했고 시그모이드(Sigmoid) 함수를 활성화함수로 사용했다. 이진 분류(Binary Classification)에서 많이 활용되는 시그모이드 함수는 Fig. 8의 수식과 그래프를 보인다.

$$h(x) = \begin{cases} x & (x > 0) \\ 0 & (x \leq 0) \end{cases} \quad (1)$$




Fig. 8 Sigmoid Function

Table 3 Deep Learning Training Condition

Configuration	Value
Loss Function	Binary Cross Entropy
Optimizer	Adam
Learning Rate	0.0001
Epochs	5
Batch Size	32

$$Loss = - [y \log f(x) + (1 - y) \log(1 - f(x))] \quad (2)$$

딥러닝 네트워크를 훈련 조건은 Table 3과 같다. 검

중 데이터와의 차이를 계산하는 손실 함수로 Binary Cross Entropy(Eq. 2)를 설정했고, 옵티마이저는 Adam 알고리즘, 학습률(Learning Rate)은 0.0001로 설정했으며 Epochs를 5로 설정하여 전체 훈련 데이터를 5회 학습하도록 설정했다.

#### 4.4 실험 결과 및 성능 개선 과정

훈련과 평가에 사용한 데이터는 일반적인 이상 탐지 연구에서 활용하는 데이터와 유사하게 데이터의 불균형(Imbalance)을 보였다. 데이터는 정상 약 200만 개, 고장 약 13만 개로 15:1 비율을 나타냈으며 모두 정상으로 판단해도 약 93%의 정확도가 나올 수 있다. 데이터 불균형 문제는 언더샘플링(Undersampling)을 통해 보완하여 Table 4와 같이 정상과 고장이 4:1의 비율을 갖는 데이터를 준비했다[16,17]. 훈련 간 검증 세트는 훈련 세트의 10%로 설정했으며 실험에 사용한 컴퓨터 자원 및 소프트웨어 라이브러리는 Table 5와 같다.

**Table 4** Data Set Size

Train set	Normal : 160,000
	Failure : 40,000
Test set	Normal : 40,000
	Failure : 10,000


**Table 5** HW, SW Resource

CPU	Dual Intel Xeon E5
GPU	Nvidia Tesla V100(2cores)
Language	Python 3.8
SW Library	Tensorflow(Keras) 2.9

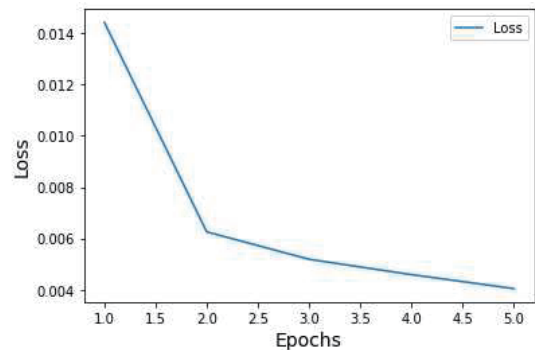
같은 조건에서 훈련과 평가를 5회 독립적으로 수행했다. 그 결과 훈련 정확도는 평균 99.83%, 평가 정확도는 평균 99.78%를 보였다. 고장의 영향이 심각한 위험을 유발할 수 있는 항공 시스템의 경우에는 고장이 아닌데 이상(Anomaly)이라고 판단하는 위험보다 고장인데 이상이 아니라고 판단하는 위험이 크기 때문에 정확도 보다 이상에 대한 재현율(Eq. 3)이 더 중요하다고 할 수 있다[6]. 총 5회 실험 결과 이상 판단에 대한 재현율은 약 98.93% 성능을 확인했다. 평가 데

이터 중 1,000개의 샘플 데이터에 대한 혼돈 행렬(Confusion Matrix)은 Fig. 9와 같다. 혼돈 행렬에서는 이상 탐지 모델이 198개의 고장 데이터 중 194개 데이터를 이상이라고 판단하고 4개를 정상이라고 오판단했음을 나타낸다.

$$Recall = \frac{TruePositive}{TruePositive + FalseNagative} \quad (3)$$



**Fig. 9** Confusion Matrix(1000 samples)



**Fig. 10** Loss-Epochs Graph

실험 과정에서 성능 개선을 위해 학습률(Learning Rate) 조정(Tuning)이 필요했다. 10회 독립적으로 실험한 결과 4회는 99% 수준의 정확도를 보였으나 6회는 2~3 Epochs(전체 훈련 데이터 학습 반복 횟수) 수행 중 83% 수준으로 정확도가 감소하는 현상을 보였다. Adam 옵티마이저의 기본 학습률 0.001로는 최적의 값을 찾지 못하고 발산(Divergence)하는 경우가 있는 것으로 판단된다. 발산 현상을 줄이기 위한 쉬운 방법으로 학습률과 배치 크기를 조정하는 것이 있는데

학습률을 0.0001로 조정하여 발산하는 현상을 제거할 수 있었다. 또한 적절한 수준의 Epochs를 설정하기 위해 값을 변화하며 실험한 결과 Fig. 10과 같이 Epochs 2 이상에서는 Loss 값 감소 수준이 낮아 Epochs 값을 5로 설정했다.

실험에서 사용한 데이터 세트는 언더샘플링으로 데이터 불균형을 보완했지만, 정상과 고장이 4:1 비율로 다소 불균형하다. 이상 탐지 모델의 신뢰도를 높이기 위해 추가적인 언더샘플링으로 정상과 고장 데이터를 Table 6과 같이 1:1 비율로 조정하여 실험한 결과도 98% 수준의 재현율을 확인할 수 있었다.

**Table 6** Undersampled Data Set Size

Train set	Normal : 80,000
	Failure : 80,000
Test set	Normal : 20,000
	Failure : 20,000

## 5. 결 론

본 연구에서는 항공 시스템이 저온 상황에서 고장이 발생했을 때의 전류 데이터를 분석하고 그래프 이미지 데이터로 변환한 후 이를 이용해 이상 탐지 딥러닝 모델을 훈련하고 평가했다. 그 결과 약 98% 이상의 재현율을 갖는 모델을 생성할 수 있었다. 98% 이상의 정확한 재현율이 나올 수 있었던 이유는 실험에서 사용한 그래프 이미지는 일부 이미지를 제외하고는 사람의 눈으로도 이상을 식별할 수 있을 정도의 두드러진 특이점을 보였기 때문이다. 사람의 눈으로 이상(Anomaly)을 식별할 수 있지만 그 형태를 표현하기 어렵고, 다양한 형태의 고장을 전통적인 프로그래밍 방법으로 시스템의 자체점검 기능을 구현하기 어렵다는 점 때문에 딥러닝을 활용한 이상 탐지가 항공 시스템 개발 및 생산에 적용될 필요가 있다고 할 수 있다.

전자/기계 시스템의 이상 탐지 연구는 다양한 형태로 이뤄지고 있다. 진동센서 값과 전류센서를 이용한 기계 시설물 이상 탐지 연구[3], 저항값의 변화를 통해 열화상 카메라의 고장을 진단하는 연구[11], 음향 신호를 기반한 드론 고장 감지 연구[12] 등을 확인할 수 있었다. 항공 시스템도 전류값 외에 관성 센서

(IMU) 데이터, 영상 계측 데이터, RF(Radio Frequency) 통신 데이터 등의 다양한 데이터를 출력하기 때문에 이를 활용한 이상 탐지 연구가 필요하다.

본 연구의 데이터 전처리 과정에서는 이미지의 크기, 그래프 선의 두께 등 다양한 결정 사항들이 있었고 네트워크 구성 간 다양한 선택 옵션이 있었다. 이러한 결정 사항에 변화를 주어 성능에 어떤 영향을 미치는지 실험할 계획이다. 또한 다양한 이미지 변환 기법을 활용한 연구도 이어갈 예정이다.

## References

- [1] Y. Kim, I. Choi “Analysis of Human Casualties on the Ground in Urban Area due to UAM Crash,” *Journal of Advanced Navigation Technology*, vol. 26 no. 5, pp. 281-288, Oct 2022
- [2] UAM Team Korea, “K-UAM Concept of Operations 1.0,” Sep. 2021.
- [3] 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.
- [4] 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.
- [5] E. Lee, H. Bae, H. Kim, H. Han, Y. Lee, J. Son, “Trends in AI Technology for Smart Manufacturing in the future,” *Electronics and Telecommunications Trends*, vol. 35, no. 1, pp. 60-70, Feb 2020
- [6] A. Géron, Hands-On Machine Learning with Scikit-Learn & Tensorflow, *O’Reilly Media*, Oct. 2019
- [7] J. Oh, J. Kim, H. Lee, K. Choi, “The Fundamental Design and Analysis of UAV Avionics System for Maritime Operation,” *KSAS 2018 Fall Conference*, pp. 1317-1319, Nov 2018.
- [8] Q. Wen, L. Sun, F. Yang, X. Song, J. Gao, X. Wang, H. Xu “Time Series Data Augmentaion for

- Deep Learning: A Survey” IJCAI 2021, March 2021.
- [9] L. Basora, X. Olive, T. Dubot “Recent Advances in Anomaly Detection Methods Applied to Aviation” *Aerospace 2019*, vol. 6, no 11:117, Oct 2019.
- [10]N. Park “Research Trends on Deep Learning for Anomaly Detection of Aviation Safety,” *Electronics and Telecommunications Trends*, vol. 36, no. 5, pp. 82-91, Oct 2021
- [11]S. Jeong, J. Shin, S. Min, J. Hur “Failure Diagnostics of Thermal Imaging Camera by the LSTM,” *Journal of the Korea Academia-Industrial*, vol. 23, no. 12, pp. 355-363, Dec 2022.
- [12]E. Kim, S. Shin “Audio-Based Drone Defect Detection Using Recurrence Plot and Deep Learning,” *The Journal of Korea Institute of Communication and Information Sciences*, vol. 48, no. 1, pp. 114-122, Jan 2023.
- [13]M. Kim “Anomaly Diagnosis of Rotational Machinery Using Time-Series Vibration Data Based on Time-Distributed CNN-LSTM” *Journal of Korea Multimedia Society*, vol. 25, no. 11, pp. 1547-1556, Nov 2022.
- [14]Y. LeCun, Y. Bengio, G. Hinton “Deep Learning,” *Nature*, vol. 521, pp. 436-444, May 2015
- [15]M. Lee, H. Ahn “A Time Series Graph based Convolutional Neural Network Model for Effective Input Variable Pattern Learning : Application to the Prediction of Stock Market” *J Intell Inform Syst*, vol. 24, no. 1, pp. 167-181, March 2018.
- [16]M. Saripuddin, A. Suliman, S. S. Sameon, B. N. Jorgensen “Random Undersampling on Inbalance Time Series Data for Anomaly Detection” *4<sup>th</sup> International Conference on Machine Learning and Machine Intelligence*, pp. 151-156, Sep 2021.
- [17]S. Mishra “Handling Imbalanced Data: SMOTE vs. Random Undersampling” *IRJET*, vol. 4 no, 8, pp. 317-320, Aug 2017.