

# 딥러닝 모델을 활용한 승강기 결함 분류

정영진\* · 장찬영\* · 강성우\*

\*인하대학교 산업경영공학과

## Elevator Fault Classification Using Deep Learning Model

Young-Jin Jung\* · Chan-Young Jang\* · Sung-Woo Kang\*

\*Department of Industrial Engineering, Inha University

### Abstract

Elevators are the main means of transport in buildings. A malfunction of an elevator in operation may cause in convenience to users. Furthermore, fatal accidents, such as injuries and death, may occur to the passengers also. Therefore, it is important to prevent failure before accidents happen. In related studies, preventive measures are proposed through analyzing failures, and the lifespan of elevator components. However, these methods are limited to existing an elevator model and its surroundings, including operating conditions and installed environments. Vibration occurs when the elevator is operated. Experts have classified types of faults, which are symptoms for malfunctions (failures), via analyzing vibration. This study proposes an artificial intelligent model for classifying faults automatically with deep learning algorithms through elevator vibration data, hereby preventing failures before they occur. In this study, the vibration data of six elevators are collected. The proposed methodology in this paper removes "the measurement error data" with incorrect measurements and extracts operating sections from the input datasets for proceeding deep learning models. As a result of comparing the performance of training five deep learning models, the maximum performance indicates Accuracy 97% and F1 Score 97%, respectively. This paper presents an artificial intelligent model for detecting elevator fault automatically. The users' safety and convenience may increase by detecting fault prior to the fatal malfunctions. In addition, it is possible to reduce manpower and time by assisting experts who have previously classified faults.

**Keywords :** Elevator Fault Classification, Deep Learning, Elevator Failure Prevention

### 1. 서론

승강기는 건물의 주요한 이동 수단으로, 사람이나 화물을 승강장으로 옮긴다. 우리나라의 승강기 산업은 1910년 최초 도입 이후, 지속적인 발전을 거듭하여 신규 설치 대수는 세계 3위, 설치되어 운행하는 대수로는 세계 7위 규모로 성장했다[1]. 건축법에 따라 6층 이상의 건축물에는 승강기 설치가 의무화되고, 인구 밀집화와 도시화 등 사회 환경 변화, 건물 고층화 및 주거공간의 복합화 등으로 인해 승강기 시장은 지속해서 확대될 전망이다[2].

승강기 고장은 이용자에게 불편을 주는 것을 넘어 사고로 이어질 경우, 안전에 심각한 위협이 된다. 최근 안전에 대한 사회의 관심이 높아짐에 따라, 승강기 고장에 대한 보고와 조사 의무를 확대하는 승강기 안전관리법이 전면 개정되었다(2018년). 이는 그동안 부분적으로 파악되었던 승강기 고장에 대한 정보를 더 많이 수집하는 계기가 되었다[3]. 일례로, 지난 2019년부터 2021년까지 3년간 발생한 승강기 고장은 49,265건이며, 각각 8,591건, 17,316건, 23,358건으로 점점 늘어나고 있다[4]. 같은 기간, 승강기 고장으로 인한 사고건수는 233건이며, 각각 72건, 86건, 75건으로 매년 70건 이상이다[5].

<sup>†</sup>이 연구는 2022년도 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(No. 2022H1D8A3037396)  
이 연구는 2022년도 산업통상자원부 및 산업기술평가원(KEIT) 연구비 지원에 의한 연구임(20011249)

<sup>†</sup>Corresponding Author : Sung-Woo Kang, Industrial Engineering, INHA UNIVERSITY, 100, inha-ro, Michuhol-gu, Incheon, E-mail: kangsungwoo@inha.ac.kr

관련 연구로는 승강기 고장을 분석하여 예방책을 제시한 연구[6][7][8][9], 승강기 부품의 수명을 분석한 연구[10]가 있다. 이는 새로운 승강기 모델이 개발되면, 다시 고장이 날 때까지 기다려야 한다는 문제가 있다. 글로벌 승강기 제조 업체들은 사물인터넷(IoT, Internet of Things)을 활용해 예지보전 서비스를 도입하고자 하지만, 아직은 사람이 직접 승강기 운행상태를 감시하고 원격으로 제어하는 수준이다[1][11].

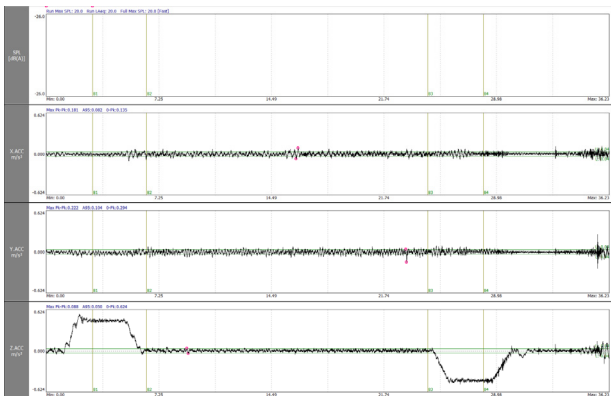
승강기를 운행하면 진동이 발생한다. 운행 중에 발생하는 진동을 측정하고 분석하면 승강기가 보유한 결함에 따라 진동이 다르게 발생함을 알 수 있다[12]. 따라서 본 연구에서는 승강기 진동 데이터를 통해 결함을 분류하는 모델을 제안하여, 고장이 발생하기 전에 예방하고자 한다. 본 논문은 2장 데이터 수집 및 전처리, 3장 승강기 결함 분류, 4장 결론 순으로 이어진다.

## 2. 데이터 수집 및 전처리

### 2.1 데이터 수집

본 연구는 한국승강기안전공단에서 측정한 승강기 진동 데이터를 사용한다. 이는 약 20층 높이 아파트에 설치된 승강기로, 약 3.5m/s 속도로 움직이는 특성이 있다. 이 중 결함을 보유한 6개 승강기의 진동 데이터 281개를 사용한다.


수집된 승강기 진동 데이터는 그래프, X축, Y축, Z축 구역으로 나뉜다. 그래프 구역은 거리, 속도, 가속도, Jerk 등 데이터의 간단한 분석을 보여준다. X축, Y축, Z축 구역은 시간에 따른 가속도 데이터로 진동을 보여준다[Figure 1].



[Figure 1] Elevator Vibration Data Example

승강기는 권상기에 의해 끌어 올리거나 내리는 상하 운동을 한다. 레일을 따라 수직 방향인 Z축으로 움직이기 때

문에, Z축 진동 데이터에 이상 진동이 가장 명확하게 나타난다. 본 연구는 승강기의 상승과 하강 과정에서의 진동을 분석하기 위해 Z축 진동 데이터에 국한하여 연구를 진행한다[Figure 2].



[Figure 2] Elevator Z-axis Vibration Data

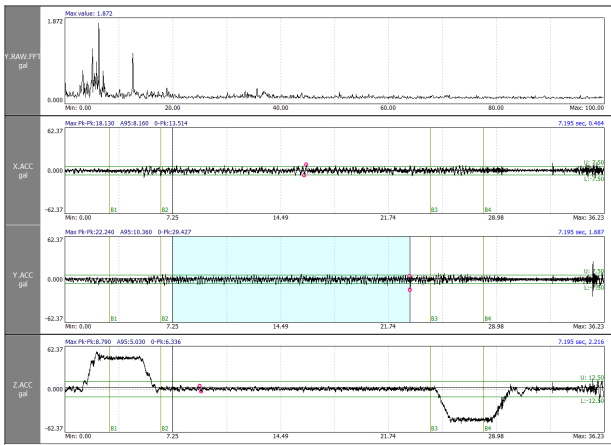
사용된 데이터는 6개 승강기의 진동 데이터로, 승강기 전문가에 의해 네 가지 결함이 의심되는 281개의 데이터이다<Table 1>.

<Table 1> Fault Data (Before Preprocessing)

Unit Number	Fault Type	Number of Data
1	Guide Roller Overload	63
2	Z-axis Rope Tension Imbalance	68
3	Z-axis Rope Tension Imbalance	49
4	Mass Unbalance	52
5	Guide Rail Gap	38
6	Guide Rail Gap	11
Total		281


네 가지 결함은 가이드 롤러 과부하(Guide Roller Overload), 로프 텐션 불균등(Rope Tension Imbalance), 질량 불평형(Mass Unbalance), 가이드 레일 오차(Guide Rail Gap)이다. 1호기는 가이드 롤러 과부하로 진단받았고 수집된 데이터는 63개이다. 2호기와 3호기는 로프 텐션 불균등으로 진단받았고 수집된 데이터는 117개이다. 4호기는 질량 불평형으로 진단받았고 수집된 데이터는 52개이다. 5호기와 6호기는 가이드 레일 오차로 진단받았고 수집된 데이터는 49개이다.

가이드 롤러는 승강기의 카 또는 균형추를, 레일을 따라 안내하기 위한 장치이다. 가이드 롤러 과부하는 고속 운전 시 주행방향으로 진동과 소음을 발생시켜 가이드 롤러의 수명에 영향을 준다[Figure 3].




[Figure 3] Guide Roller Overload

로프 텐션 불균등은 로프의 장력이 불균등한 상태로, 로프, 도르래의 마모와 로프슬립 등의 원인이 되고, 로프의 수명에 영향을 준다[Figure 4].



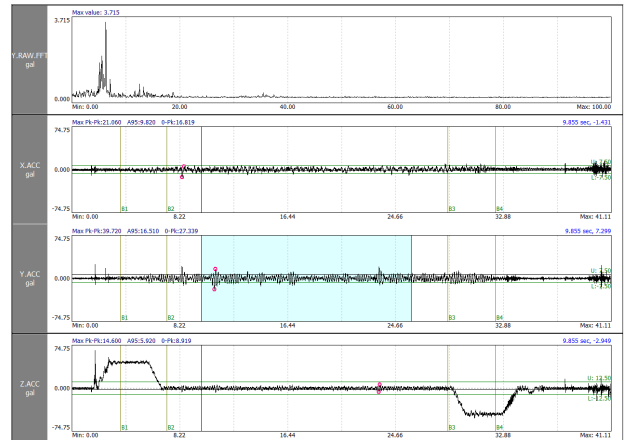
[Figure 4] Rope Tension Imbalance

질량 불평형은 회전체의 질량중심과 기하학적인 중심이 일치하지 않음을 말한다. 이로 발생하는 진동은 회전체, 베어링 등의 수명을 단축한다[13] [Figure 5].



[Figure 5] Mass Unbalance

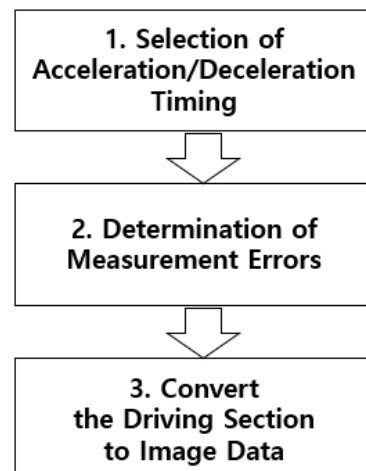
가이드 레일은 승강기 카 또는 균형추의 이동을 안내하고 수직으로 움직일 수 있도록 설치된 장치이다. 가이드 레일 단차는 승강기의 횡진동을 유발하는 결함이다 [13] [Figure 6].



[Figure 6] Guide Rail Gap

## 2.2 데이터 전처리 방법

수집된 진동 데이터 중에서는 측정이 제대로 된 데이터도 있고, 측정이 제대로 되지 않은 데이터도 있다. 측정이 제대로 되지 않은 데이터를 제거하고, 진동 데이터를 분석하여 결함을 분류하기 위해 다음과 같은 데이터 전처리 단계를 수행한다[Figure 7].



[Figure 7] Data Preprocessing Steps

첫 번째로 승강기의 가속/감속 시점을 정한다. 승강기의 가속/감속 시점은 가속 시작 시점(B1), 가속 종료 시점(B2), 감속 시작 시점(B3), 감속 종료 시점(B4)으로 나뉜다. 승강기는 정지된 상태에서 사용자가 탑승하여 이

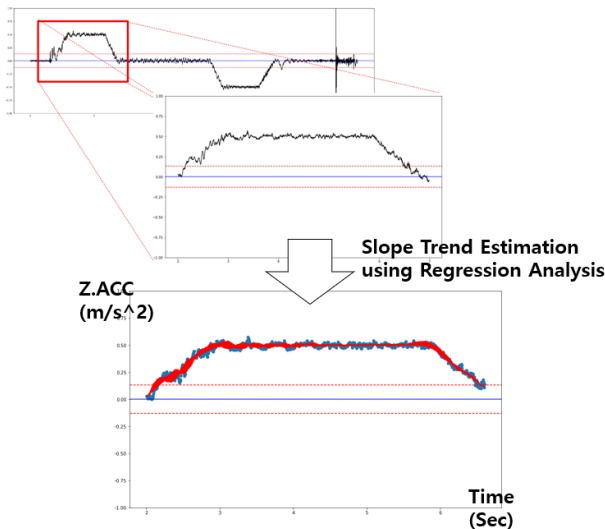
동하려는 층을 누르면 이동하기 시작한다. 승강기 문이 닫히고 이동을 시작한 시점을 가속 시작 시점(B1)이라고 한다. 가속하던 승강기는 일정 속도에 도달하면 가속을 종료하여 등속으로 주행하기 시작하는데, 이를 가속 종료 시점(B2)이라고 한다. 등속으로 주행하던 승강기가 이동하려는 층에 다르면 감속을 시작하는데 이를 감속 시작 시점(B3)이라고 한다. 이동하려는 층에 도착하여 감속을 종료하고 완전히 멈추면 이를 감속 종료 시점(B4)이라고 한다.

두 번째로 앞에 네 가지 시점을 이용해 측정이 제대로 된 데이터인지를 판단한다. 측정 오류인 데이터일 경우 삭제하고, 제대로 측정된 데이터만 다음 단계로 넘긴다.

세 번째로 승강기의 주행 구간만으로 데이터를 잘라내어 이미지 데이터로 변환한다. 주행 구간은 가속 종료 지점(B2)과 감속 시작 지점(B3) 사이로, 승강기가 등속으로 주행하는 구간을 의미한다.

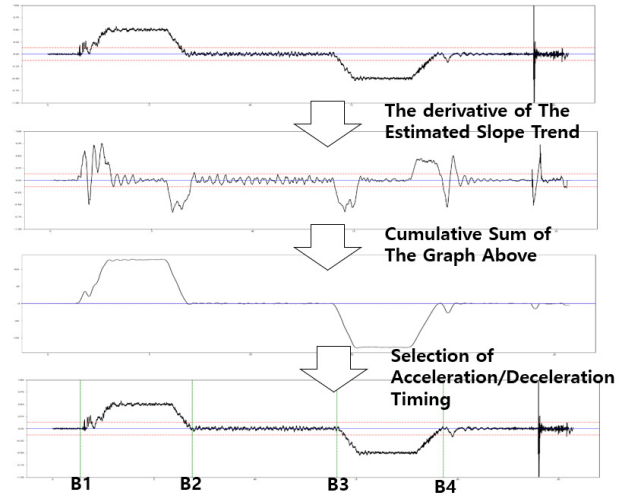
### 2.3 데이터 전처리 결과

수집한 281개의 데이터에 전처리 단계를 수행한다. 첫 번째 단계인 가속/감속 시점을 정하기 위해 회귀분석을 사용하여 진동 데이터의 기울기 추세를 추정한다[Figure 8].




[Figure 8] Slope Trend Estimation using Regression Analysis

이후 추정된 기울기 추세를 미분하여 얻은 값을 다 더해 누적 합 값을 구하고, 누적 합 값이 가장 큰 곳과 가장 작은 곳을 찾아 그 양옆을 각각 B1, B2, B3, B4로 정한다 [Figure 9].




[Figure 9] Selection of Acceleration/Deceleration Timing

두 번째로 측정 오류 데이터를 삭제한다. 측정 오류 데이터는 진동 데이터 수집기의 오작동, 수집기와 승강기 카 사이 이격 등으로 인해 측정이 제대로 되지 않은 데이터이다. 측정이 제대로 된 데이터와 측정 오류 데이터는 다음과 같다[Figure 10] [Figure 11].




[Figure 10] Measurement Normal Data



[Figure 11] Measurement Error Data

세 번째로 승강기의 주행 구간의 데이터를 잘라내어 이미지 데이터로 변환한다[Figure 12].



[Figure 12] Driving Section Image Data

데이터 전처리를 통해 281개 중 측정 오류 데이터 108개를 제거하여 측정이 제대로 된 173개의 데이터를 얻었다. 이를 이미지 분류 모델에 넣기 위해 이미지 데이

터로 변환한 후 네 가지 결함에 대한 정수 라벨링을 한다 <Table 2>.

<Table 2> Fault Data (After Preprocessing)

Fault Type	Number of Data	Label Number
Guide Roller Overload	53	0
Z-axis Rope Tension Imbalance	44	1
Mass Unbalance	41	2
Guide Rail Gap	35	3
Total	173	

### 3. 승강기 결함 분류

#### 3.1 승강기 결함 분류 방법

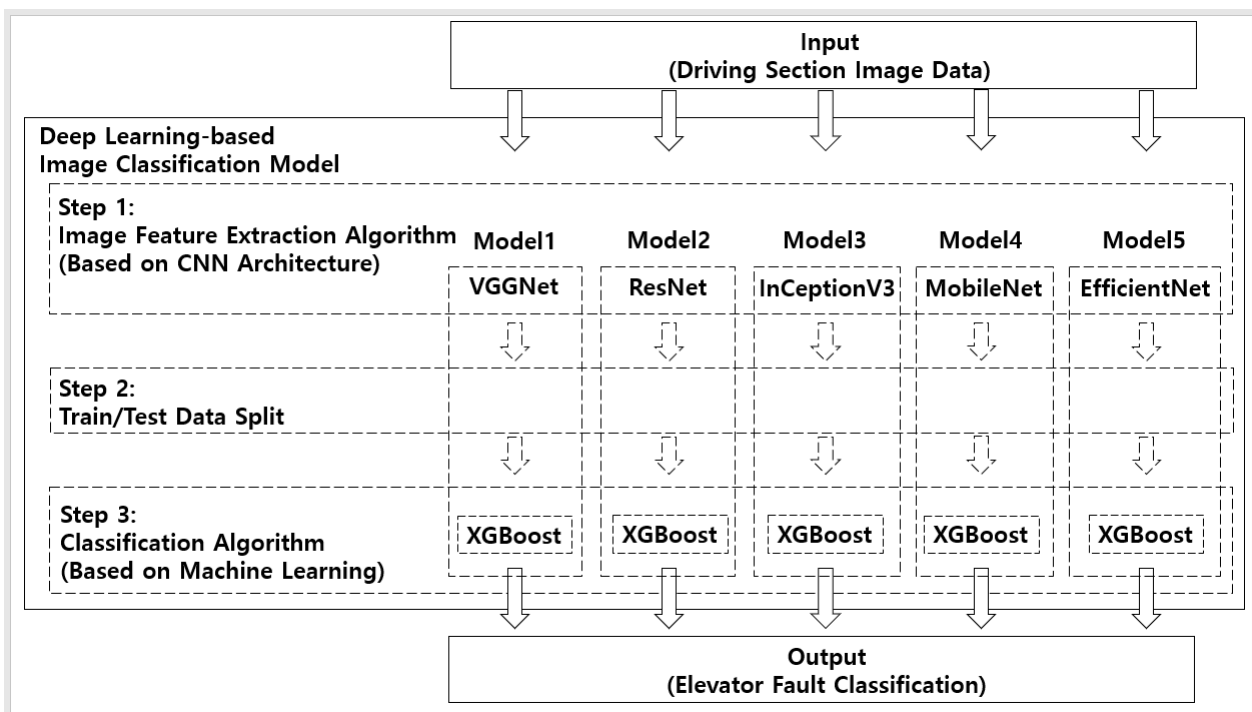
본 연구에서는 전처리가 완료된 이미지 데이터 173 개를 딥러닝 기반 이미지 분류 모델에 넣는다. 먼저 Convolutional Neural Networks(CNN) 아키텍처 기반 이미지 특성 추출 알고리즘에 넣어 특성을 추출한다. 추출된 특성을 학습 데이터와 검증 데이터로 분할한다. 이를 머신러닝 기반 분류 알고리즘에 넣어 학습시킨다 [Figure 13].

Convolutional Neural Networks(CNN)는 이미지 분류 모델에 널리 적용되는 딥러닝 아키텍처다. 2차원 이미지 데이터를 입력 데이터로 받아 이미지의 특징을 인식, 추출한다. 본 연구에서 사용된 다섯 가지 CNN 아키텍처 기반 이미지 특성 추출 알고리즘은 VGGNet, ResNet, InceptionV3 MobileNet, EfficientNet이다.

VGGNet은 옥스퍼드 대학의 연구팀 VGG(Visual Geometry Group)에 의해 개발된 딥러닝 아키텍처다. VGGNet의 핵심은 네트워크의 깊이를 깊게 만들어 성능을 확인하는 것이다. VGGNet 이전 CNN 기반 아키텍처는 비교적 큰 수용영역을 갖는 11 x 11 필터나 7 x 7 필터를 사용했지만, VGGNet은 오직 3 x 3 크기의 작은 필터만 사용하여 이미지 분류 성능을 올린다. VGGNet은 작은 필터를 반복적으로 사용해 결정 함수의 비선형성을 증가시키고, 학습 파라미터 수를 감소시키는 특징이 있다[14].

ResNet은 잔차(Residual) 개념을 도입해서 기존 CNN 기반 아키텍처보다 층수를 깊게 쌓았다. ResNet은 이전 층의 입력 데이터를 다음 층으로 전달하기 위해 신경망의 층을 뛰어넘어 전달하는 구조(Shortcut Connection)를 사용하여 인공신경망이 더 깊어질수록 생기는 문제인 기울기 소실/폭주 (Gradient Vanishing/Exploding)를 해결하는 것이 특징이다[15].

InceptionV3는 합성곱 분해를 활용해 연산량을 최소화 하면서 모델 크기를 키워 성능을 올린다. 기존 Inception 모델의 7 x 7 필터 대신 3 x 3 연산을 3번 사용한다.



[Figure 13] Elevator Fault Classification using Deep Learning Model

InceptionV3는 딥러닝 층을 깊게 만들어 성능을 올리기 때문에 깊어진 만큼 연산량이 많아져 학습 시간이 오래 걸리는 것이 특징이다[16].

MobileNet은 Depth-wise Separable Convolution을 활용하여 모델을 경량화한다[17]. 이를 통해 해상도를 줄이고 연산 효율에 집중하여 핸드폰이나 임베디드 시스템 같이 저용량 메모리 환경에서도 딥러닝을 적용하는 것이 특징이다.

EfficientNet은 기존 CNN기반 아키텍처보다 훨씬 적은 파라미터 수로 더욱 좋은 성능을 내기 위해 설계되었다. 기존 모델들은 성능을 올리기 위해 Scaling Up을 많이 시도했고, 이는 아키텍처가 깊어져 연산량이 많아지는 단점이 있다. EfficientNet은 네트워크의 Depth를 늘리는 것, Channel Width를 늘리는 것, 입력 데이터의 Resolution을 올리는 것, 이 세 가지의 최적 조합을 AutoML을 통해 찾았다는 특징이 있다[18].

### 3.2 승강기 결함 분류 결과

본 연구에서는 학습 데이터와 검증 데이터를 8:2 비율로 나눈다. 학습 데이터는 139개, 검증 데이터는 34개이다. 이를 다섯 가지 이미지 분류 모델에 넣어 모델 성능을 구한다. 모델 성능 지표로는 Accuracy, Precision, Recall, F1 Score를 사용한다<Table 3>.

Accuracy는 전체 데이터 중에 정확하게 예측한 데이터의 수를 의미한다. Precision은 모델이 양성으로 판단한 데이터 중에 실제로 양성인 데이터의 비율이다. Recall은 실제로 양성인 데이터 중에 모델이 올바르게 양성으로 판단한 비율이다. F1 Score는 Precision과 Recall을 결합하여 만든 지표이다. Precision과 Recall 성능이 어느 한 쪽으로 치우치지 않게, 두 지표의 조화 평균으로 계산한다. Accuracy와 F1 Score가 가장 높은 모델은 Model3로 Accuracy 97%, Precision 96%, Recall 98%, F1

Score 97%의 성능을 보인다.

## 4. 결론

승강기 보유대수와 고장건수가 꾸준히 늘어나는 상황에서 승강기 고장으로 인한 피해와 불편 또한 늘어날 것이다. 본 연구는 이를 줄이기 위해 승강기 진동 데이터를 분석하여 결함을 분류한다. 분석을 위해 한국승강기안전공단에서 측정한 승강기 진동 데이터를 사용하였고, 측정 오류 데이터를 제거하고, 주행 구간으로 자르는 전처리를 수행한다. 이후 다섯 가지 딥러닝 모델을 통해 특성을 추출하고 학습시켜, 성능을 비교한다.

2022년 초 시행된 중대재해처벌법으로 인해 안전에 대한 우리 사회의 관심이 높아지고 있다. 본 연구를 통해 개발한 승강기 결함 분류 모델은 승강기 고장을 예방하여 승강기 고장으로 인한 사고를 줄일 수 있다. 또한, 측정 오류 여부를 자동으로 확인하고, 측정이 제대로 된 데이터의 결함을 분류하여, 기존에 승강기 데이터를 직접 분석할 때와 비교하여 인력과 시간의 낭비를 줄일 수 있을 것으로 기대된다. 본 연구는 제공 받은 데이터를 사용했기 때문에, 승강기의 진동을 실시간으로 분석하지 않았다는 한계점이 있다. 따라서 본 연구팀은 향후 연구로 승강기 진동 데이터를 실시간으로 수집하여 분석하는 실시간 결함 분류 시스템을 만들고자 한다.

## 5. References

- [1] H. H. Jeon, et al.(2020), "Elevator industry technology trend and industry prospect." KEIT PD Issue Report, 20(5):69-85.
- [2] B. G. Gu(2020), "Design and implementation of data

<Table 3> Model Confusion Matrix

Model	Accuracy	Precision	Recall	F1 Score
Model1 VGGNet+XGBoost	91%	91%	93%	91%
Model2 ResNet+XGBoost	97%	96%	97%	96%
Model3 InceptionV3+XGBoost	97%	96%	98%	97%
Model4 MobileNet+XGBoost	91%	92%	92%	91%
Model5 EfficientNet+XGBoost	92%	90%	92%	91%

- logger for elevator remote monitoring.” *Journal of Platform Technology*, 8(4):3-10.
- [3] Korea Elevator Information Center(2022a), Elevator inspection status.
- [4] Korea Elevator Information Center(2022b), Elevator failure status.
- [5] Korea Elevator Information Center(2022c), Elevator accident status.
- [6] B. S. Kim, P. Park(2020), “Derivation of safety management implications through analysis of major elevator failures.” *J. Korea Saf. Manag. Sci.*, 22(3):23-29.
- [7] S. W. Jang, Y. J. Kim(2022), “A study on safety management measures for accident prevention through user error analysis among elevator accident cases.” *Journal of the Korea Academia-Industrial Cooperation Society*, 23(3):549-558.
- [8] O. N. Jeong, et al.(2016), “Accident prevention for the elevator and escalator by the accident type analysis.” *J. Korean Soc. Saf.*, 31(4):15-21.
- [9] J. M. Kim, et al.(2016), “Public service design to prevent negligent accident: Focused on escalator in subway station.” *J. Industrial Design*, 10(1):51-60.
- [10] H. J. Kim, et al.(2017), “A study on the estimation of the optimum lifetime of elevator components for elevator accident prevention.” *KIEE*, 66(8):1278-1284.
- [11] S. J. Yoo, et al.(2020), “Design of test bed for the fault diagnosis of traction machines for elevators.” *Proceedings of the Korean Society of Mechanical Engineers*, 2020:113-114.
- [12] T. B. Song, K. H. Choi(2010), “Predictive maintenance using vibration analysis of elevator's parts fault.” *Proceedings of the Spring Conference of the Korean Society for Precision Engineering*, 2010:239-240.
- [13] K. Y. Kim, K. M. Kwak(2008), “Dynamic modeling and controller design for active vibration control of elevator.” *Proceedings of the Spring Conference of the Korean Society for Noise and Vibration Engineering*, 2008:71-76.
- [14] S. Karen, A. Zisserman(2014), Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*.
- [15] H. Kaiming, et al.(2016), “Deep residual learning for image recognition.” *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2016:770-778.
- [16] S. Christian, et al.(2016), “Rethinking the inception architecture for computer vision.” *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2016:2818-2826.
- [17] A. G. Howard et al.(2017), Mobilenets: Efficient convolutional neural networks for mobile vision applications. *arXiv preprint arXiv:1704.04861*.
- [18] M. Tan, Q. Le(2019), “Efficientnet: Rethinking model scaling for convolutional neural networks.” *International Conference on Machine Learning*, PMLR, 2019:6105-6114.

## 저자 소개



### 정 영 진

인하대학교 산업경영공학과 학사 취득.  
현재 인하대학교 대학원 산업경영공학과 통합  
과정 재학 중.  
관심분야 : Data Science



### 장 찬 영

현재 인하대학교 산업경영공학과 학사과정 재  
학 중.  
관심분야 : Data Science, Quality Engineering



### 강 성 우

인하대학교 산업경영공학과 학사 취득.  
펜실베이니아 주립 대학 산업제조공학과에서 석  
사와 박사를 취득.  
현재 인하대학교 산업경영공학과 조교수로 재  
직 중.  
관심분야: 빅데이터(3D 이미지, 텍스트 데이  
터) 프로세싱을 기반한 제품 설계, 공학 설계,  
생산 장비 예측 진단 및 관리