

## 다중 클래스 이상치 탐지를 위한 계층 CNN의 효과적인 클래스 분할 방법

김지현<sup>0</sup>, 이세영<sup>\*</sup>, 김예림<sup>\*</sup>, 안서영<sup>\*</sup>, 박새롬<sup>\*\*</sup>

<sup>0</sup>성신여자대학교대학원 미래융합기술공학과,

<sup>\*</sup>성신여자대학교대학원 미래융합기술공학과,

<sup>\*\*</sup>성신여자대학교 융합보안공학과

e-mail: jeehyunee3@naver.com<sup>0</sup>, 220216030@sungshin.ac.kr<sup>\*</sup>, 220216126@sungshin.ac.kr<sup>\*</sup>,

98\_0731@honglab.org<sup>\*</sup>, psr6275@sungshin.ac.kr<sup>\*\*</sup>

## Effective Classification Method of Hierarchical CNN for Multi-Class Outlier Detection

Jee-Hyun Kim<sup>0</sup>, Seyoung Lee<sup>\*</sup>, Yerim Kim<sup>\*</sup>, Seo-Yeong Ahn<sup>\*</sup>, Saerom Park<sup>\*\*</sup>

<sup>0</sup>Dept. of Future Convergence Technology Engineering, Sungshin Women's University,

<sup>\*</sup>Dept. of Future Convergence Technology Engineering, Sungshin Women's University,

<sup>\*\*</sup>Dept. of Convergence Security engineering, Sunghin Women's University

### ● 요약 ●

제조 산업에서의 이상치 검출은 생산품의 품질과 운영비용을 절감하기 위한 중요한 요소로 최근 딥러닝을 사용하여 자동화되고 있다. 이상치 검출을 위한 딥러닝 기법에는 CNN이 있으며, CNN을 계층적으로 구성할 경우 단일 CNN 모델에 비해 상대적으로 성능의 향상을 보일 수 있다는 것이 많은 선행 연구에서 나타났다. 이에 MVTec-AD 데이터셋을 이용하여 계층 CNN이 다중 클래스 이상치 판별 문제에 대해 효과적인지를 탐구하고자 하였다. 실험 결과 단일 CNN의 정확도는 0.7715, 계층 CNN의 정확도는 0.7838로 다중 클래스 이상치 판별 문제에 있어 계층 CNN 방식 접근이 다중 클래스 이상치 탐지 문제에서 알고리즘의 성능을 향상할 수 있음을 확인할 수 있었다. 계층 CNN은 모델과 파라미터의 개수와 리소스의 사용이 단일 CNN에 비하여 기하급수적으로 증가한다는 단점이 존재한다. 이에 계층 CNN의 장점을 유지하며 사용 리소스를 절감하고자 하였고 K-means, GMM, 계층적 클러스터링 알고리즘을 통해 제작한 새로운 클래스를 이용해 계층 CNN을 구성하여 각각 정확도 0.7930, 0.7891, 0.7936의 결과를 얻을 수 있었다. 이를 통해 Clustering 알고리즘을 사용하여 적절히 물체를 분류할 경우 물체에 따른 개별 상태 판단 모델을 제작하는 것과 비슷하거나 더 좋은 성능을 내며 리소스 사용을 줄일 수 있음을 확인할 수 있었다.

**키워드:** 합성곱신경망(Convolutional Neural Network+), 군집화(Clustering), 계층적 구조(Hierarchical Structure), 이미지 분류(Image Classification), 이상치 탐지(Anomaly Detection), 딥 러닝(Deep Learning), 다중 일반 클래스(Multiple Normal Classes)

### I. Introduction

최근 제조 산업에서 생산품의 품질을 높이고 운영비용을 절감하기 위한 인공지능 모델 연구가 활발히 진행되고 있다. [1] 효율적인 생산을 위해 제조 공정의 각 과정마다 생산품의 결함을 확인하여 다음 생산 과정에서의 오류를 줄일 수 있도록 빠르고 정확하게 제품의 결함을 확인하는 시스템이 필요하다. 이전까지 생산품의 결함 탐지는 사람이 육안으로 제품을 확인하여 정상 제품과 이상 제품을 분류하였기 때문에 시간이 오래 소요되었고, 작은 결함은 빠르게 확인하기

어려워 이상 제품으로 인해 생산품의 품질이 저하되기도 하였다 [2].

CNN 기반의 모델은 이미지 인식 분류에 뛰어난 성능을 보이지만, 외형이 비슷한 물체의 분류에서는 비교적 낮은 성능을 보인다 [3]. 예를 들어 나사와 망치를 분류하는 작업에서는 좋은 성능을 보이지만, 정상 나사와 스크래치가 있는 나사를 분류할 때는 낮은 성능을 보인다. CNN 기반 모델의 성능을 높이기 위해 레이어의 수를 증가시키고

많은 양의 데이터로 사전 학습시킨 대형 모델들이 많이 연구되었다[4, 5]. 하지만 여러 물체들의 정상과 비정상을 판별할 때 단일 CNN 모델을 사용하여 분류할 때 물체의 종류가 증가할수록 이상 데이터를 탐지하는 모델의 성능이 저하되었다. 계층 CNN 모델을 사용하여 한 번에 분류하는 클래스 수를 줄여 성능을 높이고 데이터 특성을 더 잘 반영하여 분류할 수 있었다 [6]. 나아가 계층적 CNN 분류를 위해 데이터의 특성에 따라 효율적인 클래스 분할 방법도 연구되고 있다 [7]. 제조 공정에서 사용되는 인공지능 모델은 효율적인 공정을 위해 컴퓨팅 자원을 절약하면서 정확도가 보장되는 모델이 필요하다. 따라서 본 논문에서는 성능의 저하 없이 컴퓨팅 자원을 효율적으로 사용하는 계층 CNN 모델과 효율적인 Clustering 기법을 제안한다. 각 물체 별 정상 클래스와 이상 클래스로 분류하는 단일 CNN과 계층적으로 이상 제품을 분류하는 계층 CNN을 구현하여 성능을 비교하였고, 다양한 Clustering 기법을 사용하여 가장 효율적인 클래스 분할 방법을 탐색해보았다.

## II. Preliminaries

### 1. Related works

대상 이미지로 결함을 탐지하는 인공지능 모델은 결함 부위를 탐지하는 오토 인코더와 같은 비지도 학습 방법과 물체의 이미지를 정상 혹은 이상 클래스로 분류하는 CNN 모델과 같은 지도 학습 방법이 있다.

제조 공정에서 사람이 육안으로 결함을 확인하듯 시각적인 정보를 활용하여 이상 탐지를 할 수 있는 범용 인공지능 모델에 대한 연구가 진행되고 있다. CNN 기반 모델이 물체의 종류는 잘 분류하지만 물체의 정상과 이상 클래스를 잘 분류하지 못하는 문제를 해결하기 위한 계층 CNN 모델이 활발하게 연구되고 있다 [6].

사물 이미지를 계층적으로 분류하는 방법을 제시한 기존 연구에서는 효율적인 클래스 구성 방식을 제안하였다 [7]. 거울, 노트북 등 36가지의 물체들을 재질, 유형, 용도, 범주에 따라 9개의 클래스로 새로 분할한 후 CNN 모델에 적용하였을 때 단일 CNN보다 단계적으로 분류하는 계층 CNN의 정확도가 44% 상승하였다. 연구자가 임의로 선정한 기준에 맞춰 범주를 나누었기 때문에 인공지능 모델이 인식하는 물체 이미지 데이터의 특성을 잘 반영했다고 보기 어렵다.

본 논문에서는 단일 CNN과 계층 CNN을 사용하여 사물을 각 클래스별 이상치로 나누어 성능을 확인한 후 다양한 Clustering 기법을 적용하여 효과적인 클래스 분할 방식을 탐구해보고자 하였다.

### 2. Data sources

본 논문에서 사용된 데이터는 MVTec-AD 데이터 셋 [3, 10]으로 15개 물체에 대한 고해상도 이미지를 학습 데이터와 테스트 데이터로 구분해두었다. 학습 데이터는 물체별로 정상 데이터만으로, 테스트 데이터는 정상 데이터와 다양한 종류의 이상 데이터로 구성되어있다.

본 연구에서는 이상 데이터가 포함된 테스트 데이터만을 사용하였다. 한 물체 내 다양한 종류의 이상 라벨을 ‘outlier’ 라벨로 통합하였으

며 데이터를 학습/검증/테스트 데이터로 나눠주고 정확도를 높이기 위해 증강기법을 사용하여 학습 데이터의 수를 증가시켰다. 최종적으로 데이터는 15가지의 물체 클래스와 normal/outlier 상태 하나를 갖게 되며 학습 데이터, 검증 데이터, 테스트 데이터로 나누어 존재한다.

Table 1. 클래스 별 데이터 수

class	train	vaild	test
bottle	205	84	84
cable	280	107	107
capsule	242	101	101
carpet	286	114	114
grid	246	98	98
hazlenut	393	144	144
leather	277	106	106
metalnut	225	96	96
pill	308	124	124
screw	357	138	138
tile	255	100	100
toothbrush	158	28	28
transistor	241	90	90
wood	242	94	94
zipper	269	112	112

## III. The Proposed Scheme

### 1. 단일, 계층 CNN 모델 비교

#### 1.1. 단일 CNN 모델

본 연구에서는 모델 간 성능 비교를 위한 베이스 라인으로 단일 CNN 모델을 사용하였다. 단일 CNN 모델은 15가지의 물체와 각 물체에 대한 정상, 이상 2개의 상태를 나타내는 30개의 클래스로 분류하는 1개의 CNN 모델로 구성했다.

베이스라인 모델에 사용되는 적절한 입력 이미지와 레이어 수를 선정하기 위해 입력 이미지 사이즈와 컨볼루션 레이어를 다르게 한 총 7개의 단일 CNN 모델에 대한 실험을 수행하였다.

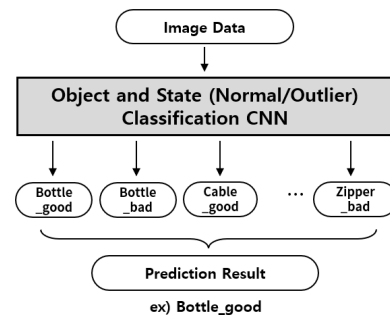


Fig. 1. 단일 CNN 모델 구조

각 모델의 학습을 위해 categorical\_crossentropy loss 함수, adam optimizer을 이용했으며 하이퍼 파라미터로서 batch size 128, epoch 100을 사용하였다. 과적합을 방지하기 위하여 각 epoch 마다 loss를

기준으로 일정 수준 이상의 성능 향상이 나타나지 않으면 자동으로 학습이 종료되도록 하였다. 각 모델의 성능은 <Table 2>과 같으며, 모델 평가 성능 지표로 정확도(Accuracy)를 사용하였다. 입력 이미지 사이즈로 128\*128, 컨볼루션 레이어 수는 5개의 CNN 모델이 정확도 0.7715로 실험을 수행한 단일 CNN 모델 중 가장 성능이 높게 나타났다. 해당 모델의 구성 요소는 <Table 3>와 같으며, 해당 모델을 기준으로 하여 실험을 진행하였다.

Table 2. 입력 이미지 사이즈 및 컨볼루션 레이어 수에 따른 단일 CNN 모델 성능

이미지 사이즈	컨볼루션 레이어 수	Accuracy	F1-score	Parameters
64*64	2	0.7495	0.554	7,396,190
128*128	2	0.765	0.5215	31,513,438
256*256	2	0.679	0.4998	130,079,582
128*128	5	0.7691	0.5927	7,433,118
<b>128*128</b>	<b>5</b>	<b>0.7715</b>	<b>0.5258</b>	<b>429,086</b>
128*128	7	0.7428	0.5758	216,222

Table 3. 단일 CNN 베이스라인 모델 구조

베이스라인 모델 구조
Conv2D-Conv2D-MaxPool2D-Conv2D-MaxPool2D-Conv2D-MaxPool2D-Conv2D-MaxPool2D-Conv2D-MaxPool2D

1.2. 계층 CNN 모델

계층 CNN 모델의 구조는 <Fig 2>와 같다. 계층 CNN 모델은 물체의 종류를 분류하는 물체 분류 CNN 모델과 각 각의 물체 종류에 대해 정상/이상 여부를 분류하는 15개의 정상/이상 분류 CNN, 총 16개의 단일 CNN 모델로 이루어져 있다. 우선 이미지를 물체 분류 CNN 모델에 입력하여 물체 분류 결과를 도출한 후 해당 결과를 토대로 15개의 정상/이상치 분류 CNN 모델 중 판정된 결과 물체에 해당하는 CNN 모델에 이미지를 입력하여 클래스 예측 결과를 도출한다. 계층 CNN의 경우 총 16개의 모델과 6,809,261개의 파라미터가 필요했으며 0.7838의 정확도를 보였다.

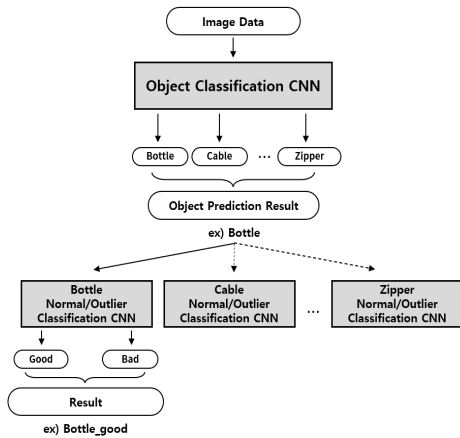


Fig. 2. 계층 CNN 모델 구조

2. 클래스 분할에 따른 성능 비교

계층 CNN의 경우 물체를 분류하는 모델 1개와 각 물체의 정상/이상을 분류하는 모델 15개를 필요로 한다. 또한 학습시켜야 할 모델 수가 늘어남에 따라 많은 리소스를 필요로 하게 되고 학습 파라미터 수도 또한 증가하게 된다. 이 점을 보완하고자 여러 클러스터링을 통해 클래스를 분할하여 정상/이상을 분류하는 모델의 개수와 필요 리소스를 감소시키고자 했다. 기존에 클래스 유사도 확인에 많이 사용되는 방식인 K-means 클러스터링, Gaussian Mixture Model 클러스터링, 계층적 클러스터링을 사용하여 클래스를 분할하여 실험하였다. k-means 알고리즘을 사용한 경우는 3개의 그룹으로 클러스터링을 한 결과가 가장 좋았고, GMM 알고리즘을 사용한 경우는 3개의 그룹으로 클러스터링한 결과가 가장 좋았다. 마지막으로 Hierarchical 알고리즘을 사용한 경우는 2개의 그룹으로 클러스터링한 결과가 가장 좋았다. 이 중 가장 정확도가 높았던 클러스터링 방법은 Hierarchical 클러스터링이다.

Table 4. 클러스터링 정확도, 파라미터 수

Cluster	Accuracy	Parameters
K-means by 3 groups	0.7930	1,703,573
K-means by 5 groups	0.7799	2,554,521
K-means by 7 groups	0.7018	3,405,469
GMM by 3 groups	0.7891	1,703,573
GMM by 6 groups	0.7780	3,024,995
<b>Hierarchical by 2 groups</b>	<b>0.7936</b>	<b>1,278,099</b>
Hierarchical by 5 groups	0.7897	2,554,521
Hierarchical by 7 groups	0.7643	3,405,469

IV. Conclusions

본 연구에서는 이상치 판별 문제에서도 단일 CNN보다 계층 CNN이 더 좋은 성능을 보이는지 확인하고자 정확도를 비교하였다. 그 결과, 계층 CNN이 더 높은 정확도를 보였고, 기존 연구들과 동일하게 이상치 판별 문제에서도 계층 CNN이 단일 CNN 모델에 비해 성능의 향상을 보인다는 것을 확인하였다. 하지만, 계층 CNN의 경우 학습되는 파라미터 수가 기하급수적으로 상승한다는 단점을 보였고 이를 보완하고자 본 연구에서는 K-means, GMM, Hierarchical Clustering을 사용하여 클래스를 분할하는 실험을 진행하였다. 정확도는 유지한 채 파라미터 수가 5배가량 감소하는 효과를 보였고 이를 통해 Clustering을 통한 클래스 분류가 계층 CNN의 성능 향상이라는 장점은 유지한 채 파라미터 수를 절감할 수 있음을 확인할 수 있었다. 향후 연구에서는 비지도 학습의 대표적 모델인 정상 데이터만을 사용하여 결함 부위를 탐지하는 오토 인코더 모형으로 다중 이상치 판별 문제를 다룰 때도 계층적 모형이 효과적인 지에 대해 연구해보고자 한다.

## ACKNOWLEDGEMENT

이 논문은 2022년도 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원(No. 022R1F1A1065171)과 2022년도 산업통상자원부의 재원으로 한국산업기술진흥원의 지원을 받아 신기술분야융합디자인 전문인력양성사업의 일환으로 수행된 연구임(P0012725)

## REFERENCES

- [1] Wang, T., Chen, Y., Qiao, M., & Snoussi, H. (2018). A fast and robust convolutional neural network-based defect detection model in product quality control. *The International Journal of Advanced Manufacturing Technology*, 94(9), 3465-3471.
- [2] Wei, B., Hao, K., Tang, X. S., & Ren, L. (2018, June). Fabric defect detection based on faster RCNN. In *international conference on artificial intelligence on textile and apparel* (pp. 45-51). Springer, Cham.
- [3] Paul Bergmann, Michael Fauser, David Sattlegger, Carsten Steger: MVTEC AD - A Comprehensive Real-World Dataset for Unsupervised Anomaly Detection; in: *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 9584-9592, 2019, DOI: 10.1109/CVPR.2019.00982.
- [4] He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 770-778).
- [5] LeCun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278-2324.
- [6] Xiao, T., Xu, Y., Yang, K., Zhang, J., Peng, Y., & Zhang, Z. The application of two-level attention models in deep convolutional neural network for fine-grained image classification. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 842-850, 2015.
- [7] You, Taewoo, Kim, Yunuk, Jeong, Hamin, Yoo, Hyunsoo, Ahn, Yonghak.(2018).Design and Implementation of Hierarchical Image Classification System for Efficient Image Classification of Objects. *융합보안논문지*, 18(3), 53-59.
- [8] Tae Woo Joo, Seoung Bum Kim.(2013).A Novelty Detection Algorithm for Multiple Normal Classes : Application to TFT-LCD Processes. *Journal of the Korean Institute of Industrial Engineers*, 39(2), 82-89.
- [9] J. G. Kim, G. S. Cho, C. M. Cho, Y. J. Park, H. T. Kwak.(2020).Product defect monitoring using image processing and Faster R-CNN. *Proceedings of the KSMTE* ,(),128-128.
- [10] Paul Bergmann, Kilian Batzner, Michael Fauser, David Sattlegger, Carsten Steger: The MVTEC Anomaly Detection Dataset: A Comprehensive Real-World Dataset for Unsupervised Anomaly Detection; in: *International Journal of Computer Vision* 129(4):1038-1059, 2021, DOI: 10.1007/s11263-020-01400-4.