

# 데이터 증강방법론을 활용한 이미지 분류 앙상블 모델 연구

장재석, 탕청, 김균엽, 정하일\*

인터엑스, \*인터엑스

jay.jang@interxlab.com, tangqing@interxlab.com, gy.kim@interxlab.com, \*hail.jung@interxlab.com

## A Study on Ensemble Model for Image Classification Using Data Augmentation Methodologies

Jaeseok Jang, Qing Tang, Gyun Yeop Kim, Hail Jung\*

INTERX, \*INTERX

### 요약

본 논문은 제조 공정 자율화에 핵심 기술인 양품 불량을 구분하는 모델링 뿐만 아니라 품질 향상을 위한 불량의 종류를 구분하는 AI 모델을 구축하는데 성능 향상을 야기할 수 있는 증강기법을 활용한 새로운 앙상블 방법론을 제안하였다.

### I. 서론

제조 공정에서 자율화된 스마트 팩토리로 나아가는 과정에는 여전히 여러 가지 난제가 존재합니다[1,2]. 특히, 양품과 불량을 구분하는 작업에서 알고리즘 기반의 모델링을 활용하면 매우 높은 정확도로 문제를 해결할 수 있습니다.

그러나 전체 공정을 처음부터 AI로 모델링하여 실시간으로 양품과 불량을 분류하는 것은 어려움이 따릅니다[3]. 초당 다수의 제품을 생산하는 고속 공정에서는 딥러닝을 적용하여 모든 제품을 처리하기에 시간이 부족 할 수 있기 때문입니다. 따라서 상대적으로 가벼운 컴퓨터 비전 기반 패턴 인식 알고리즘을 활용해 양품과 불량을 분류하는 것이 더 적합합니다. 이러한 알고리즘은 AI보다 빠르게 높은 정확도로 불량을 분류할 수 있습니다.

그럼에도 불구하고, 불량으로 분류된 제품에 대해 불량의 종류를 세부적으로 구분하는 작업 또한 매우 중요합니다. 여러 연구에서는 결함의 정확한 분류가 공정의 품질 관리 효율성을 높일 수 있다고 보고합니다(예: "Detection and Classification of Defects on Printed Circuit Board Assembly through Deep Learning"). 이는 불량의 유형에 따라 크기와 모양에 따른 허용 범위가 다르기 때문입니다. 또한, 단순 이물질로 인해 발생한 불량은 양품으로 인정될 수 있는 경우도 있습니다.

현재는 대부분의 제조업체에서 작업자가 불량 이미지를 육안으로 판별하여 불량의 종류를 구분하고 있습니다. 하지만 불량 유형이 매우 다양하고, 작업자 간 불량 분류 기준이 명확하지 않아 일관된 분류가 어려운 실정입니다. 이러한 수작업 방식은 5% 이내의 오차율을 보이지만, 같은 불량 이미지를 두고도 작업자마다 다른 판단을 내리는 경우가 흔합니다.

따라서 육안에 의존한 불량 분류 방식은 높은 오류율을 수반하며, 자동화를 통해 품질을 향상시키고 불량 정의의 정확성을 높이는 것이 필수적입니다. 그러나 제조업체의 특성상, 불량 데이터의 양이 매우 제한적이며, 이를 세부 유형별로 분류하면 각 유형에 대한 데이터의 양이 더욱 적어집니다. 이로 인해 고성능 AI 모델을 활용하는 데 제약이 따르며, 검사 시간

또한 길어져 실시간 공정에서 AI를 적용하는 데 한계가 있습니다.

본 논문에서는 자율 공정을 위한 이미지 분류 성능을 향상시키기 위해 다양한 연구를 진행하였습니다. 특히, 불량 데이터가 부족한 상황에서 가벼운 모델을 사용하여, 고성능 AI 모델과 유사하거나 이를 능가하는 성능을 발휘할 수 있는 방안을 제시하고자 합니다.

### II. 본론

본 논문에서 제안하는 방법론은 다음과 같습니다. 먼저, 표준 데이터 증강 기법을 훈련 데이터셋에 적용하여 데이터를 확장합니다. 이와 동시에 동일한 증강 기법을 검증 및 테스트 데이터셋에도 한 번씩 적용하여 각각의 별도 경로를 만듭니다. 예를 들어, 훈련 데이터에 네 가지 증강 기법이 적용되면, 검증 및 테스트 데이터셋에도 원본 이미지를 포함한 다섯 가지 경로가 생성됩니다.

이러한 증강된 데이터셋을 기반으로 동일한 모델 아키텍처를 사용하여 훈련을 진행합니다. 훈련 데이터는 계속해서 증강 기법으로 확장되는 반면, 검증 및 테스트 데이터셋은 모델 최적화를 위해 다른 증강된 데이터로 교체됩니다. 훈련된 모델을 사용해 검증 데이터셋에 대한 예측 확률을 계산하고, 이를 통해 최적의 모델을 도출합니다.

검증 및 테스트 데이터셋의 예측 확률은 각각 증강된 검증 데이터셋에 최적화된 모델을 통해 획득됩니다. 이후, 검증 데이터의 예측 확률을 다시 훈련용과 검증용 데이터로 나누어, Optuna를 통해 최종 예측 결과를 최적화합니다.

본 연구에서는 이 방법론을 사용하여 EfficientNetB0 [4] 과 ResNet 시리즈(50, 101, 152)를 CIFAR-10 [6] 데이터셋에 적용한 후, 앙상블 모델을 사용하기 전과 후의 성능 변화를 관찰했습니다. 훈련 및 테스트 데이터셋은 각각 5만 건과 1만 건으로 구성되어 있으며, 훈련 세트는 4만 건의 훈련 데이터와 1만 건의 검증 데이터로 나누어 모델을 학습시켰습니다. 이후 4만 건

의 훈련 데이터를 증강 기법을 이용해 8만 건으로 증강했습니다.

검증 데이터셋은 1만 건을 각 증강 방법론을 통해 원본을 포함한 다섯 개의 폴더로 나누어 각 증강별 모델의 loss를 측정하여 모델을 생성하였습니다. 테스트 데이터셋 역시 동일한 방식으로 다섯 개의 폴더로 나누어 모델 성능을 평가했습니다.

데이터 증강 기법으로는 가로 이동, 너비 이동, 회전, 줌 등 네 가지 기법을 적용하였으며, 이로 인해 총 다섯 가지 모델이 생성되었습니다. 이 모델들을 기반으로 양상을 모델을 구축하고, 이를 통해 테스트 세트에 대한 예측을 수행했습니다.

다음 표는 트레이닝 데이터를 증강한 이후 각 테스트 데이터셋을 증강한 후 결과들에 대한 결과값을 요약한 것입니다.

사용 모델	Original	horizontal	shear(0.2)	zoom(0.2)	widthShift(0.2)
EfficientNet B20	<b>0.9764</b>	0.9740	0.9697	0.9729	0.9608
ResNet50	0.9556	0.9503	<b>0.9569</b>	0.9528	0.9519
ResNet101	0.9562	<b>0.9632</b>	0.9638	0.9640	0.9575
ResNet152	<b>0.9679</b>	0.9591	0.9592	0.9625	0.9614

다음 표는 각 증강 모델중 Best Score를 가진 모델과 모든 증강 모델들을 optuna를 활용하여 양상을 모델링 한 결과입니다.

사용 모델	single best	ensemble(lgbm)	ensemble(xgb)	ensemble(ebm)	ensemble(rf)
EfficientNetB20	0.9764 (original)	0.9807	0.9803	0.9814	<b>0.9821</b>
ResNet50	0.9569 (shear)	0.9665	0.9668	<b>0.9672</b>	0.9659
ResNet101	0.9632 (horizontal)	0.9734	0.9735	0.9717	<b>0.9747</b>
ResNet152	0.9679 (original)	0.9750	0.9749	0.9743	<b>0.9752</b>

표에서 볼 수 있듯이, 양상을 결과는 단일 모델 기준 정확도가 최소 0.7% 향상되었고, ResNet101, 152 모델에서는 단일 best 모델 대비 정확도 측면에서 1% 이상의 증가를 보였습니다.

### III. 결론

이미지 분류 모델링에서 다양한 이미지에 여러 증강 기법을 적용함으로써 보다 정밀한 분류 모델을 구축할 수 있다는 사실이 확인되었습니다. 특히, 새로운 증강 기법을 적용한 결과, 각 기법이 상이한 이미지 특성에 따라 구분 가능성을 높이는 점이 드러났습니다. 이는 검증 및 테스트 데이터셋에도 증강 기법을 적용할 경우 유사한 성능 향상이 가능하다는 가설로 이어졌으며, 실제로 원본 데이터만 사용했을 때보다 더 우수한 결과를 도출하였습니다. 이는 기존에 단일 증강 기법을 활용한 모델보다도 높은 성능을 보였습니다.

따라서 각 증강 기법의 강점을 극대화하고, 이를 통해 최적의 결과를 도출하는 것을 목표로 다양한 테스트 및 검증 데이터셋을 생성하였으며, 그 결과를 기반으로 본 논문을 작성하였습니다. 본 논문에서 제시한 방법론은 대부분의 이미지 분류 모델에 적용 가능하며, 스레딩 기법을 사용해 GPU 효율성을 극대화하면 동일한 모델 구조를 반복적으로 활용하여 예측 시간을 단축할 수 있습니다.

제안된 기법을 ResNet 시리즈(50, 101, 152)와 EfficientNet 계열 모델(B0)에 적용한 결과, 두 모델 모두에서 성능 향상을 확인할 수 있었습니다.

다. 특히, 훈련 데이터가 부족한 경우에는 테스트 세트까지 증강하는 방법을 통해 성능이 크게 향상되었습니다.

현재 자율 공장으로의 발전 과정에서, 최종 조립을 담당하지 않는 공장에서도 결합 검사 비용이 상당히 높으며, 그럼에도 불구하고 만족스러운 결합 탐지를 달성하는 것은 어려운 문제로 남아있습니다. 특히 결합 데이터가 매우 부족하고, 예측 시간을 단축해야 하는 상황에서 본 연구에서 제시한 방법론을 적용한 결과, 분류 정확도가 크게 개선되었습니다.

본 방법론은 단일 알고리즘 기반 모델의 성능을 높일 수 있는 효과적인 접근법으로, GPU 기술의 발전에 따라 고성능 모델의 사용이 점차 짧은 시간 내에 이루어질 것으로 기대됩니다. 이때 본 논문에서 제시한 양상을 기법을 적용한다면, 고성능 모델에서 조차 기준 이상의 성능 향상을 기대할 수 있습니다.

결론적으로, 본 연구는 데이터 품질 개선과 결합 데이터의 지속적 관리, 그리고 본 알고리즘을 활용한 파이프라인 구축을 통해 자율 공장으로 나아가는 길을 더 정확하고 효율적으로 개척할 수 있는 가능성을 제시합니다.

### ACKNOWLEDGMENT

본 논문은 울산시-ETRI 2차 공동협력사업의 일환으로 수행되었습니다. [24AB1600, 제조 혁신을 위한 주력산업 지능화 기술 개발 및 산업현장에서의 사람-이동체-공간 자율협업지능 기술 개발]

This work was supported by the Ulsan City & Electronics and Telecommunications Research Institute (ETRI) grant funded by the Ulsan City [24AB1600, the development of intelligentization technology for the main industry for manufacturing innovation and Human-mobile-space autonomous collaboration intelligence technology development in industrial sites]

### 참 고 문 헌

- [1] Öztemel, Ercan and Samet Gursev. "Literature review of Industry 4.0 and related technologies." Journal of Intelligent Manufacturing 31 (2018): 127-182.
- [2] Sánchez, Manuel et al. "Industry 4.0: survey from a system integration perspective." International Journal of Computer Integrated Manufacturing 33 (2020): 1017-1041.
- [3] Devasena, D. et al. "AI-Based Quality Inspection of Industrial Products." Handbook of Research on Thrust Technologies Effect on Image Processing (2023): 19-35.
- [4] Tan, Mingxing and Quoc V. Le. "EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks." Proceedings of the 36th International Conference on Machine Learning 97 (2019): 6105-6114.
- [5] He, Kaiming, Xiangyu Zhang, Shaoqing Ren, and Jian Sun. "Deep Residual Learning for Image Recognition." Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (2016): 770-778.
- [6] Krizhevsky, Alex. "Learning Multiple Layers of Features from Tiny Images." Technical Report, University of Toronto (2009).