

YOLOv8-based plastic surface inspector with custom labeling for defect detection

In-Bok Jung*, Sangmin Suh**

*Student, Dept. of Biomedical Convergence Engineering, Gangneung-Wonju National University, Wonju, Korea

**Professor, Dept. of Information & Telecommunication Engineering, Gangneung-Wonju National University, Wonju, Korea

[Abstract]

The rapid advancement of society due to industrialization, particularly through mass production enabled by automation, has led to the production of numerous products. However, it is difficult to ensure that all products are manufactured perfectly without defects. Therefore, identifying defects in products during the production process has become crucial. In modern society, detecting defects in various materials is highly valued. This paper focuses on detecting defects in plastic materials, which are among the most widely used and practical materials. In this study, we manually labeled the dataset, creating a dataset consisting of two classes. We utilized the YOLOv8 (You Only Look Once) model, which is capable of object detection, for training. To ensure fair evaluation, k-Fold Cross Validation was performed, resulting in an average F1 Score of 0.95, mAP50 of 0.97, and mAP50-95 of 0.68.

▶ **Key words:** Plastic Defect, Object Detection, You Only Look Once, Labeling, Deep learning

[요약]

산업화로 인해 사회는 빠르게 발전하고 있다. 특히 자동화에 의한 대량 생산으로 많은 제품이 생산되고 있다. 그러나 모든 제품이 결함 없이 완벽하게 생산되기는 어렵다. 그러므로 생산과정 중에 제품에 생기는 결함을 찾아내는 것은 중요하다. 현대 사회에서는 다양한 소재에서 결함을 찾아내는 것을 중요하게 여기고 있다. 본 논문에서는 가장 활용도가 높고 많이 사용하는 플라스틱에 초점을 맞추어 플라스틱 소재의 결함을 검출하는 것을 목표로 하였다. 본 논문에서는 데이터 세트(Data set)의 레이블링(Labeling)을 직접 하여, 2개의 클래스로 구성된 데이터 세트를 만들었다. 본 논문에서는 객체 탐지가 가능한 YOLOv8(You Only Look Once) 모델을 사용하여 훈련하였다. 공정한 검증을 위해 k-폴드 교차 검증(k-Fold Cross Validation)을 진행하였으며, 평균 F1 Score=0.95, mAP50=0.97, 그리고 mAP50-95=0.68을 얻었다.

▶ **주제어:** 플라스틱 결함, 객체 감지, 오픈, 레이블링, 딥러닝

- First Author: In-Bok Jung, Corresponding Author: Sangmin Suh
*In-Bok Jung (dlsqhrvv@naver.com), Dept. of Biomedical Convergence Engineering, Gangneung-Wonju National University
**Sangmin Suh (sangminsuh@gwnu.ac.kr), Dept. of Information & Telecommunication Engineering, Gangneung-Wonju National University
- Received: 2024. 07. 31, Revised: 2024. 10. 29, Accepted: 2024. 10. 29.

I. Introduction

산업화의 발전으로 인한 대량 생산과 자동화로 인해 현대 사회는 빠르게 발전하고 있다. 다양한 소재를 사용한 수많은 제품이 생산되는 상황에서, 제품들의 제조 과정에서 발생할 수 있는 결함을 찾아내는 것은 매우 중요한 과제가 되었다.

전통적인 방식의 결함 검사는 사람이 직접 수동으로 분류하였으나, 분류에 대한 사전 교육 과정이 필요하고, 수동 노동에 의한 검사는 일관성이 없어 주관적인 관점에 영향을 받는 문제가 있다[1]. 또한, 높은 인건비와 느린 분류 속도로 인하여 수동으로 검사하는 방법에 대한 대안이 필요하게 되었다[2]. 이를 해결하기 위해 광학 장치와 비접촉 센서를 통해 실제 객체의 이미지를 자동으로 수집하고 처리하는 머신 비전(Machine Vision)이 기술이 도입되었다. 산업 제품의 표면 이미지를 특정 조명 조건에서 CCD(Charge-Coupled Device) 카메라를 사용하여 촬영한 것을 이미지 처리를 통하여 결함을 감지한다[1, 3]. 또한, 서포트 벡터 머신(Support Vector Machine, SVM)을 사용해, 주어진 데이터의 특징을 기반으로 결함과 비결함을 분류한다[4-7]. K-최근접 이웃(K-Nearest Neighbors, K-NN)을 사용하여 새로운 데이터를 가장 가까운 k 개의 이웃 데이터와 비교하여 분류하는 비지도 학습도 제안되기도 하였다[7, 8]. 최근에는 합성곱 신경망(Convolutional Neural Network, CNN)의 도입으로 이미지에서 자동으로 특징을 학습하여 수동적인 특징 추출의 필요성이 사라져 다양한 기법이 사용되고 있다. Faster R-CNN(Faster Region-based Convolutional Neural Network), YOLO(You Only Look Once), SSD(Single Shot Multibox Detector)와 같은 기술들의 사용으로 실시간으로 정확한 결함 검출이 가능해졌고, 실제 적용을 위하여 YOLOv3과 Inception-Resnet-v2 모델을 사용해 플라스틱병의 뚜껑 결함을 정확하게 검출하였다[9].

본 논문에서는 사전에 레이블링 되어 있는 데이터 세트 중에 레이블링은 사용하지 않고 이미지만을 사용한다. 기존의 레이블링 데이터는 우리의 목적에 부합하지 않으므로 사용하지 않고, 우리의 검출 목표인 dent와 crack으로 따로 레이블링한 데이터를 생성하여 훈련을 진행하였다. 이 논문의 기여를 정리하면 다음과 같다.

- 작은 불량을 검출하기 위해 dent와 crack을 검출할 수 있는 새로운 데이터 세트를 만들었다.
- 기존 YOLO에서는 한 번의 훈련과 평가로만 성능을

검증하였지만, 그와 다르게 이 논문에서는 Stratified K-fold를 이용하여 5회에 걸쳐 훈련과 평가를 진행하였고, 각 훈련에 따른 성능 차이가 없음을 확인하였으며, 평가에서도 다른 논문과 다르게 외부 데이터 세트에 강인한 성능이 보임을 증명하였다.

- 이를 통하여 효율적인 제품 생산과 제품의 품질 향상, 그리고 제조 과정에서 발생하는 문제점을 파악하여, 제조 공정 개선에 기여할 수 있다.

논문의 구성은 다음과 같다. 논문의 2장에서는 관련 연구를 살펴보고 3장에서는 데이터 세트에 관해 설명한다. 4장에서는 훈련한 결과에 대해 분석하고 5장에서 분석한 결과를 통해 결론을 기술한다.

II. Related Works

1. Related works

1.1 Aluminum Products

알루미늄은 제조 산업에서 자주 사용되는 소재이다. 다양한 결함(마모, 오염 점, 수평 변형 등)이 발생할 수 있는데, 이는 제품 품질에 영향을 미치게 되는 데 전통적인 검출 방법은 비효율적이고 정확성이 떨어져, YOLOv5-ESP 알고리즘을 사용하여 문제를 해결한다[10]. 기존에 사용하던 YOLOv5에 몇 가지 모듈을 도입하여 성능을 향상시켜, 기존 YOLOv5의 모델과 비교해 더 높은 결함 검출 정확도와, 낮은 누락 및 오탐율을 달성하였다.

1.2 Solar Panels

기존 YOLOv5 및 YOLOv8 모델의 크기가 크고 검출 효율이 낮은 문제를 해결하기 위해 경량화된 YOLOv8-GD 알고리즘이 제안됐다[11]. 파라미터(Parameter)의 수를 줄이고 추론 속도를 향상하고, 표준 합성곱을 대체하여 모델의 정확도와 속도 균형을 맞추었다. 또한 맥락 정보를 풍부하게 하여 결함 검출의 정확도를 높이는 모듈을 추가하였다. 기존 알고리즘과 비교하면 성능이 향상되고 모델 크기는 감소하는 결과를 얻었다.

1.3 Automotive Plastic Parts

플라스틱 부품의 표면 결함을 실시간으로 검출하기 위해 YOLOv8 모델을 사용하였고, 가장 빈번하게 발생하는 스크래치, 얼룩, 광택 검출을 목표로 하였다[12]. YOLOv8의 다양한 모델(n(nano) : 매우 작은 객체, s(small) : 작은 객체, m(medium) : 중간 크기의 객체, l(large) : 큰

객체, x(xlarge) : 매우 큰 객체)을 사용하여 이 중에서 가장 높은 평균 정밀도(mAP)를 달성한 모델 YOLOv8s을 찾았다.

1.4 Flexible Sensors

유연 센서를 생산하기 위해 일반적으로 잉크젯 프린팅 기술을 사용한다. 이때 생산과정에서 발견되는 결함(커피링 효과(Coffee Ring Effect), 필름 균열, 불균일한 표면 등)들은 제품의 전기적 특성과 기계적 성능에 큰 영향을 미친다. 그에 따른 문제를 해결하기 위해, 이 논문은 두 가지 목표를 가졌는데, 첫째 목표는 인쇄 전에 결함 발생을 줄이고, 인쇄 품질을 높이는 최적의 값을 찾아 모델을 만드는 것을 목표로 정했다. 두 번째 목표는 인쇄 과정과 인쇄 후에 결함을 실시간으로 탐지하는 모델을 생성하는 것을 목표로 정했다[13]. 그 목표를 달성하기 위해 신경망 구조 탐색(Neural Architecture Search, NAS) 기술을 사용하였다. NAS 기술을 적용하여 설계된 모델은 네 가지 유형의 결함(균열, 불순물, 구멍, 위성 액적)을 인식하고 높은 정확도와 빠른 처리 속도를 달성하였다.

1.5 Plastic Injection Molding Process

플라스틱 사출 성형 공정에서 클래스 불균형 문제를 해결하기 위해 딥러닝 기반의 결함 탐지와 생산 공정 최적화를 목표로 하였다[14]. 제조 과정 중 결함 발생 가능성이 낮고, 정상 제품이 대부분을 차지하는 클래스 불균형 문제가 발생한다. 이를 극복하기 위해 SL-CBL(Supervised Learning with Class-Balancing Loss)과 FSRO(Feature-Similarity-Based Recipe Optimization) 방법을 사용하였다. SL-CBL은 F1 Score 기반 손실함수와 가중치가 부여된 Focal Loss를 결합하여 불량 샘플(소수 클래스)를 정확하게 탐지할 수 있게 하며, FSRO는 정상 제품을 생산하기 위한 최적의 공정 과정을 찾는 방법이다. 유클리드 거리를 최소화하는 방향으로 공정 과정을 최적화하며, 추출된 공정 조건과 정상 샘플들의 특성 중심간의 거리를 최소화하여 최적의 공정 과정을 자동으로 탐색한다. 이 연구에서는 SL-CBL과 FSRO를 사용하여 클래스 불균형 문제로 인해 제대로 결함을 탐지하지 못했던 문제를 해결하고 최적의 공정 과정을 찾아 비용 절감과 생산 효율성을 증가시키는 방법을 찾아내었다.

1.6 Nonwovens

다양한 산업에서 사용되는 부직포에서는 표면 불순물, 기름얼룩, 주름, 구멍 등과 같은 결함들이 자주 발생한다 [15]. 기존의 시각 기반 결함 탐지 방법은 색상이 유사한 불순물을 제대로 구분하지 못하는 문제가 발생했다. 이를 해결하기 위해 하이퍼스펙트럴 이미징(Hyperspectral Imaging) 기술과 개선된 YOLOv5 모델을 결합한 결함 탐지 방법을 고안하였다. 하이퍼스펙트럴 이미징 기술은 물체의 이미지를 여러 개의 스펙트럼 대역에서 촬영하는 기술인데, 가시광선을 포함하여, 적외선, 자외선까지 포함한 다양한 스펙트럼 정보를 수집하고, 수집된 정보를 통해 물체의 성질과 구성 성분을 분석할 수 있다. 또한 YOLOv5에 LSK Attention 모듈과 Light-RepFRPN을 추가하여 훈련했다. 그 결과 기존 YOLOv5 모델보다 정확도가 향상되고 작은 결함을 탐지하였다.

III. Data set

본 논문에 사용된 데이터 세트는 Roboflow의 개방 데이터 세트의 이미지만을 활용하였다[16]. 본 논문에서는 좀 더 정밀하게 불량 타입을 검출하기 위해서 기존의 Crack을 새로운 Crack과 Dent로 나누어 레이블링을 하였다. 클래스는 Crack과 Dent로 구분 지었고, Dent는 움푹 파인 결함으로 구분하였고, 그 외의 결함은 Crack으로 구별하였다. 참고로 기존의 레이블링은 이 두 가지를 하나의 Crack으로 정하여 정밀하게 불량을 구분할 수 없었다. 이러한 작업은 LabelImg¹⁾ 프로그램을 사용하여 클래스를 두 개로 나누어 레이블링 작업을 하였다. 직접 레이블링한 데이터 세트는 2,412개의 이미지 파일과 4,996개의 객체로 구성하였다. 데이터의 레이블링은 (클래스 번호, X_center, Y_center, 너비, 높이)로 이루어져 있다. X_center와 Y_center는 바운딩 박스(Bounding Box)의 중심 좌표이고, 너비와 높이는 그 바운딩 박스의 가로와 세로의 크기를 나타낸다.

1) <https://github.com/HumanSignal/labelImg>




Fig. 1. Sample Images

Fig. 1은 데이터 세트의 이미지이다. 본 논문에서는 이 이미지 데이터 세트에 본 논문의 목적에 맞도록 Crack과 Dent 불량에 해당하는 맞춤형 바운딩 박스를 설계하였다. Fig. 1의 데이터 세트 이미지를 바운딩 박스를 표시하여 레이블링하게 되면 Fig. 2와 같다.




Fig. 2. Labeled images

IV. Experimental Results

1. Model Training and k-Fold Cross Validation

본 논문에서는 모델 훈련을 위해 AdamW(Adam With Decoupled Weight Decay)을 사용하였고 학습률(Learning Rate)은 0.001, 모멘텀(Momentum)으로는 0.9, 감쇠율은 0.00005, Epoch은 256을 사용하였다. 또한 공정한 평가를 위하여 k-폴드 교차 검증을 사용한다.

교차 검증은, 데이터를 여러 개의 작은 하위 집합으로 나누어 학습과 검증을 반복하는 방법이다. k개의 Fold로 나누어 Fold 중 하나를 검증 데이터로 사용하고 k-1개는 훈련 데이터로 사용한다. 데이터 불균형 문제를 해결하기 위해 클래스 분할을 유지할 수 있는 k-폴드 교차 검증의 변형인 Stratified K-fold 사용하여 훈련하였다. k-폴드


교차 검증을 할 때 일부 클래스가 아예 없는 문제가 발생할 수 있는데 Stratified K-fold를 사용하여 클래스의 분포를 균등하게 유지하여 데이터의 쓸림을 방지하였다. 본 논문에서는 전체 데이터를 5 등분하였고, 1/5을 검증 데이터로, 나머지 4/5를 학습 데이터로 사용하였다. 훈련 데이터와 검증 데이터 세트를 바꿔 가면서 훈련하여 5개의 성능 결과를 도출하였고, 손실값과 mAP 실험에서는 각 평균값도 같이 계산하여 각 평균 성능을 나타내었다.

2. Loss and Performance Metrics

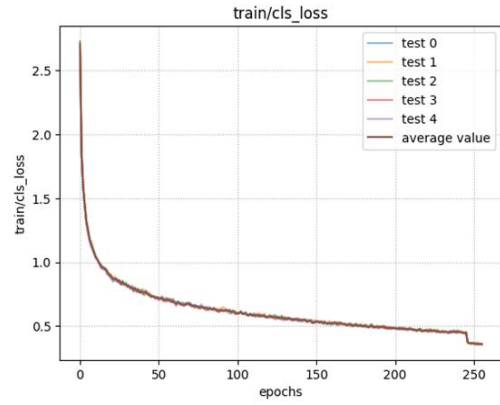
객체 인식 문제에서 총손실은 바운딩 박스 예측 손실과 클래스 예측 손실의 합으로 표현된다. 바운딩 박스의 예측 정확성을 확인할 때 CloU(Complete Intersection over Union)가 사용된다. 실제 바운딩 박스와 예측한 바운딩 박스의 겹친 최소 바운딩 박스의 대각 길이의 곱으로 나눠 계산되며, 수학적으로 수식 (1)과 같이 표현된다. CloU는 객체 탐지 분야에서 예측된 객체 영역과 실제 객체 영역의 겹치는 비율을 나타낸다. IoU는 예측 상자와 실제 상자가 겹치는 척도이고, $p^2(b, b^g)$ 은 예측 상자 b 와 실제 상자 b^g 의 중심점 사이의 거리이다. c^2 는 예측 상자와 실제 상자를 포함하는 최소로 경계를 감싸는 상자의 대각선 길이의 제곱이다. a 는 가중치이며 v 는 종횡비의 차이이다.

$$CloU = 1 - IoU + \frac{p^2(b, b^g)}{c^2} + av \quad (1)$$


본 논문에서는 Stratified K-fold를 진행하였고 K=5를 설정하여 훈련 및 검증을 진행하였다. Fig. 3을 보면 그 5 번의 실험 결과값과 그들의 평균값을 확인할 수 있다. Epoch이 증가함에 따라 바운딩 박스의 손실 값이 감소해 훈련이 정상적으로 진행됨을 알 수 있다. 또한 검증 데이터의 손실값도 Epoch이 증가함에 따라서 감소하고 있어서, Epoch이 증가함에 따라서 모델의 바운딩 박스 추론 성능이 향상하고 있는 것을 보인다.




(a)



(a)



(b)



(b)

Fig. 3. Box loss variation. (a): Box loss over training data. (b): Box loss over validation data.

모델의 클래스 분류 능력은 이진 분류 손실함수(Binary Cross-Entropy Loss)를 사용한다. 즉, 이 이진 분류 손실함수가 작으면 작을수록 설계된 모델의 객체 클래스 분류 능력은 우수하다. 이 이진 분류 손실함수는 수식 (2)이다. N 은 전체 샘플의 수이고 y_i 는 실제 클래스 레이블로 0 또는 1의 값을 가진다. p_i 는 모델이 예측한 샘플 i 에 대한 확률값이다. 예측값과 실제 값이 일치할수록 손실 값이 작아진다. Fig. 4를 보면 모든 실험에서 Epoch이 증가함에 따라 손실 값이 줄어들면서 안정화되는 모습이 보인다. 훈련이 진행됨에 따라서 정상적으로 훈련되고 있음을 확인할 수 있다.

$$BCE Loss = -\frac{1}{N} \sum_{i=1}^N (y_i \log(p_i) + (1 - y_i) \log(1 - p_i)) \quad (2)$$

Fig. 4. Class loss variation. (a): Class loss over training data. (b): Class loss over validation data.

YOLOv8에서 객체 검출 모델에서 바운딩 박스의 위치와 크기 예측의 정밀도를 더 높이기 위해 Distribution Focal Loss(DFL Loss)가 손실함수에 추가되었다. 이는 예측 분포와 실제 값 사이의 차이를 줄여 모델이 각 위치에 대한 더 높은 확신을 하게 한다. DFL Loss를 구하기 위해서, Focal Loss의 값을 구해야 하는데 구하는 공식은 수식 (3)과 같다. 수식 (3)을 통하여 구한 Focal Loss를 통해 DFL Loss를 구하는 공식은 수식 (4)이다. p_i 는 모델이 예측한 정답 클래스에 대한 확률이고 0과1 사이의 값을 가진다. $1 - p_i$ 는 예측이 잘못되었을 확률로 예측이 잘못되는 샘플에 대해 높은 값을 가진다. γ 은 조정 인자로 어려운 샘플에 더 많은 가중치를 부여하는 정도를 조절한다.

$$Focal Loss(P_i) = -(1 - p_i)^\gamma \log(p_i) \quad (3)$$

$$DFL Loss = \sum_{i=1}^N (-(1 - p_i)^\gamma \log(p_i)) \quad (4)$$

Epoch에 따른 DFL Loss의 변화 그래프는 Fig. 5이다. Fig. 5를 보면 Epoch이 진행됨에 따라 훈련 데이터와 검증 데이터의 DFL Loss 값이 모두 감소하고 있음을 볼 수 있다.

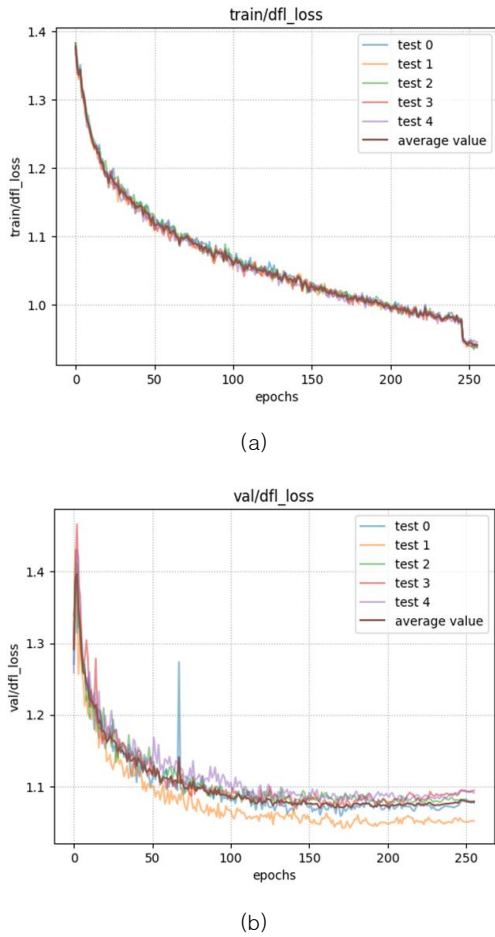


Fig. 5. DFL loss variation. (a): DFL loss over training data. (b): DFL loss over validation data.

훈련이 진행됨에 따라 Precision과 Recall의 성능도 개선된다. Fig. 6은 Epoch에 따른 정밀도와 재현율 그래프이다. 정밀도는 양성으로 예측한 샘플 중 실제 양성 샘플의 비율이다. 재현율은 실제 양성 샘플 중 양성으로 올바르게 예측한 샘플의 비율이다. 정밀도와 신뢰도 그래프 둘다 초기에는 낮다가 급격하게 증가하며 안정화되는 것을 확인할 수 있다. 평균값으로 살펴보았을 때 Epoch이 100 이상부터 모델이 안정화되는 것을 볼 수 있다.

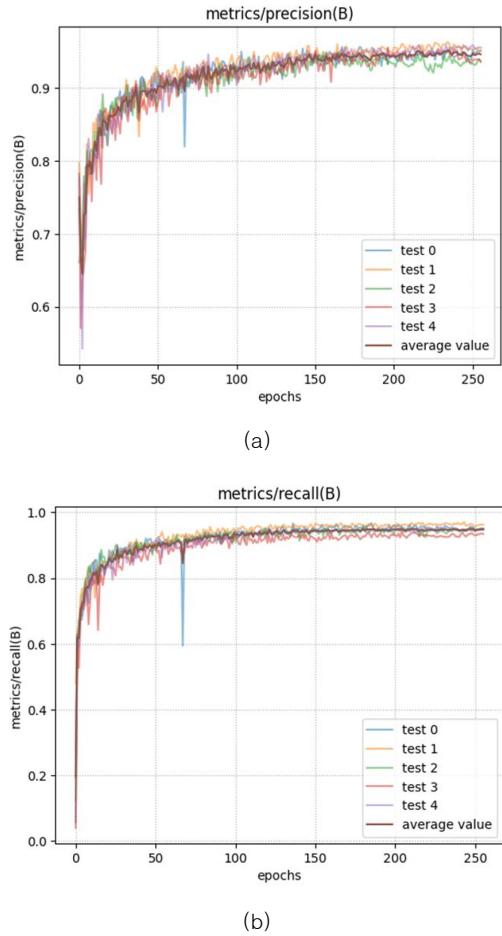


Fig. 6. Performance metrics variation. (a): Precision over training process. (b): Recall over training process.

3. Confusion Matrix

5회의 교차 검증을 통하여 5개의 혼동행렬을 각각 계산하였고, 이를 정규화한 평균 혼동행렬의 결과를 Fig. 7에 보였다.

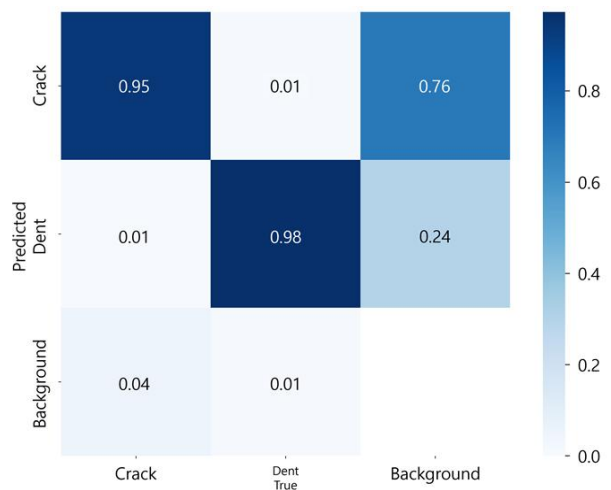


Fig. 7. Average confusion matrix.

Crack과 Dent를 예측한 결과의 5회의 교차 검증의 평균은 0.95와 0.98로 두 결함에 대한 검출이 잘 이루어지고 있음을 보여준다.

4. Performance Curves

Precision-Confidence Curve는 모델이 예측을 얼마나 신뢰하는지는 시각화한 그래프이다. 모델이 예측한 양성 샘플 중 실제 양성인 비율을 나타낸다. Fig. 8은 실험의 Precision-Confidence Curve를 각각 나타낸 것이다. 본 논문에서는, 모든 그래프를 한 그래프에 표시하면 구분이 어렵기 때문에, 각 실험마다 모두 표시하였다. Fig. 8을 살펴보면 클래스별 모델의 신뢰수준에 따른 정밀도를 확인할 수 있다. 신뢰도가 높아질수록 정밀도가 증가하는데, 모델이 높은 신뢰도로 예측할수록 정밀도가 높아진다.




Fig. 8. Precision-Confidence Curve.

Precision-Recall Curve는 정밀도와 재현율의 상관관계에 대해서 시각적으로 보여주는 그래프이다. 재현율은 실제 양성 샘플 중 모델이 양성으로 정확히 예측한 결과이다. Fig. 9는 실험의 Precision-Recall Curve를 나타낸 것이다. Fig. 9를 살펴보면 모두 0.961 이상에서 mAP 0.5를 달성하였다. 높은 재현율 구간에서도 정밀도가 높게 측정되는데, 이는 양성모델을 잘 예측하고 잘못 예측한 예측이 적다는 것을 알 수 있다.

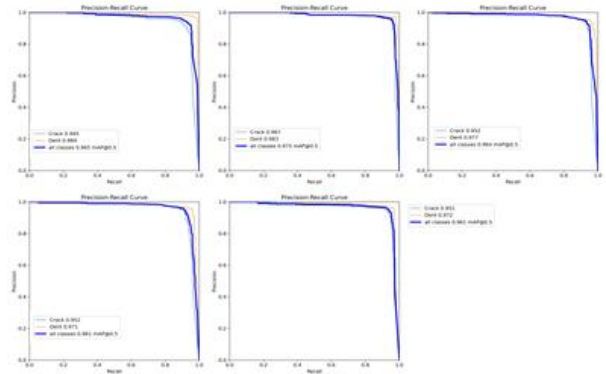


Fig. 9. Precision-Recall Curve

Recall-Confidence Curve는 다양한 신뢰도 임계값에서 모델의 성능을 평가하는 그래프이다. 이 모델이 특정 예측을 얼마나 신뢰하는 지를 Recall을 통해 나타냈고, 모델의 신뢰도 임계값에 따른 재현율의 변화를 보여준다. Fig. 10은 각 실험의 Recall-Confidence Curve를 나타내고 있다. Fig. 10에서, 실험 모두 confidence 0.97 이상에서 recall 0을 달성하였다. 모든 평가 실험에서, Dent의 재현율이 Crack보다 더 높아, Dent 결함 검출이 더 잘되고 있음을 알 수 있다.




Fig. 10. Recall-Confidence Curve

F1-Confidence Curve는 모델의 예측 신뢰수준에 따른 F1 Score의 변화를 시각적으로 보여주는 그래프이다. 데이터 세트의 클래스 불균형으로 인한 잘못된 성능 평가가 발생이 될 수 있는데, F1 Score를 통해 정밀도와 재현율의 균형을 맞추므로 모델의 성능을 종합적으로 평가할 수 있다. Fig. 11은 각 평가 실험에서 얻어진 F1-Confidence Curve를 보여주고 있다. Fig. 11을 보면 모든 실험에서 Crack과 Dent 클래스에 대해 높은 성능을 보였고, 안정적인 성능을 나타낸다.




Fig. 11. F1-Confidence Curve


5. Mean Average Precision

객체 인식에서 가장 중요한 성능 평가 지표는 mAP(mean Average Precision)와 FPS(frame per second)이다. FPS는 동적으로 객체 인식할 때, 얼마나 빠르게 인식할 수 있는가를 나타내는 지표이고, mAP는 여러 클래스에 대한 AP 평균을 구한 것으로 모델의 전체적 객체 검출 성능을 평가할 때 사용한다. 본 논문에서는 동영상 객체 인식을 다루지 않기 때문에 mAP에 초점을 맞춘다. AP는 Precision-Recall Curve 아래의 면적을 측정하여 구하며 수식 (5)이다. AP의 값을 구한 후 클래스의 총 개수로 나누게 되면 mAP가 나오며 수식 (6)과 같다. R_i 는 특정 임계값에서의 재현율이고 $P(R_i)$ 는 재현율 R_i 에 해당하는 정밀도 값이다. N 은 전체 샘플의 수이고 AP_i 는 특정 클래스 또는 특정 객체 i 에 대한 AP(Average Precision) 값이다.


$$AP = \sum_{i=1}^{n-1} P(R_i) \cdot (R_{i+1} - R_i) \quad (5)$$

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i \quad (6)$$

Fig. 12을 보면 훈련이 진행됨에 따라 mAP 성능이 개선되고 있다는 것을 보인다. 모든 실험에서 mAP 값이 증가하고 안정화되는 것을 보아 훈련이 잘되고 있음을 확인할 수 있다.



(a)



(b)

Fig. 12. mAP variation. (a): mAP50 during training. (b): mAP50-95 during training.

Fig. 12에서 mAP50은 IoU가 0.5(50%)이상이면 정답으로 인정하는 방법이고, mAP50-95는 0.5부터 0.95까지 0.05단계로 검증한 결과의 평균으로 mAP50-95가 훨씬 더 성능 검증에 엄격한 기준이다. 그럼에도 불구하고 본 논문에서는 mAP50-95는 평균 0.68을 이루었으며 이는 상당히 고무적인 결과이다.

6. Image Test

훈련한 모델에 (test-0) 이미지 테스트를 한 결과를 Fig. 13에 보인다. 이미지 실험에서, 균열이 있는 곳은 Crack으로 예측하였고, 움푹 파인 결함은 Dent로 잘 예측한 것을 볼 수 있다.




Fig. 13. Classification result image

V. Conclusions

본 논문에서는 플라스틱 표면 검출을 위해 사용자 레이블링하여 데이터 세트를 만들고 YOLOv8을 활용하여 모델의 훈련을 진행하였다. 단일 클래스로 이루어진 데이터 세트를 2가지 클래스로 재 레이블링하는 과정에서, 일부 클래스의 개수가 한쪽으로 편향된 문제점을 해결하고자 k-폴드 교차 검증을 사용하여 설계된 모델 성능 결과의 신뢰성을 높였다. 5회의 교차 검증을 통하여 $mAP_{50} = 9.5$, $mAP_{50-95} = 0.68$ 을 얻었다.

ACKNOWLEDGEMENT

This work was supported by Innovative Human Resource Development for Local Intellectualization program through the Institute of Information & Communications Technology Planning & Evaluation(IITP) grant funded by the Korea government(MSIT)(IITP-2024-RS-2023-00260267)

REFERENCES

- [1] M. I. B. Roslan, Z. Ibrahim, and Z. A. Aziz, "Real-Time Plastic Surface Defect Detection Using Deep Learning," in 2022 IEEE 12th Symposium on Computer Applications & Industrial Electronics (ISCAIE), 2022.
- [2] Alaa Aldein M. S. Ibrahim and Jules-Raymond Tapamo, "A Survey of Vision-Based Methods for Surface Defects' Detection and Classification in Steel Products," *Informatics*, Vol. 11, No. 2, p. 25, 2024.
- [3] Z. Ren, F. Fang, N. Yan, and Y. Wu, "State of the Art in Defect Detection Based on Machine Vision," *International Journal of Precision Engineering and Manufacturing-Green Technology*, Vol. 9, pp. 661-691, 2022.
- [4] R. V. Patil, Y. P. Reddy, and A. M. Thote, "Multi-class Weld Defect Detection and Classification by Support Vector Machine and Artificial Neural Network," *Journal of Intelligent Manufacturing*, Vol. 31, No. 3, pp. 540-550, Mar. 2020.
- [5] F. Nagata, K. Tokuno, K. Mitarai, A. Otsuka, T. Ikeda, and H. Ochi, "Defect detection method using deep convolutional neural network, support vector machine and template matching techniques," *Artificial Life and Robotics*, Vol. 23, No. 1, pp. 120-130, Jan. 2018.
- [6] Y. Zhang, X. Chen, H. Li, J. Zhong, and S. Chen, "Surface defect detection of industrial components based on vision," *Journal of Intelligent Manufacturing*, Vol. 33, No. 4, pp. 867-879, Apr. 2022.
- [7] L. A. Demidova, "Two-Stage Hybrid Data Classifiers Based on SVM and kNN Algorithms," *Symmetry*, Vol. 13, No. 4, pp. 615, Apr. 2021.
- [8] H. Khanzadeh, J. Hu, S. Azizi, and S. Hashemzadeh, "Machine learning algorithms for defect detection in metal laser-based manufacturing," *ScienceDirect*, Vol. 28, No. 3, pp. 459-472, Mar. 2020.
- [9] M. Kazmi, B. Hafeez, H. R. Khan, and S. A. Qazi, "Machine-Vision-Based Plastic Bottle Inspection for Quality Assurance," in *Proceedings of the Engineering Proceedings*, Vol. 20, p. 9, MDPI, July 2022.
- [10] J. Liang, R. Kong, R. Ma, J. Zhang, and X. Bian, "Aluminum Surface Defect Detection Algorithm Based on Improved YOLOv5," *Adv. Theory Simul.*, Vol. 7, No. 2, pp. 1-11, Dec. 2023, DOI: 10.1002/adts.202300695.
- [11] Y. Cao, D. Pang, Q. Zhao, Y. Yan, Y. Jiang, C. Tian, F. Wang, and J. Li, "Improved YOLOv8-GD deep learning model for defect detection in electroluminescence images of solar photovoltaic modules," *Engineering Applications of Artificial Intelligence*, Vol. 131, p. 107866, 2024, DOI: 10.1016/j.engappai.2024.107866.
- [12] M. T. Çelik, S. Arslankaya, and A. Yildiz, "Real-time detection of plastic part surface defects using deep learning-based object detection model," *Measurement*, Vol. 235, No. 114975, pp. 1-14, May 2024, DOI: 10.1016/j.measurement.2024.114975.
- [13] C. Yao, L. Wang, Q. Wang, Z. Liu, G. Liu, and M. Zhang, "Deep-Learning-Guided Evaluation Method for the High-Volume Preparation of Flexible Sensors Based on Inkjet Printing," *ACS Applied Materials & Interfaces*, Vol. 16, No. 10, pp. 13326-13334, Mar. 2024, DOI: 10.1021/acsami.4c00322.
- [14] J. U. Ko, J. Lee, T. Kim, Y. C. Kim, and B. D. Youn, "Deep-learning-based fault detection and recipe optimization for

- a plastic injection molding process under the class-imbalance problem," J. Comput. Des. Eng., Vol. 10, pp. 694-710, Feb. 2023, DOI: 10.1093/jcde/qwad011.
- [15] H. Lv, H. Zhang, M. Wang, J. Xu, X. Li, and C. Liu, "Hyperspectral Imaging Based Nonwoven Fabric Defect Detection Method Using LL-YOLOv5," IEEE Access, Vol. 12, pp. 41988-41998, Mar. 2024, DOI: 10.1109/ACCESS.2024.3378739.
- [16] G. Jocher, A. Stoken, J. Chaurasia, and A. Borovec, "ultralytics/ultralytics: YOLOv8," <https://github.com/ultralytics/ultralytics>.
- [17] Nam Trng, Seg_Cass_Crack(Crack) Computer Vision Project, https://universe.roboflow.com/nam-trng/seg_cass_crack-crack.

Authors



In-Bok Jung received a B.S. and M.S. degree in Dept. of Information & Telecommunication Engineering and Dept. of Biomedical Convergence Engineering in Gangneung-Wonju National University.

Her current interests include object detection.



Sangmin Suh received B.s., M.s., and Ph.D degree in the electronics engineering in the Hanyang university of Seoul Korea in 1991, 1994, and 2003 respectively. From 1994 to 1999, he has been with Daewoo

telecommunication. From 2003 to 2019, he was in Samsung electronics. He currently holds assistant professor in the department of information and telecommunication engineering at Gangneung-Wonju national university. His current research interests include artificial intelligence and robotics.