creative commons

COMMONS DEED

저작자표시-비영리-변경금지 2.0 대한민국

이용자는 아래의 조건을 따르는 경우에 한하여 자유롭게

- 이 저작물을 복제, 배포, 전송, 전시, 공연 및 방송할 수 있습니다.

다음과 같은 조건을 따라야 합니다:

저작자표시. 귀하는 원저작자를 표시하여야 합니다.

비영리. 귀하는 이 저작물을 영리 목적으로 이용할 수 없습니다.

변경금지. 귀하는 이 저작물을 개작, 변형 또는 가공할 수 없습니다.

- 귀하는, 이 저작물의 재이용이나 배포의 경우, 이 저작물에 적용된 이용허락조건을 명확하게 나타내어야 합니다.
- 저작권자로부터 별도의 허가를 받으면 이러한 조건들은 적용되지 않습니다.

저작권법에 따른 이용자의 권리는 위의 내용에 의하여 영향을 받지 않습니다.

이것은 이용허락규약(Legal Code)을 이해하기 쉽게 요약한 것입니다.

Disclaimer

dCollection

공학전문석사 학위 연구보고서

딥러닝을 활용한 핀 비전 검사 검출력 강화 및 추론 속도 향상에 관한 연구

Pin Vision Inspection Detectability and Inference Time Improvement using Deep Learning Based Method

2023 년 2 월

서울대학교 공학전문대학원

응용공학과 응용공학전공

허 승 진

딥러닝을 활용한 핀 비전 검사 검출력 강화 및 추론 속도 향상에 관한 연구

지도교수 조 남 익

이 프로젝트 연구보고서를 공학전문석사 학위 연구보고서로 제출함

2023 년 2 월

서울대학교 공학전문대학원
응용공학과 응용공학전공
허 승 진

허승진의 공학전문석사 학위연구보고서를 인준함

2023 년 2 월

위 원 장 _____ 곽 우 영 _____ (인)

위 원 _____ 조 남 익 _____ (인)

위 원 _____ 서 은 석 _____ (인)

국문초록

핀 비전 검사는 텔레매틱스(Telematics) 제조 현장에서 차량 하네스(Harness)와 조립되는 메인 커넥터 핀의 이상점 탐지 및 검출을 위해 활용되고 있으며, 규칙 기반(Rule-based)의 알고리즘 기법을 활용하여 인접한 핀(neighbor pin)들 간의 거리 측정 방식을 통해 Bent pin을 감지해내고 있다. 하지만 Bent Pin 이외의 불량 현상들을 검출을 해내지 못하는 한계점이 존재하여 차량 조립 시 불량이 지속 발생하고 있으며 전체 핀의 인식 및 거리 계산을 방식으로 하는 알고리즘의 복잡도로 인해 검사 시간 및 가성 불량이 증가하는 문제점도 안고 있다.

본 연구에서는 딥러닝 기반의 객체 검출(Object Detection) 방법을 활용하여 현재 핀 비전 검사에서 검출해내지 못하는 정형화 된 미세 이물 및 Bent Pin 이외의 핀 변형 불량을 감지하여 불량 검출력을 강화함으로써 제품 출하 이후의 불량률을 개선하고자 한다. 또한 복잡한 알고리즘을 통한 계산 방식이 아닌 특정 객체를 기반으로한 딥러닝 학습 방식을 활용하여 추론 속도를 향상시켜 공정 처리 시간을 단축함으로써 제품의 생산성을 높이는 방법을 제안한다.

정형화 되지 않은 불량이나 모조품 혹은 미승인품들의 경우는 정상 데이터들에서의 특징들을 추출하여 정상이 아닌 데이터가 감지되었을 때 이상점을 판별하는 이상점 탐지(Anomaly Detection) 기법을 통하여 불량을 감지한다. 최종적으로는 객체 검출 기법과 이상점 탐지 방법의 앙상블을 통해 정형화 및 비정형화된 불량을 모두 검출할 수 있는 방법론을 제안한다.

공정 데이터의 고질적인 문제인 데이터 부족 현상은 추가 불량 데이터 제작 및 데이터 증량(Data Augmentation) 기법을 활용한 데이터 증량 방식을 통하여 해결하였으며 추론 시간 최소화를 위해 실시간 객체 검출 방법 중에서 이미지 레벨의 정확도(Accuracy)와 F1 Score를 최대화할 수 있는 모델 중 가장 경량화된 모델을 적용하였고, 이상점 탐지 기법의 경우 이미지 레벨의 검출 AUROC를 최대화 하는 모델 중 가량 경량화된 모델을 적용 가능 하도록 연구하였다.

주요어 : 비전 검사, 딥러닝, 객체 검출, 이상점 탐지, 데이터 증량 기법, 앙상블
학 번 : 2021-29199

목 차

제 1 장 서 론 ····· 1
1.1. 연구 배경 ····· 1
1.2. 연구 내용 ····· 4
1.3. 연구 보고서 구성 ····· 6

제 2 장 관련 연구 ····· 7
2.1. 분류 기법 ····· 7
2.1.1. 합성곱 신경망 ····· 7
2.1.2. ResNet ····· 9
2.2. 객체 검출 기법 ····· 10
2.2.1. 2-스테이지 2D 객체 검출 ····· 11
2.2.2. 1-스테이지 2D 객체 검출 ····· 13
2.3. 이상점 탐지 기법 ····· 17
2.3.1. 복원 기반 방법론 ····· 17
2.3.2. 대표성 기반 방법론 ····· 20

제 3 장 문제 정의 및 방법론 ····· 24
3.1. 문제 정의 및 데이터 분석 ····· 24
3.2. 문제 해결을 위한 방법론 고찰 ····· 26
3.3. 성능 평가 지표 ····· 30

제 4 장 실험 및 평가 결과 ····· 33
4.1. 데이터셋의 구성과 전처리 ····· 33
4.2. 실험 환경 ····· 36
4.3. 실험 결과 및 평가 ····· 37
4.3.1. 객체 검출 기반 실험 결과 ····· 37
4.3.2. 이상점 탐지 기반 실험 결과 ····· 43
4.3.3. 앙상블을 통한 개선 모델 제안 ····· 46

제 5 장 결 론 ····· 48

참고문헌 ····· 50

Abstract ····· 55

부 록 ····· 57

표 목차

표 3-1. 데이터 분류 및 불량 세분화 ····· 24
표 3-2. 혼동 행렬 ····· 30
표 4-1. 최종 확보된 데이터셋 ····· 33
표 4-2. 실험 환경 ····· 36
표 4-3. YOLOv5 검증 결과 ····· 40
표 4-4. YOLOv5 모델별 정확도 실험 결과 ····· 41
표 4-5. YOLOv5 모델별 추론 속도 측정 결과 ····· 42
표 4-6. 이상점 탐지 방법론에 따른 AUROC ····· 44
표 4-7. PaDiM 방법론 최적화 검토 결과 ····· 45

그림 목차

그림 1-1. 제품 불량률 추이 (2020) ····· 1
그림 1-2. 커넥터 핀 불량 유형 ····· 2
그림 1-3. 핀 비전 검사 불량 조건 ····· 3
그림 2-1. 컨볼루션과 풀링 계층 ····· 8
그림 2-2. 잔차 블럭 ····· 10
그림 2-3. Sliding Windows ····· 11
그림 2-4. R-CNN 모델 ····· 13
그림 2-5. YOLO 아키텍처 ····· 14
그림 2-6. Autoencoder를 활용한 이상점 탐지 ····· 17
그림 2-7. Autoencoder의 이상점 점수 분포 결과 ····· 19
그림 2-8. SPADE 방법론을 활용한 이상점 탐지 ····· 21
그림 2-9. PaDiM 방법론을 이용한 이상점 탐지 ····· 22
그림 3-1. 불량 이미지 예시 및 분류 ····· 25
그림 3-2. 문제 해결을 위한 Logic Tree ····· 27
그림 3-3. 추가 확보된 불량 데이터 ····· 28
그림 3-4. 데이터 증량 이미지 예시 ····· 29
그림 3-5. ROC 곡선 ····· 32
그림 4-1. 객체 예시 및 분포 ····· 34
그림 4-2. 이미지 전처리 및 라벨링 ····· 35
그림 4-3. 학습 및 검증 진행 시 손실과 정확도 추이 ····· 38
그림 4-4. 검증 결과 예시 ····· 39
그림 4-5. 불량 유형별 추론 결과 예시 ····· 43
그림 4-6. AUROC 곡선과 이상점 Heat Map ····· 46
그림 4-7. 앙상블 기법을 적용한 생산 순서도 ····· 47

제 1 장 서 론

1.1 연구 배경

차량에 무선 인터넷(Wireless Connectivity) 기능을 확보해주는 텔레매틱스(Telematics) 제품이 개발된 이래로 그 수요가 꾸준히 늘고 있으며 근래에는 안전규격(Safety regulation) 강화, 사물인터넷(IoT)과 자율주행차 기술 발전과 더불어 차량에서 기본적으로 필요한 필수 기능으로 인식되고 있다. 이러한 텔레매틱스 제품의 품질 확보를 위해 생산 라인에서의 품질 검사가 이루어지고 있으며 특히 제품 출하 후 차량 조립 공정에 투입되어 실제 차량에 있는 하네스와 연결이 되는 제품의 메인 커넥터 부품의 품질은 가장 기본이면서도 중요한 지표라고 할 수 있다. 하지만 4G LTE통신을 기반으로 하는 텔레매틱스 모델이 2019년도에 양산되고 차량에 조립되어 시장에 출하되기 시작한 이래로 [그림 1-1]과 같이 2020년도 3분기 이후에 불량률이 급증하는 현상을 확인할 수 있었다.

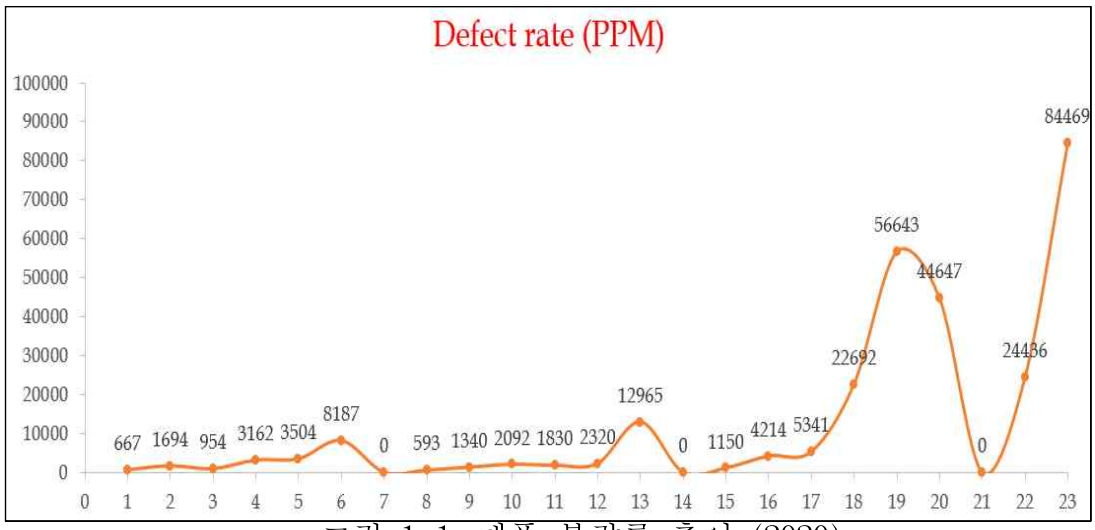

그림 1-1. 제품 불량률 추이 (2020)

해당 불량들은 텔레매틱스 모듈의 부팅 불량 및 특정 기능이 동작하지 않아 사용자들이 텔레매틱스 서비스를 사용할 수 없는 문제 현상들을 보여주었고, 문제 현상의 원인은 회로적인 하드웨어 디자인이나 소프트웨어 기능 문제가 아닌 차량 하네스에 연결되는 메인 커넥터 핀들의 휨(Bent), 처박힘, 이물(Particle)로 인해 차량 하네스와 조립 불가 혹은 특정 핀이 연결되지 않아 물리적으로 단선되어 발생되는 문제들로 확인이 되었다.

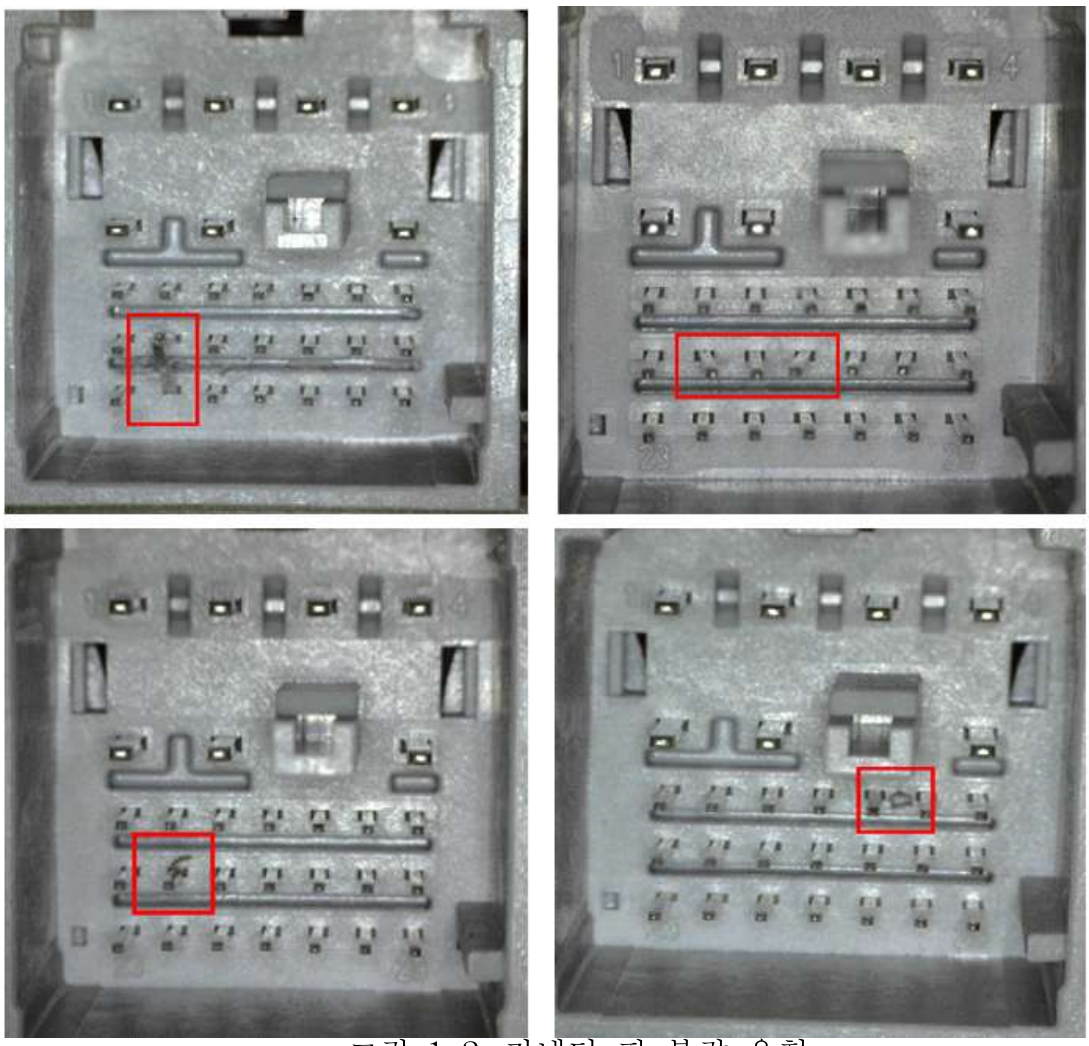

그림 1-2. 커넥터 핀 불량 유형

[그림 1-2]에 커넥터 핀 불량 유형들이 나타나 있으며 이러한 불량을 개선하기 위하여 생산 공정 상에서 설비 변경, 작업 조건 변경, 공정 추가 및 조립 지그(JIG) 변경 등의 개선 작업이 이루어졌고, 검출력 강화의 일환으로 핀 비전 검사 공정이 추가되었다. 해당 공정은 메인 커넥터 전체 28핀 내부의 이미지를 촬영한 뒤 각 핀들의 위치를 엣지 검출 (Edge Detection)을 통해 인식을 하게 되며, 그 후 2가지 구역으로 나누어 각 21핀과 7핀의 인접 핀(Neighbor Pin)간의 거리를 측정하게 된다. 측정된 거리가 정의되어 있는 기준점 이내이면 정상으로 분류되어 공정에서 출하 처리되며, 측정된 거리가 정의되어 있는 기준점 범위 이상이면 Bent Pin으로 판정되어 출하 금지 처리된다. [그림 1-3]에 해당 공정에서 실제 진행되는 이미지 및 기준점에 대해 설명이 되어있다.

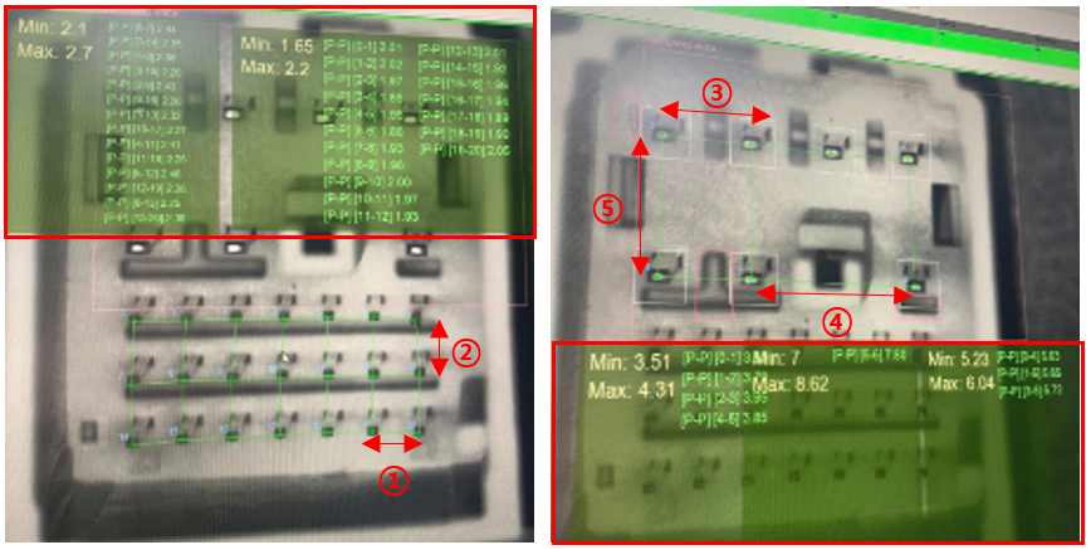

① : 좌우 Pin간 거리 (Range: 1.65 – 2.2mm)
② : 수직 Pin간 거리 (Range: 2.1 – 2.7mm)
③ 좌우 Pin간 거리 (Range: 3.51 – 4.31mm)
④ 좌우 Pin간 거리 (Range: 7 – 8.62mm)
⑤ 수직 Pin간 거리 (Range: 5.23 – 6.04mm)

그림 1-3. 핀 비전 검사 불량 조건

본 연구는 현재 공정에서 진행되고 있는 핀 비전 검사의 한계점을 극복하여 제품의 출하 품질을 향상시키고 추론 속도 최적화를 통해 생산성을 향상시키는 것을 목적으로 한다. 현재 공정 진행을 위해서는 커넥터 내부의 28개 핀을 모두 인식하고 각각의 거리를 2단계로 나누어

측정하게 되는데, 공정에서의 불균일한 조명이나 이미지 취득 시점에 따라 핀 인식에 오류가 생길 가능성이 있어 이에 따른 불필요한 가성 불량이 발생되고 있다. 또한 각각의 인접핀 간 거리 계산을 해야하므로 복잡도가 증가하고 거리만으로 불량을 판별하기 때문에 Bent Pin 현상 이외의 미세 이물 및 핀 처박힘 불량에 대해서는 정상적인 출하 처리가 되어 잠재적인 불량을 유발할 수 있는 위험성을 안고 있다. 이러한 한계점을 개선하고자 딥러닝 기반의 객체 검출(Object Detection) / 이상점 탐지 (Anomaly Detection) [1][2] 방법을 활용하여 실제 공정에 적용함으로써 현재 정형화된 불량들을 더 빠른 추론 속도로 검출을 하고 비정형화된 불량들 또한 공정에 투입되는 것을 방지하여 공정 품질 개선, 출하 품질 비용 절감 및 공정 택타임 (Takt Time)을 개선하고자 한다.

1.2. 연구 내용

본 연구의 목적은 딥러닝 기반의 인공지능 기술을 적용하여 현재 공정의 검출력 강화 및 추론 속도를 향상 시키는데 있다. 딥러닝이라는 빅 데이터에 기반한 기술을 적용을 위해서 가장 중요한 것은 데이터의 양과 질이다. 따라서 알고리즘 개선과 더불어 본 연구에서 가장 많은 부분을 차지한 것은 양질의 실제 생산 데이터 확보 및 전처리 과정이었으며 이를 위해 실제 베트남 생산법인 품질/생산 부서와의 협업이 중요하였고 부족한 데이터들은 고품질의 유사 불량 데이터 제작 및 여러 데이터 증량 기법들을 활용하여 증량시킬 수 있었다.

데이터 확보 후에는 정형화된 불량들을 정의하고 학습 시키는 과정이 필요하였는데 데이터 분석 결과 불량 현상들은 크게 아래 2가지의 불량 현상으로 분류할 수 있었다.

i. Bent Pin (핀 휨/ 처박힘/ 구부러짐/ 데미지)
ii. Particle (회로 연결에 영향을 주는 이물 형상)

Bent Pin과 Particle 2가지를 최종적으로 불량으로 검출할 객체로 분류하고 객체들에 대한 형상/특징들을 학습할 수 있도록 각각의 이미지에 있는 객체들을 라벨링 하는 작업을 진행하였다. 라벨링 완료된 객체들을 여러 실시간 객체 검출 모델을 활용하여 학습을 진행 후 추론을 진행하였다. 추론된 결과들은 TP(True Positive), TN(True Negative), FP(False Positive), FN(False Negative) 으로 분류하고 검출력의 판단 기준으로는 정확도(Accuracy)와 F1 Score를 활용하였다. 또한 실제 적용을 위해서는 빠른 추론 속도가 필수이기 때문에 정확도 대비 추론 속도가 가장 빠른 경량화 모델을 찾는 것에 집중하였다.

실제 생산 과정에서는 Bent Pin과 Particle로 정의된 객체 이외의 불량이 발생할 가능성도 있다. 특히 승인되지 않은 부품이 투입되거나 모조품(counterfeit) 투입 시 제품 출하 이후 더 큰 품질 이슈를 유발하거나 사업 관계에서의 신뢰성 문제까지 야기시킬 수 있다. 따라서 비정형화된 불량들을 초기 생산 단계에 검출해 내고자 이상점 탐지 기법에 대한 연구를 진행하였다. 선행 학습된 합성곱 신경망 (Convolutional Neural Network)을 통해 정상 이미지들의 Global Feature를 뽑아내어 이를 다른 이미지들과 비교하여 비정상적인 부분을 찾는데 활용하였다. 이상점 탐지의 정량적인 지표로는 TP, FP를 활용한 ROC 곡선의 면적을 나타내는 AUROC (Area Under the Receiver Operator Curve)을 사용하였고 AUROC를 가장 높일 수 있는 이상점 탐지 모델을 연구하고 최적화하였다.

1.3. 연구 보고서 구성

본 연구 보고서의 2장에서는 연구를 진행하는데 필요한 기존 연구 내용들과 필요한 배경 지식에 대해 설명하며, 3장에서는 구체적으로 풀어야 할 문제점에 대해서 정의를 하고 정의된 문제점을 해결하기 위한 구체적인 방법론들에 대해 기술하였다. 4장에서는 해당 방법론들을 구현하기 위한 데이터 분류와 전처리 방법들에 대해 설명하고 실제적인 실험 결과들을 통해 최적화된 해결 방안을 제안한다. 마지막으로 5장에서는 연구 결과를 기반으로 한 결론 도출 및 향후 연구 방향에 대한 내용을 기술하였다.

제 2 장 관련 연구

2.1. 분류 기법

분류 기법 (Classification)이란 어떠한 객체를 의도된 대로 분류하는 작업을 말한다. 2.1.절에서는 이미지 분류 방법론 중에 가장 널리 이용되는 합성곱 신경망 (Convolutional Neural Network) [3] 과 합성곱 신경망의 발전된 형태 중 본 연구에 직접적으로 사용될 ResNet [4] 에 대해서 알아본다.

2.1.1 합성곱 신경망

합성곱 신경망 이전에 가장 많이 사용하던 방식은 완전 연결 계층 (Fully Connected Layer) 방식이었다. 말 그대로 입력과 출력의 node들이 모두 연결 (Fully Connected) 되어있는 인공 신경망 구조로써 입력이 $n \times 1$ 벡터이고 출력이 $m \times 1$ 벡터라면 $n \times m$개의 마디 (node)에 대한 신경망 수식 ($Y = W^T X$)이 모두 필요하기 때문에 학습이 필요한 가중치와 같은 파라미터의 갯수가 $n \times m$개가 된다. 그리고 이미지 자체를 단순 1D 데이터로 보고 학습을 진행하기 때문에 각 마디의 중요도나 우선 순위는 배제한다. 하지만 이미지의 경우 인접 픽셀과의 연관성이 매우 중요하고 위치마다 반복되는 이미지의 특성이 존재하기 때문에 지역적으로 연결 (Locally connected) 되어도 그 특성을 추출하는데 문제가 없다. 모두 연결 방식을 사용할 경우 인공 신경망의 계층이 복잡하고 깊어질수록 필요한 연산량이 기하급수적으로 늘어난다는 단점이 있다. 그래서 합성곱 신경망이라는 방식이 생겨나게 되었다.

합성곱 신경망은 이미지의 특징점을 추출하는 컨볼루션 계층과 추출된 특징점을 서브 샘플링하는 풀링 계층으로 구성이 되어있다. 컨볼루션 계층에서는 이미지의 특징점을 추출하기 위하여 현재 위치의 데이터에 컨볼루션 필터를 곱하여 인접한 픽셀의 영향을 고려한

출력값을 얻게 된다. 그 후에 풀링 계층을 통하여 추출된 특징점들을 더 축약시킨다. [그림 2-1]에 컨볼루션 계층과 풀링 계층 설명을 위한 예시가 나타나 있으며 6x6 입력이 들어갔을 경우를 가정했을 때 3x3 컨볼루션 필터를 통한 컨볼루션 연산이 진행되면 4x4 출력이 나오게 되고 풀링 계층에서 맥스 풀링 (max pooling) 작업이 진행되게 되면 출력은 2x2로 간소화되어 나온다.

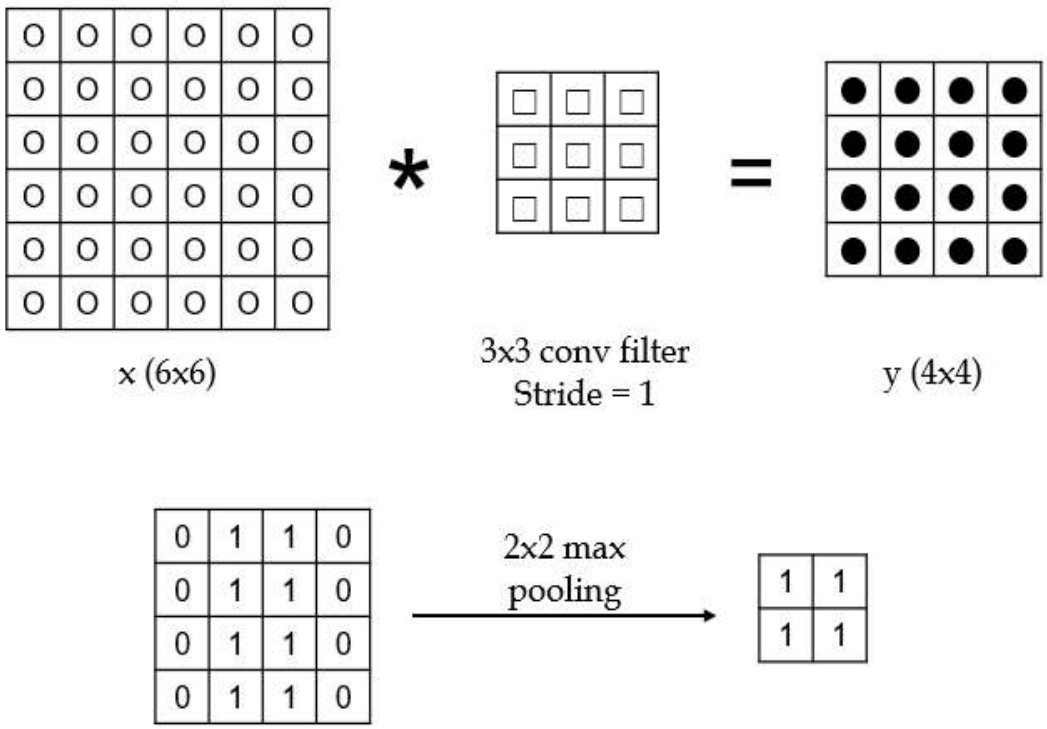

그림 2-1. 컨볼루션과 풀링 계층

이와 같은 특징으로 인해 합성곱 신경망은 완전 연결 계층에 비하여 아래와 같은 3가지 장점을 갖게되어 현재 이미지 분류 작업에 반드시 필요한 하나의 도구로 쓰이고 있다.

i. 파라미터 공유로 인한 메모리 사용 감소
ii. 지역적 연결 특성으로 인한 계산량 감소
iii. 정규화 (Regularization)를 통한 과적합 방지

2.1.2 ResNet

이미지 분류에 합성곱 신경망이 쓰이기 시작한 이후 심층 신경망 (Deep Neural Network)이 큰 관심을 받게 되었고 AlexNet [5]이 발표되면서 이미지 분류 성능이 한층 더 높아지게 된다. 이후 좀더 단순하고 균일화 된 방법론인 VGG-16 [6]이 나오면서 신경망을 좀 더 깊게 쌓을수록 이미지 분류 성능이 높아지는 것을 알게되었고, 이에 1x1 컨볼루션을 이용한 병목 계층 (Bottleneck Layer)을 개발하여 계산량을 효율적으로 낮추어 22 계층의 심층 신경망을 쌓을 수 있게 만든 Inception [7] 방법론까지 등장하게 된다. Inception 이론에서 병목 계층으로 인해 다량의 정보가 소실되어도 실제 성능에 영향이 없음이 확인되면서 합성곱 신경망에 여전히 불필요한 계산이 많이 있을거라는 추정이 되었고, 이에 나온 것이 ResNet 이론이다.

ResNet은 결국 이미 분류 성능 향상을 위해 심층 신경망을 좀 더 깊고 많이 쌓기 위해 계산의 효율성을 증가시켜 연산량을 줄인 방법인데, 계층을 너무 깊게 만들면 오히려 성능이 안좋아지는 문제를 잔차 연결 (Residual Connection)이란 개념을 도입함으로써 해결하였다. [그림 2-2]의 왼쪽에 있는 그림이 일반적인 플레인 계층 (plain layer)를 설명하고 있으며 오른쪽에 있는 그림이 잔차 블럭을 설명하고 있다.

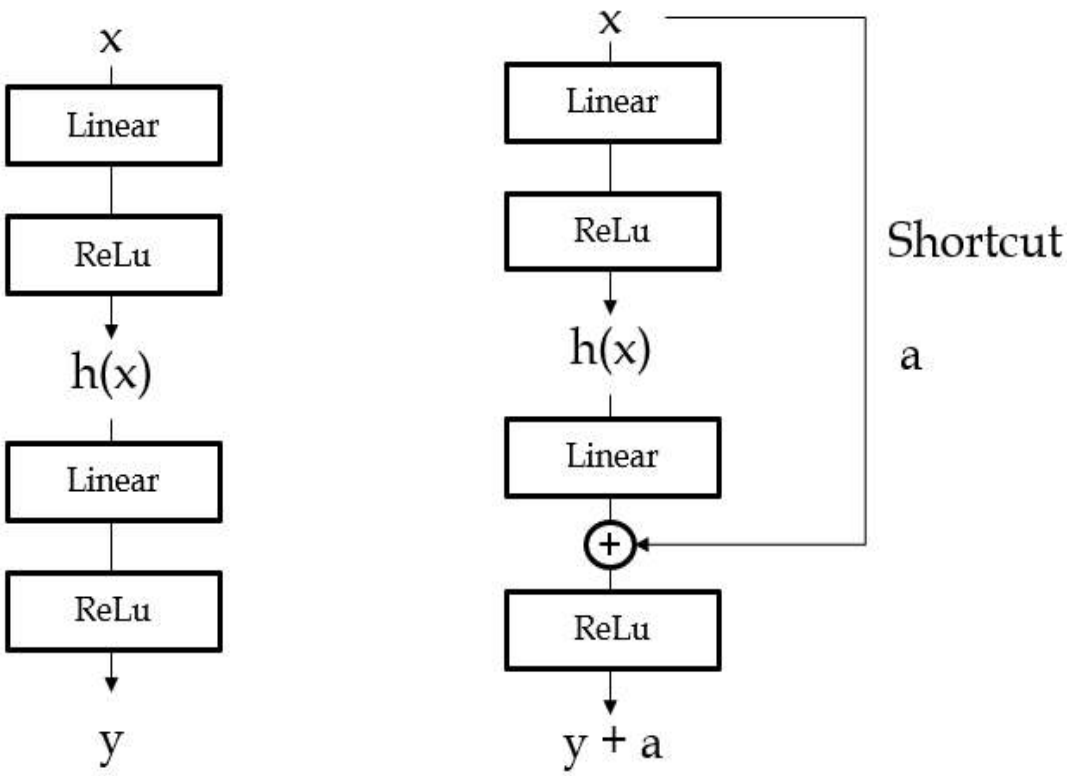

그림 2-2. 잔차 블럭

잔차 블럭을 통해 지름길 (Shortcut)을 만들어줌으로써 건너뛰기 연결 (skip connection)을 만들어 파라미터들이 소실되지 않고 지속적으로 학습이 진행되게 만들어주어 성능 저하 없이 안정적으로 100층 이상의 심층 신경망을 만드는데 성공하게 된다.

2.2. 객체 검출 기법

객체 검출이란 원하는 객체나 사물을 검출하는 것을 말하며 2.1절에서 설명되어있는 이미지 분류 개념에 그 물체가 어디에 있는지까지 표시해주는 Localization 개념이 포함되어 있다. 2.2절에서는 2-스테이지 2D 객체 검출 기법과 본 연구에 직접적으로 사용될 1-스테이지 2D 객체 검출 기법에 대해 알아본다.

2.2.1 2-스테이지 2D 객체 검출

2.2에서 언급 되었듯이 객체 검출은 분류와 Localization 2가지 문제를 모두 해결하는 과정이다. 여기에서 분류와 Localization을 순차적으로 해결하는지 아니면 동시에 해결하는지에 따라 크게 2가지 객체 검출 기법으로 구분이 되는데 먼저 2.2.1절에서는 이 2가지 문제를 순차적으로 해결하는 2-스테이지 2D 객체 검출에 대해서 알아본다.

전체 이미지에서 해당하는 물체가 있는지 판단하고 위치를 표시해주기 위하여 바운딩 박스 (Bounding Box)라는 개념이 등장하고 이에 가장 처음 나온 방법론은 Sliding Windows [8]이다. Sliding Windows의 동작 방식은 아래 [그림 2-3]에 나타나있다. 우선 그 물체가 존재하는지 판단을 하기 위하여 합성곱 신경망을 학습시킨다. 그리고 나서 그림에 있는 ①에서 ③과 같은 순서로 이미지내의 모든 위치마다 모든 크기의 바운딩 박스를 제안하여 그 박스안에 원하는 물체가 있는지를 판단한다. 굉장히 직관적인 방법론이지만 굉장히 방대한 계산량을 필요로하고 시간이 많이 걸린다는 단점이 있다.

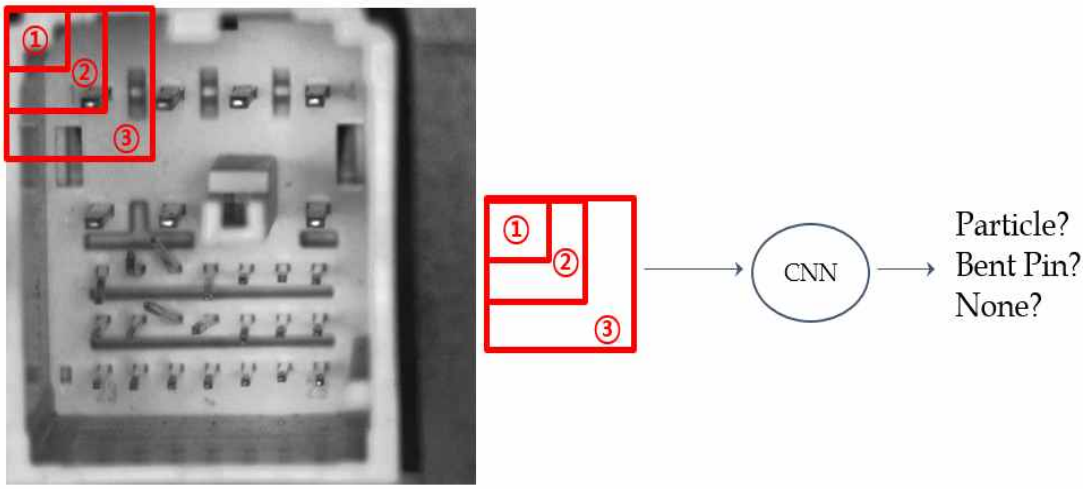

그림 2-3. Sliding Windows

이러한 단점을 보완하고 좀 더 효율적으로 바운딩 박스를 제안하고자 나온 이론이 Selective Search [9] 이다. Selective

Search에서는 이미지의 모든 곳에서 모든 크기의 바운딩 박스를 제안하는 것이 아니라 이미지 내의 픽셀간의 유사성을 검토하여 효율적으로 바운딩 박스를 제안하게 하면서 제안하는 바운딩 박스의 숫자를 크게 줄임으로써 연산량과 처리 시간을 크게 줄일 수 있게된다.

이러한 방법론들을 이용하여 합성곱 신경망을 객체 검출 분야에 최초로 적용시킨 방법론이 바로 R-CNN (Regions with Convolutional Neuron Networks features) [10] 모델이다. R-CNN은 크게 아래의 6가지 단계를 통하여 객체 검출을 진행하며 전체적인 흐름도는 아래 [그림 2-4]에 정리되어 있다.

i. 지역적 제안 (Regional Proposal) : Selective Search 기술을 이용하여 2,000개의 바운딩 박스만 제안한다.
ii. 축소 (Warping) : 제안된 Box의 이미지 크기를 227x227로 줄이고 합성곱 신경망의 입력으로 들어갈 수 있게 만든다.
iii. 특징점 추출 (Feature Extraction) : 합성곱 신경망을 이용하여 특징을 추출하고 Labeling을 진행한다. 이때 ImageNet 데이터셋 [11] 을 이용하여 선행 학습된 AlexNet을 이용하며 PASCAL, VoC 데이터셋 [12] 을 이용하여 미세 조정 (fine-tuning) 한다. IoU (Intersection over Union)이 0.5 이상인 바운딩 박스의 범주만 인정한다.
iv. 분류 : SVM (Support Vector Machine) [13] 모델을 이용하여 이미지 분류를 진행한다.
v. 바운딩 박스 회귀 : Localization 오류를 최소화하기 위하여 현재 제안된 바운딩 박스의 위치와 gound-truth 위치 차이를 최소화 하도록 미세 조정을 진행한다.
vi. Non-max suppression : 가장 높은 점수와 가장 높은 IoU를 갖고 있는 바운딩 박스만 남기고 나머지는 모두 제거한다.

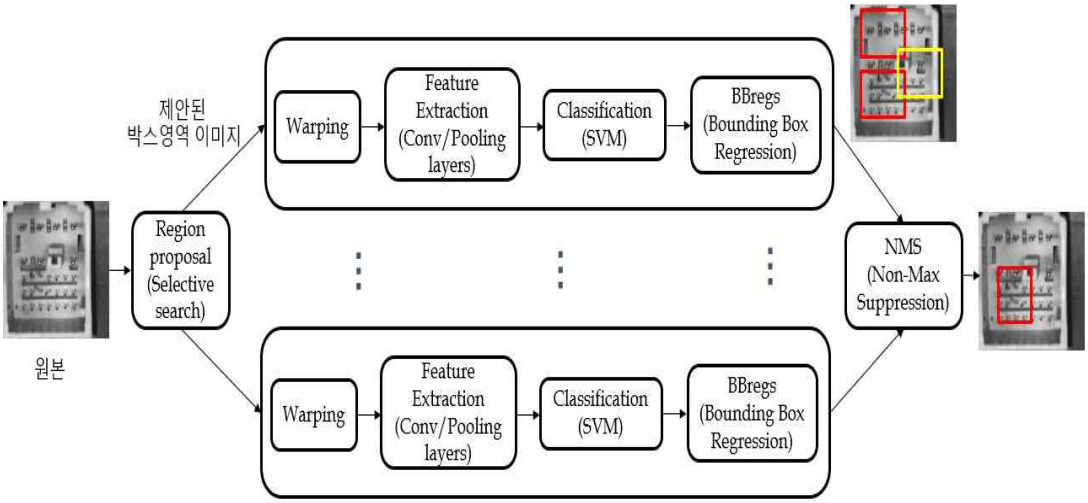

그림 2-4. R-CNN 모델

R-CNN의 등장으로 합성곱 신경망을 활용한 객체 검출의 정확도가 매우 높아졌지만 합성곱 신경망, SVM, 바운딩 박스 회귀 등의 매우 복잡한 과정을 거치기 때문에 여전히 속도는 매우 느리다는 단점이 있었다. 2-스테이지 2D 객체 검출의 단점을 보완하기 위하여 SPP(Spatial Pyramid Pooling) 계층 개념을 도입한 SPPnet [14] , 싱글 스테이지 학습을 도입한 Fast R-CNN [15] 그리고 Selective search 대신 GPU에서 지역적 제안 네트워크를 처리하게 한 Faster R-CNN [16] 모델들이 등장하였으며 지금도 발전된 2-스테이지 2D 객체 검출 모델들이 지속적으로 제안되고 있다.

2.2.2 1-스테이지 2D 객체 검출

2-스테이지 2D 객체 검출에서는 이미지 분류와 Localization을 순차적으로 진행했기 때문에 정확도는 높으나 속도가 느린 단점이 있어 실시간으로 활용하기에는 무리가 있다. 이에 대한 단점을 보완하고 실시간 활용도를 높이기 위해 분류와 Localization을 동시에 진행하는 1-스테이지 2D 객체 검출 모델이 생겨나게 되었다.

가장 대표적인 모델은 YOLO (You Only Look Once) [17] 모델로써 일반적으로 사람들은 어떠한 물체를 인식하고 어디에 있는지 판단할 때 이미지를 전체적으로 한번만 보고 파악이 가능하다는 점에서 착안했다. ROI(Region Of Interest)를 선정하여 바운딩 박스를 제안하는 대신 전체 이미지를 통째로 처리하며 한번의 합성곱 신경망을 통과시켜 한 이미지에 있는 여러개의 객체를 찾아낼 수 있다. [그림 2-5]에 YOLO의 아키텍처가 정리되어있다.

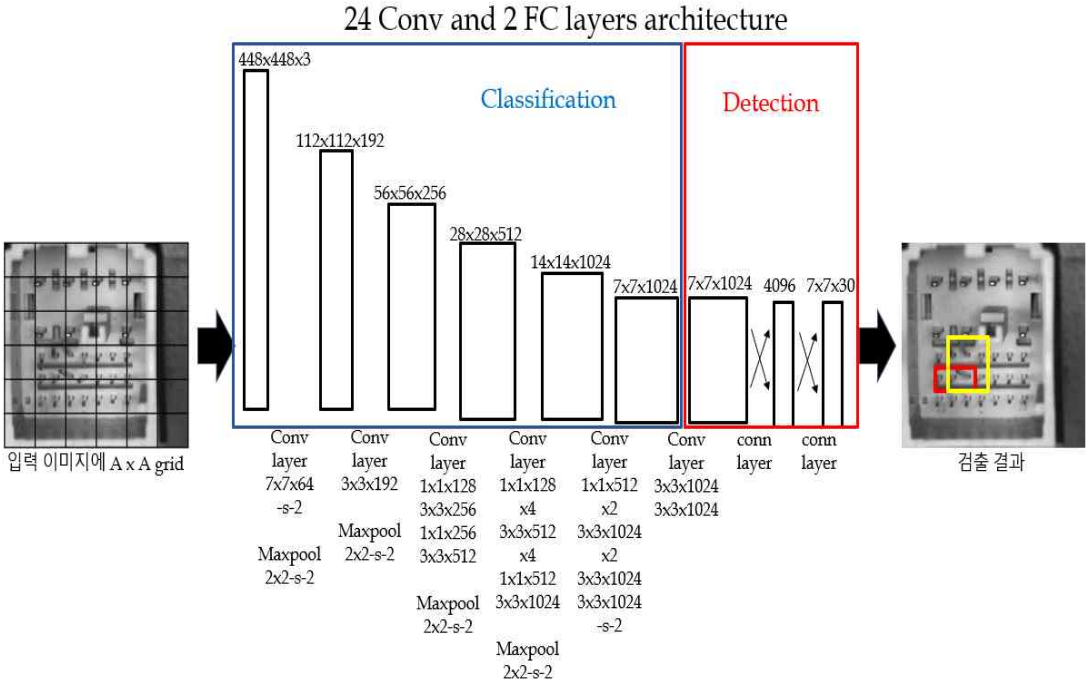

그림 2-5. YOLO 아키텍처

먼저 이미지는 A x A 그리드로 나누어지게 되며 각 그리드 셀(grid cell) 마다 해당 그리드 셀 내에 중심점을 갖는 B개의 바운딩 박스를 제안한다. 이때 바운딩 박스는 $[p_c \quad b_x \quad b_y \quad b_h \quad b_w]$ 5가지 정보를 포함하고 있는데 $[b_x \quad b_y]$는 바운딩 박스의 중심점, $[b_h \quad b_w]$는 바운딩 박스의 높이와 넓이를 나타낸다. 마지막으로 $[p_c]$는 바운딩 박스의 정확도에 대한 신뢰 수준을 나타내는 지표로써 유효한 객체를 포함하고 있는지와 박스의 위치가 얼마나 정확한지를 지표로써 나타낸다. 각 그리드 셀은 여러개의 바운딩 박스를 제안할 수 있지만 확률이 가장 높은 1개의 범주 만을

제안할 수 있다. 이러한 과정을 통해 제안된 여러개의 바운딩 박스 중에서 신뢰 수준이 낮은 것들은 제외하고 Non-max suppression을 통해서 최종 박스당 1개의 객체만을 갖도록 바운딩 박스를 제안한다.

YOLO 모델의 전체 처리 과정중에서 중요한 것은 이 모든 과정을 한번에 처리하기 위해서 이미지 전체를 입력으로 사용한다는 것과 24개의 컨볼루션 계층 그리고 2개의 완전 연결 계층으로 만들어진 1개의 합성곱 신경망 아키텍처를 사용한다는 것이다. [그림 2-5]에 이 부분이 분류(Classification)와 검출(Detection)로 구분되어 있으며 먼저 분류를 위해 ImageNet과 같은 데이터셋을 이용한 선행 학습된 모델을 사용한다. 이후 전이 학습 (Transfer Learning)을 통해 학습이 진행되는데 학습 과정에서 Localization, 분류 및 객체의 정확도까지 한번에 학습될 수 있도록 관련된 모든 정보가 포함된 다기능 손실 함수(Multi-task loss function)가 사용된다. 다기능 손실 함수의 수식은 아래 2.1~2.3 에 나타나있다.

$$\lambda_{coord}\sum_{i=0}^{A^2}\sum_{j=0}^{B}I_{ij}^{obj}[(x_i-\widehat{x_i})^2+(y_i-\widehat{y_i})^2] \tag{2.1}$$

$$+\lambda_{coord}\sum_{i=0}^{A^2}\sum_{j=0}^{B}I_{ij}^{obj}[(\sqrt{w_i}-\sqrt{\widehat{w_i}})^2+\sqrt{h_i}-\sqrt{\widehat{h_i}})^2]$$

$$+\sum_{i=0}^{A^2}\sum_{j=0}^{B}I_{ij}^{obj}(C_i-\hat{C}_i)^2+\lambda_{noobj}\sum_{i=0}^{A^2}\sum_{j=0}^{B}I_{ij}^{noobj}(C_i-\hat{C}_i)^2 \tag{2.2}$$

$$+\sum_{i=0}^{A^2}I_i^{obj}\sum_{c\in classes}(p_i(c)-\widehat{p_i}(c))^2 \tag{2.3}$$

여기에서 x, y는 바운딩 박스의 중심점을 나타내고 w, h는 바운딩 박스의 높이와 넓이를 나타낸다. C는 정의될 수 있는 객체의 종류를 나타내며 p는 해당 객체를 나타낸 바운딩 박스의 신뢰 수준을 나타낸다. 마지막으로 I_{ij}^{obj}는 i번째 셀에 객체가 있으며 j번째 바운딩 박스 그 객체를 나타낸다는 의미이다.

2.1은 Localization을 위한 손실 함수 (Loss function)이며 만약 특정 cell에 객체가 있다고 판단됐을 때 바운딩 박스의 중심점과 높이/넓이에

대한 오차를 측정한다. 높이/넓이가 루트 값으로 계산되는 이유는 크기가 작은 박스의 경우 크기가 큰 박스에 비해 오차가 작게 계산될 것이기 때문에 오차를 증폭 시키기 위해서이다. 그리고 Localization과 분류의 오차에 똑같은 가중치를 주면 안되기 때문에 Localization 오차에 5배 정도의 가중치를 더 주기 위해서 λ_{coord}라는 상수를 추가한다.

2.2는 신뢰 수준에 대한 손실 함수이며 물체가 있는지 없는지에 대한 오차를 계산한다. 이 때 λ_{noobj} 가중치 즉, 물체가 없을 때의 경우에 물체가 있을 때보다 가중치가 부과된 것을 볼 수 있다. 이것은 객체 검출의 목적이 물체가 없는 것을 찾는 것이 아니라 물체가 있는 것을 찾는 것이기 때문이며, 이미지의 대부분을 차지하는 물체가 없는 부분을 찾는 것이 정확도에 포함되지 않게하기 위해서이다.

마지막으로 2.3의 수식을 통해서 그리드 셀이 1개의 물체를 갖고 있을 경우에 모든 범주에 대한 오차를 계산하여 해당하는 물체가 어떤 범주의 물체인지 판단한다.

이러한 YOLO 방식은 2.2.1절에서 소개된 R-CNN, Fast R-CNN 방식에 비해 정확도는 다소 떨어지지만 실시간으로 처리될 수 있을만큼 개선된 속도를 보여준다. R-CNN의 경우 이미지 1장 처리 시간에 40초 정도가 소요되었지만 YOLO의 경우 이미지 1장을 처리하는데 22ms 정도밖에 소요되지 않는다. 이러한 YOLO의 장점으로 인하여 YOLOv2 [18], YOLOv3 [19], YOLOv5 등으로 연구가 발전되며 더 빠르고 정확도가 개선되면서 실시간 객체 검출기로서 널리 사용되고 있고 현재도 개선된 버전의 연구가 지속 진행 중이다.

2.3. 이상점 탐지 기법

산업 데이터의 특성상 양품의 숫자가 절대적으로 부족한 것이 일반적이며 이때 사용할 수 있는 방법론이 이상점 탐지 기법이다. 2.3절에서는 산업용 이상점 탐지를 위한 데이터셋 중 가장 널리 이용되는 MVTec AD [20] 데이터셋을 기반으로 효과적인 성능을 보여주었던 이상점 탐지 방법론 2가지에 대해서 살펴본다.

2.3.1 복원 기반 방법론

첫 번째 방법론은 복원 기반 방법론 (Reconstruction-based method)이며 양품 이미지 데이터만을 이용하여 원본을 복원시키는 학습을 진행한다. 이렇게 하여 원본으로 복원시킬 수 있는 특징점 추출기 (Feature extractor)가 만들어지게 되며 양품 이미지를 입력으로 넣었을 경우 복원이 잘 되겠지만 불량 이미지를 입력으로 넣었을 경우 복원이 잘 되지 않게 된다. 이를 이상점 점수로 환산하여 이상점을 찾는 방법이다.

대표적으로 Autoencoders [21], Variational Autoencoders [22], Generative Variational Networks [23] 등이 있으며 대표적으로 Autoencoder를 이용한 이상점 탐지 방법론을 아래 [그림 2-6]에 정리하였다.

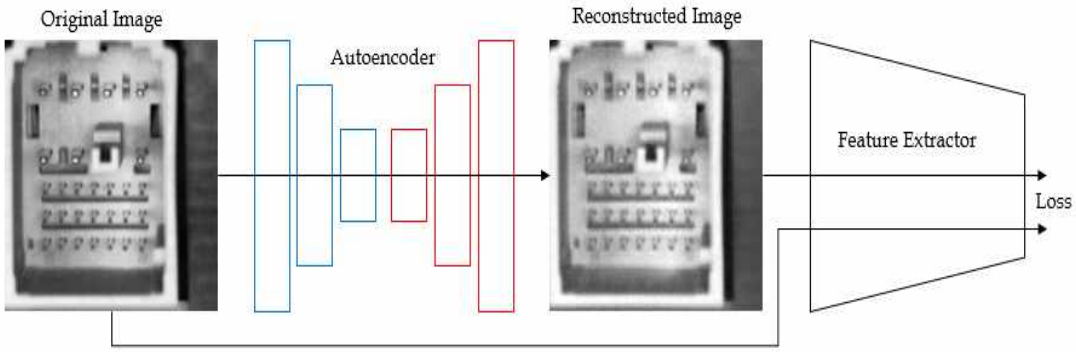

그림 2-6. Autoencoder를 활용한 이상점 탐지

먼저 원본 이미지를 Autoencoder의 입력에 넣어서 인코딩 (Encoding), 디코딩 (Decoding) 과정을 거쳐 원본 이미지를 복원하는

학습을 진행하게 된다. 이렇게 해서 원본을 복원할 수 있는 특징점을 추출한 특징점 추출기를 얻을 수 있게 된다. 특징점 추출기의 손실은 원본 이미지와 복원된 이미지의 차이를 아래 2.4의 MSE (Mean Square Error) 손실 수식을 이용하여 계산한다.

$$MSELoss = \frac{1}{N}\sum_{i=1}^{N}(x_i - \hat{x_i})^2 \tag{2.4}$$

N개의 이미지가 있다고 가정했을 때 원본 x_i와 복원하고자 하는 이미지 $\hat{x_i}$의 차이의 제곱을 N개로 평균을 내어 손실을 산정하는 방식이다. 간단하고 직관적으로 손실을 계산하는 방식이지만 오차가 커질수록 손실이 제곱으로 증가하기 때문에 손실에 매우 민감하다는 특징이 있다.

최적화된 특징점 추출기를 사용하여 양품 이미지와 불량 이미지를 넣었을 때의 최종 손실 값을 이상점 점수로 활용하며 아래 [그림 2-7]와 같이 이상점 점수의 분포를 확인해 보면 불량과 양품 이미지를 구분할 수 있는 임계값 (Threshold)를 설정할 수 있게 된다. 최종 설정된 임계값을 이용하여 양품이 아닌 불량이 의심되는 이미지들을 검출할 수 있게 된다.

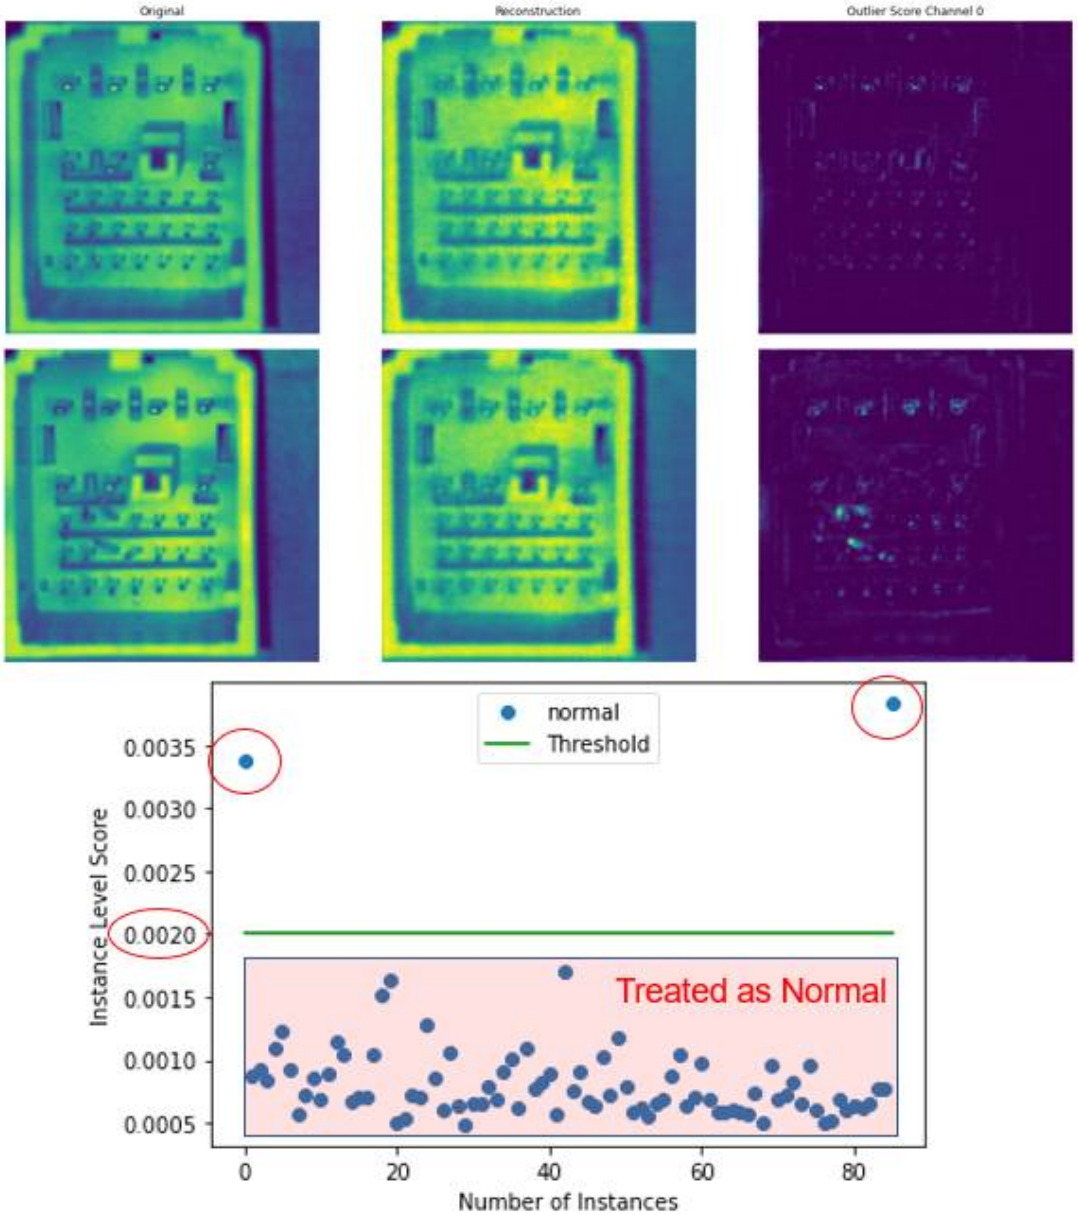

그림 2-7. Autoencoder의 이상점 점수 분포 결과

Variational Autoencoder는 단순 MSE 손실 뿐만이 아니라 데이터들의 평균 및 분산을 고려하여 KL (Kullback-Leibler) Divergence 손실까지 고려한다. 아래 2.5에 Variational Autoencoder의 최종 손실 함수 수식이 나타나 있다.

$$Loss = MSE\,Loss + KLdivergence\ Loss \tag{2.5}$$
$$= \frac{1}{N}\sum_{i=1}^{N}(x_i - \hat{x_i})^2 + KL(p(z) \parallel N(0,I))$$

2.4 수식에서 설명한 MSE 손실 함수에 KL divergence가 결합된 형태로써 정규 분포 $N(0,I)$과 원본 데이터를 대표하는 확률 정보 $p(z)$의 손실이 얼마였는지 즉, 정규성을 판단하는 수식까지 포함하고 있다.

이로 인해 원본 데이터를 복원함에 있어 Autoencoder 보다 장점을 갖게 되며 생성적인 (Gernerative) 특성까지 갖게되어 원본을 복원하는 것 이외에도 데이터를 생성할 수 있는 특징까지 갖게된다. 이러한 복원 기반 방법론은 매우 직관적인 방법론으로 이상점 탐지 방법론 중에서 가장 널리 쓰이는 방식이긴 하나 불량까지 복원하려는 특성으로 인해 미세 불량 검출에는 한계점이 존재하게 된다.

2.3.2 대표성 기반 방법론

두 번째 이상점 탐지 방법론은 대표성 기반 방법론 (Representation-based method)이다. 이 방식의 가장 큰 특징은 별도의 학습 과정이 필요하지 않다는 것이다. 제한된 산업용 이미지의 학습으로부터 얻을 수 있는 데이터는 매우 한정적일 뿐 아니라 전체 산업용 이미지의 특징을 대변할 수 없기 때문에 주어진 산업용 데이터를 이용하여 아무리 많은 반복 학습을 한다고 해도 이미지의 특징을 추출하는 특징점 추출기를 만들어내는데 한계점이 있을 것이란 가정으로부터 생겨나게 되었다. 주어진 산업용 데이터에서만 특징을 추출하는 대신, 이미지 자체의 특징을 추출 한다는 점에 집중하여 ResNet이나 EfficientNet [24] 등의 심층 신경망을 이용하여 1,400여 만장의 ImageNet 데이터셋으로 선행 학습된 합성곱 신경망을 특징점 추출기로 사용한다. 이러한 방식을 사용하는 이상점 탐지 모델 중 대표적인 SPADE (Semantic Pyramid Anomaly Detection) [25] , PaDiM (Patch Distribution modeling) [26] , PatchCore [27] 모델에 대해 살펴본다.

SPADE 방법론을 활용한 이상점 탐지 기법은 아래 [그림 2-8]에 나타나있다. 심층 신경망을 이용하여 ImageNet 등의 방대한 데이터셋으로 선행 학습된 합성곱 신경망으로부터 양품 이미지의 특징점들을 특정 Layer (f1, f2, f3)들을 통해 추출해 낸다. 그 이후 K nearest neighbors(kNN) [28] 방식을 활용하여 테스트하고자 하는 이미지와 가장 유사한 K개의 양품 이미지를 선별한다. 그 이후 차이의 정도를 수식 2.6에 있는 유클리드 거리 (Euclidean distance)를 이용하여 측정한다.

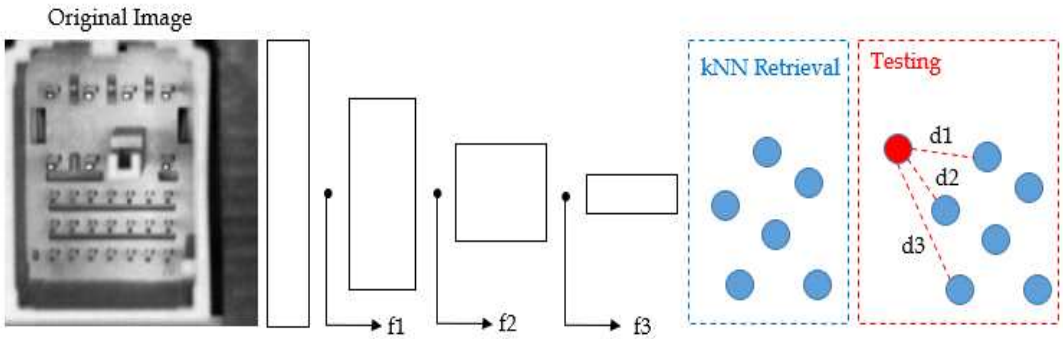

그림 2-8. SPADE 방법론을 활용한 이상점 탐지

$$d(y) = \frac{1}{K} \sum_{f \in N_K(f_y)} \| f - f_y \|^2 \tag{2.6}$$

테스트하고자 하는 이미지를 y라고 하고, 양품 이미지들로부터 추출된 특징점들을 $N_k(f_y)$라고 한다면, 이 중에서 kNN 알고리즘으로 K개의 가장 유사한 이미지를 선별하고나서 각각의 거리를 측정하게 되고 만약 이 거리가 설정한 임계값 보다 크게 되면 최종적으로 이미지에 이상점이 있다고 판단하게 된다.

SPADE는 MVTec AD 데이터셋 기준으로 이상점 탐지 성능에서 SOTA를 달성할만큼 효과적인 방법론이긴 하나 테스트 진행 시에 kNN 알고리즘을 이용해 유사 이미지 선별하는 작업을 전체 양품 이미지 기반으로 진행하기 때문에 계산의 복잡도가 높고 전체 이미지 개수에 따라 복잡도가 선형적으로 증가되는 문제가 있다. 이러한 문제를

개선하고자 Gaussian-AD [29]의 Multivariate Gaussian 개념을 도입하여 공분산과 평균을 고려한 마할라노비스 거리 (Mahalanobis distance) [30] 활용하는 PaDiM 방법론이 등장하였고 아래 [그림 2-9]와 같이 나타낼 수 있다.

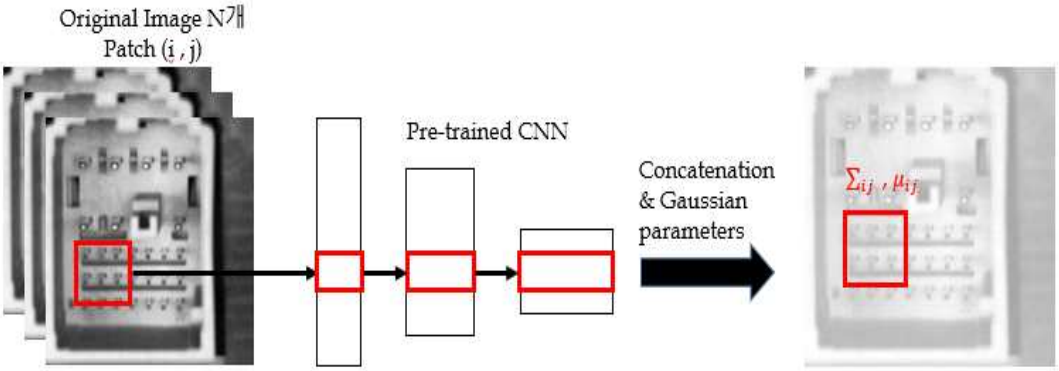

그림 2-9. PaDiM 방법론을 이용한 이상점 탐지

PaDiM의 경우 이미지를 패치 (Patch) 단위로 쪼개서 특징점을 추출하게 된다. [그림 2-9]와 같이 1개의 이미지를 패치(i,j)의 벡터로 나누고 이를 선행 학습된 합성곱 신경망의 각 Layer를 통과시켜 특징점을 추출한다. 이렇게 나오는 결과물들의 size가 모두 다르기 때문에 이를 통일화 시켜 주기 위해 concatenation을 수행하여 size를 모두 맞춰주어 1개 패치의 특징점 추출을 완료한다. 이를 N개의 이미지로부터 모두 수행하여 각 패치간의 평균값과 공분산을 계산하여 이를 패치가 해당하는 위치를 대표하는 특성을 갖는 Guassian 파라미터 matrix로 만든다. 테스트 이미지 입력을 x라고 한다면 테스트 이미지의 특정 패치의 특징점을 추출한 후 Guassian 파라미터 matrix에 있는 값과 수식 2.7에 나타나 있는 마할라노비스 거리를 계산하여 차이점을 수치화 한다.

$$M(x) = \sqrt{(x-\mu)^{\top} \Sigma^{-1} (x-\mu)} \tag{2.7}$$

수식에서 볼 수 있듯이 평균값 μ뿐만 아니라 공분산 Σ까지 고려하여 차이점을 계산함으로써 주변 패치들과의 연관성까지 고려하게

되면서 불량의 위치를 찾는데 이점을 갖게된다.

마할라노비스 거리가 설정한 임계값 보다 높을 경우 불량이라고 판단할 수 있으며, 이미지를 패치 기반으로 쪼개서 분석하였기 때문에 작은 불량의 위치도 수치를 heat map으로 표시했을 때 눈으로 확인할 수 있다. 공분산과 평균 개념을 활용하였기 때문에 kNN 방법론 보다 계산의 복잡성과 시간이 줄어들게 되었으며 각 이미지 패치들 간의 연관성도 고려하므로 정확도도 향상되게 된다.

PatchCore 방법론의 경우 현재 MVTec AD 데이터셋 기준 이상점 탐지 관련해 SOTA 성능을 달성하고 있는 모델이며 PaDiM과 마찬가지로 이미지를 패치로 쪼개어 접근하며 선행 학습된 합성곱 신경망으로부터 특징점을 추출한다. 패치의 특성을 추출할 때 인접한 패치의 특성까지도 고려하여 Localization 성능 향상에 기여하였으며 정확도 및 추론 속도 향상을 위해서 ImageNet에 편향되는 현상을 최대한 막고자 합성곱 신경망의 중간 Layer로부터 특징점을 추출하고 Coreset 서브샘플링 [31] 방법을 이용하여 뽑아낸 특징점들을 Memory-bank 개념으로 저장하고 추론할 때 활용한다.

제 3 장 문제 정의 및 방법론

3.1. 문제 정의 및 데이터 분석

산업 현장에서의 문제를 딥러닝 기반 방식으로 해결하는데 있어서 가장 어려운 점은 데이터 확보에 비용과 시간이 많이들 뿐만 아니라 데이터 간의 불균형이 심하다는 것이다. 실제 핀 비전 검사의 이미지들을 생산 법인에서 받았을 때 양품 8,123장 / 불량 86장으로 불량 이미지의 수가 현저히 적어 불균형이 심한 상태였다. 86장의 불량을 세분화 했을 경우 아래 [표 3-1]과 같이 Bent Pin 불량, Bent Pin과 Particle이 혼재된 불량 그리고 Particle이 있는 불량으로 나눌 수 있었고 이 불량 현상들 간에도 수량의 불균형이 심한 것을 확인할 수 있었다. 불량 현상들은 [그림 3-1]과 같은 대표적인 형상을 가지며 각 불량 형상들로 인해 조립 불가, 특정 기능 오동작 그리고 진행성 접점 불량을 야기 시킬 수 있다.

총 데이터 수	양품	불량 (86)		
		Bent Pin	Bent Pin + Particle	Particle
8,209	8,123	4	2	80

표 3-1. 데이터 분류 및 불량 세분화

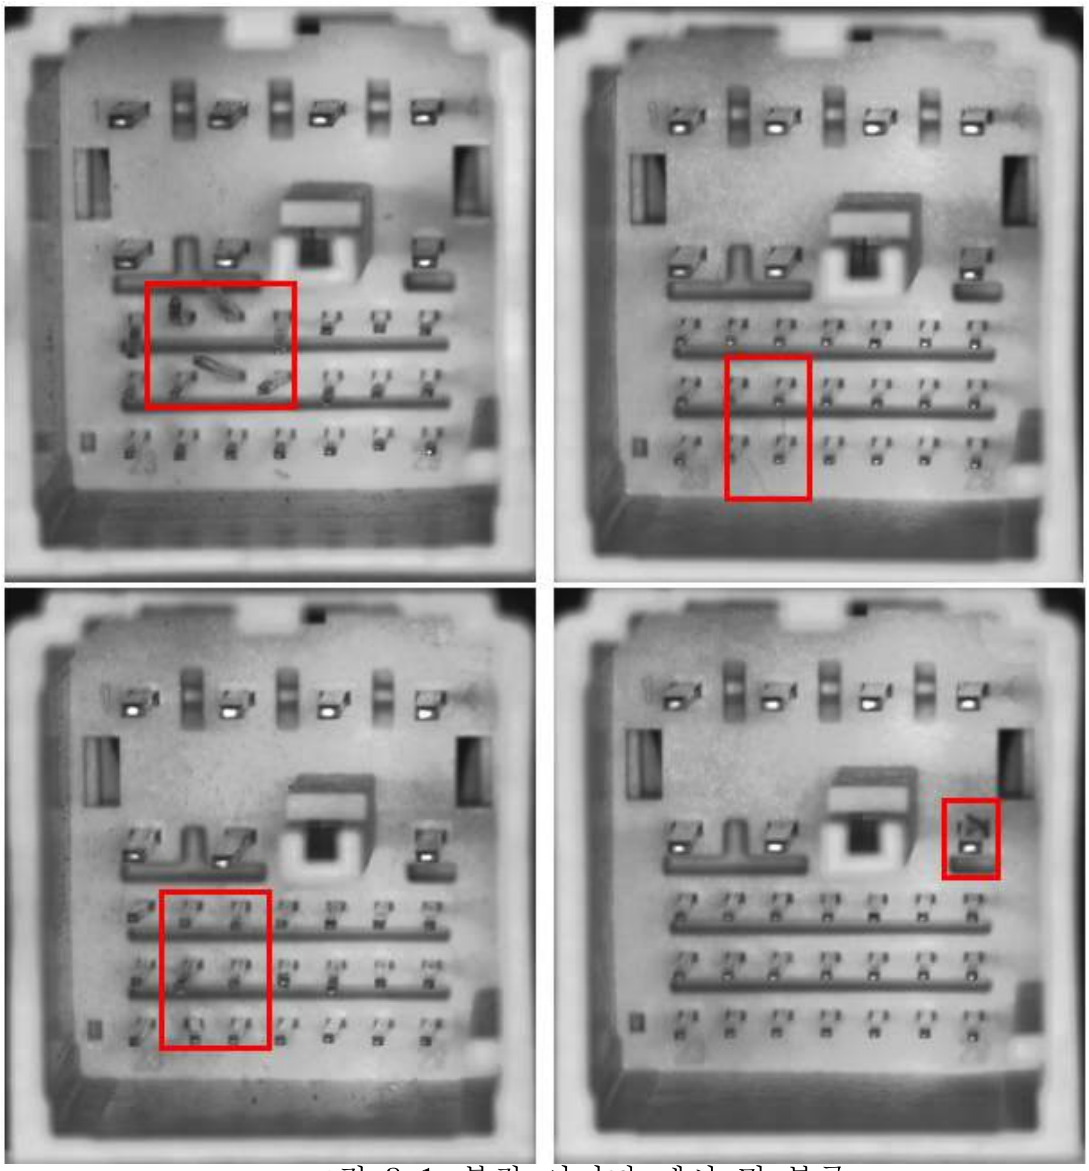

그림 3-1. 불량 이미지 예시 및 분류

이상점 탐지 기법을 활용할 경우 양품 데이터에서만의 특징을 추출하여 불량을 검출하는 방법이기 때문에 추가 데이터없이도 현재 데이터 만으로도 전반적인 형상 불량 검출이 가능한 장점이 있지만 이상점 탐지 기법의 특성상 전반적이고 전체를 고려한 특징점만을 추출하여 다른 이미지와 비교하기 때문에 현재 불량 데이터에서 가장 점유율이 높은 Particle과 같은 미세 불량의 검출에는 한계점이 존재하게

된다. 이러한 문제점 극복을 위해서는 객체 검출 기법으로의 접근이 필요하며 객체 학습을 위한 불량 데이터 추가 확보 및 딥러닝 기법에 많이 이용되고 있는 데이터 증량 기법을 통한 데이터 증량이 필수적으로 선행되어야 한다. 이러한 과정을 통해 학습 시킬 수 있는 다양한 객체의 절대적인 개수를 증가시킴으로써 딥러닝 기반의 객체 검출의 정확도를 향상 시킬 수 있다.

3.2. 문제 해결을 위한 방법론 고찰

3.1.에서 정의된 문제점과 데이터의 특성을 고려하였을 때 문제 해결을 위한 Logic Tree를 [그림 3-2]에 나타내었다. 데이터 간의 불균형 여부와 불량 데이터가 충분한지 여부에 따라 크게 이상점 탐지 기법과 분류/ 객체 검출 기법 2가지 방법론으로 분석이 가능함을 확인할 수 있다.

데이터의 추가 획득이나 가공 없이 입수한 데이터를 그대로 사용하게 되면 데이터간의 불균형도 심하고 불량의 수가 현저히 적기 때문에 선택할 수 있는 방법은 이상점 탐지 기법이다. 정상 이미지의 특징을 추출하는 방법에 따라 복원 기반 방법론과 대표성 기반 방법론으로 나눌 수 있으며 두가지 모두 별도의 학습과정 없이 특징을 추출하여 불량을 검출할 수 있다는 장점은 있지만 Particle과 같은 미세한 불량을 검출해 내는데는 한계점이 존재한다. 따라서 이상점 탐지 기법을 활용하여 정형화되지 않은 불량 유형 및 LOT성 불량 검출과 미승인품 혹은 모조품 투입을 생산 초기에 검출하는 도구로써 활용한다. 복원 기반 방법론의 경우 특징을 추출하는 과정에서 불량 현상을 복원하려는 성질이 있기 때문에 본 연구에서는 대표성 기반 방법론 중에서 핀 비전 데이터셋에 가장 효과적인 방법론을 찾아 최적화 한다.

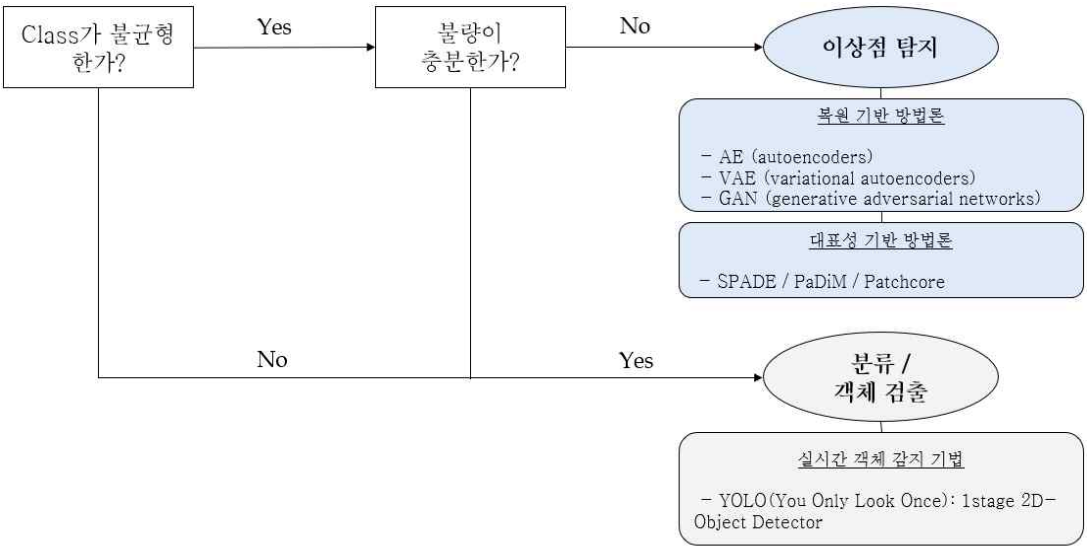

그림 3-2. 문제 해결을 위한 Logic Tree

정형화되어있는 Bent Pin과 Particle 유형의 불량을 모두 검출해 내기 위해서는 데이터간의 수량 불균형을 없애는 작업이 필요한데 결국 이는 충분한 수의 불량 데이터 확보가 필요하다는 말과 같다. 충분한 수의 데이터를 확보하기 위하여 생산 현장에서의 불량 이미지 추가 확보를 우선적으로 진행하고 정형화된 불량 형상들을 기반으로 양질의 인위적인 불량 데이터를 추가적으로 제작하였다. 실제 불량 이미지들을 최대한 증가시킨 뒤 추가적인 정확도 확보를 위해 데이터 증량 기법을 통하여 학습할 수 있는 불량 이미지를 최대화 한다.

[그림 3-3]에 추가 확보된 불량 데이터들의 예시가 있다. 실제 생산에서 발생된 Bent Pin, Particle 형상을 기반으로 추가로 제작되었으며 생산라인에서 확보된 이미지 대비 해상도가 떨어지고 조도가 일정하지 않지만 Bent pin과 Particle의 객체 학습 측면으로 보면 다양성을 확보하고 과적합(Overfitting) 문제를 해결할 수 있기 때문에 검출 정확성을 확보하는데에 도움이 된다.

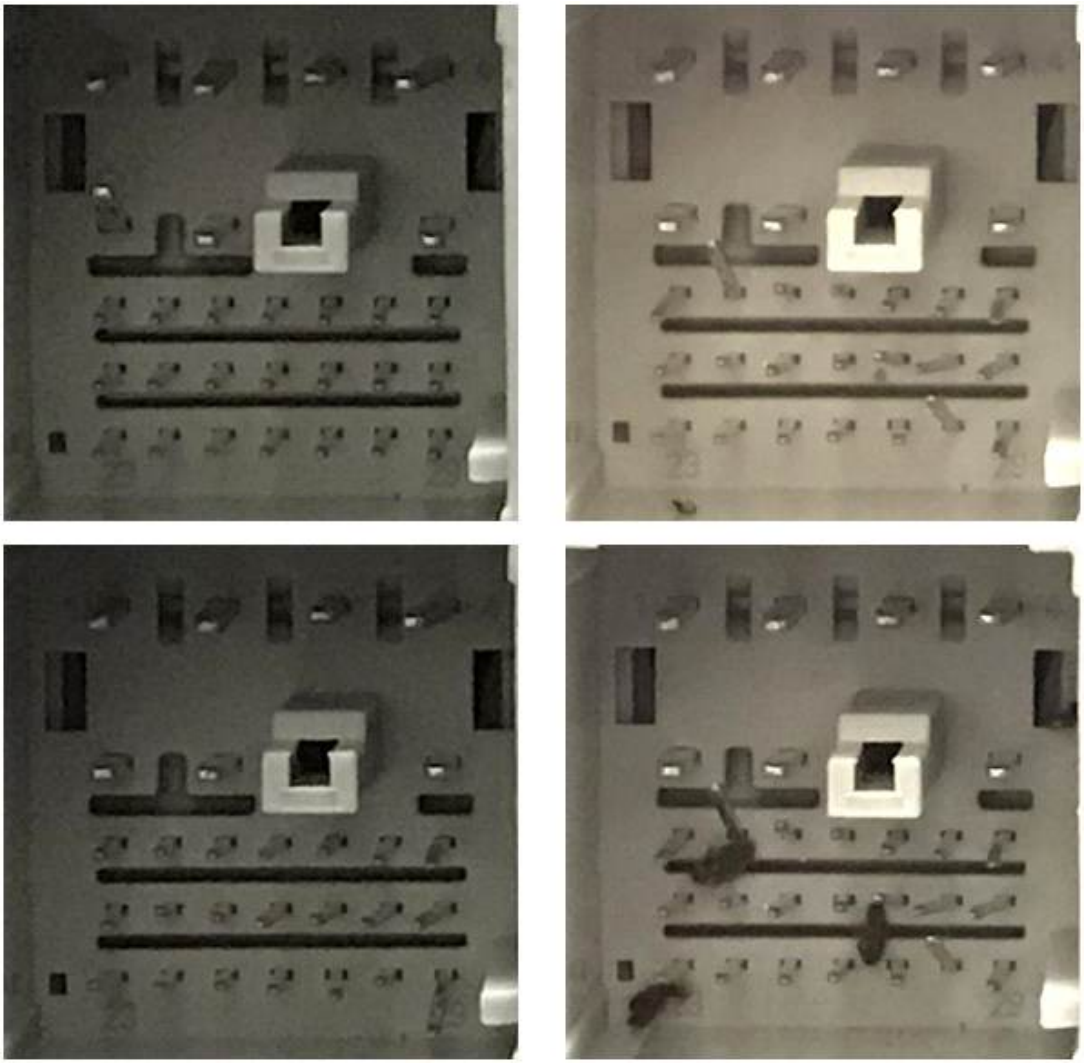

그림 3-3. 추가 확보된 불량 데이터

같은 목적으로 데이터 증량 기법을 활용하여 학습에 확용할 수 있는데이터 수를 최대화 시킬 수 있다. [그림 3-4]에 나와있는 예시처럼 원본 이미지에서 조도 (Brightness) 조절, 이미지 반전 (Hrizontal/ Vertical Flip) 및 각도 조절 (Rotation)을 통해서 사람에게는 유사해 보일 수 있지만 컴퓨터 비전 측면에서 학습할 수 있는 이미지들이 다량으로 생성되게 된다. 하나의 불량 이미지에 다량의 Bent Pin 및 Particle 불량 형상이 섞여있는 경우도 있으므로 학습 할 수 있는 객체의 갯수는 이미지 갯수 대비 현저히 늘어나는 효과를 기대할 수 있다.

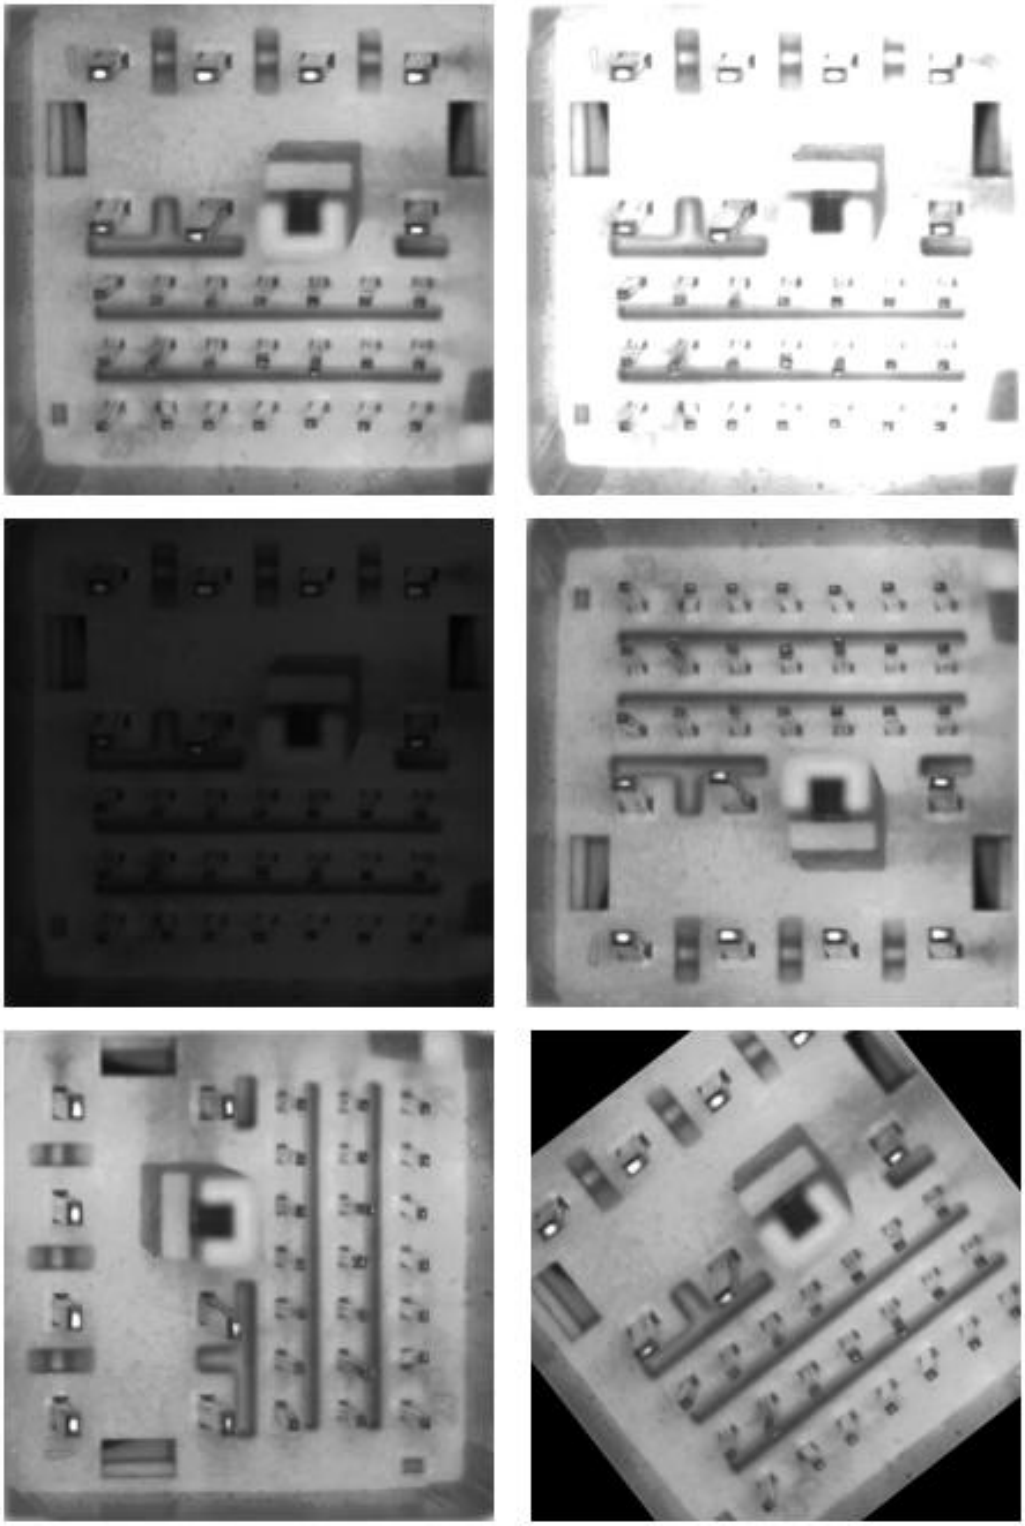

그림 3-4. 데이터 증량 이미지 예시

본 연구의 목적이 정형화된 불량 이미지 검출의 정확도와 추론 속도를 모두 개선하는 것이므로 증량된 이미지로 부터 정의된 Bent Pin, Particel을 학습/ 추론 시키는데에 1-스테이지 2D 객체 검출 모델 중 실시간 객체 검출 성능에서 SOTA(State Of The Art)를 기록했던 YOLO v5의 Nano/ Small/ Medium/ Large/ X-Large 5가지 모델의 신뢰 수준을 변화 시키면서 정확도와 추론속도 2가지 측면에서 모두 최적의 성능을 나타낼 수 있는 모델을 연구한다.

최적화 작업 이후 최종 선택된 이상점 탐지 모델과 객체 검출 모델을 기반으로 생산 최초 투입 부터 출하까지 비정형화된 불량 및 정형화된 불량을 모두 검출하면서 기존 검출 방법보다 추론 속도를 개선시켜 사업적인 성과를 얻을 수 있는 방법론을 최종 제안한다.

3.3. 성능 평가 지표

정형화된 불량을 검출해내는 성능을 평가하는 지표(Metric)로서는 정확도(Accuracy), F1-score를 사용한다. 해당 지표를 정의하려면 우선 아래 [표 3-2]에 있는 혼동 행렬 (Confusion Matrix)에 대한 이해가 필요하다.

		예측값	
		정답 (Positive)	오답 (Negative)
실제값	정답 (Positive)	TP (True Positive)	FN (False Negative)
	오답 (Negative)	FP (False Positive)	TN (True Negative)

표 3-2. 혼동 행렬

본 연구에서는 불량이 제대로 검출된 경우를 정답(Positive)으로 정의한다. 따라서 각각의 지표들은 아래와 같이 정의될 수 있다.

i. TP : 불량을 불량으로 제대로 검출한 경우

ii. FP : 양품인데 불량으로 잘못 검출한 경우

iii. FN : 불량인데 양품으로 잘못 검출한 경우

iv. TN : 양품을 양품으로 제대로 검출한 경우

분류/ 객체 검출 모델에서 TP, FP, FN, TN의 경우를 분류하여 학습을 통한 예측값을 실제값과 비교하기 위해 만든 표가 혼동 행렬이며 이 값들을 통한 성능 지표를 아래의 3.1~3.4의 4가지 정밀도 (Precision), 재현율 (Recall), 정확도, F1-score 수식으로 구분할 수 있다.

$$\mathrm{Pr}ecision = \frac{TP}{TP + FP} \tag{3.1}$$

$$Recall = \frac{TP}{TP + FN} \tag{3.2}$$

$$Accuracy = \frac{TP + TN}{TP + FN + FP + TN} \tag{3.3}$$

$$F1 - score = 2 \times \frac{1}{\frac{1}{\mathrm{Pr}ecision} + \frac{1}{Recall}} \tag{3.4}$$

4가지 지표 중에서 정형화된 불량 검출의 최종 성능은 얼마나 정확하게 예측했는지와 재현율 및 정밀도의 평균값을 통해 평가할 수 있도록 정확도와 F1-score로 나타내도록 한다.

비정형화 된 불량의 검출력은 이상점을 검출하는 이진 분류기의 성능을 나타내는데 주로 사용되는 AUROC (Area Under the Receiver Operator Curve)를 사용한다. 여기에는 혼동 행렬에서 정의된 지표 중 TP, FP가 사용되며 TPR (True Positive Rate)와 FPR (False Positive Rate)값을 이용하여 그린 그래프를 ROC 곡선이라고 하며 [그림 3.5]에 나타나 있다.

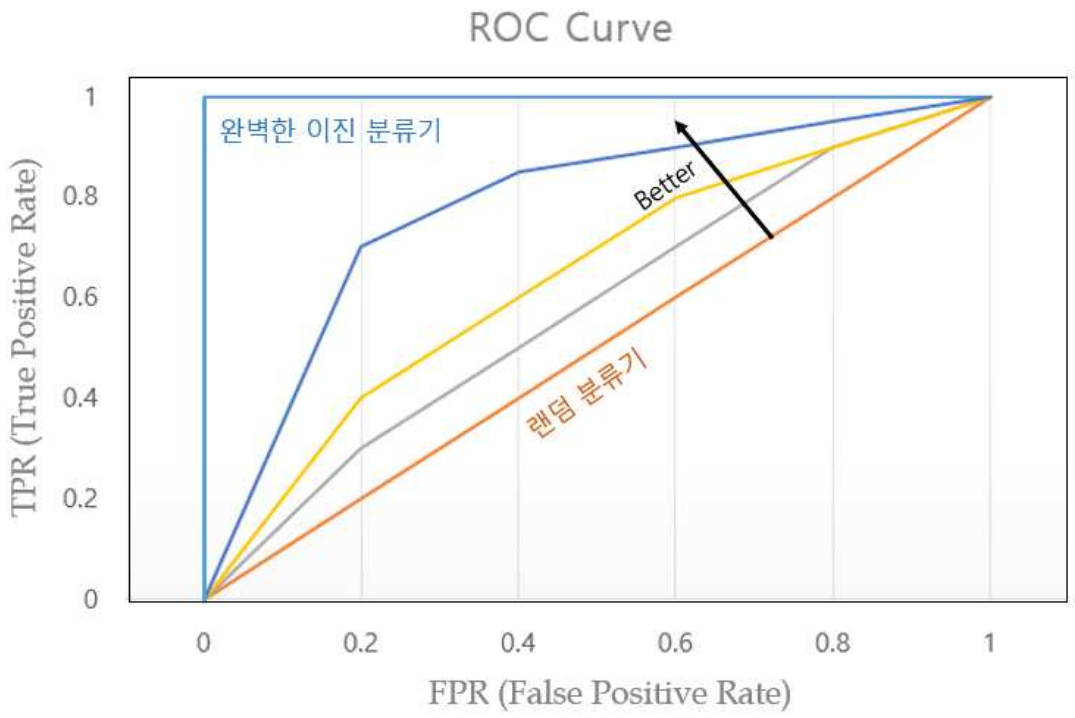

그림 3.5. ROC 곡선

ROC 곡선에서 나타나는 면적을 AUROC라고 하며 이를 이상점 탐지 기법의 성능 지표로 나타낸다. AUROC값이 1에 가까울 수록 완벽한 이진 분류기로 동작한다는 것이고 0.5일 경우 랜덤 분류기의 성능을 나타내므로 이진 분류기의 역할을 할 수 없는 것으로 판단한다.

제 4 장 실험 및 평가 결과

4.1. 데이터셋의 구성과 전처리

3.2.에서 불량 데이터 증량 방법론으로 제안된 추가 실제 생산 불량 이미지 확보, 인위적인 불량 데이터 추가 제작 및 데이터 증량 기법을 통하여 최종 확보된 데이터셋은 아래 [표 4-1]과 같다.

총 데이터	양품	불량 Bent Pin / Particle (1,467)			
		원본	생산법인	자체제작	데이터 증량
9,590	8,123	86	43	98	1,240

표 4-1. 최종 확보된 데이터셋

최초 86장이었던 불량은 생산 법인으로부터 추가 확보된 43장, 자체제작된 98장 그리고 회전, 반전, 조도 조절 등의 데이터 증량 기법으로 증량된 1,240장을 더하여 최종 1,467장으로 증량되었다. 이 중 생산 라인에서 실제 불량으로 발생된 원본 86장과 생산법인 43장, 총 129장은 최종 Test 용도로만 사용하며 나머지 1,338장을 이용해 학습(Training)과 검증 (Validation)을 진행한다. 불량 이미지의 갯수는 1,467장으로 정해졌지만 불량 이미지 1장에도 여러가지의 Bent Pin 및 Particle 형상이 있는 경우도 많이 있다. [그림 4-1]에서 실제 여러 객체들이 혼재되어 있는 이미지를 볼 수 있으며 이러한 경우를 고려했을 때 학습/ 검증이 가능한 전체 1,338장의 불량 이미지에서 얻어지는 Bent Pin 객체는 약 1,000여개 그리고 Particle 객체는 약 1,600여개로써 이미지 갯수보다 객체 측면에서 더 많은 데이터를 얻을 수 있음이 확인되었고 학습/ 검증 과정을 거쳐 Test 진행 시 객체 검출력을 높이는데 도움이 될 것으로 예상한다.

학습을 진행하기 전에 이미지 크기 조정 / 자르기 (resizing & crop)작업 및 학습이 진행되어야 할 객체에 대한 라벨링(Labeling)작업이 선행되어야 한다. 원본 이미지는 고해상도로 2526x2236 크기를 갖기 때문에 컴퓨터 비전으로 처리하기에는 너무 크고 시간도 오래 걸린다. 그래서 이미지를 512x512로 크기 조정을 진행하며, 커넥터 내부의 Bent Pin 및 Particle 감지하는 것이 목표이기 때문에 불필요한 커넥터 이외의 부분들은 자르기한다. 이후에는 Bent pin과 Particle이 있는 위치와 형상들을 학습할 수 있도록 하나씩 박스로 지정하고 라벨링 작업을 진행한다. [그림 4-2]에 이미지 크기 조정 / 자르기 및 객체 라벨링의 전처리의 결과물을 보여주고 있다.

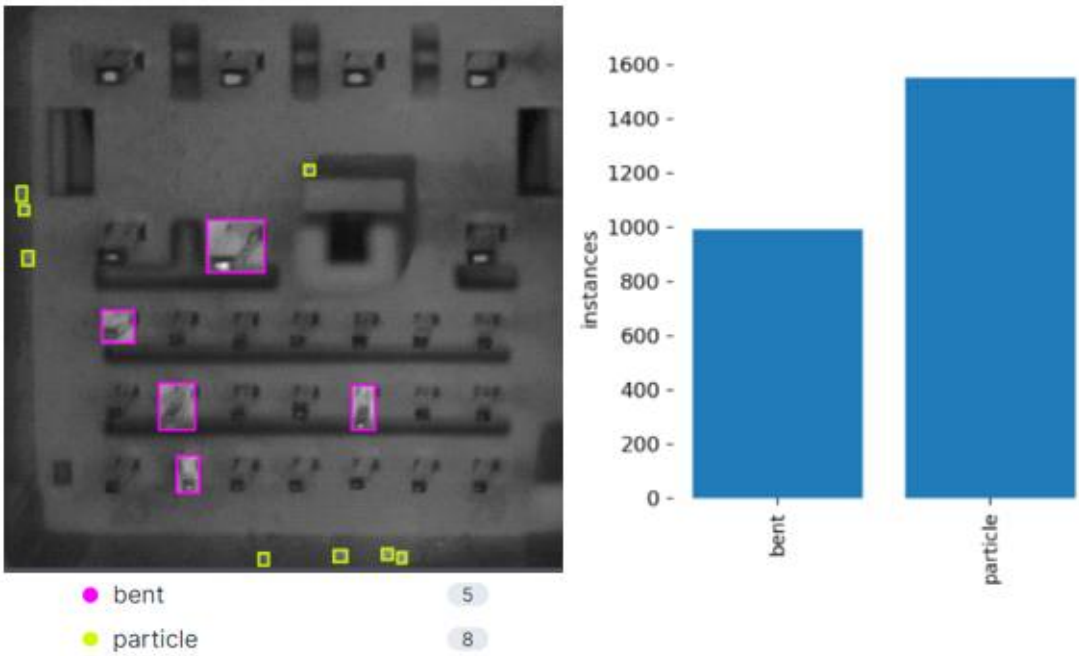

그림 4-1. 객체 예시 및 분포

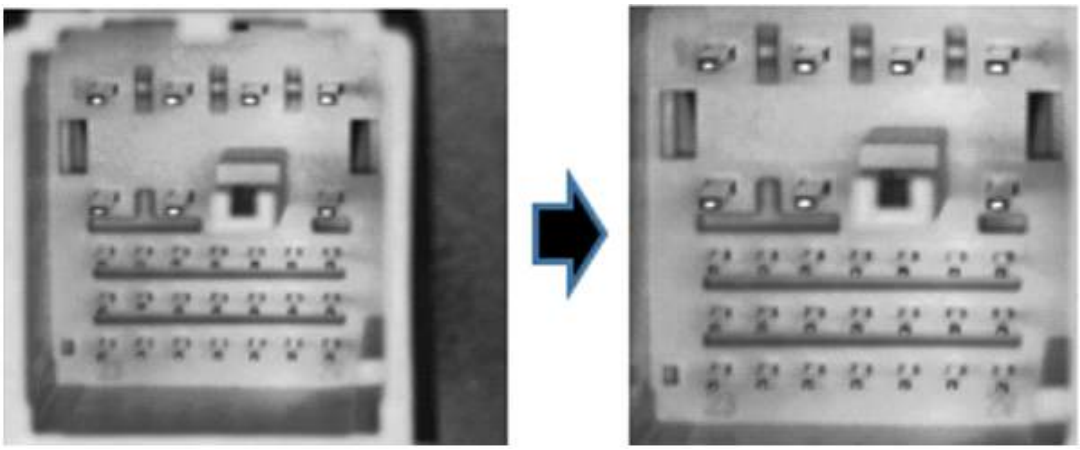

(a) 크기 조정 및 자르기

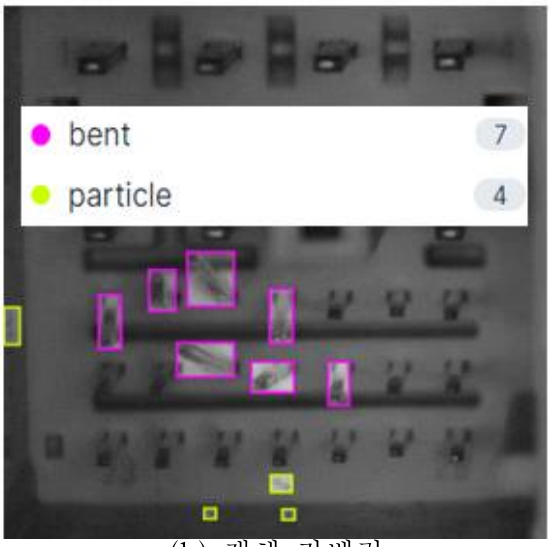

(b) 객체 라벨링

그림4-2. 이미지 전처리 및 라벨링

이상점 탐지 기법의 경우는 전체 이미지로 판단을 하기 때문에 별도 라벨링 작업을 진행하지 않고 단순히 양품과 실제 불량으로만 구분을 하고 양품으로 부터 특징점을 추출하여 불량 이미지와 테스트를 진행한다

최종 추론 진행 시에는 양품 300장과 실제 생산에서 얻고 학습에 사용되지 않은 불량이미지 129장을 사용해 정확도, F1-score, AUROC를 정확도 성능 지표로 산출하고 추론 시간을 측정한다.

4.2. 실험 환경

주요 실험은 실험 진행의 시간과 효율성 그리고 실제 생산 라인에서 사용될 경우를 고려하여 아래 [표 4-2]와 같은 환경에서 진행되었다.

Items	Specification
OS	Ubuntu 18.04.5 LTS
GPU	NVIDIA GeForce RTX 3090
CPU	(Server) Intel(R) Core(TM) i7-9700K (Local) Intel(R) Core(TM) i7-8550U
Python	3.9.7
Library	Pytorch 1.10.1 CUDA 11.6

표 4-2. 실험 환경

OS는 Ubuntu 18.04.5 LTS를 사용하였으며 단순한 객체 검출 / 이상점 탐지 모델부터 복잡한 신경망을 필요로하여 연산량이 많은 모델을 빠른 시간안에 효율적으로 테스트 하기 위해서 Intel(R) Core(TM) i7-9700K CPU와 NVIDIA GeForce RTX 3090 GPU 환경에서 진행하였다. 실제 생산 환경을 고려한 추론 시간 측정 시에는 일반 노트북에 많이 사용되고 있는 Intel(R) Core(TM) i7-8550U CPU만으로 테스트를 진행하였다. Language는 Python 3.9.7 기반으로 Pytorch 1.10.1을 사용하여 YOLO, PaDiM 등의 객체 검출, 이상점 탐지 알고리즘 구현을 진행하였다.

4.3. 실험 결과 및 평가

4.3.1 객체 검출 기반 실험 결과

객체 검출 성능 측정을 위하여 선택한 모델은 실시간 객체 검출 성능에서 SOTA를 달성했던 YOLOv5 모델이다. YOLOv5 모델의 경우 합성곱 신경망의 복잡도에 따라 Nano, Small, Medium, Large, X-Large 총 5가지 모델로 구분이 되며 핀 비전 데이터셋에 가장 효과적인 모델을 찾기 위해 5가지 모델의 경우에 대해 모두 학습/ 검증/ 테스트를 진행하였다.

4.1.에 설명된대로 이미지 크기 조정, 자르기 및 라벨링까지 전처리가 완료된 데이터 1,338장은 학습과 검증을 위하여 8:2의 비율로 임의로 나눠지게 되며 Batch Size 32, Epoch 1,000회 기준으로 5가지 YOLOv5 모델로 학습을 진행하였다. 학습을 진행하면서 Loss 값은 0에 수렴하고 정확도는 100%에 가까워지는 이상적인 그래프를 얻을 수 있었다. 5가지의 YOLOv5 모델 중 YOLOv5 Small 모델의 Epoch 1,000회 동안의 학습, 검증 데이터들의 객체 손실 및 정확도의 경향성은 [그림 4-3]에서 확인할 수 있으며 검증 과정을 통해 검출된 이미지의 예시는 [그림 4-4]에서 확인할 수 있다.

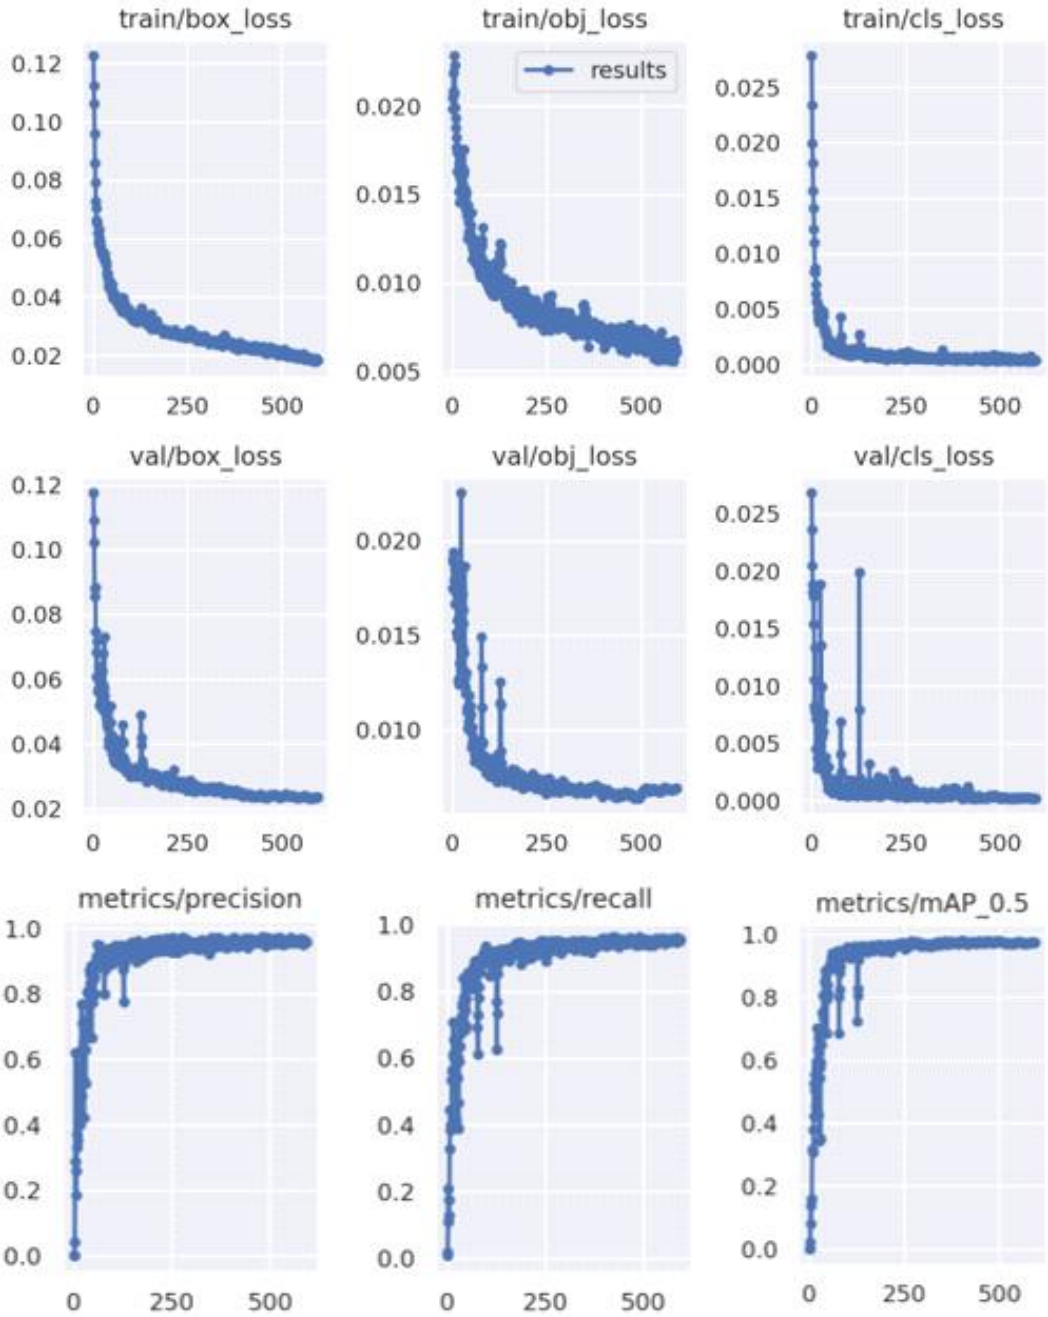

그림 4-3. 학습 및 검증 진행 시 손실과 정확도 추이

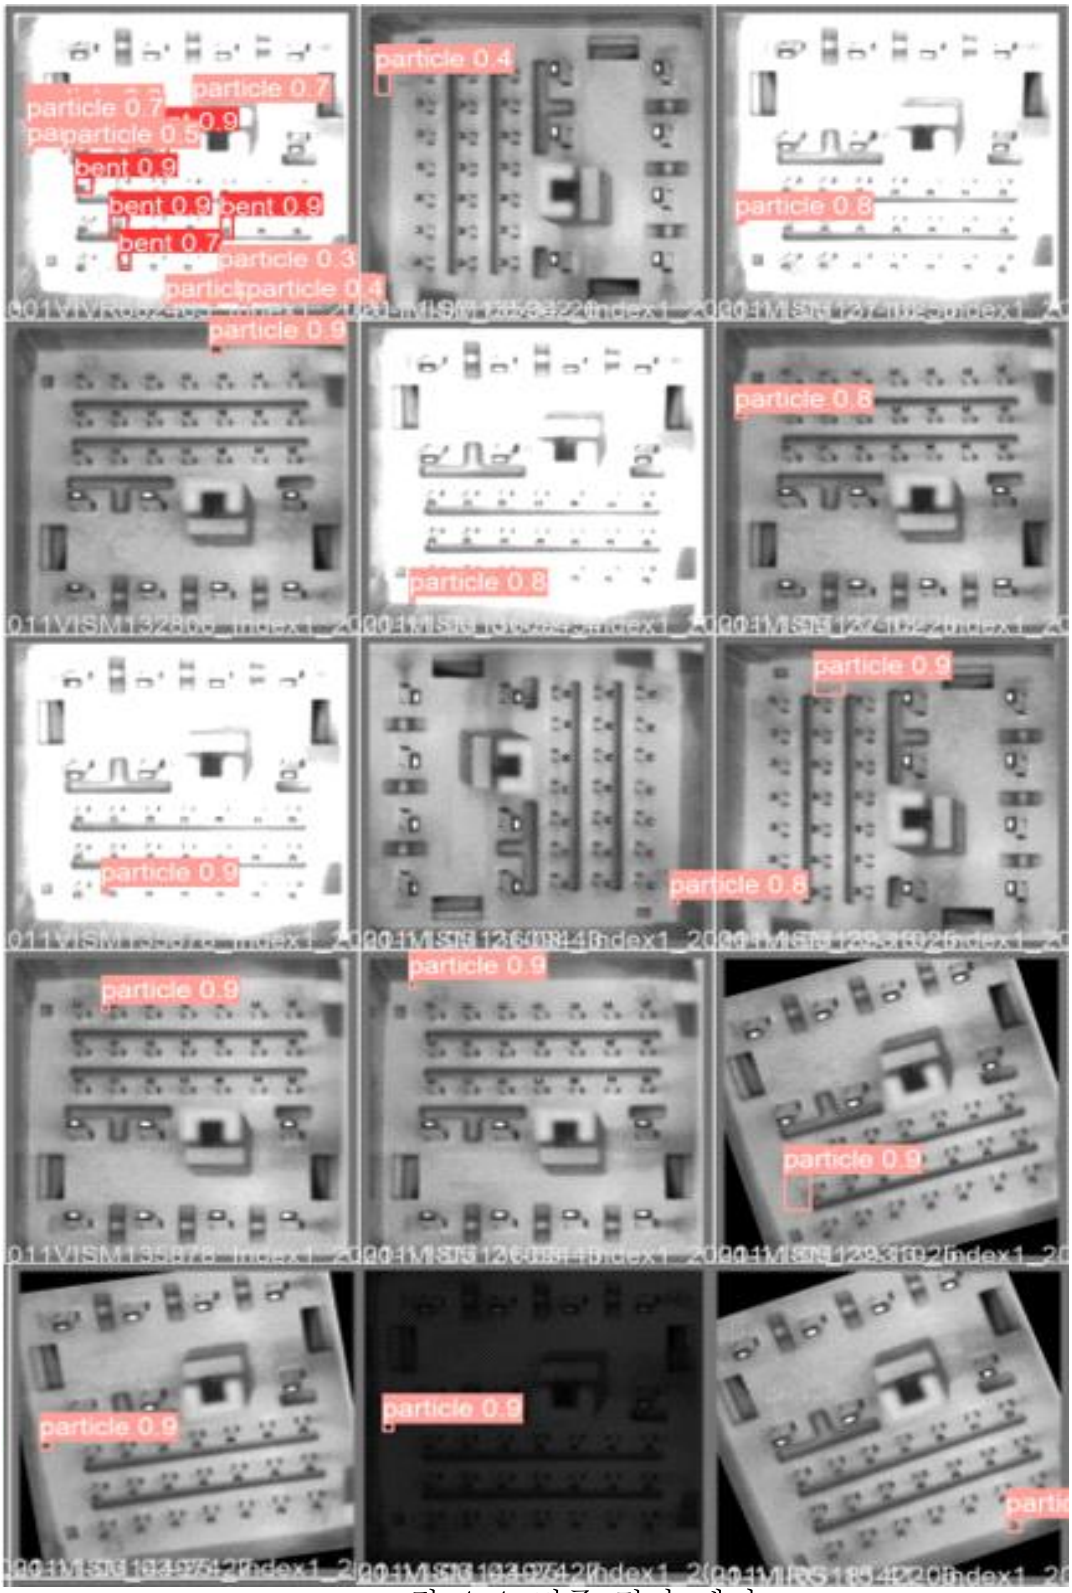
particle 0.7
particle 0.7
0.9
papaparticle 0.5
bent 0.9
bent 0.9
bent 0.9
bent 0.7
particle 0.3
particlparticle 0.4
particle 0.9
particle 0.4
particle 0.8
particle 0.9
particle 0.8
particle 0.8
particle 0.9
particle 0.9
particle 0.8
particle 0.9
particle 0.9
particle 0.9
particle 0.9
particle 0.9
particle 0.9

그림 4-4. 검증 결과 예시

5가지 YOLOv5 모델로 최종 학습된 결과를 이용하여 검증을 진행한 결과를 [표 4-3]에 나타내었다. Bent Pin과 Particle 각각의 객체에 대한 결과 및 2가지 객체를 통합했을 때의 결과도 보여주고 있으며 F1-score 기준으로 보면 전체 객체에 대한 성능은 Small 모델이 95.9%로 가장 좋으며 Bent Pin 객체에 대한 성능은 Medium 모델이 96.4%로 가장 좋다. 마지막으로 Particle 객체에 대한 성능은 Large 모델이 96.1%로 가장 좋은 것을 확인할 수 있었다. 모델이 무조건 복잡할수록 성능이 좋은 것이 아니라는 것을 보여준 결과이며, 분석하고자 하는 데이터의 특성 및 형상에 따라 최적의 모델을 선택해야 한다는 것을 알 수 있었다.

분류	YOLOv5 모델	정밀도	재현율	F1-score
전체 객체	Nano	0.964	0.932	0.948
	Small	0.971	0.948	0.959
	Medium	0.953	0.959	0.956
	Large	0.966	0.948	0.957
	X-Large	0.946	0.921	0.933
Bent Pin	Nano	0.969	0.941	0.955
	Small	0.974	0.951	0.962
	Medium	0.943	0.987	0.964
	Large	0.961	0.945	0.953
	X-Large	0.935	0.961	0.948
Particle	Nano	0.959	0.924	0.941
	Small	0.969	0.945	0.957
	Medium	0.962	0.93	0.946
	Large	0.972	0.951	0.961
	X-Large	0.956	0.88	0.916

표 4-3. YOLOv5 검증 결과

이후 Epoch 1,000회의 학습과 검증 과정을 통해 얻은 YOLOv5 Nano, Small, Large, X-Large 5모델의 가중치 값을 이용하여 테스트를 진행하였고, 학습과 검증에 사용되지 않은 원본 불량 이미지 129장과 양품 이미지 300장을 이용하여 최종 성능을 확인하였다. 테스트는 객체를 판단하는 기준인 신뢰 수준을 0.7, 0.8, 0.9 세 가지로 설정했을 때 결과를 확인하여 최적의 값을 찾도록 진행하였으며 정확도 결과는 아래 [표 4-4]에 나타나 있고 연산 장치에 따른 추론 속도 측정 결과는 [표4-5]에 나타나있다.

YOLOv5 모델	신뢰 수준	정밀도	재현율	정확도	F1-Score
Nano	0.7	0.984	0.984	0.99	0.984
	0.8	1	0.875	0.962	0.933
	0.9	N/A	N/A	N/A	N/A
Small	0.7	0.984	1	0.995	0.992
	0.8	0.984	0.984	0.99	0.984
	0.9	1	0.488	0.846	0.656
Mideum	0.7	0.972	1	0.993	0.988
	0.8	0.972	1	0.993	0.988
	0.9	0.991	0.953	0.983	0.972
Large	0.7	0.948	1	0.983	0.973
	0.8	0.969	1	0.99	0.984
	0.9	1	0.86	0.958	0.925
X-Large	0.7	0.969	1	0.99	0.984
	0.8	0.99	0.961	0.986	0.976
	0.9	N/A	N/A	N/A	N/A

표 4-4. YOLOv5 모델별 정확도 실험 결과

YOLOv5 모델	추론 속도(ms)	
	GPU NVIDIA GeForce RTX 3090	CPU Intel(R) Core(TM) I-7 8550U
Nano	6.7	145.2
Small	7.3	256
Mideum	9.7	580.6
Large	12.7	1,161.4
X-Large	15.4	1,992

표 4-5. YOLOv5 모델별 추론 속도 측정 결과

실제 생산 라인에서는 Bent Pin이나 Particle이 해당 이미지에 1개만 존재하더라도 불량품으로 판정이 되기 때문에 검출 정확도는 전체 이미지 Level로 검출이 되는지를 기준으로 판단하였다. 5개의 YOLOv5 모델과 여러 신뢰 수준을 조합하여 테스트 진행해 본 결과 YOLOv5 Small 모델을 0.7의 신뢰 수준으로 설정하여 테스트 하였을 때 정확도 99.53%, F1-score 99.23%로 가장 좋은 성능을 보여주었다. 모델이 복잡할수록 과검출 되어 FP 경우가 많아지는 것을 확인할 수 있었고 너무 간단할 경우 미세 Particle 불량이 검출이 안되는 경우가 생기는 것을 확인할 수 있었다. 따라서 정형화된 Bent pin과 Particle의 검출 모델로는 YOLOv5 Small 모델을 0.7의 신뢰 수준으로 사용한다.

추론 시간의 결과는 [표 4-5]에 정리되어 있으며 연구 검토를 목적으로 GPU (NVIDIA GeForce RTX 3090)를 사용했을 때의 결과와 생산 라인 조건에 즉 적용했을 때의 결과 비교를 위해 CPU (Intel(R) Core(TM) i7-8550U)를 사용했을 때의 추론 속도를 비교하여 정리하였다. 최종 선택한 YOLOv5 Small 모델을 사용했을 때 GPU의 경우 7.3ms, CPU를 사용했을 때는 256ms로 실제 실시간으로 생산 라인에 적용해서 사용하기에 문제가 없는 수준으로 확인하였다. 불량 유형별로 최종적으로 진행된 추론의 결과의 예시를 아래 [그림 4-5]에나 나타내었다.

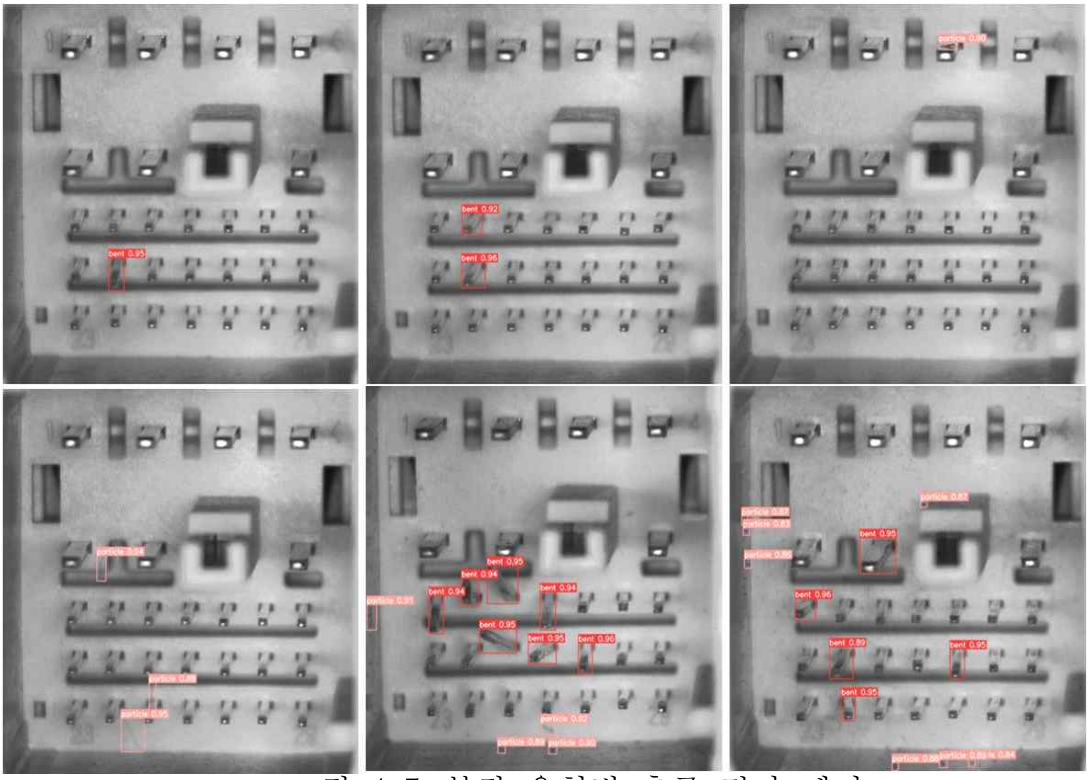

그림 4-5. 불량 유형별 추론 결과 예시

4.3.2 이상점 탐지 기반 실험 결과

이상점 탐지 기반 성능 검토를 위해 선택한 모델은 산업용 불량 이미지의 이상점 탐지 연구에 널리 사용되는 MVTec AD 데이터에서 가장 높은 검출 AUROC를 달성했던 SPADE, PaDiM, PatchCore 모델이다. 3가지 모델 모두 대표성 기반 방법론으로서 별도의 학습 과정은 필요하지 않으며 선행 학습된 합성곱 신경망으로부터 불량들의 특징을 추출하여 이상점을 찾아내는 방법이다.

미세 조정 이전에 첫째로 본 연구에 사용되는 핀 비전 데이터에 가장 효과적인 방법론을 찾기 위하여 SPADE, PaDiM, PatchCore 3가지 방법론을 핀 비전 데이터에 적용 후 이미지 레벨의 AUROC를 측정한 결과를 아래 [표4-6]에 나타내었다.

	SPADE	PaDiM	PatchCore
MVTec 데이터셋	85.5%	97.9%	99.1%
핀 비전 데이터셋	64.1%	96.1%	88.3%

표 4-6. 이상점 탐지 방법론에 따른 AUROC

레퍼런스로 활용했던 MVTec AD 산업용 이미지의 경우에는 PatchCore 기법을 적용했을 때 AUROC가 99.1%로 가장 높았지만 본 연구에서 최종 확인하고자 하는 핀 비전 데이터의 경우에는 PaDiM 기법을 적용했을 때 AUROC가 96.1%로 가장 높을 것을 확인할 수 있었다. 따라서 PaDiM 기법을 적용하여 가장 높은 성능을 낼 수 있도록 미세 조정을 진행하였고 그 결과와 이미지를 아래 [표 4-7]에 나타내었다.

특징점 추출기는 ImageNet에서 선행 학습된 ResNet18, Wide ResNet50 그리고 EfficientNet-B5를 이용하였고 추론 시간 단축을 위해 PaDiM 방법론에서 제시했던 Random Dimensionality Reduction을 활용하여 임의로 선택된 차원을 이용하여 차원 수를 감소하여 테스트를 진행하였다. 그 결과 ResNet18을 특징점 추출기로 사용하면서 임의의 차원 감소수를 400으로 했을 때 가장 높은 97.4%의 AUROC를 나타내었다. 따라서 비정형화된 핀 비전의 불량 검출해 내는데에는 ResNet18로 특징을 추출하여 400 차원으로 감소시킨 PaDiM 모델을 사용하며 이때의 AUROC 곡선과 Heat Map으로 표시한 불량 검출 예시를 [그림 4-6]에 나타내었다.

	PaDiM			
Pre-Trained CNN for feature extraction	ResNet18 (448차원)		Wide ResNet50 (1,792차원)	EfficientNet-B5 (1,280차원)
Random Dimensionality Reduction	100	400	550	728
Image Level AUROC	96.1%	97.4%	97%	93.5%

표 4-7. PaDiM 방법론 최적화 검토 결과

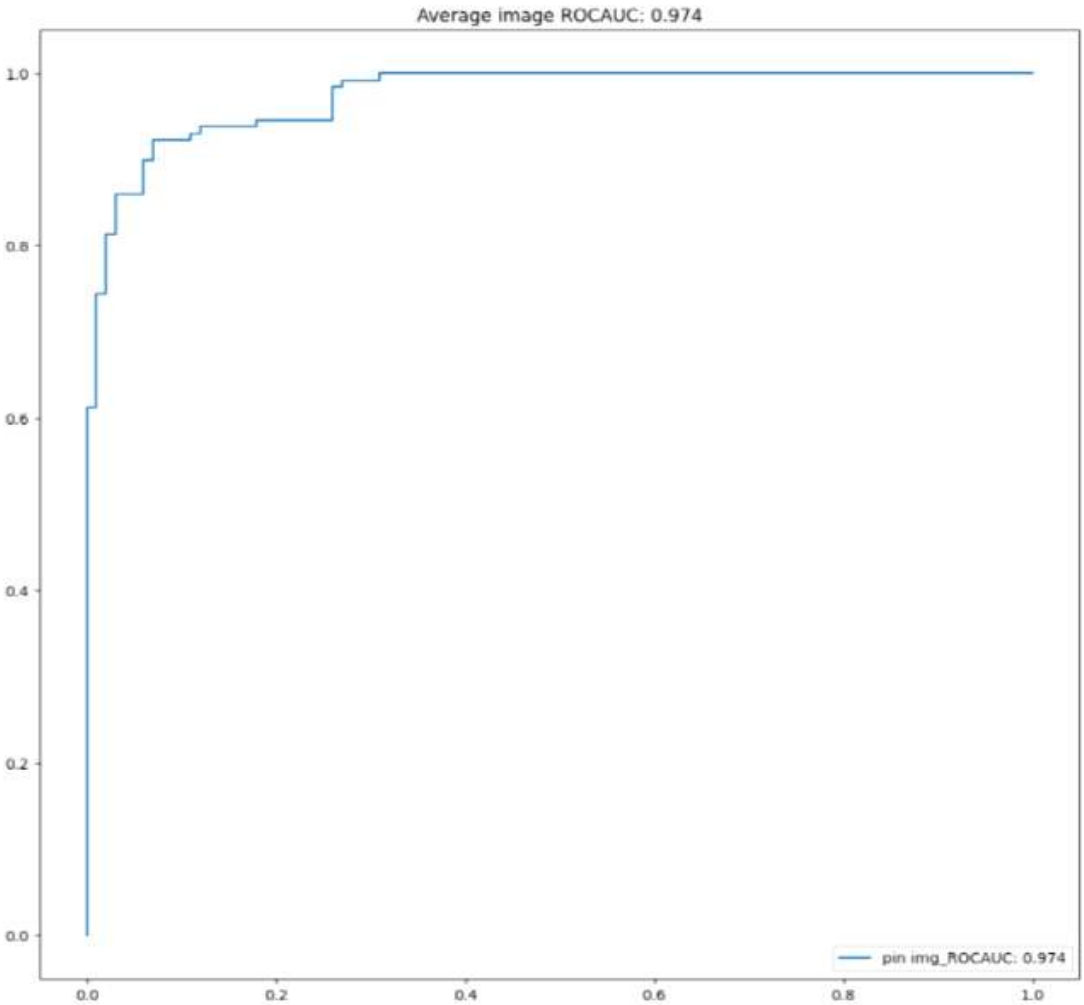

(a) 검출 AUROC 곡선

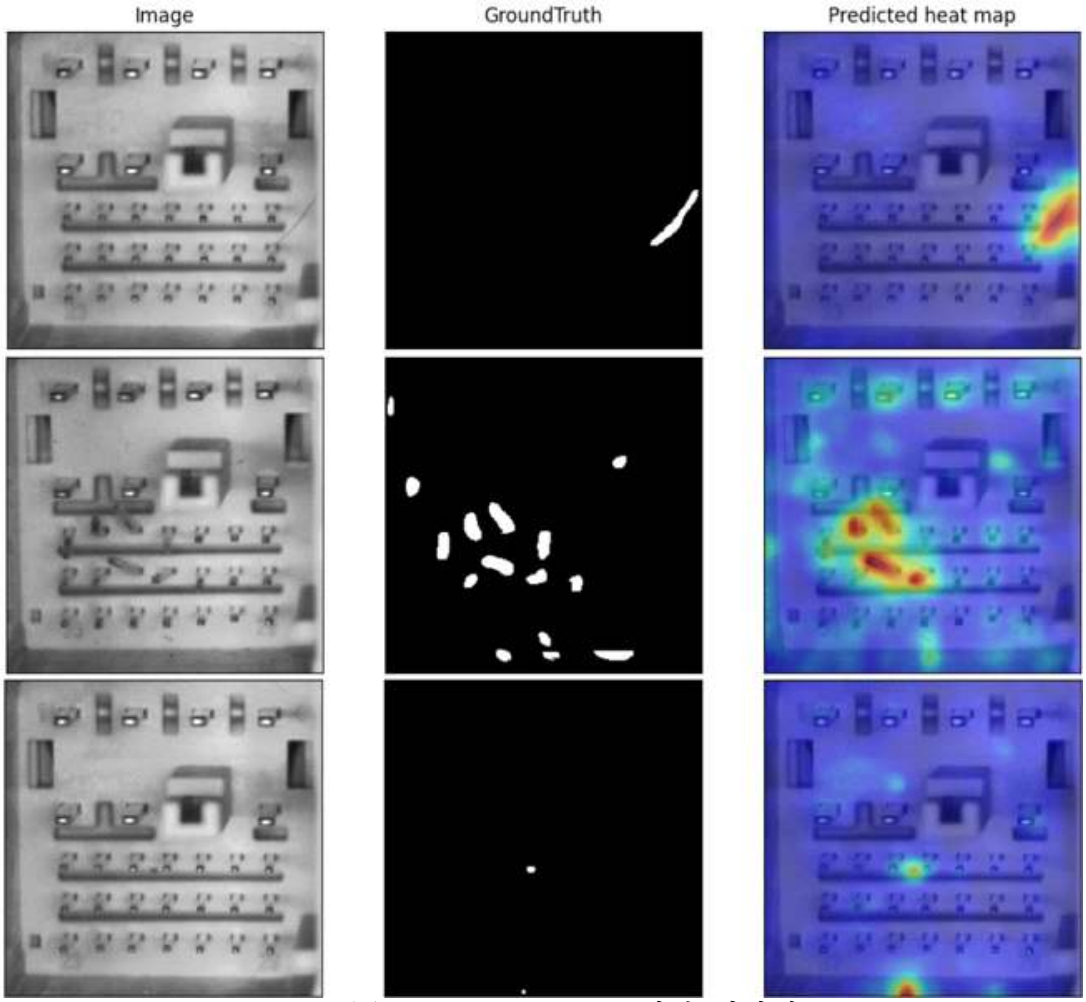

(b) Heat Map으로 표현된 이상점

그림 4-6. AUROC 곡선과 이상점 Heat Map

4.3.3 앙상블을 통한 개선 모델 제안

4.3.1과 4.3.2의 연구 결과를 통해 YOLOv5와 PaDiM 방법론으로 각각 정형화된 불량 유형과 비정형화된 불량 유형을 검출할 수 있음이 확인되었다. YOLOv5 기반 방법론을 사용하면 미세한 Particle이라도 검출이 가능하지만 학습되지 않은 불량 유형은 검출할 수 없다는 단점이 있고 PaDiM 기반 방법론을 사용하면 기존에 학습되지 않았던 유형의 불량도 검출이 가능하나 미세한 불량은 잡아낼 수 없다는 단점이 있다.

따라서 본 연구에서는 이 두가지 방법론을 앙상블 기법을 적용하여 실제 생산 라인에 적용함으로써 불량 유형에 관계없이 불량을 검출해내는 시스템을 구축하고자 한다. 제안 시스템에 대한 도식이 [그림 4-7]에 나타나 있으며 PaDiM 기법을 최초 생산 LOT에 적용하여 비정형화된 LOT성 불량 및 모조품 혹은 미승인품 불량을 검출해 내고, 이상점이 없을 경우 정식 생산이 시작되면 추론 속도가 빠른 YOLOv5 기법을 사용하여 생산 중 실시간으로 불량을 감지해 내는 방법이다.

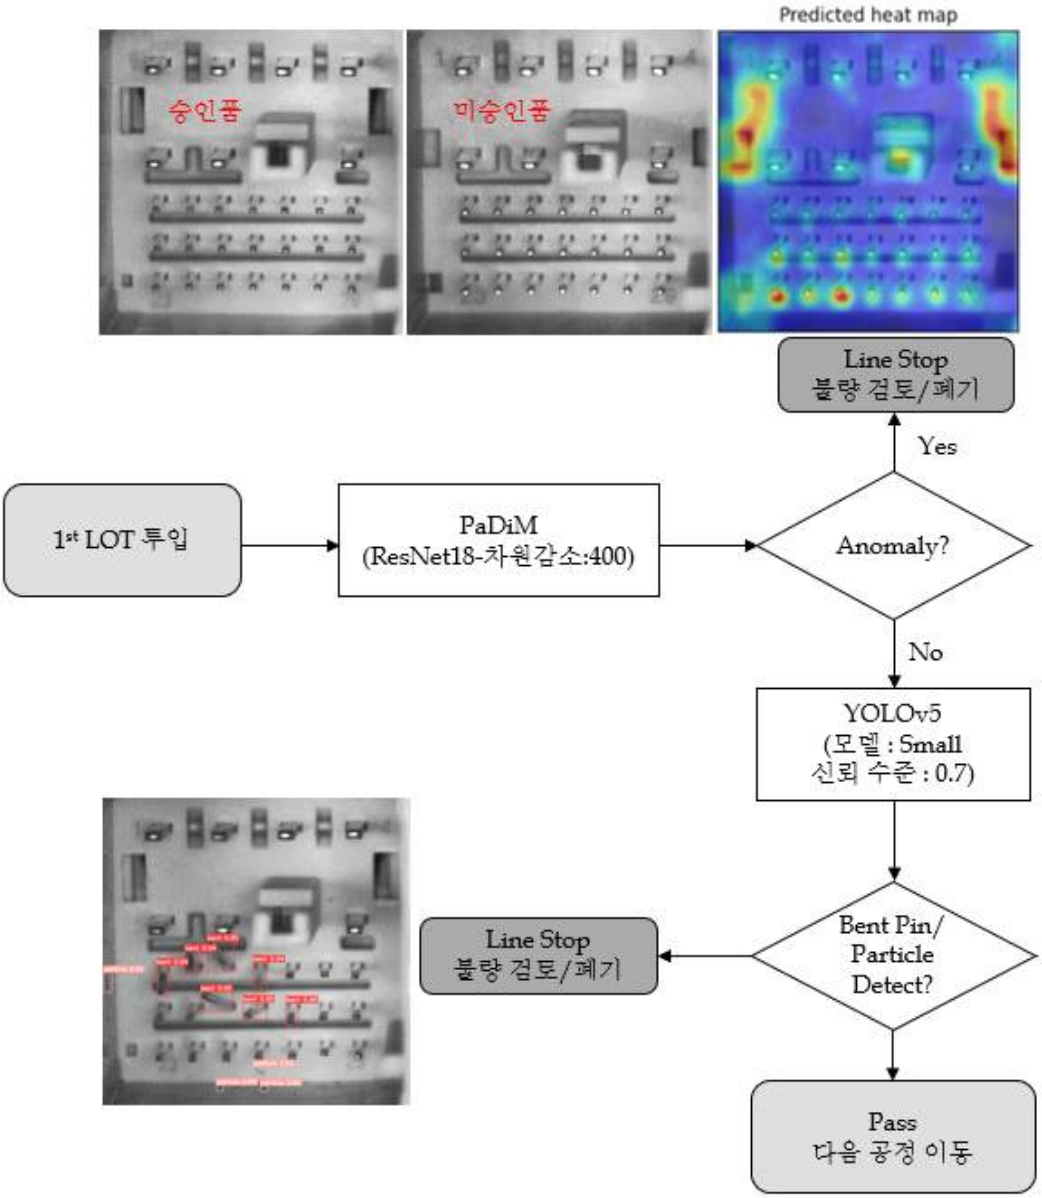

그림 4-7. 앙상블 기법을 적용한 생산 순서도

제 5 장 결 론

본 연구에서는 텔레매틱스 제품 생산 시 실제 발생하고 있는 핀 비전 불량의 검출력 개선 및 추론 속도 향상을 위하여 딥러닝 기반의 방법론을 연구하여 최적의 개선안을 제안하였다.

정형화 되어있는 Bent Pin과 Particle 불량의 검출력 개선을 위하여 최초 86장이었던 불량 이미지를 데이터 추가 제작 및 데이터 증량 기법을 통하여 1,467장으로 증량하였다. 해당 불량 이미지들을 실시간 불량 검출을 위하여 실시간 객체 검출에서 좋은 성능을 보여왔던 YOLOv5 모델 기반으로 학습을 진행하였고 최종적으로 YOLOv5 Small 모델을 신뢰 수준 0.7로 적용했을 때 검출 정확도를 정확도 99.53%, F1-score 99.23% 까지 확보할 수 있었고 실제 공정 적용을 위해 GPU를 사용하지 않고 일반 노트북에 사용되는 Intel(R) Core(TM) i7-8550U CPU 기반으로 진행했을 때 256ms의 추론 속도를 확보할 수 있었다.

비정형화 되어있는 불량들이나 모조품/미승인품 투입 감지를 위해 이상점 탐지 기법을 연구하였다. 산업 이미지 이상점 검출에 효과가 있었던 기법 중 PaDiM 기법을 적용했을 때 96.1%의 검출 AUROC 성능을 확인할 수 있었으며, 추가적인 최적화 작업을 통해 ResNet18을 특징점 추출기로 사용하고 추출된 feature 벡터를 400 차원으로 임의로 감소 시켰을 때 검출 AUROC 97.4%를 확보할 수 있었다.

최종적으로 두가지 방법론을 모두 사용하여 생산 라인에서 정형화된 불량과 비정형화된 불량을 모두 검출해내는 시스템을 제안하였다. 정식 생산이 들어가기 전에 생산 라인 검증을 위해 투입되는 최초 LOT에서 PaDiM 기법을 통해 비정형화된 불량, 모조품 투입 혹은 미승인품 투입을 감지한다. 문제없이 검증이 완료될 경우 이후 정식 생산 공정이 진행되며 YOLOv5 기법을 통하여 정형화된 불량을 256ms의 개선된 추론속도로 실시간 감지한다. 연구 결과를 실제 적용할 경우 현재 미검출 되고 있는 불량의 검출력까지 확보하게 되므로 실제 공정에서 발생하는 불량률은 0.1% 미만이 될 것으로 예상이 된다. 현재 일반적인

CPU를 사용하였을 때 추론속도도 256ms 수준으로 현재 사용하고 있는 공정의 추론 속도 보다 80% 가량 개선이 되지만, 추론 속도 추가 향상을 위하여 실험에 사용한 RTX 3090 대신 RTX 3060과 같은 저가형 GPU를 사용한다면 100ms 이하의 추론 속도를 적은 투자 비용으로 확보할 수 있을 것으로 예상한다.

본 연구를 통하여 기존의 규칙 기반 검사 방식에서 벗어난 개선된 추론 속도의 딥러닝 기반의 불량 검출 방법론을 제안하고 검증하였다. 이러한 연구 결과가 실제 적용될 경우 출하 후 품질 개선, 가성 불량 감소로 인한 공정 비용 감소 그리고 택타임 개선으로 인한 생산성 향상이 기대된다. 핀 비전 검사 공정 뿐만 아니라 향후 스마트 공장 환경 조성에 있어 본 연구에 사용된 것과 같은 방법론이 도움이 될 것으로 예상한다. 아직 100%를 달성하지 못한 검출력은 향후 추가적인 실제 데이터가 확보되고 추가적인 학습이 이루어진다면 개선될 것으로 보이며 추론 속도가 향상된 방법론들에 대한 지속적인 연구가 이루어지고 있으므로 본 연구에 사용된 방법론을 현재 텔레매틱스 공정에 적용하고 향후 지속적인 데이터 수집과 방법론 연구를 통해 지속적으로 개선해 나가고자 한다.

참 고 문 헌

[1] Zhao, Zhong-Qiu, et al. "Object detection with deep learning: A review." IEEE transactions on neural networks and learning systems 30.11 (2019): 3212-3232..

[2] Chandola, Varun, Arindam Banerjee, and Vipin Kumar. "Anomaly detection: A survey." ACM computing surveys (CSUR) 41.3 (2009): 1-58.

[3] O'Shea, Keiron, and Ryan Nash. "An introduction to convolutional neural networks." arXiv preprint arXiv:1511.08458 (2015).

[4] He, Kaiming, et al. "Deep residual learning for image recognition." Proceedings of the IEEE conference on computer vision and pattern recognition. 2016.

[5] Krizhevsky, Alex, Ilya Sutskever, and Geoffrey E. Hinton. "Imagenet classification with deep convolutional neural networks." Communications of the ACM 60.6 (2017): 84-90.

[6] Simonyan, Karen, and Andrew Zisserman. "Very deep convolutional networks for large-scale image recognition." arXiv preprint arXiv:1409.1556 (2014).

[7] Szegedy, Christian, et al. "Going deeper with convolutions." Proceedings of the IEEE conference on computer vision and pattern recognition. 2015.

[8] Lee, Jinsu, Junseong Bang, and Seong-Il Yang. "Object detection with sliding window in images including multiple similar objects." 2017 international conference on information and communication technology convergence (ICTC). IEEE, 2017.

[9] Uijlings, Jasper RR, et al. "Selective search for object recognition." International journal of computer vision 104.2 (2013): 154-171.

[10] He, Kaiming, et al. "Mask r-cnn." Proceedings of the IEEE international conference on computer vision. 2017.

[11] Deng, Jia, et al. "Imagenet: A large-scale hierarchical image database." 2009 IEEE conference on computer vision and pattern recognition. Ieee, 2009.

[12] Everingham, Mark, et al. "The pascal visual object classes (voc) challenge." International journal of computer vision 88.2 (2010): 303-338.

[13] Hearst, Marti A., et al. "Support vector machines." IEEE Intelligent Systems and their applications 13.4 (1998): 18-28.

[14] He, Kaiming, et al. "Spatial pyramid pooling in deep convolutional networks for visual recognition." IEEE transactions on pattern analysis and machine intelligence 37.9 (2015): 1904-1916.

[15] Girshick, Ross. "Fast r-cnn." Proceedings of the IEEE international conference on computer vision. 2015.

[16] Ren, Shaoqing, et al. "Faster r-cnn: Towards real-time object detection with region proposal networks." Advances in neural information processing systems 28 (2015).

[17] Redmon, Joseph, et al. "You only look once: Unified, real-time object detection." Proceedings of the IEEE conference on computer vision and pattern recognition. 2016.

[18] Redmon, Joseph, and Ali Farhadi. "YOLO9000: better, faster, stronger." Proceedings of the IEEE conference on computer vision and pattern recognition. 2017.

[19] Redmon, Joseph, and Ali Farhadi. "Yolov3: An incremental improvement." arXiv preprint arXiv:1804.02767 (2018).

[20] Bergmann, Paul, et al. "MVTec AD--A comprehensive real-world dataset for unsupervised anomaly detection." Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. 2019.

[21] Shvetsova, Nina, et al. "Anomaly detection in medical imaging with deep perceptual autoencoders." IEEE Access 9 (2021): 118571-118583.

[22] Kingma, Diederik P., and Max Welling. "Auto-encoding variational bayes." arXiv preprint arXiv:1312.6114 (2013).

[23] Creswell, Antonia, et al. "Generative adversarial networks: An overview." IEEE signal processing magazine 35.1 (2018): 53-65.

[24] Tan, Mingxing, and Quoc Le. "Efficientnet: Rethinking model scaling for convolutional neural networks." International conference on machine learning. PMLR, 2019.

[25] Cohen, Niv, and Yedid Hoshen. "Sub-image anomaly detection with deep pyramid correspondences." arXiv preprint arXiv:2005.02357 (2020).

[26] Defard, Thomas, et al. "Padim: a patch distribution modeling framework for anomaly detection and localization." International Conference on Pattern Recognition. Springer, Cham, 2021.

[27] Roth, Karsten, et al. "Towards total recall in industrial anomaly detection." Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2022.

[28] Eskin, Eleazar, et al. "A geometric framework for unsupervised anomaly detection." Applications of data mining in computer security. Springer, Boston, MA, 2002. 77-101.

[29] Rippel, Oliver, Patrick Mertens, and Dorit Merhof. "Modeling the distribution of normal data in pre-trained deep features for anomaly detection." 2020 25th International Conference on

Pattern Recognition (ICPR). IEEE, 2021.

[30] McLachlan, Goeffrey J. "Mahalanobis distance." Resonance 4.6 (1999): 20-26.

[31] Huggins, Jonathan, Trevor Campbell, and Tamara Broderick. "Coresets for scalable Bayesian logistic regression." Advances in Neural Information Processing Systems 29 (2016).

Abstract

Pin Vision Inspection Detectability and Inference Time Improvement using Deep Learning Based Method

Seungjin Heo
Department of Engineering Practice
Graduate School of Engineering Practice
Seoul National University

Pin Vision inspection is used in the Telematics manufacturing industry to detect abnormality of the main connector pin, which is directly connected to the vehicle harness. Currently, a bent pin is detected by calculating the distance between neighbor pins based on rule-based algorithms. However, there is a limitation that various failures, other than the bent pin, cannot be screened out by this conventional method. Specifically, there remain different kinds of failures appearing as NTF (No Trouble Found), and thus we need more sophisticated algorithms requiring more computation time to deal with such false negatives if we still want to use conventional rule-based algorithms.

In this regard, this paper presents a new method to reduce detection failure cases by utilizing deep-learning-based Object Detection and Anomaly Detection, which can detect gray-area failures that the conventional methods generally miss, as stated above. This

paper also introduces a method to reduce computation time by modifying conventional deep networks to have lightweight structures. Overall, experiments show that the detection rate is enhanced while the detection speed is also increased.

To be precise with the proposed algorithm, Anomaly Detection performs their normal/anomaly decision first, where only normal data is used for training, without the need for anomaly data, and then Object Detection finds the parts to be inspected. To overcome lack of failure sample issue, this paper also introduces a new data augmentation method. Hence, there is no burden in preparing a large failure dataset for deep learning.

The proposed learning process successfully finds feature maps that can easily differentiate between the normal and anomaly parts. The modified lightweight deep networks are shown to be effective both on GPU and CPU, and it is shown that the proposed method meets the real-time condition in the targeted inspection system. In terms of the accuracy metric, the proposed method is shown to provide the highest accuracy and F1 score among similar variants of the deep networks. The studies and methodologies in this paper can be modified and extended to other various vison-inspection systems.

keywords : Vision Inspection, Deep Learning, Object Detection, Anomaly Detection, Data Augmentation, Ensemble
Student Number : 2021-29199

부 록

#YOLOv5를 통해 검출된 불량 이미지의 예시

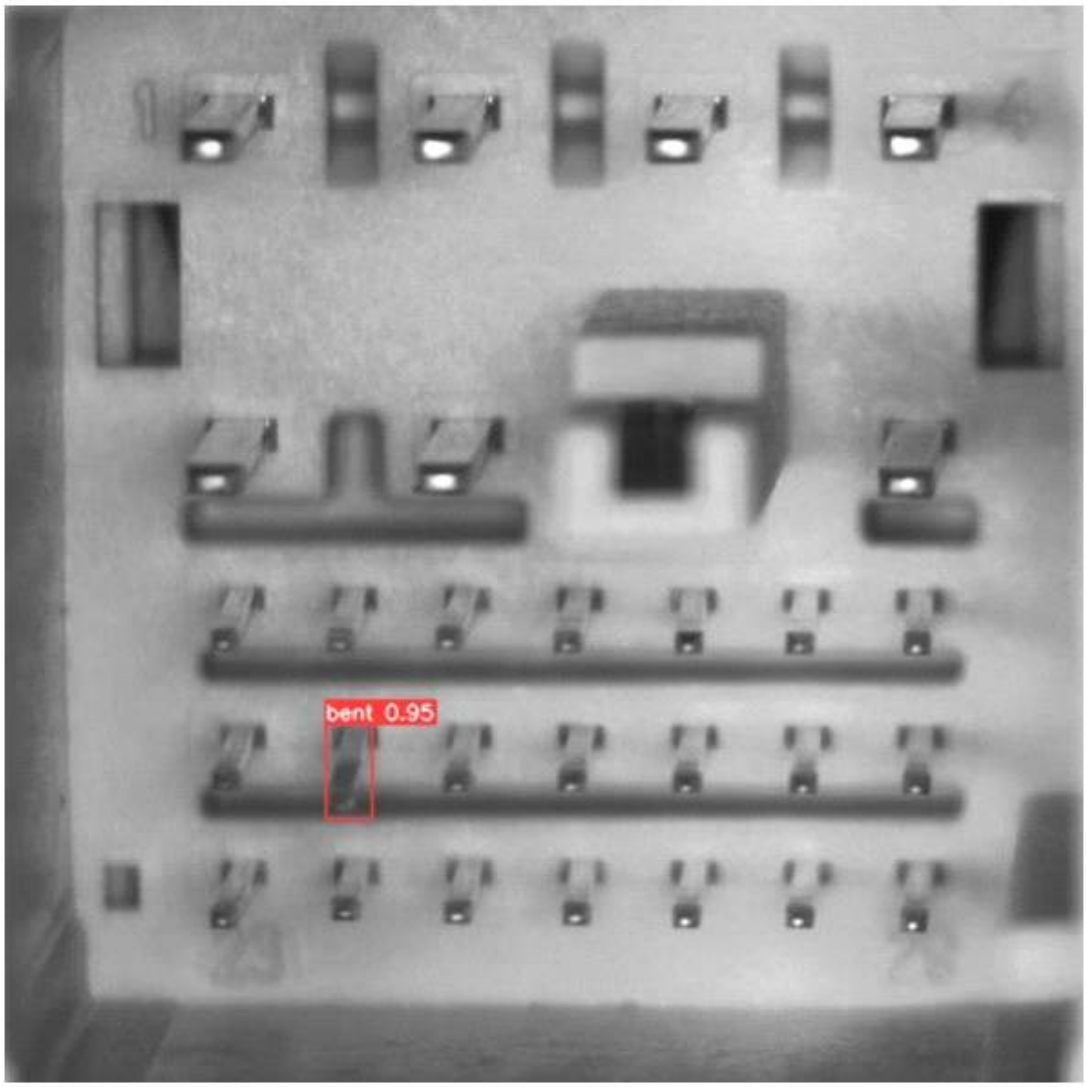

(a) Bent pin 불량 #1

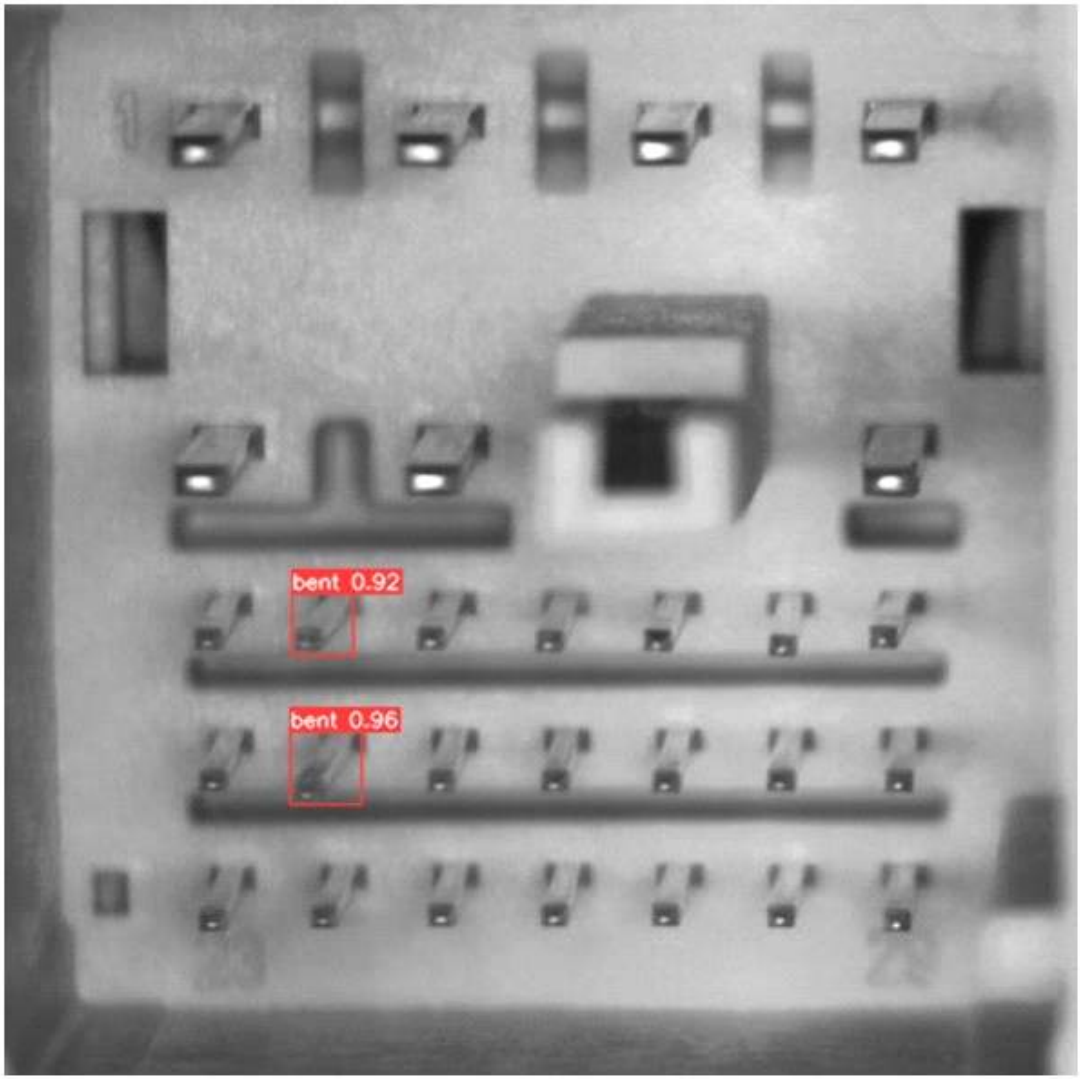

(b) Bent pin 불량 #2

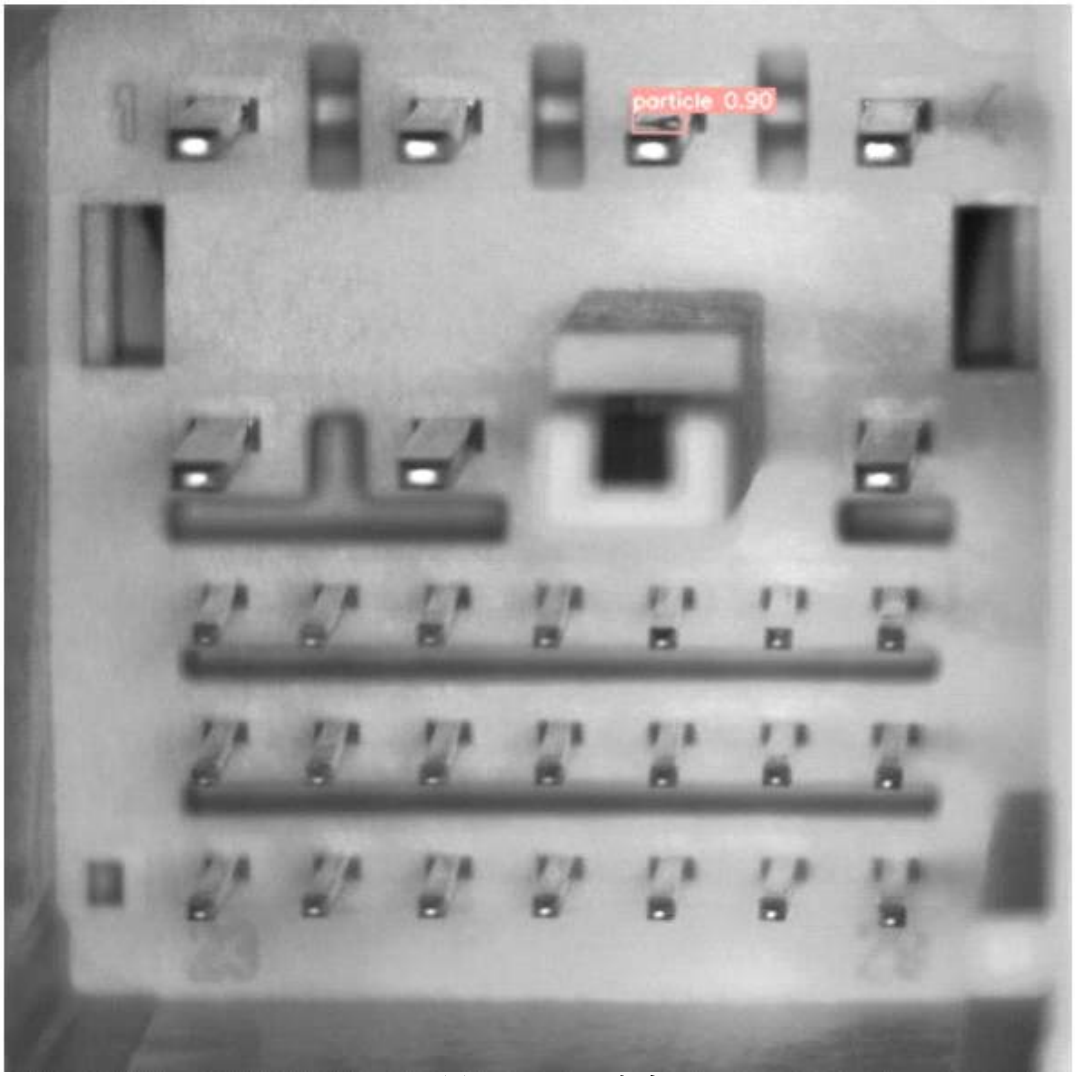

(c) Particle 불량 #1

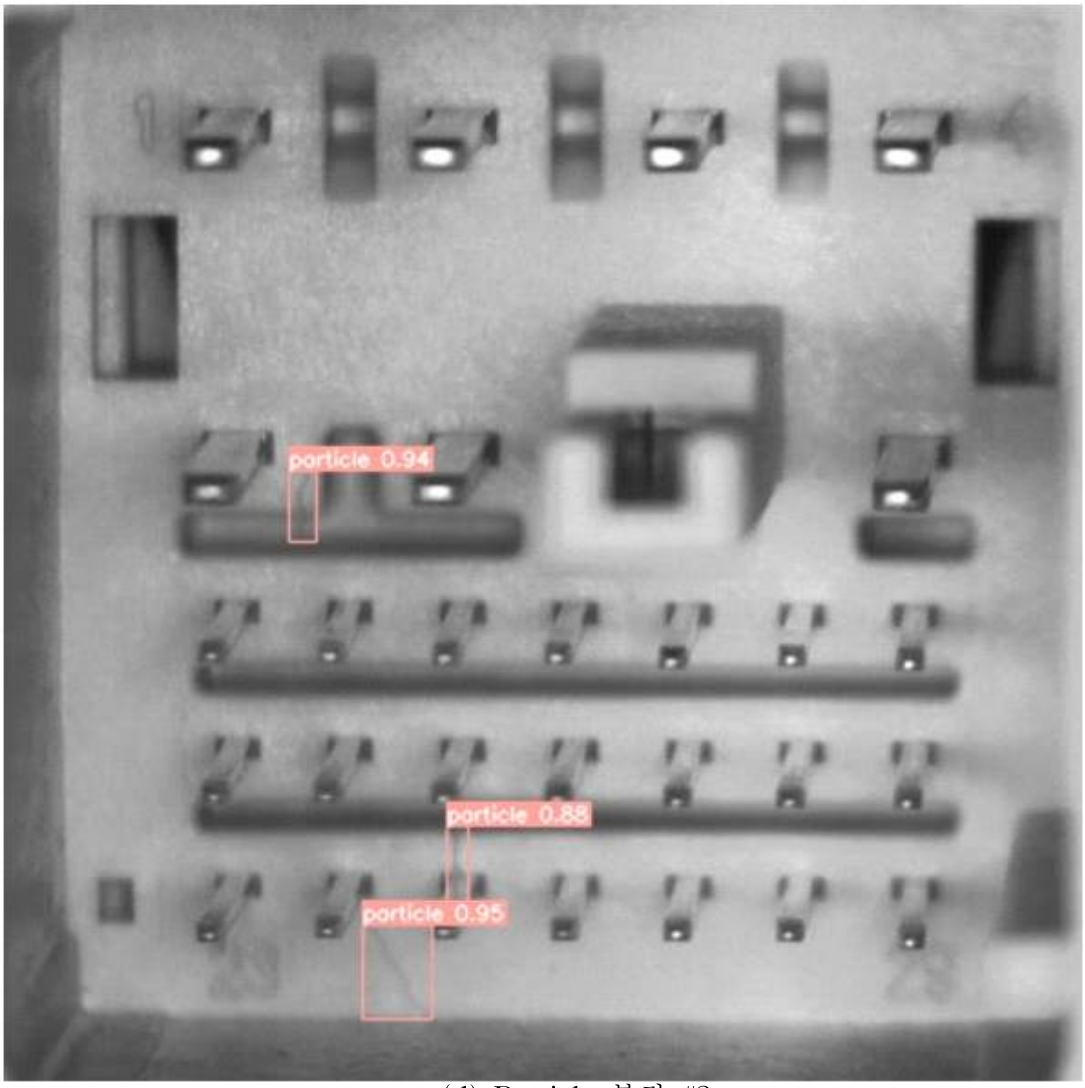

(d) Particle 불량 #2

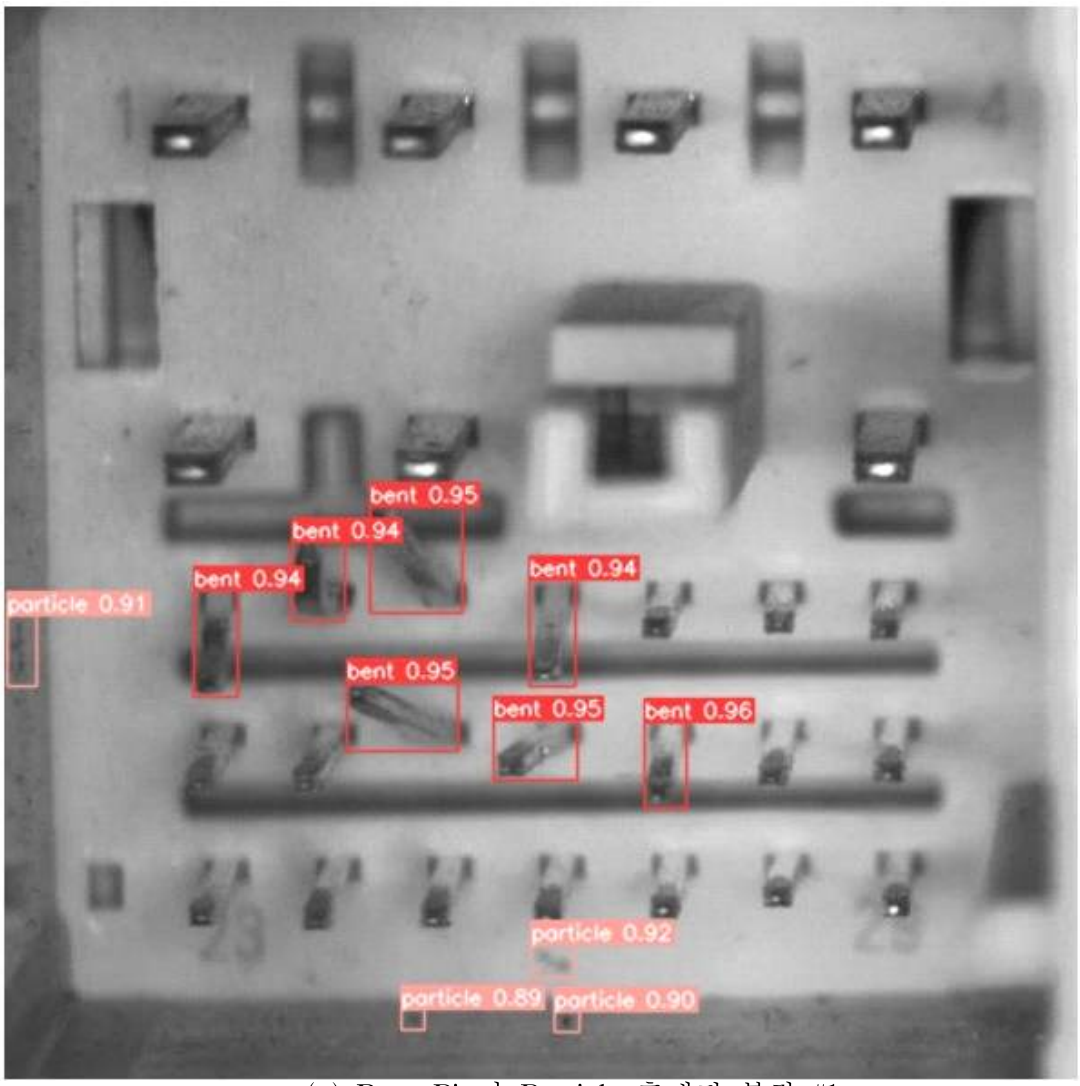

(e) Bent Pin과 Particle 혼재된 불량 #1

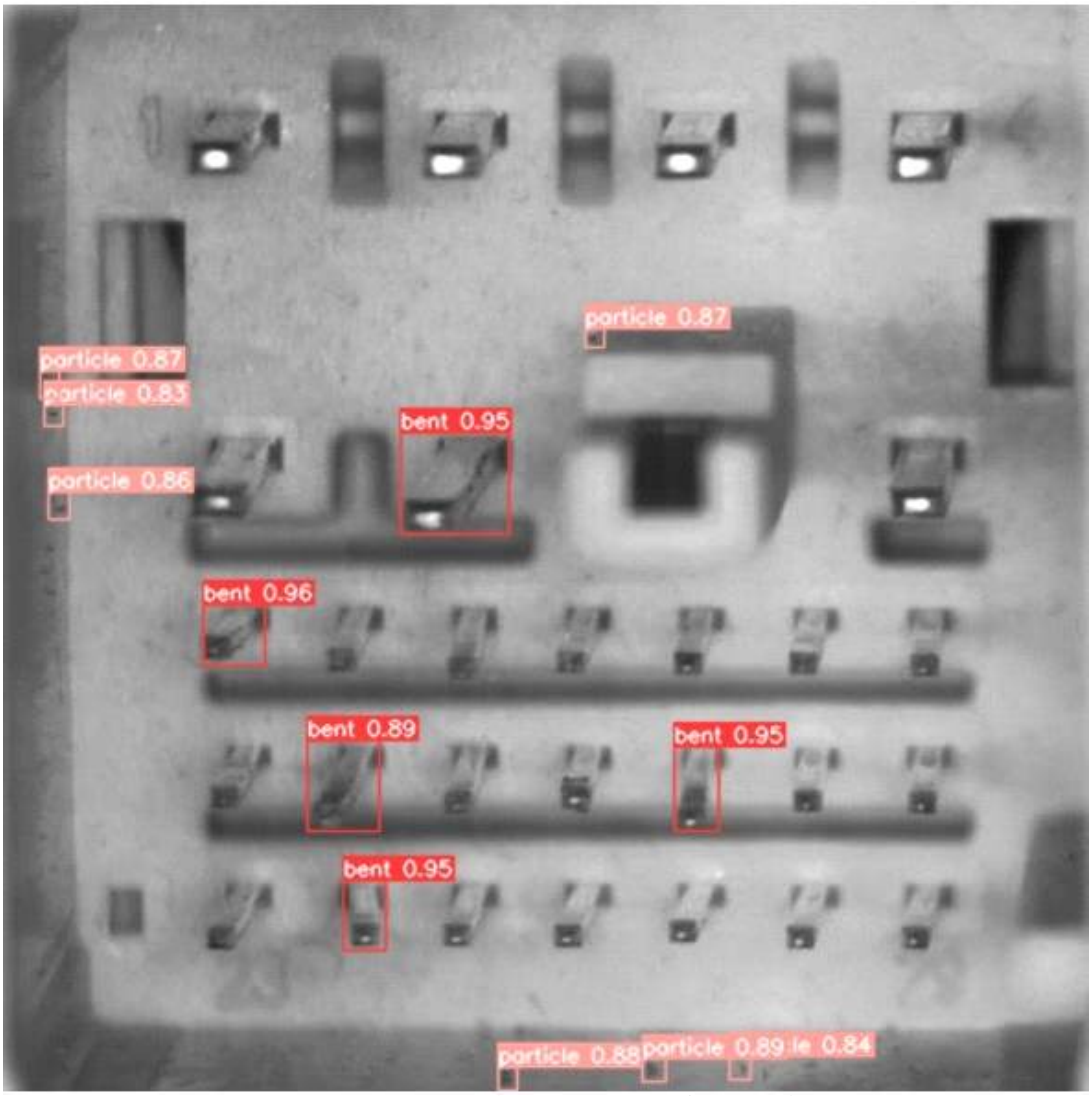

(f) Bent Pin과 Particle 혼재된 불량 #2