



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](#)

석사학위논문

딥러닝 기반 Vision AI를 활용한 불량부품 검사시스템 개선 실증 연구

- 자동차 부품 제조 공정 중심으로 -



한성대학교 지식서비스&컨설팅대학원

스마트융합컨설팅학과

스마트융합기술컨설팅전공

김 시 영

석사학위논문
지도교수 원종혁

딥러닝 기반 Vision AI를 활용한 불량부품 검사시스템 개선 실증 연구

- 자동차 부품 제조 공정 중심으로 -

An Empirical Study on the Improvement of
Defective Parts Inspection System Using Vision AI
Based on Deep Learning

- Focusing on Automotive Parts Manufacturing -

2025년 6월 일

한성대학교 지식서비스&컨설팅대학원

스마트융합컨설팅학과

스마트융합기술컨설팅전공

김 시 영

석사학위논문
지도교수 원종혁

딥러닝 기반 Vision AI를 활용한 불량부품 검사시스템 개선 실증 연구

- 자동차 부품 제조 공정 중심으로 -

An Empirical Study on the Improvement of
Defective Parts Inspection System Using Vision AI
Based on Deep Learning

- Focusing on Automotive Parts Manufacturing -

위 논문을 컨설팅학 석사학위 논문으로 제출함

2025년 6월 일

한성대학교 지식서비스&컨설팅대학원

스마트융합컨설팅학과

스마트융합기술컨설팅전공

김 시 영

김시영의 컨설팅학 석사학위 논문을 인준함

2025년 6월 일



심사위원장 주 형근 (인)

심 사 위 원 정 병호 (인)

심 사 위 원 원 종혁 (인)

국 문 초 록

딥러닝 기반 Vision AI를 활용한 불량부품 검사시스템 개선 실증 연구

- 자동차 부품 제조 공정 중심으로 -

한성대학교 지식서비스&컨설팅대학원

스 마 트 융 합 컨 설 팅 학 과

스 마 트 융 합 기 술 컨 설 팅 전 공

김 시 영

최근 제조업은 자동화와 디지털 전환을 빠르게 진행하고 있으며 이로 인해 기존 제조 공정에 적용되지 않았던 AI, 빅데이터, IoT 등 첨단 기술을 활용해 생산 공정의 자동화와 최적화를 실현하게 되었다. 이러한 제조 환경은 생산 효율성 극대화를 통해 경쟁력을 강화하는 새로운 제조 패러다임을 제시하게 되었다. 그리고 가장 중요한 품질 관리 공정의 혁신을 위한 수단으로써 AI 기술의 도입 계획이 증가하게 되었다.

본 연구는 비전 AI 기술을 활용하여 자동차 부품 제조업의 품질검사 공정을 개선하기 위한 실증 연구로서 기존에 육안으로 검사하던 부품결함 검출 방법을 AI 기술로 완전 자동화함으로써 혁신적인 품질공정을 구현하고자 하였다. 기존의 부품결함 품질검사 방식은 주로 사람의 품질 검사에 의존하게

되면서 많은 한계점에 부딪히게 되었다. 우선 불량품 육안 검사의 효율성을 유지하기 위해서는 숙련자의 역량이 매우 중요하다. 이러한 숙련자는 경력이 많다는 특징이 있기 때문에 경쟁사로의 이직이 빈번하게 발생하게 되었다. 그 결과 비숙련자가 대체 업무를 처리하게 되면서 불량률 검출률이 낮아지게 되었고 생산성이 저하되는 문제가 발생하게 되었다. 이처럼 검사자가 주관적으로 판단함에 따라 인적 실수와 오류가 발생하기 쉬웠고 검사 시간도 길기 때문에 품질 검사 공정 목표에 한계가 있었다. 이러한 문제를 해결하기 위해 컴퓨터 비전을 통해 규칙 기반 불량 검사 시스템이 도입되었지만 복잡한 결함에는 대응이 어렵고 환경 변화에 민감하여 새로운 불량이 발생할 때마다 규칙을 수정해야 해 유지 관리에 많은 비용이 든다는 단점이 있었다.

본 연구에서는 AI 기술을 활용해 제품 검사 시스템의 검사 속도를 향상시키고 자동화를 이루어 경쟁력을 강화하는 기술을 구현하였다. 기존 육안 검사 방식의 한계를 극복하고자 객체 탐지 모델(Object Detection Model)을 적용하여 불량 부품을 실시간으로 정확하게 검출함으로써 품질 관리의 정확성을 높이고 검사 공정 자동화를 촉진하는 것을 목표로 한다.

자동 검사 시스템 환경에서는 불량부품의 신속한 판별 및 자동화된 품질 관리가 필수적이다. YOLO, Faster R-CNN, MobileNet 모델을 비교 분석하여 각 알고리즘의 검출 정확도와 처리 속도를 비교분석 및 검증하였으며 YOLO 모델이 타 모델에 비하여 우수한 성능을 나타내었음을 실증하였다.

본 연구의 결과로서 객체 탐지(Object Detection) 모델을 중심으로 한 딥러닝 기술의 적용 가능성을 높일 수 있었으며 실시간 검사 및 불량부품 판별에 최적의 효과를 확인할 수 있었다. 이러한 결과는 자동차 부품 제조업의 불량부품 검사 시스템에 인공지능 기술을 적용할 경우, 생산 효율성 향상과, 검사 비용 절감에 효과성을 입증함으로써 경영 개선에도 큰 기여를 할 수 있음을 보여준다.

【주요어】 스마트 제조, AI 기반 품질 검사, 자동차 부품 제조, 딥러닝

목 차

I. 서 론	1
1.1 연구의 배경	1
1.2 연구의 목적	4
II. 이론적 배경	5
2.1 인공지능(AI) 정의	5
2.1.1 AI 개요	5
2.1.2 AI 역사	8
2.1.3 AI 적용 분야	13
2.2 딥러닝 기반 AI 아키텍처 정의	15
2.2.1 비전(Vision) 시스템 정의	15
2.2.2 YOLO(You Only Look Once) 정의	18
2.2.3 Faster R-CNN 정의	21
2.2.4 MobileNet 정의	25
2.2.5 AI 모델 선정	28
2.3 품질 검사 정의	38
2.3.1 품질 검사 개요	38
2.3.2 불량 검사 기법의 종류	39
2.3.3 이상치 감지 알고리즘	40
2.4 선행연구 분석	42
2.4.1 국내 선행연구 분석	42
2.4.2 해외 선행연구 분석	49
III. 연구방법 및 결과	53
3.1 연구 환경 및 구성	53
3.1.1 데이터 수집 장치	55
3.1.2 서버 및 운영 PC 구성	57

3.1.3 데이터 라벨링 툴	58
3.1.4 불량 검출 유형	59
3.2 연구 결과 및 분석	61
3.2.1 데이터 수집	61
3.2.2 데이터 수집 결과	63
3.2.3 연구 결과 검증	67
IV. 결 론	72
4.1 결론 및 시사점	72
4.2 연구의 한계점 및 향후 연구 방향	73
참 고 문 헌	74
ABSTRACT	86



표 목 차

[표 2-1] IoU 값 해석	29
[표 2-2] 혼동 행렬	30
[표 2-3] MobileNet 버전별 성능 비교	32
[표 2-4] Faster R-CNN의 성능 지표	33
[표 2-5] YOLO 모델들의 성능 지표	34
[표 2-6] YOLOv10의 기본 6모델	36
[표 2-7] YOLOv10의 모델 크기별 성능	36
[표 2-8] 품질 검사 유형 분류	38
[표 2-9] 국내 불량검출 선행연구 분석	42
[표 2-10] 해외 선행연구 분석	49
[표 3-1] Basler사의 카메라 사양	55
[표 3-2] Basler사의 렌즈 사양	56
[표 3-3] 학습용 서버와 운영 PC의 사양	57
[표 3-4] 어노테이션 툴 CVAT의 환경	58
[표 3-5] 검사용 부품 불량 외관 예시	60
[표 3-6] 검사 부품에서 발견되는 불량 유형	60
[표 3-7] 수집한 이미지 데이터 수량	61
[표 3-8] 작업 차수별 불량 라벨 수	63
[표 3-9] 데이터 증강 관련 하이퍼 파라미터	64
[표 3-10] 모델 학습용 하이퍼 파라미터	65
[표 3-11] YOLOv10m 모델의 성능	65
[표 3-12] YOLOv10b 모델의 성능	66
[표 3-13] 테스트용 데이터셋 수량	67
[표 3-14] 불량품 검사 결과	70
[표 3-15] 양품 검사 결과 중 오탐 비율	71
[표 3-16] 세부 오탐 비율	71

그 립 목 차

[그림 2-1] 인공지능 연구 체계	5
[그림 2-2] AI 학습과 기술 간의 관계 다이어그램	6
[그림 2-3] 인공지능 윤리 관련 연관도	7
[그림 2-4] 뉴런 연결 패턴 유형	8
[그림 2-5] 역전파 네트워크	9
[그림 2-6] 전문가 시스템 예시	10
[그림 2-7] AlexNet의 CNN 아키텍처	11
[그림 2-8] 이전 버전과 비교한 GPT-4의 텍스트 처리 분량	12
[그림 2-9] 솔루션 프레임워크 IDEF0 다이어그램	15
[그림 2-10] 비전시스템 흐름도	16
[그림 2-11] 망막 질환 진단 AI	17
[그림 2-12] YOLO 모델 이미지 탐지 예시	18
[그림 2-13] YOLO의 아키텍처	19
[그림 2-14] YOLO 모델과 타 모델의 비교	20
[그림 2-15] Faster R-CNN의 단일 통합 네트워크	21
[그림 2-16] 기존 이미지 피라미드와 FPN	23
[그림 2-17] Faster R-CNN의 위성 이미지 객체 검출	24
[그림 2-18] 모바일 기기에 최적화된 MobileNet	25
[그림 2-19] 경량화된 Pointwise Convolution	26
[그림 2-20] ECA 다이어그램	27
[그림 2-21] 비파괴 시험 및 평가 기법의 범주	40
[그림 3-1] 서버와 운영 PC의 workflow	53
[그림 3-2] 연구 환경 아키텍처	54
[그림 3-3] 서스펜션 부상 장착 부위 예시	59
[그림 3-4] 검사용 부품 양품 외관 예시	59

I. 서론

1.1 연구의 배경

근대사회 이후 자동차가 대중 교통수단으로 자리를 잡은 이후 전 세계적으로 수요가 폭발하면서 자동차 산업은 물론 자동차 부품 제조업까지 빠르게 성장했다. 그런데 이렇게 발전한 자동차 제조업 공정에서도 품질 검사는 여전히 사람에게 의존하는 육안 검사 방식을 사용하는 경우가 많다. 육안 검사 방식은 빠르게 많은 제품을 검사하기에는 효율이 떨어지는 단점이 있지만 현재 까지도 많은 제조업의 품질 검사에서 높은 비중을 차지하고 있다(Ferguson et al., 2018).

육안 검사는 검사자의 숙련도 및 컨디션에 따라 검사 결과가 달라질 수 있는 한계가 있다. 검사자의 피로도가 누적될 경우 중요한 결함을 간과할 위험이 존재하며 동일한 부품에 대해서도 검사자별로 결과가 다르게 나타나는 경우가 발생한다. 이러한 특성으로 인해 육안 검사는 일관성 있는 품질 관리를 수행하는 데 어려움이 따른다.

최근에는 이런 문제를 해결하기 위해 비전 검사 시스템을 도입하려는 시도가 많아지고 있다. 그중에 가장 많이 도입되고 있는 검사 방식은 규칙 기반(Rule-based) 비전 검사 방식이다. 이러한 검사 방식은 카메라와 같은 광학 장치를 이용하여 검사자가 아닌 알고리즘이 제품을 분석하고 불량을 검출하는 방식으로 운영된다. 규칙 기반 비전 검사는 일정 수준의 정확도를 제공하며 대량 생산 환경에서 불량 검출이 가능하다는 장점을 갖는다.

그러나 이러한 방식은 검사할 부품에 맞춰 검사할 부품의 특징을 바탕으로 사전에 명확하고 고정된 규칙을 정의해야 한다는 한계를 지닌다. 예를 들어, 부품의 길이, 폭, 색상, 결함 유형 등에 대해 허용 오차 범위나 정상 조건과 비정상 조건 등을 사람이 직접 지정해야 하며 이렇게 지정된 규칙에 따라 단순한 조건 비교나 임계값 기반 판단으로 검사가 진행된다. 복잡한 형태의 부품에서는 설정해야 할 기준이 증가하여 추가적으로 시간과 비용이 소요되

고 정의된 규칙이 많기 때문에 규칙 간 충돌이나 누락으로 인해 오검출이나 미검출이 발생할 수 있다. 또한 주변 환경의 변화에 민감하여 조명 변화나 부품 표면 상태의 미세한 차이에도 검사 정확도가 저하될 가능성이 크다. 이러한 한계점들 때문에 규칙 기반 검사 방식을 도입했다가 다시 육안 검사로 돌아가는 제조업체들도 생겨났다. 이러한 한계점을 극복하기 위해 복잡하고 비정형적인 불량을 탐지가 요구되는 공정에 호환성이 높은 AI 기반 비전 검사 기술이 점차 주목받고 있다. 효율성과 정확성을 동시에 높일 수 있는 대안으로 자리 잡고 있는 것이다.

글로벌 제조업 분야에서는 급속히 발전되고 있는 AI 활용에 대한 적용 사례들이 증가하면서 AI 기술 도입에 대한 관심이 크게 증가하게 되었다. 글로벌 AI 시장 규모는 2023년 32억 달러에서 2028년 208억 달러로 크게 증가할 것으로 예상하며 연평균 약45.6%의 매우 높은 성장률을 나타낼 것이라 예상하였다(한국산업기술진흥협회, 2024).

이러한 성장 요인으로는 대규모 데이터의 효율적 처리에 대한 필요성이 증가하였으며 IoT 기술을 활용한 실시간 데이터 취득, 자동화 기술을 적용한 더욱 개선된 연산 처리 능력 등이 먼저 거론되고 있다. 주요 적용 분야는 유지관리를 위한 예지 보전, 기계검사, 사이버보안, 품질관리, 산업용 로봇, 재고 최적화, 생산 계획, 현장 서비스 순서로 많이 활용되고 있다(한국산업기술진흥협회, 2024).

그리고 제조업 내 산업별로는 자동차 산업 분야가 가장 많이 활용되고 있으며 그다음으로 에너지 및 전력 산업, 제약, 반도체, 전자제품, 금속 및 중기계, 식품 및 음료 순으로 활용되고 있다(대한상공회의소, 2024). 더욱이 2028년에는 산업별로 활용도가 급성장할 것으로 전망되며 그중에 자동차 산업 분야의 비중이 가장 크다고 예상되고 있다(한국산업기술진흥협회, 2024).

중소기업중앙회(2024)에서 발표한 중소 제조업 기준의 AI 기술 도입에 대한 적용계획에는 비전 시스템을 활용한 제품 결함 탐지, 불량률 요인 분석에 대한 이슈가 가장 크다는 것을 알 수 있다.

이에 따라 본 연구에서는 자동차 부품 중에서 진동과 충격을 흡수하며 차량의 조향 안정성을 유지시키는 역할을 하는 서스펜션 부품을 실증 대상으로

선정하여 AI 기반 결함 탐지 기술의 적용 가능성을 검증하고자 한다. 서스펜션 부식에는 차량 주행 시 발생하는 노면 불규칙, 차량의 가속과 감속, 코너링 등의 상황에서 단순한 힘뿐 아니라 비선형적이고 다방향에서 변하는 힘이 가해지므로 서스펜션 부식이 받는 하중은 매우 복잡하며 일정하지 않다 (Ambrósio & Verissimo, 2009). 이러한 특성으로 인해 부식의 마모, 균열, 손상은 차량 성능 저하뿐만 아니라 고장의 주요 원인이 되며 부식의 초기 불량은 이러한 손상 과정을 가속화하는 요인으로 작용한다. 본 연구는 서스펜션 부식의 조기 불량을 효과적으로 검출할 수 있는 비전 기반 검사 시스템을 구현함으로써 출하 단계에서의 품질 신뢰성을 확보하고 불량률 저감에 기여하고자 한다.

본 연구에서 실증하려고 하는 AI 기반 비전 검사 방식은 기존의 규칙 기반 검사와 달리 딥러닝(Deep Learning) 기술을 활용하여 다양한 결함 유형을 스스로 인식할 수 있다. 특히, YOLO(You Only Look Once)와 같은 딥러닝 기반 모델은 종단(End-to-End) 학습 방식을 적용하여 입력부터 출력까지 인간의 개입을 최소화하며 부품의 변화에도 빠르게 적응할 수 있다.

그러나 AI 비전 검사를 효과적으로 활용하려면 부품의 특성에 맞는 학습 데이터 구축이 필수적이다. 부품의 형태, 소재, 결함 유형 등의 정보를 AI 모델이 학습할 수 있도록 준비해야 하며 이는 일정한 전문 지식과 시간이 필요하다. 이와 같이 구축 시 어려움이 있더라도 기존의 규칙 기반 검사를 대체할 최적의 기술로 인식되면서 활용도가 증가하게 되었다. 높은 정확도를 바탕으로 자동화 전환 시 매우 유용한 AI 비전 검사 방식은 기업의 생산 효율성을 높이고 품질 관리 개선을 향상시킬 수 있기 때문에 향후 경영 개선에 기여도가 높을 것으로 전망된다. 또한 다양한 산업 분야에서 폭넓게 활용될 것으로 기대한다.

1.2 연구의 목적

본 연구는 자동차의 조종 안정성 및 승차감 등에 영향을 미치는 서스펜션 부싱의 조립 공정에서 발생할 수 있는 불량률보다 정확하게 검출하기 위해 딥러닝 기반 객체 탐지 모델을 적용하여 성능을 평가하는 데 목적이 있다.

특히 기존 육안 검사나 규칙 기반 알고리즘에서 자주 발생하는 오탐지 및 누락 등의 문제를 개선하고 이를 대체할 수 있는 모델을 개발함으로써 향후 자동화된 불량 검출 시스템 구현의 기반을 마련하고자 하였다.

이에 본 연구에서는 YOLO를 활용하여 딥러닝 학습 기반의 비전 모델을 구축하고 별도의 코드나 복잡한 설정 없이도 현장에서 쉽게 사용할 수 있는 불량 검출 시스템이 구현 가능한지 여부를 실증적으로 평가하고자 한다. 학습은 다양한 불량 유형을 포함한 이미지와 라벨 데이터를 기반으로 수행되었으며 이후 모델의 정확도와 추론 속도를 확인하여 실제 공정에 적용 가능한 수준인지를 검토할 예정이다.


궁극적으로는 부품 누락, 조립 불량 등의 생산 현장에서 자주 발생하는 문제들을 개선하고 검사 자동화와 품질관리 효율성을 높여 비용 절감에 실질적인 도움을 주는 시스템을 구축하는 것이 본 연구의 최종 목표이다.

Ⅱ. 이론적 배경

2.1 인공지능(AI) 정의

2.1.1 AI 개요

인공지능은 지능화 수준과 능력 및 적용 범위에 따라 아래 [그림 2-1]과 같이 크게 세 가지 분야로 분류되고 있다. 특정한 작업에 특화된 좁은 범위의 인공지능인 ANI(Artificial Narrow Intelligence), 인간과 유사한 계산 능력을 보여주는 가장 일반적인 인공지능인 AGI (Artificial General Intelligence), 인간의 지능 능력을 초월하는 초인공지능인 ASI(Artificial Super Intelligence)로 구분할 수 있다(Kelly et al., 2023).




[그림 2-1] 인공지능 연구 체계 (Kelly et al., 2023)

이 중에 가장 많이 알려져 있는 머신러닝 (ML : Machine Learning)은 인간의 학습 능력과 같은 기능을 컴퓨터에서 실현하고자 하는 연구 분야로서 ANI의 세부 연구 분야로 분류된다. 그리고 기계 학습 언어로서 가장 많이 알려진 딥러닝 기술은 AGI의 세부 연구 분야로 분류되고 있다(Kelly et al., 2023).

ANI는 특정 작업에 특화된 인공지능으로, 음성 인식, 이미지 분류, 기계 번역과 같은 영역에서 이미 실생활에 폭넓게 활용되고 있다. 스마트폰의 음성 비서나 실시간 번역 애플리케이션은 ANI의 대표적인 활용 사례이다(Young et al., 2018).

AGI는 인간과 유사한 수준의 전반적인 인지 능력을 갖춘 시스템을 의미하며 이를 실현하기 위한 심층 강화학습(deep reinforcement learning), 신경망(neural network), 자가 지도 학습(self-supervised learning)과 같은 기술이 빠르게 발전하고 있다. AGI가 실현될 경우 복잡적이고 새로운 문제에 대해 인간의 개입 없이 자율적으로 해결 방안을 도출할 수 있을 것으로 예상된다(Pei et al., 2019). ASI는 이론적으로 인간의 지능을 초월하는 인공지능으로 기술적 구현 가능성뿐만 아니라 윤리적, 사회적 영향에 대한 논의가 함께 이루어지고 있다(Bostrom, 2016).



[그림 2-2] AI 학습과 기술 간의 관계 다이어그램 (Li, 2023)


[그림 2-2]는 인공지능(AI)에 사용되는 기술들의 관계를 시각적으로 보여준다. AI의 핵심 기술로는 머신러닝과 딥러닝이 있다. 머신러닝은 대규모 데

이터로부터 패턴을 학습하고 예측하는 알고리즘을 포함하며 지도 학습, 비지도 학습, 강화학습 등의 학습 방식으로 세분화된다(Li, 2023).

지도 학습은 입력과 출력 데이터를 기반으로 모델을 훈련시키는 방식이며 이미지 분류나 스팸 메일 탐지와 같은 문제에서 널리 사용된다. 비지도 학습은 정답 레이블 없이 데이터의 구조적 패턴을 학습하며 이상 탐지나 클러스터링 작업에 주로 활용된다(LeCun et al., 2015). 강화학습은 에이전트가 환경과 상호작용을 하면서 보상을 최대화하는 행동 전략을 학습하는 방식으로 게임 AI, 로봇 제어, 자율주행 등에서 강력한 성능을 보인다(LeCun et al., 2015).

딥러닝은 다층 신경망을 기반으로 학습을 수행하며 보다 복잡하고 고차원적인 문제에서 기존 인공지능 알고리즘 대비 우수한 성능을 보이고 있다(LeCun et al., 2015).


그러나 인공지능의 급격한 발전은 [그림 2-3]과 같은 윤리적 문제를 동반하고 있으며 그에 대한 논의도 점차 확대되고 있다. 개인정보 침해, 일자리 대체 가능성, 의사결정의 불투명성 등의 문제들은 책임 있는 개발과 활용을 요구하는 배경이 되고 있다(Doshi-Velez & Kim, 2017). 이를 해결하기 위해 연구자들은 설명 가능한 인공지능(Explainable AI, XAI)과 인공지능 윤리(AI ethics) 등의 연구를 통해 기술의 투명성과 공정성을 보장하기 위한 다양한 접근 방식을 탐구하고 있다(Doshi-Velez & Kim, 2017).



[그림 2-3] 인공지능 윤리 관련 연관도 (Huang et al., 2022)

2.1.2 AI 역사

인공지능연구의 기초는 1943년 Warren McCulloch과 Walter Pitts가 제안한 인공 뉴런 모델에 뿌리를 두고 있다. 이들은 뇌의 뉴런 구조를 수학적으로 모델링하여 기계가 정보 처리를 할 수 있는 가능성을 제시하였고 인간의 뇌처럼 여러 개의 연결된 뉴런들이 상호작용을 하며 문제를 해결하는 방식으로 AI를 발전시킬 수 있는 기초를 마련했다. 각 뉴런은 [그림 2-4]와 같이 다양한 논리 게이트의 연결 방식으로 연결될 수 있다.



[그림 2-4] 뉴런 연결 패턴 유형 (Piccinini, 2004)


1950년, Alan Turing은 ‘Computing Machinery and Intelligence’ 논문에서 기계 지능을 평가하는 방법으로 튜링 테스트를 제안하였다. 이 테스트는 기계의 대화 능력이 인간과 구별되지 않는다면 지능을 가졌다고 판단할 수 있다는 중요한 개념을 제시하였다.

1951년, Marvin Minsky와 Dean Edmonds는 최초의 신경망 기계인 SNARC을 개발하였다. SNARC은 여러 개의 진공관을 이용해 뉴런과 시냅스

구조를 모사하여 무작위 연결 네트워크와 강화학습을 통해 미로를 해결하는 능력을 갖춘 계산기였다.

1957년, Frank Rosenblatt는 퍼셉트론을 개발하였다. 퍼셉트론은 다수의 입력을 받아 하나의 출력을 생성하는 알고리즘으로 뇌의 뉴런 구조를 모방한 초기 형태의 인공 신경망이다. 이 모델은 선형 분리 가능한 문제에 효과적이었으나 XOR 문제와 같은 선형 분리 불가능한 문제를 해결하는 데 한계가 있었다. 퍼셉트론의 한계는 신경망 연구에 대한 관심을 잠시 감소시켰지만 이는 나중에 더 복잡한 신경망 모델들이 등장하는 계기가 되었다.

1969년, Marvin Minsky와 Seymour Papert는 퍼셉트론이 XOR 문제를 해결할 수 없음을 증명하였다. 이는 신경망 연구에 대한 연구자들의 관심을 급격히 감소시켰고 당시의 제한된 컴퓨터 성능과 맞물려 관련 연구가 중단되고 연구에 대한 재정적 지원도 감소하는 결과를 초래하였다. 이후 이 시기는 첫 번째 ‘AI 겨울’로 불리게 되었다.




[그림 2-5] 역전파 네트워크 (Rojas, 1996)

1986년, 역전파(backpropagation) 알고리즘이 개발되었다. 위의 [그림 2-5]는 역전파 알고리즘의 개념도이다. 역전파 알고리즘은 다층 신경망의 학습을 가능하게 하여 신경망이 복잡한 패턴을 학습하고 인식하는 데 중요한

역할을 하였으며 다양한 패턴을 인식하고 예측하는 데 유용하게 사용되어 딥러닝 기술 발전의 중요한 기초가 되었다(Rumelhart et al., 1986).

1986년, Geoffrey Hinton과 David Parker는 역전파 알고리즘을 실용적으로 구현하여 신경망의 학습 성능을 크게 향상시켰다.

1980년대에 등장한 전문가 시스템은 특정 분야의 전문 지식을 컴퓨터 시스템에 통합하여 인간 전문가의 의사 결정을 지원하는 프로그램이었다. MYCIN은 감염성 질병을 진단하고 항생제를 처방하는 데 사용되었으며 제한된 테스트에서 전문의와 유사한 성능을 보였다(Buchanan & Smith, 1988).




[그림 2-6] 전문가 시스템 예시(Tan, 2008)

[그림 2-6]은 와이어 본딩 기계의 고장 원인 진단을 자동화하여 숙련 기술자 의존과 관련 비용을 절감시키는 전문가 시스템이다. 전문가 시스템은 특정 분야의 문제를 해결하는 데 도움을 주었지만 복잡한 문제를 다루는 데 한계가 있었다. 이러한 한계로 인해 1987년부터 1997년까지 두 번째 'AI 겨울'이 찾아왔다. 두 번째 'AI 겨울'은 AI 기술에 대한 과도한 기대가 현실과 맞지 않음을 인식하면서 연구 자금과 관심이 급격히 줄어든 시기를 지칭한다(Toosi et al., 2021). Marvin Minsky와 Roger Schank가 1984년 미국인공지능학회(AAAD)에서 두 번째 'AI 겨울'의 가능성을 공식적으로 제기했으며 몇

년 뒤에 두 번째 'AI 겨울'을 맞이한다. 복잡한 문제나 예외적인 상황을 처리하는 데 한계가 있던 전문가 시스템에 대해 점차 비판적인 시각이 많아졌다. 이로 인해 AI 연구의 주도적인 지원을 해왔던 기업들이 연구 자금을 줄이거나 철수하면서 AI 연구의 전반적인 침체가 이어졌다(Toosi et al., 2021).

1990년대 후반부터 인터넷과 컴퓨터 하드웨어의 발전으로 AI 연구에 대한 관심이 재점화되었다. 1997년 IBM의 Deep Blue와 체스 세계 챔피언 카스파로프와의 대결에서 Deep Blue가 승리를 거둒으로써 AI가 인간의 사고를 능가할 수 있는 가능성을 보여주었고 AI가 실용적인 분야에서도 큰 성과를 낼 수 있음을 입증하는 계기가 되었다(van den Herik, 2019).

2010년대는 클라우드 컴퓨팅의 발전과 함께 AI 연구가 많은 발전이 이루어진 시기였다. 2012년, Alex Krizhevsky와 Geoffrey Hinton은 [그림 2-7]과 같은 AlexNet을 개발하여 이미지 인식 분야에서 딥러닝의 성능을 입증하였다.




[그림 2-7] AlexNet의 CNN 아키텍처 (Krizhevsky et al., 2012)

2016년, 구글 딥마인드가 개발한 인공지능 프로그램 '알파고(AlphaGo)'와 세계 정상급 바둑 기사 이세돌 9단과의 대국에서 알파고는 4승 1패로 승리하며 인공지능 연구의 역사에 중요한 전환점을 만들었다. 바둑은 경우의 수가 많아 단순한 계산으로 풀기 어려운 게임이지만 알파고는 딥러닝과 강화학습을 통해 기보를 학습하고 스스로 대국하며 기력을 향상시켰다(Silver et al., 2016). 이 대결은 AI가 복잡한 문제 해결에서 인간의 한계를 넘어설 가능성을 시사했으며 이후 딥마인드는 인간의 데이터 없이 자율 학습하는 '알파고

제로(AlphaGo Zero)'를 개발해 더욱 강력한 성능을 구현했다(Silver et al., 2017). 이세돌과 알파고의 대결은 인공지능의 다양한 산업 분야에서 AI의 활용 가능성과 윤리적 논의를 확장시키는 계기가 되었다(Oh et al., 2017).

2022년, OpenAI는 ChatGPT를 출시하였다. ChatGPT는 자연스러운 언어 처리가 가능하며 이메일 초안 작성, 기사 작성, 코드 생성 등 다양한 작업을 수행할 수 있는 능력을 갖추었다(Ray, 2023).



[그림 2-8] 이전 버전과 비교한 GPT-4의 텍스트 처리 분량 (Ray, 2023)

이후 OpenAI는 GPT-4 모델을 개발하여 위의 [그림 2-8]과 같이 성능을 더욱 향상시키고 AI 대중화에 큰 기여를 하였다. ChatGPT는 고객 서비스, 콘텐츠 생성, 교육, 심리 상담 등 여러 분야에서 실용적으로 사용되고 있으며, 인공지능 기술의 접근성과 활용도를 크게 확장시켰다.

2.1.3 AI 적용 분야

인공지능(AI) 기술은 산업과 사회 전반에 적용되며 많은 변화를 이끌고 있다. 전자상거래 분야에서는 고객 행동 데이터, 검색 이력 등 다양한 데이터를 기반으로 하는 상품 추천 시스템이 고도화되고 있으며 매출 예측 및 공급망 관리 최적화 기술을 통해 재고 관리 효율성을 획기적으로 향상시키고 있다(Zhang et al., 2019).

의료 분야에서 인공지능(AI)은 의료 영상 및 건강 데이터를 분석하여 보다 정확한 진단과 환자 맞춤형 치료 계획 수립을 지원하고 있다. 또한 웨어러블 장치와 통합되어 환자의 생체 신호를 모니터링하고 이상 징후를 조기에 발견하는 기술도 발전하고 있다(Miotto et al., 2018). 인공지능 기술 적용이 가장 앞서고 있는 대표적인 시스템으로는 IBM의 인지 컴퓨터 시스템 '왓슨'을 들 수 있다. 이 시스템은 현재 여러 병원에서 암 치료를 지원하고 있으며 각종 암 치료에 많이 활용되고 있다(정동규, 2017).

농업 분야에서는 작물 성장 상태 모니터링, 해충 침입 예측, 최적 수확 시기 결정 등 다양한 농업 관리 활동에 AI가 활용되고 있으며 이는 환경 보호와도 연계되어 대규모 기후 데이터를 분석함으로써 기후 변화 예측 및 자연재해 대응에도 중요한 역할을 수행하고 있다(이승헌 et al., 2022).

금융 분야에서도 AI 기술의 활용이 늘어나고 있다. 거래 데이터와 금융로그 분석을 통해 이상 거래를 탐지하고 사기 행위를 예방하는 시스템이 도입되었으며 고객 맞춤형 금융 자문 및 재무 계획 수립에도 AI가 적극 활용되고 있다(Ali et al., 2022). IBM의 인공지능 로봇인 '왓슨'은 의료분야뿐만 아니라 소비자들에게 상품선택, 인증, 결제, 서비스 제안까지 통합 지원을 수행하고 있다(정동규, 2017).

자동차 제조 분야에서도 AI 기술의 활용이 확대되고 있다. 생산 라인에서 센서 및 비전 시스템으로 수집된 데이터를 분석하여 불량품을 조기에 탐지하고 품질 관리를 최적화하며 예측 유지보수를 통해 설비 가동 중단을 최소화하고 있다(Kamran et al., 2018).

이처럼 AI 기술은 다양한 산업 분야에 걸쳐 혁신을 지속적으로 이끌고 있


으며 과거에는 불가능했던 서비스와 기능을 실현하고 있다. 다양한 기술과의 융합을 통해 새로운 형태의 산업 및 서비스 영역이 생겨나고 있으며 AI 기술의 지속적인 발전은 향후 더욱 폭넓은 산업 분야에서 심층적이고 혁신적인 변화를 가져올 것으로 기대된다.



2.2 딥러닝 기반 AI 아키텍처 정의

2.2.1 비전(Vision) 시스템 정의


비전 시스템은 컴퓨터가 이미지를 분석하고 해석하여 인간의 시각적 인식 능력을 모방하는 기술이다(Binford, 1975). 비전 시스템은 카메라, 센서, 이미지 처리 소프트웨어 및 알고리즘을 활용하여 영상을 획득하고 이를 분석하며 주어진 환경에서 객체를 인식하고 패턴을 분석하며 복잡한 장면을 이해하는 능력을 제공한다(Patel et al., 2021). 비전 시스템의 발전은 인공지능(AI) 및 머신러닝(ML) 기술의 발전과 맞물려 있으며 최근 딥러닝을 활용하여 자율적으로 학습하고 더욱 정교한 인식 및 분석을 수행할 수 있는 능력을 갖추게 되었다(Voulodimos et al., 2018). [그림 2-9]는 공장 환경 내에서 객체 탐지 모델을 사용하는 비전 시스템의 프로세스를 표현한 다이어그램이다.



[그림 2-9] 솔루션 프레임워크 IDEF0 다이어그램 (Urgo et al., 2024)

2.2.1.1 Vision 시스템 개요

비전 시스템은 여러 단계의 과정을 통해 이미지를 분석하고 해석한다. 크게 아래의 [그림2-10]과 같은 5가지의 단계의 과정을 거친다.



[그림 2-10] 비전 시스템 흐름도 (Patel et al., 2012; 연구자 재구성, 2025)

영상 획득(Image Acquisition) 단계에서는 목적에 맞는 다양한 카메라나 센서를 사용하여 이미지를 수집하며 수집된 영상은 시스템이 분석할 수 있는 형태로 변환된다(Malamas et al., 2003).

전처리(Preprocessing) 단계에서는 노이즈 제거, 색상 보정, 대비 조정 등을 통해 영상의 품질을 향상시켜 분석이 용이하게 만든다. 이 과정에서 히스토그램 평활화 기법 또는 가우시안 블러와 같은 기법이 자주 사용된다(Stark, 2000).

특징 추출(Feature Extraction) 단계에서는 엣지 검출, 코너 검출 등의 알고리즘을 사용하여 영상에서 유의미한 특징을 찾는다(Malamas et al., 2003).

분류 및 분석(Classification and Analysis) 단계에서는 추출된 특징을 바탕으로 객체를 분류하거나 분석한다.

결과 출력 및 의사결정(Output & Decision Making) 단계에서는 분석된 내용을 사용자에게 전달하거나 자동화 시스템이 적절한 행동을 스스로 수행한다(Malamas et al., 2003).

2.2.1.2 Vision 시스템 역사


비전 시스템의 발전은 1960년대 초반에 시작되었다. 초기에는 기초적인 이미지 프로세싱 기법을 연구하였고 이 시기의 연구는 주로 기하학적인 형태를 인식하는 것에 집중되었다. 1980년대와 1990년대에는 필터링 기법, 엣지 검출과 같은 알고리즘이 발전하며 비전 시스템의 성능이 향상되었다(Canny, 1986). 이 시기에 얼굴 인식 및 OCR(광학 문자 인식) 기술이 등장하였고 비

전 시스템이 실제적인 응용 분야에서 활용될 수 있는 가능성이 커졌다. 2000년대 들어서는 딥러닝 기술의 발전이 비전 시스템에 큰 영향을 미쳤다. AlexNet, VGGNet, ResNet과 같은 CNN 기반 모델들이 등장하면서 이미지 분류 및 객체 탐지 기술이 비약적으로 발전하였다(Simonyan & Zisserman, 2014).

2.2.1.3 Vision 시스템 적용 분야

비전 시스템은 사람의 시각 능력을 모방하는 능력을 기반으로 다양한 산업 분야에서 활용되고 있다.

영상을 분석하는 일이 많은 의료 분야에서 비전 시스템은 MRI나 CT, X-ray 등의 의료 영상을 분석하여 의료진이 진단을 내리는 것을 돕는 역할을 수행한다. [그림 2-11]에 나오는 망막 질환 진단 모델은 의료 영상에서 질환의 위치나 크기 등을 분석하고 탐지하여 의료진의 진단을 보조한다(Schmidt-Erfurth et al., 2018).




[그림 2-11] 망막 질환 진단 AI (Schmidt-Erfurth et al., 2018)

산업자동화 분야에서는 비전 시스템이 제조 공정에서 제품 결함을 검출하고 로봇을 제어하는 데 중요한 역할을 하며 품질 관리 및 생산 자동화에 핵심적인 기술로 자리 잡고 있다(Zhou, 2022).

2.2.2 YOLO(You Only Look Once) 정의

YOLO(You Only Look Once)는 이미지 내에서 객체를 빠르고 정확하게 탐지하는 모델이다. 기존의 객체 탐지 방법들은 이미지를 여러 개의 영역으로 분할하여 각 영역에 대해 독립적으로 객체를 탐지하는 방식인 반면 YOLO는 전체 이미지를 한 번에 처리하여 객체를 탐지하는 방식으로 효율성을 극대화한 모델이다(Redmon et al., 2016).



[그림 2-12] YOLO 모델 이미지 탐지 예시 (Redmon et al., 2016)

이 방식은 [그림 2-12]와 같이 이미지 전체를 그리드로 나누고 각 그리드 셀에 대해 객체의 경계 상자(bounding box)와 클래스 정보를 동시에 예측한다(Redmon et al., 2016).


2.2.2.1 YOLO 개요

YOLO 모델의 핵심적인 특징은 실시간 성능을 요구하는 곳에서 탁월한 장점을 제공한다는 것이다. 이전에 등장한 딥러닝 모델들은 이미지를 여러 번에 걸쳐 분석하는 방식으로 동작하여 한 장의 이미지를 처리하는 데 상당한

시간이 소요되었기 때문에 실시간 물체 검출이 요구되는 상황에서 사용이 어려웠다. 그러나 YOLO는 이미지를 한 번에 처리하여 탐지하는 방식으로 동영상과 같은 실시간 객체 탐지가 요구되는 상황에서는 속도가 느린 다른 모델들과 비교하여 결정적인 장점을 제공할 수 있다(Redmon et al., 2016).

2.2.2.2 YOLO 역사

YOLO는 2015년에 Joseph Redmon이 최초로 발표한 객체 탐지 모델이다. YOLO는 [그림 2-13]과 같이 단일 Convolutional Neural Network 네트워크로 구성되어 실시간 객체 탐지를 가능하게 한 모델이다(Redmon et al., 2016).



[그림 2-13] YOLO의 아키텍처 (Redmon et al., 2016)


YOLO의 첫 번째 버전인 YOLOv1은 기존의 탐지 방식들에 비해 속도와 정확도에서 뛰어난 성과를 보였지만 작은 객체에 대한 탐지 정확도에는 한계가 있었다. 2016년에 발표된 YOLOv2는 앵커 박스(anchor box)라는 개념을 도입하여 작은 객체에 대한 탐지 성능을 개선하였다.

2018년에 발표된 YOLOv3는 다양한 해상도에서 객체를 탐지할 수 있는 기능이 추가되었으며 산업 전반에서 많이 채택되는 객체 탐지 기술로 자리잡았다(Sapkota et al., 2025).

2020년에 발표된 YOLOv5는 다양한 크기의 모델을 제공하여 사용자가 자신의 목적에 맞는 모델을 선택할 수 있도록 하였다.

YOLOv6와 YOLOv7은 2022년에 발표되었으며 주로 모바일 및 엣지 디바이스에서 실행하기에 적합하도록 설계되어 비교적 낮은 성능을 가진 디바이스에서도 우수한 탐지 능력을 발휘할 수 있게 되었다(Sapkota et al., 2025).

2023년에 발표된 YOLOv8은 모델의 구현과 튜닝 과정을 단순화하여 상업적, 연구적 용도로 널리 채택되었으며 2024년에는 백본 네트워크의 최적화를 통해 작은 객체 탐지 성능을 더욱 향상시킨 YOLOv9이 발표되었다. 같은 해에 발표된 YOLOv10은 성능과 연산 비용을 개선한 모델로 주목을 받고 있다(Sapkota et al., 2025). [그림 2-14]와 같이 YOLOv10은 기존 YOLO 모델 및 타 객체 탐지 모델들보다 더 나은 성능을 보여준다(Wang, A et al., 2025).



[그림 2-14] YOLO 모델과 타 모델의 비교 (Wang, A et al., 2025)

2.2.2.3 YOLO 적용 분야

YOLO 모델은 주로 실시간 객체 탐지가 요구되는 산업 분야에서 활용되고 있다. 도로의 상황을 실시간으로 인식하고 처리하는 것이 필요한 자율주행 분야에서 YOLO 모델은 차량이나 보행자 등의 복잡한 도로상황을 실시간으로 탐지할 수 있으며 자율주행 시스템이 안전하게 동작할 수 있도록 한다(Jamil et al., 2020).


보안 영상 분야에서는 주로 CCTV 영상 내의 움직이는 물체나 사람의 이상 행동 등을 실시간으로 탐지하여 결과를 즉각적으로 전달하여 빠른 대응이

가능하도록 돕는 데 YOLO 모델이 사용된다(Siva et al., 2025).

산업 자동화 분야에서도 YOLO는 제품 불량 검출, 로봇 비전 시스템 등 다양한 작업에 적용되고 있다. 실시간으로 결함을 인식하여 불량품을 자동으로 선별하거나 작업 현장을 감지해 로봇의 움직임을 제어하는 등, 스마트 제조 시스템 구축에 핵심적인 기술로 자리 잡고 있다(Hussain, 2023).

2.2.3 Faster R-CNN 정의

Faster R-CNN은 객체 탐지를 위한 딥러닝 기반 모델로 R-CNN 계열(Selective Search 기반)의 단점을 개선한 빠르고 정확한 객체 탐지 알고리즘이다(Ren et al., 2015).



[그림 2-15] Faster R-CNN의 단일 통합 네트워크 (Ren et al., 2015)

Faster R-CNN은 [그림 2-15]와 같이 영역 제안 네트워크(Region Proposal Network, RPN)를 활용하여 객체 후보 영역을 빠르게 생성하고 CNN을 통해 분류 및 바운딩 박스 회귀(Bounding box Regression)를 수행하는 구조를 갖는다(Ren et al., 2015).

2.2.3.1 Faster R-CNN 개요

Faster R-CNN은 Microsoft Research에서 제안된 딥러닝 기반 2단계 객체 탐지 모델이다. 이전 R-CNN보다 효율적인 End-to-End 학습 방식을 적용하여 성능을 크게 향상시켰다(Ren et al., 2015).

기존 R-CNN과 Fast R-CNN의 많은 계산량과 느린 속도를 해결하기 위해 Selective Search를 제거하고 신경망 자체가 직접 객체가 있을 가능성이 높은 영역을 예측하도록 설계된 RPN을 추가하였다. RPN은 CNN을 통해 추출된 피쳐 맵을 입력으로 받아 특정 영역에 객체가 존재할 확률과 그에 해당하는 바운딩 박스를 동시에 예측한다. 이 과정에서 각 위치마다 여러 개의 앵커 박스(Anchor Box)를 사용하여 다양한 크기와 종횡비를 고려하며 높은 확률을 가진 후보 영역을 남긴다. RPN의 도입으로 인해 객체 탐지 과정이 훨씬 효율적으로 이루어졌으며 연산 속도가 향상되었다(Ren et al., 2015).


2.2.3.2 Faster R-CNN 역사

2014년에 발표된 R-CNN은 Selective Search 기법을 활용하여 이미지 내 객체 후보 영역을 추출하고 이를 분류하는 구조였다. 하지만 Selective Search를 수행하는 과정에서 많은 연산 자원이 소모되어 전체적인 처리 속도가 매우 느리다는 단점이 있었다(Girshick et al., 2014).

2015년에 발표된 Fast R-CNN은 R-CNN의 느린 처리 속도를 개선하기 위해 RoI Pooling 기법을 도입하여 객체 후보 영역을 효율적으로 분류하는 방식을 제안하였다. 이 방식은 이미지 전체에서 한 번만 CNN 연산을 수행한 후 각 후보 영역을 공통 특징 맵에서 추출함으로써 연산 효율을 크게 향상시켰다. 그러나 여전히 객체 후보 영역을 생성하는 데 Selective Search를 사용하고 있어 병목 현상이 발생하는 한계가 있었다(Girshick, 2015).

같은 해에 이러한 단점을 보완하기 위해 제안된 Faster R-CNN은 Selective Search를 대체하기 위해 Region Proposal Network(RPN)을 통합하였다(Ren et al., 2015). RPN은 CNN으로부터 추출된 특징 맵을 기반으로 객체가 존재할 가능성이 높은 영역을 자동으로 예측하며 객체 탐지의 정확도와 처리 속도 모두에서 큰 향상을 이루었다(Ren et al., 2015).

이후 작은 객체의 탐지 성능을 개선하기 위해 Feature Pyramid Network가 Faster R-CNN과 결합되었다. [그림 2-16]은 FPN의 구조를 나타낸 것으로 FPN은 CNN의 다층 피쳐 맵을 활용하여 다양한 크기의 객체를 효과적으로 탐지할 수 있도록 도와주며 다중 스케일 객체 탐지 성능을 향상시켰다(Lin et al., 2017).



[그림 2-16] 기존 이미지 피라미드와 FPN (Lin et al., 2017)


최근 Faster R-CNN은 Transformer 기반 객체 탐지 모델(DETR, Swin Transformer)과 결합되거나 Anchor-Free 방식을 도입하는 등 다양한 방식으로 발전하고 있다(Carion et al., 2020).

2.2.3.3 Faster R-CNN 적용 분야

Faster R-CNN은 다양한 산업 분야에서 활용되며 특히 정밀한 객체 인식이 필요하여 높은 정확도를 요구하는 환경에서 뛰어난 성능을 발휘한다.

의료 영상 분석 분야에서 Faster R-CNN은 MRI나 CT 등의 의료 영상을 분석하여 질병이 존재하는 영역을 탐지하는 데 사용되어 의료진이 진단을 내릴 수 있도록 돕고 환자의 건강 상태를 지속적으로 모니터링하는 데 사용된다(Raimundo et al., 2023).

위성 이미지 분석 분야에서는 건물, 도로, 산불 등의 객체를 탐지하는 데 사용된다. Faster R-CNN은 높은 정확도로 지형과 환경 변화를 분석할 수 있어 기상 예측, 도시 개발, 산림 보호, 재해 관리 등 다양한 분야에서 중요한 역할을 한다(Rabbi et al., 2020). [그림 2-17]은 위성 이미지상에서 자동차 객체를 검출한 사례를 보여준다.



[그림 2-17] Faster R-CNN의 위성 이미지 객체 검출 (Rabbi et al., 2020)

산불이 발생한 지역을 빠르게 탐지하고 확산 경로를 예측할 수 있으며 환경 보호 모니터링을 통해 산림 벌채, 해양 오염, 기후 변화 등의 문제를 감시하고 대응하는 데에도 유용하게 활용될 수 있다(Choi et al., 2025).

2.2.4 MobileNet 정의

MobileNet은 CNN 구조를 경량화한 모델로, 모바일 및 엣지 디바이스 환경에서 빠르고 효율적인 이미지 처리를 목표로 개발되었다. 기존의 신경망 구조에 비해 연산량을 크게 줄이면서도 높은 정확도를 유지할 수 있도록 최적화되어 있다(Howard et al., 2017).

경량성과 가장 중점적으로 고려한 MobileNet은 [그림 2-18]과 같이 스마트폰, IoT 기기, 드론, 웨어러블 디바이스 등과 같은 자원이 제한된 환경에서도 실시간으로 다양한 기능을 안정적으로 수행할 수 있다(Howard et al., 2017).




[그림 2-18] 모바일 기기에 최적화된 MobileNet (Howard et al., 2017)

2.2.4.1 MobileNet 개요

MobileNet은 기존의 CNN보다 가볍고 효율적인 구조를 갖추기 위해 여러 가지 최적화 기법을 사용하였다.

그 중 핵심적인 최적화 기법은 Depthwise Separable Convolution(깊이별 분리 합성곱)이다. 일반적인 합성곱 연산은 공간 정보와 채널 정보를 동시에 처리하지만 MobileNet은 이 과정을 분리하여 연산량을 감소시켰다. [그림 2-19]에서 볼 수 있듯이 먼저 Depthwise Convolution을 통해 특징을 추출한 다음 Pointwise Convolution을 이용해 최종 출력을 생성한다. 이러한 방식으

로 합성곱 연산을 수행하면 기존 CNN과 비교하여 연산량이 약 8~9배 감소하며 모델의 경량화가 가능해진다(Howard et al., 2017).



[그림 2-19] 경량화된 Pointwise Convolution (Howard et al., 2017)

두 번째 최적화 기법은 Width Multiplier(폭 조정 계수, α)이다. 이 기법은 채널 수를 조절함으로써 전체 연산량을 줄이는 기법이다. 기본 α 값인 1.0은 원래의 모델 구조를 그대로 유지하지만 α 값을 낮추면 채널 수가 감소하면서 모델이 더 가볍게 구성된다. α 값 조정으로 다양한 하드웨어 환경에 따라 모델의 복잡도를 유연하게 조절할 수 있다(Howard et al., 2017).


이러한 최적화 기법들을 통해 MobileNet은 기존 CNN 모델과 유사한 수준의 정확도를 유지하면서도 모바일 및 엣지 디바이스 환경에서 효율적으로 동작할 수 있게 되었다(Howard et al., 2017).

2.2.4.2 MobileNet 역사

2017년에 발표된 MobileNetV1은 CNN 아키텍처에 Depthwise Separable Convolution 기법을 도입하였다. 이 구조를 통해 연산량을 크게 줄이면서도 높은 인식 성능을 유지할 수 있었다(Howard et al., 2017).

2018년에 발표된 MobileNetV2는 Linear Bottleneck 구조와 Residual Connection을 도입하여 MobileNetV1의 성능을 개선한 모델이다. 추론 속도가 더욱 빨라졌으며 정확도 또한 향상되었다(Sandler et al., 2018). 2019년에 발표된 MobileNetV3는 성능을 극대화하기 위해 Neural Architecture Search 기법을 적용하여 최적화된 모델이다. 또한 Squeeze-and-Excitation 모듈을 도입하여 성능을 더욱 향상시켰다(Howard et al., 2019).

2023년에 발표된 MobileNetV4는 기존 MobileNet 아키텍처에서 사용된 Depthwise Separable Convolution 기법을 더욱 최적화하고 [그림 2-20]과 같은 최신의 신경망 설계 기법인 Efficient Channel Attention을 도입하여 특징 추출 성능을 개선하였다(Wang, Q et al., 2020).



[그림 2-20] ECA 다이어그램 (Wang, Q et al., 2020)

또한, MobileNetV4는 연산 효율성을 극대화하기 위해 하드웨어 친화적인 연산 구조를 적용하여 CPU와 GPU뿐만 아니라 NPU(Neural Processing Unit) 및 TPU(Tensor Processing Unit)와 같은 전용 AI 가속기에서도 높은 성능을 발휘할 수 있도록 설계되었다(Wang, Q et al., 2020).

2.2.4.3 MobileNet 적용 분야

MobileNet 모델은 스마트폰이나 드론과 같은 소형 디바이스에서 빠른 속도로 이미지를 처리할 수 있어 이미지 검색이나 증강 현실(AR) 등의 애플리케이션에서 사용된다(Howard et al., 2017).

MobileNet은 다양한 인식 기술에도 널리 사용되고 있다. 얼굴 인식 영역에서 스마트폰 사용자의 얼굴을 인식해 잠금을 해제하는 기능 등에 활용된다. 음성 인식과 문자 인식과 영역에서도 사용되고 있다. 사용자의 명령어를 실시간으로 인식하여 스마트폰이나 디지털 기기의 기능을 제어하는 데 활용되고 카메라로 촬영한 이미지나 화면상의 텍스트를 빠르게 분석하고 추출하는 데 사용된다. 이처럼 MobileNet은 경량성과 실시간 처리가 중요한 다양한 응용 분야에서 유용하게 활용되고 있다(Sandler et al., 2018).

2.2.5 AI 모델 선정

2.2.5.1 객체 탐지 모델 평가 기준

자동 검사 시스템에 적용되는 AI 모델은 빠른 탐지 속도와 높은 정확도를 동시에 갖추는 것이 필수적이다. 공장 환경에서는 GPU 및 CPU 자원에 제약이 있는 경우가 많기 때문에 연산 자원의 효율적인 활용 역시 매우 중요하다(Park et al., 2022). AI 모델은 딥러닝 기반 객체 탐지 알고리즘인 YOLO, Faster R-CNN, MobileNetV4를 중심으로 각각의 정확도 성능(mAP), 탐지 속도(FPS)를 종합적으로 비교한 후 선정하였다. mAP는 모델이 객체를 얼마나 정확하게 탐지하는지를 나타낸다. 초당 프레임 수는 모델이 1초 동안 처리할 수 있는 이미지 수를 의미하며 높은 FPS를 제공하는 모델일수록 실시간 탐지에 적합하다(Tan et al., 2020).

2.2.5.2 IoU(Intersection over Union)

IoU는 모델이 예측한 바운딩 박스와 정답으로 라벨링된 바운딩 박스가 얼마나 겹치는지를 수치화한 지표이다. IoU는 예측된 바운딩 박스와 실제 객체의 바운딩 박스 사이의 겹치는 면적인 교집합(Intersection)과 전체 면적인 합

집합(Union)의 비율로 정의된다(Yu et al., 2016). 이는 다음 수식으로 표현할 수 있다.

$$IoU = \frac{|A \cap B|}{|A \cup B|}$$

위의 수식에서 A는 모델이 예측한 바운딩 박스의 면적, B는 사람이 라벨링한 바운딩 박스의 면적을 나타낸다. $|A \cap B|$ 는 두 바운딩 박스의 교집합인 서로 겹치는 영역의 면적을 나타내고 $|A \cup B|$ 는 두 바운딩 박스의 합집합인 전체 면적을 의미한다. IoU 값은 0과 1 사이의 실숫값이며 그 해석은 [표 2-1]과 같다.

[표 2-1] IoU 값 해석 (연구자 재구성, 2025)

IoU 값	내 용
IoU = 0	두 박스가 전혀 겹치지 않음
$0 < IoU < 0.5$	부분적으로 겹치지만 겹침 정도가 작음
IoU = 0.5	박스의 절반 정도가 겹침 (일반적인 성공 기준)
$IoU > 0.5$	높은 정확도로 탐지됨
IoU = 1	완벽하게 일치함

객체 탐지 모델은 일반적으로 $IoU > 0.5$ 를 정탐(True Positive)으로 간주하며, mAP(mean Average Precision) 계산 시 IoU 임곗값(Threshold)을 조절하여 성능을 평가한다(Everingham et al., 2010).

2.2.5.3 혼동 행렬

혼동 행렬(Confusion Matrix)은 모델이 예측한 결과와 실제 정답을 비교하여 네 가지로 분류한 행렬이며 이는 [표 2-2]와 같이 나타낼 수 있다.

[표 2-2] 혼동 행렬 (Sokolova & Lapalme, 2020; 연구자 재구성, 2025)

구분		예측값	
		Negative	Positive
실제값	Negative	True Negative	False Positive
	Positive	False Negative	True Positive

True Positive(TP)는 모델이 양성(Positive)으로 예측한 샘플 중 실제로도 양성인 샘플의 수를 의미한다. 이는 모델이 정확하게 예측한 양성 샘플을 나타낸다(Sokolova & Lapalme, 2020).

TP = 실제 양성 샘플 중 모델이 양성으로 예측한 샘플 수

True Negative(TN)는 모델이 음성(Negative)으로 예측한 샘플 중 실제로도 음성인 샘플의 수를 의미한다. 즉, 모델이 정확하게 예측한 음성 샘플을 나타낸다(Sokolova & Lapalme, 2020).

TN = 실제 음성 샘플 중 모델이 음성으로 예측한 샘플 수

False Positive(FP)는 모델이 양성(Positive)으로 예측한 샘플 중 실제로는 음성(Negative)인 샘플의 수를 의미한다. 즉, 모델이 양성으로 잘못 예측한 샘플을 나타낸다(Sokolova & Lapalme, 2020).

FP = 실제 음성 샘플 중 모델이 양성으로 예측한 샘플 수

False Negative(FN)는 모델이 음성(Negative)으로 예측한 샘플 중 실제로는 양성(Positive)인 샘플의 수를 의미한다. 즉, 모델이 음성으로 잘못 예측한 샘플을 나타낸다(Sokolova & Lapalme, 2020).

FN = 실제 양성 샘플 중 모델이 음성으로 예측한 샘플 수

2.2.5.4 Precision & Recall

Precision은 모델이 양성(Positive)으로 예측한 샘플 중 실제로 양성인 샘플의 비율을 의미한다. 이는 다음 수식으로 표현할 수 있다(Sokolova & Lapalme, 2020).

$$Precision = \frac{TP}{TP + FP}$$

Recall은 실제 양성 샘플 중에서 모델이 양성으로 정확히 예측한 샘플의 비율을 의미한다(Sokolova & Lapalme, 2020). 이는 다음 수식으로 표현할 수 있다(Sokolova & Lapalme, 2020).

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

Precision과 Recall은 모델 성능 평가에 중요한 지표로 활용된다. 이동열(2024), 이승호(2024), 하승재(2021)는 이 두 지표를 중심으로 모델의 탐지 정확도와 재현율을 종합적으로 평가하여 모델의 신뢰성을 분석하였다.

2.2.5.5 mAP@0.5 & mAP@0.5:0.95

mAP@0.5는 IoU 임계값을 0.5로 고정했을 때의 평균 정확도를 의미하며 다음과 같은 수식으로 표현된다(Padilla et al., 2021).

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i$$

위의 수식에서 $P(i)$ 는 i 번째 예측에 대한 Precision 값이고 N 은 각 클래스별 예측에 대한 Precision-Recall 곡선의 포인트 수이다.

$mAP@0.5:0.95$ 는 IoU의 임계값을 0.5부터 0.95까지 0.05 간격으로 증가시키며 계산한 평균 정확도를 의미한다. $mAP@0.5:0.95$ 는 더 넓은 범위의 IoU를 고려하기 때문에 더 엄격한 평가 기준이 될 수 있다. 이는 다음 수식으로 표현할 수 있다(Padilla et al., 2021). 여기서 t 는 IoU 임계값을 의미하며 $AP(t)$ 는 해당 임계값에 대한 AP를 의미한다.

$$mAP_{50:95} = \frac{1}{N} \sum_{t=50}^{95, \Delta t=5} AP(t)$$

2.2.5.6 모델 성능 비교 및 분석

본 연구에서는 김용민(2022), 김희범(2024), 유익수(2024), 이해구(2024)가 여러 모델의 성능을 비교 분석한 방식과 유사하게 MobileNet, Faster R-CNN, YOLO 모델을 처리 속도 및 정확도 측면에서 비교하였다.

MobileNetV4 모델은 모바일 및 임베디드 장치에서 효율적으로 실행될 수 있도록 설계되었다. MobileNetV4는 경량화와 연산 속도 최적화를 위해 설계되었기 때문에 다른 모델들에 비해 정확도가 낮은 단점이 있다. 아래의 [표 2-3]은 MobileNet의 버전 별 성능 비교표이다.

[표 2-3] MobileNet 버전별 성능 비교 (Qin et al., 2024)

Backbone	COCO Val AP	Pixel 6 CPU latency (ms)
MobileNet v1	31.0	66.4
MobileNet Multi-AVG	32.7	58.1
MobileNet v2	32.9	66.4
MobileNet v3 Large	33.2	59.9
MobileNet v4 Hybrid	34.0	60.5
MobileNet v4 Conv	32.6	51.3

가장 최근 버전인 MobileNetV4는 모바일 환경에서 약 51.3ms ~ 60.5ms 정도의 latency로 1초당 16~19장의 이미지를 처리할 수 있음을 보여준다. 그렇지만 품질 검사나 이상 탐지 등 높은 정확도가 요구되는 작업에서 MobileNetV4의 비교적 낮은 32.6ms ~ 34.0의 정확도 성능이 부족하다고 판단된다. 아래의 [표 2-4]는 Faster R-CNN의 다양한 backbone method별 성능지표이다.

[표 2-4] Faster R-CNN의 성능 지표 (Ren et al., 2015)

method	data	mAP (%)	latency (ms)
SS	07	66.9	1830
SS	07+12	70.0	1830
RPN+VGG, unshared	07	68.5	342
RPN+VGG, shared	07	69.9	198
RPN+VGG, shared	07+12	73.2	198

위의 표에서 가장 성능이 좋은 모델의 정확도는 73.2로 높지만 1장의 이미지를 처리하는 데 198ms의 latency로 1초당 5장의 이미지밖에 처리하지 못한다. 이러한 이유로 실시간으로 이미지 처리가 필요한 자동 검사 시스템 환경에서는 사용하기 어렵다고 판단된다.

YOLO 모델은 이미지를 한 번만 처리하는 방식 때문에 Inferencing 속도가 다른 모델들에 비해 매우 빠르다. 아래의 [표 2-5]는 최신 YOLO 모델들의 성능 비교표이다. YOLO 모델 중 가벼운 쪽에 속하는 모델은 1장의 이미지를 처리하는 데 1.84ms가 소요되므로 1초에 500장 이상의 이미지를 처리할 수 있다. 가장 무거운 모델 또한 16.86의 latency로 1초에 60장 정도의 이미지를 처리할 수 있다. 이러한 특성은 실시간 탐지가 중요한 자동 검사 시스템 환경에서 매우 중요한 요소로 작용한다. 정확도 성능은 대부분의 모델이 50 이상으로 검사 시스템에 적용 가능한 수준이다.

[표 2-5] YOLO 모델들의 성능 지표 (Wang, A et al., 2025)

Model	FLOPs	mAP (%)	latency (ms)
YOLOv8-N	8.7	37.3	6.16
YOLOv10-N	6.7	38.5	1.84
YOLOv8-S	28.6	44.9	7.07
YOLOv9-S	26.4	46.7	-
YOLOv10-S	21.6	46.3	2.49
YOLOv8-M	78.9	50.6	9.50
YOLOv9-M	76.3	51.1	-
YOLOv10-M	59.1	51.1	4.74
YOLOv9-C	102.1	52.5	10.57
YOLOv10-B	92.0	52.5	5.74
YOLOv8-L	165.2	52.9	12.39
YOLOv10-L	120.3	53.2	7.28
YOLOv8-X	257.8	53.9	16.86
YOLOv10-X	160.4	54.4	10.70

정확도와 이미지 처리 속도를 종합적으로 고려했을 때 자동 검사 시스템 환경에서는 세 개의 모델 중 YOLO 모델이 가장 우수한 성능을 보인다. 특히, YOLO 모델은 지속적인 연구와 업데이트를 통해 성능이 개선되어 오고 있고 앞으로도 지속적인 연구가 이루어질 가능성이 높으므로 향후 활용 가치가 클 것으로 예상된다. 이로 인해 자동 검사 시스템과 같은 실시간 탐지가 요구되고 꾸준한 발전이 이루어져야 하는 환경에서 가장 적합한 선택으로 평가된다.

2.2.5.7 최적의 객체 탐지 모델 선정

가장 최근에 발표된 YOLO 모델인 YOLOv8, YOLOv9, YOLOv10의 성

능을 비교하여 최적의 모델을 선정하였다. 각 모델의 여러 버전 중 m 버전을 기준으로 비교한 결과 YOLOv8은 mAP 50.6%의 정확도와 9.50ms의 latency를 가지고 있어 충분한 처리 속도를 제공하여 균형 잡힌 성능을 보인다. YOLOv9은 mAP 51.1%로 YOLOv8보다 높은 정확도를 가지고 있다. YOLOv10은 mAP 51.1%로 YOLOv9과 같은 정확도를 가지고 있고, 4.74ms의 latency로 YOLOv8에 비해 2배 빠른 이미지 처리 속도를 가지고 있다. YOLOv9-M의 latency는 표현되어 있지 않지만 비슷한 크기의 모델인 YOLOv9-C와 YOLOv10-B의 latency가 각각 10.57ms와 5.74ms인 것으로 볼 때 YOLOv9-M의 latency는 YOLOv10-M에 비해 높을 것이라고 추측할 수 있다.

YOLOv8, YOLOv9, YOLOv10 모델의 성능을 종합적으로 비교하였을 때 가장 높은 정확도와 이미지 처리 속도를 가지고 있는 YOLOv10 모델이 적합한 모델로 선정되었다.

2.2.5.8 YOLOv10 세부 모델 비교

YOLOv10은 다양한 사용 환경에 따라 속도나 및 정확도에 대한 요구가 다를 수 있기 때문에 여섯 가지 크기의 모델로 구성된다. YOLOv10의 기본 6가지 모델 'n', 's', 'm', 'b', 'x'는 각각 'nano', 'small', 'medium', 'balance', 'large', 'x-large'의 뜻을 가지고 있다. 이름에서 알 수 있듯이 'n'이 가장 신경망 모델의 복잡도가 낮아 상대적으로 가장 낮은 정확도와 빠른 추론 속도를 가진 가벼운 모델이고 'x'는 복잡도가 높아 상대적으로 가장 높은 정확도와 느린 추론 속도를 가진 무거운 모델이다. 각 모델의 특징은 다음의 [표 2-6]과 같다.

[표 2-6] YOLOv10의 기본 6모델 (Ultralytics, 2025)

모델명	특징
YOLOv10n	극도로 제한된 리소스 환경을 위한 경량화된 모델로 임베디드 시스템 등에서 사용하기 적합
YOLOv10s	속도와 정확도 간의 균형을 중시한 소형 모델로 실시간 처리가 중요한 응용 분야에 적합
YOLOv10m	일반적인 용도의 중간 규모 모델로 다양한 상황에서 안정적인 성능을 제공
YOLOv10b	정확도 향상을 위해 모델 폭을 확장한 구조로 연산량과 성능 간의 균형을 유지
YOLOv10l	계산 자원 사용은 증가하지만 더 높은 정확도를 제공하는 대형 모델
YOLOv10x	정확도와 성능을 극대화한 초대형 모델로 자원이 충분한 환경에서 최상의 성능을 발휘

그러나 검출하려는 객체 또는 학습 데이터에 따라 정확도 성능은 달라질 수 있다. 또한, 무거운 모델일수록 학습시간이 길어진다는 단점이 존재해 프로젝트에 맞게 선정할 필요가 있다. 모델의 학습시간과 추론 속도에 관한 정보는 다음의 [표 2-7]과 같다. Image Size 640*640과 Batch size 16을 사용하여 학습했을 때의 각 세부 모델별 AP(정확도)와 Latency(추론속도)를 나타낸다. AP의 값이 클수록 모델이 예측하는 값이 정답일 가능성이 높으며 Latency의 값이 낮을수록 추론을 빠르게 할 수 있다.

[표 2-7] YOLOv10의 모델 크기별 성능 (Ultralytics, 2024)

모델	Image Size	Batch size	AP	Latency (ms)
YOLOv10n	640	16	38.5	1.84
YOLOv10s	640	16	46.3	2.49
YOLOv10m	640	16	51.1	4.74
YOLOv10b	640	16	52.5	5.74
YOLOv10l	640	16	53.2	7.28
YOLOv10x	640	16	54.4	10.70

본 연구에서는 우상진(2023)의 연구에서와 같이 YOLOv10 계열의 다양한 세부 모델을 성능 지표(AP, Latency)를 기준으로 비교 분석하였다. YOLOv10l, YOLOv10x 모델은 Latency가 길어 실시간 탐지 실험에는 적합하지 않고 학습시간 또한 다른 모델들에 비해 길기 때문에 다량의 학습을 시도하고 비교를 해야 하는 프로젝트 과정에 맞지 않아 제외하였다. YOLOv10n, YOLOv10s 모델은 경량화에 중점을 둔 구조로 인해 정확도 손실이 큰 한계가 있어 본 연구의 목표인 자동차 부품의 정밀 결함 검출에 적합하지 않기 때문에 제외하였다. YOLOv10m, YOLOv10b 모델은 적절한 정확도와 연산량 사이의 균형을 제공하며 산업 환경에서 요구되는 실시간성과 정확도를 모두 만족할 수 있는 구조이기 때문에 이 두 모델을 사용하여 학습한 뒤 비교하여 최종 모델을 선정하기로 하였다.



2.3 품질 검사 정의

품질 검사는 제품의 성능과 안정성 및 신뢰성을 보장하기 위해 수행되는 필수적인 절차이며 제조 공정에서 발생할 수 있는 제품의 결함을 출하 전에 발견하고 품질을 일정 수준 이상으로 유지하기 위한 과정이다(Babic et al., 2021). 품질 검사의 핵심 목적은 불량 제품의 출하를 방지하고 고객 만족도를 높이며 생산성 향상시키고 비용을 절감하여 궁극적으로 기업의 경쟁력을 강화하는 것이다(Babic et al., 2021).

2.3.1 품질 검사 개요

품질 검사의 유형 분류는 [표 2-8]과 같이 크게 검사 유형, 검사 시점, 검사 기술에 따라 구분할 수 있으며 각 접근 방식은 특정 상황과 조건에 따라 다르게 적용된다(Montgomery, 2020).

[표 2-8] 품질 검사 유형 분류(Montgomery, 2020; 연구자 재구성, 2025)

기준	유형	시점	목적
검사 대상	전수 검사	전체 대상을 모두 검사	완벽한 품질 보증
	표본 검사	일부 표본 검사	비용과 시간의 효율성
검사 시점	선행 검사	공정 시작 분류 전	문제 사전 예방, 기준 설정
	수시 검사	공정 중간	중간 이상 조기 발견
	후행 검사	공정 완료 시점	최종 품질 확인, 합격 여부 판정

품질 검사는 제품 수량에 따라 전수 검사와 표본 검사로, 검사 시점에 따라 선행 검사, 수시 검사, 후행 검사로 구분된다(Montgomery, 2020).

전수 검사는 생산된 모든 제품을 검사하여 품질 기준을 충족하는지 검사

하는 방법이다(Dodge, 1943). 이 방법은 품질 문제를 최대한 줄이는 데 효과적이지만 대량 생산의 경우 시간과 비용이 크게 소요될 수 있다는 단점이 있다. 하지만 실수와 같은 예측 불가능한 품질 문제를 완벽하게 통제하기 위해서는 전수 검사가 필요하다(Hinckley, 1997).

표본 검사는 전체 생산 제품 중 일부를 샘플로 선택해 품질을 검사하는 방법이다. 대량 생산 시 전수 검사를 수행하기 어려울 때 활용되며 검사 비용과 시간을 절감할 수 있지만 불량품을 놓칠 위험이 존재한다는 단점이 존재한다(Dodge, 1943).

선행 검사는 생산이 시작되기 전에 원자재 및 부품의 품질을 검사하는 방법이다. 이는 불량 원자재나 부품이 최종 제품에 영향을 미치지 않도록 하여 제품의 품질 저하를 방지한다(Hinckley, 1997).

수시 검사는 생산 과정의 각 단계에서 품질을 검사하는 방법이다. 실시간 불량 감지와 즉각적인 조치를 통해 전체 생산 과정의 효율성을 높이는 데 기여한다(Cemenska et al., 2015).

후행 검사는 최종 제품이 생산된 후 출하 전에 실시하는 검사이며 출고 전 마지막으로 소비자에게 전달되는 제품의 최종 품질을 확실히 보증하는 역할을 한다(Hinckley, 1997).


2.3.2 불량 검사 기법의 종류

불량 검사 기법은 크게 육안 검사, 기계적 검사, 그리고 AI 및 머신러닝 기반 검사로 구분할 수 있다.

육안 검사는 작업자가 제품의 외관을 직접 눈으로 확인하거나 손으로 만져보며 결함 여부를 판단하는 방식으로 현재까지도 많은 현장에서 활용되고 있다(See et al., 2017).

기계적 검사는 다시 파괴 검사와 비파괴 검사(NDT, Non-Destructive Testing)로 나뉜다. 파괴 검사는 제품에 물리적 하중을 가해 구조적 강도나 내구성을 평가하는 방식으로 제품이 설계 기준을 충족하는지 직접적으로 확인하여 고품질 확보를 위해 널리 사용된다(Yang et al., 2020).

비파괴 검사는 제품을 손상시키지 않고 내부 또는 표면 결함을 진단할 수 있다는 점에서 반복 검사나 고가 부품 검사에 적합하다. 이 방식은 아래의 [그림 2-21]과 같이 광학 기반, 영상 기반, 전자기장 기반 검사 등으로 분류되며, 주요 방식으로는 초음파 검사, 적외선 검사, X-ray 검사 등이 있다 (Wang, B et al., 2020).



[그림 2-21] 비파괴 시험 및 평가 기법의 범주 (Wang, B et al., 2020)

AI 및 머신러닝 기반 검사는 대량의 데이터로 학습시킨 인공지능 모델이 불량품을 탐지하는 검사이다. 이 기술은 검사 오류를 줄이고 속도를 높여 생산 공정의 효율성을 높이며 품질 관리의 일관성도 강화할 수 있다 (Ferguson et al., 2018).

2.3.3 이상치 감지 알고리즘

이상치 감지 알고리즘은 대부분의 데이터와는 다른 비정상적이거나 예외적인 데이터를 자동으로 식별하거나 분류하는 알고리즘이며 다양한 산업 분야에서 조기 경고 시스템이나 품질관리 시스템, 보안 시스템 등에 활용되고 있다(Chandola et al., 2009). 이상치 감지 알고리즘은 접근 방식에 따라 통

계 기반, 규칙 반기, 기계학습 기반 등으로 분류된다.

통계 기반에서는 표준 편차 기반과 사분위수 기반으로 이상치를 탐지한다(Rousseeuw & Hubert, 2011). 표준 편차 기반에서는 데이터의 표준 편차를 계산하여 표준편차에서 멀리 벗어난 데이터를 이상치로 간주하며 사분위수 기반에서는 데이터를 사분위수로 나눈 뒤에 IQR을 계산하여 일반적인 범위에서 벗어난 데이터를 이상치로 간주한다(Rousseeuw & Hubert, 2011)

규칙 기반에서는 사전에 정의된 규칙에서 벗어난 데이터를 이상치로 탐지한다. 이때 규칙은 그 분야 전문가들의 경험에 기반을 두어 정의된다(Ul-Islam et al., 2018). 박창엽(2019)과 양홍모(2020)는 규칙 기반 알고리즘을 활용하여 이상치 탐지에 관한 연구를 수행하였다.

기계학습 기반에서는 라벨링 된 데이터를 사용하여 모델을 학습시키고 새로운 데이터가 이 모델에서 얼마나 벗어나는지에 따라 이상치를 탐지하거나 라벨 없이 데이터 간의 분포, 밀도, 거리 등의 특성을 학습시켜 새로운 데이터가 이상치 인지 탐지한다(Pang et al., 2019).

2.4 선행연구 분석

2.4.1 국내 선행연구 분석

국내의 불량검출 관련 선행연구들을 아래 [표 2-9]와 같이 정리하였다. 불량검출 관련 선행연구들에서 객체 탐지(Object Detection)와 관련된 다양한 연구가 진행되어 왔음을 확인할 수 있다. 이러한 연구들은 주로 최적 모델 선정, 모델 성능 비교, 육안 검사 대체, 그리고 전반적인 검사 시스템 효율 향상에 초점을 맞추고 있다.

[표 2-9] 국내 불량검출 선행연구 분석 (연구자 재구성, 2025)

연구자	연구주제	연구방법	연구결과	주제어
박창업 (2019)	자동차 힌지 브라켓의 용접너트 누락 방지를 위한 비전 검사 시스템 개발	템플릿 정합 알고리즘과 유사 척도 매칭 알고리즘 적용, 자동화 검사 시스템 설계	- 자동화 검사 시스템의 검사 정확도 98% 달성, 불량률 50% 감소 - 육안 검사 대비 생산성 및 품질 관리 효율 향상	비전 검사, 템플릿 매칭, 검사 자동화, 품질관리 효율
서상원 (2020)	하이브리드 CNN을 이용한 영상기반 부품 불량 검출 시스템 설계	부품 인식 모델과 불량검출 모델을 융합한 모델 사용, 성능을 위해 데이터 증강	- 민감도와 특이도 측정을 통해 우수한 성능 확인 - 저비용 고효율의 장치 구성 가능성 제시	머신비전, 딥러닝, Faster R-CNN, 하이브리드, 불량 검출
양홍모 (2020)	머신비전과 딥러닝 기법을 결합한 새로운 LED 조명등 평판방열장치 검사 방법	규칙 기반 알고리즘으로 이미지 전처리 작업 후 생산 정보화 알고리즘을 적용	- 기존 육안 검사 대비 정밀한 자동 검사 가능 - 검사 자동화로 인해 불량률 6%에서 2%로 감소 및 생산성 향상	머신비전, 딥러닝, CNN, 불량 검출, 검사 자동화

연구자	연구주제	연구방법	연구결과	주제어
하승재 (2021)	반도체 장비 센서 데이터와 딥러닝을 활용한 불량예측모델에 관한 연구	동일 PCB 제조 공정 설비에서 수집된 센서 데이터 활용, 지도 학습 기반 모델 설계	- 딥러닝 예측 모델이 전통 FDC보다 정확도, 정밀도, 재현율, F1-score에서 우수함 확인 - 센서 기준을 운영자 없이 자동으로 설정	센서 데이터, 딥러닝, 불량예측모델, PCB 제조
김용민 (2022)	자동차 부품 사출제조공정의 AI 기반 Vision 불량 검출 연구	YOLOv5, Mask R-CNN, SSD 모델로 각각 학습 후 비교	- YOLOv5 모델은 Mask R-CNN 모델과 비슷한 정확도와 2배 빠른 처리속도를 보임	YOLOv5, 자동차 부품, 성능 비교, 머신비전
조춘묵 (2022)	인공지능을 이용한 실시간 튜브 결함 검출 시스템 개발	튜브 표면 결함 검출을 위해 YOLOv5 모델을 적용하여 학습 진행, 데이터 증강으로 데이터 품질을 개선함	- YOLOv5 기반 결함 검출 모델이 육안 검사보다 우수한 성능을 확인함 - K-fold 교차 검증 및 mAP 평가 결과, 일관성 있고 신뢰성 높은 결함 검출이 가능함을 증명함	인공지능, 객체 인식, YOLOv5, 결함 검출
하정혁 (2022)	딥러닝을 이용한 초소형 전지 제조 공정을 위한 비전 검사	CNN 모델을 이용해 레이저 결함 공정 불량탐지 학습, 데이터 증강	- Convolution Layer 6개와 Max Pooling Layer 5개를 사용하는 CNN 모델로 학습하여 98% 정확도 기록	딥러닝, CNN, 전지, 레이저 결함, 비전검사
김진 (2023)	자동차 커버 렌즈 공정에서 One-Class CNN 적용 불량 검출	One-Class CNN을 적용하여 정상 데이터를 학습하고, 데이터 전처리를 수행한 후 검증을 통해 모델 학습 진행	- 다양한 조명 조건에서 데이터를 수집하고 분석하여 최적의 촬영 조건 설정 - One-Class CNN을 적용한 결과, 기존 방법보다 효율성과 정밀도가 향상됨	자동차 커버 렌즈, 불량 검출, 검사 시스템, One-Class CNN

연구자	연구주제	연구방법	연구결과	주제어
우상진 (2023)	YOLOv5를 이용한 PCB 불량 검출	YOLOv5의 다양한 모델 성능을 비교, 컬러 이미지와 흑백 이미지로 성능 비교	- 가장 좋은 성능의 YOLOv5x 모델이 mAP 98.4%를 기록함 - 흑백 이미지 사용 시 추론 속도 향상	인공지능, 객체 검출, YOLOv5, PCB 불량 검사, 딥러닝, 결함 탐지
이민균 (2023)	YOLO 개선을 통한 PCB 불량 검출 시스템 설계 및 구현	YOLOv5 모델에 coutout 기법과 Pruning 기법을 적용하여 기존 모델과 성능 비교	- pruning 기법을 적용해 모델이 32%경량화 되고 성능은 약 5% 정도 하락 - fine tuning을 통해 복구하여 기존 모델 보다 좋은 성능을 가지면서 경량화 됨	YOLO, PCB 불량 검출, Image augmentation, 경량화, fine tuning
이재승 (2023)	EGR쿨러 제조 공정의 불량량 예측 모델의 성능 분석	불균형 데이터에 대해 ENN 기반 언더샘플링 적용, 모델의 차원 축소 전과 후 성능 비교	- 차원 축소 후 모델의 정밀도 향상 됨 - Tree 기반 모델은 재현율과 F1-score까지 향상 됨	불균형 데이터, 언더샘플링, XGBoost, 차원 축소, 예측 성능 평가
최낙훈 (2023)	자동차 내장 부품 제조공정의 불량 예측 모델에 관한 연구	ANN과 CNN 모델을 적용하여 학습 후 비교, Cutout 기법을 사용한 데이터 증강, 하이퍼 파라미터 최적화	- CNN이 ANN보다 우수한 성능을 보임 - 데이터양이 많을수록 성능이 향상되지만 자원 소모도 증가하기 때문에 성능과 효율 사이의 균형이 필요함을 확인	데이터 증강, Cutout, Over Sampling, CNN, 성능과 효율의 균형
강광훈 (2024)	인공지능 비전을 이용한 자동차 조립 불량 검출 시스템 설계 및 구축	자동차 부품 조립 상태 판별 모델을 설계 및 학습, 학습 이미지 수 증가에 따른 모델 성능 변화 실험	- 학습 이미지가 증가할수록 정확도 향상 - Precision 기반 계산에서 2% 미만의 false positive 비율 달성 - 품질 보증 및 작업 정확도 개선을 실현	딥러닝, 스마트 팩토리, 자동차 조립, Neuro-T Tool, Precision & Recall

연구자	연구주제	연구방법	연구결과	주제어
김희범 (2024)	이차전지 제조에서 YOLO 기반의 불량 검출 시스템 개발	YOLOv5 모델과 YOLOv8 모델 분석, 모델의 하이퍼 파라미터 조정하여 비교, 최적화	- 하이퍼 파라미터 조절 후 기존의 하이퍼 파라미터로 학습한 모델 보다 성능 향상을 보임	하이퍼 파라미터, YOLO, 불량탐지, 이차전지
유익수 (2024)	머신러닝 기법을 활용한 MCT 가공 제품의 품질 예측 모델 개발	ML 지도학습 모델 8종 비교, 정밀도, 재현율, F1-점수, AUC를 기준으로 성능 평가	- Stacking Ensemble 모델은 정밀도, 재현율, F1-점수, AUC에서 우수한 성능을 보임	지도학습, MCT 가공, 정밀도,
이동열 (2024)	PCB 제조 산업 예지 보전 시스템 구축 연구	센서 기반 데이터 수집, PCB 제조 설비에 실제 센서 부착 및 테스트베드 운영	- 설비 가동률 증가 - 고장 예측 정확도 향상으로 비정상 상황 조기 탐지 성공 - 정비 시간·비용 절감 가능성 제시	머신러닝, 데이터 전처리, PCB 제조, 예지 보전
이승호 (2024)	YOLO 알고리즘을 이용한 토마토 객체탐지 연구	딥러닝 기반 객체 탐지 모델 구축, 인력투입 시기 조절, 토마토 생산량 확대	- 정규화기법(Dropout, Weight Decay → 정밀도 향상) - 성능 지표 재현율 (Recall → 모델 세밀화, R값 향상) - 향후 스마트팜 도입 시 운영비용 절감 효과	객체인식 알고리즘, YOLO, 딥러닝, 데이터셋
이해구 (2024)	딥러닝 기반 반도체 Packaging공정 비전 검사 정확도 향상 연구	여러 가지 딥러닝 모델을 활용하여 모델 학습 후 비교, 데이터 증강 전과 후 비교	- 데이터 증강 후 모델의 Recall, F1-Score, Precision의 향상된 점수 확인	데이터 증강, F1-Score, Precision

박창업(2019)는 자동차 힌지 브라켓의 용접너트 누락 방지를 위한 비전 검사 시스템을 개발하였으며 템플릿 정합 알고리즘과 유사 척도 매칭 알고리

즘을 적용한 자동화 시스템을 구축하여 검사 정확도를 98%로 향상시키고 불량률을 50% 감소시켰다. 이를 통해 육안 검사 대비 생산성 향상과 품질 관리 효율성을 개선하였다.

서상원(2020)은 영상기반 비전 시스템에서 CNN 모델을 순차적으로 적용하는 하이브리드 CNN을 사용하여 부품의 불량을 검출하였으며 민감도와 특이도 측정을 통해 우수한 성능 확인하였고 저비용 고효율의 장치 구성 가능성을 제시하였다.

양홍모(2020)는 머신비전과 딥러닝 기법을 결합한 새로운 LED 조명등 평판방열장치 검사방법을 연구하였으며 규칙 기반 알고리즘과 딥러닝 CNN 알고리즘을 연계한 생산정보화 알고리즘을 적용한 자동화 시스템 구축을 통해 충전량 편차를 66% 개선하고 불량률을 6%에서 2%로 감소시켰다.

하승재(2021)는 반도체 장비의 센서 데이터를 활용하여 불량을 사전에 예측하는 딥러닝 모델을 개발하고 기존 FDC 시스템과의 성능을 비교하였다. 기준 임계값을 자동으로 설정하는 기능을 개발하고 모델의 정확도, 정밀도, 재현율 등의 지표에서 우수한 성능을 보였다.

김용민(2022)은 자동차 부품 사출제조공정 불량검출 연구에서 머신비전 센서로 촬영한 데이터를 YOLOv5, Mask R-CNN, SSD 모델로 각각 학습한 후 비교 분석하였으며 YOLOv5 모델이 Mask R-CNN 모델과 SSD 모델보다 더 빠른 처리속도와 더 높은 정확도를 기록했다.

조준묵(2022)은 튜브 표면 결함 검출을 위해 YOLOv5 모델을 적용하여 학습 진행하였으며 데이터 증강을 사용하여 학습 데이터 품질을 개선하여 학습된 모델이 기존 육안 검사보다 우수하고 높은 정확도와 신뢰도를 가지고 있음을 확인하였다.

하정혁(2022)은 딥러닝을 이용한 초소형전지 제조 공정의 비전 검사 연구를 수행하였으며 Data Augmentation과 노이즈 및 이미지 시프트 기능을 활용하여 데이터를 증강한 CNN 모델을 학습하여 98%의 정확도를 기록하였다.

김진(2023)은 자동차 커버 렌즈 공정에서 One-Class CNN을 적용하여 불량을 검출하는 연구를 수행하였으며 픽셀 단위의 불량 검출하고 높은 정확도로 불량 감지에 성공하여 기존 방법보다 효율성과 정밀도가 향상됨을 확인

하였다.

우상진(2023)은 YOLOv5의 다양한 모델(n, s, m, l, x) 성능을 비교하여 가장 좋은 성능의 YOLOv5x 모델로 그레이스케일 이미지 학습 시 mAP 98.4%를 기록하였으며 그레이스케일 이미지 사용 시 데이터 크기 감소, 추론 속도 향상을 확인하였다.

이민균(2023)은 YOLOv5 모델에 cutout 기법과 Pruning 기법을 적용하고 fine tuning 기법을 통해 학습된 모델을 기존 모델과 성능을 비교하였으며 YOLOv5 기본 모델보다 좋은 성능을 유지하면서도 모델을 경량화할 수 있음을 확인하였다.

이재승(2023)은 불균형 데이터에 대해 ENN 기반 언더샘플링을 적용하였고 차원 축소 전에 학습한 모델과 차원 축소 후에 학습한 모델을 서로 비교하여 차원 축소 후의 모델이 정밀도가 향상됨을 확인하였다.

최낙훈(2023)은 자동차 내장 부품 불량 예측 연구에서 데이터 증강, 하이퍼 파라미터 최적화 기법을 사용해 ANN과 CNN 모델을 학습하고 비교하여 데이터의 양이 많을수록 성능이 향상되지만 자원 소모도 증가하기 때문에 성능과 효율 사이의 균형이 필요함을 확인

강광훈(2024)은 Neuro-T/R 를 사용하여 자동차 부품 조립 상태 판별 모델을 설계 및 학습하고 학습에 사용되는 이미지 수 증가에 따른 모델 성능 변화를 실험하여 이미지가 증가할수록 모델의 정확도가 향상됨을 확인하였다.

유익수(2024)는 MCT 가공 공정에서 발생할 수 있는 불량을 예측하기 위해 머신러닝 기반 지도학습 모델 8종을 비교 분석하여 Stacking Ensemble 모델이 가장 우수한 예측 성능과 빠른 학습 속도를 보여 품질 관리 자동화의 가능성을 확인하였다.

이동열(2024)은 PCB 제조 설비에 센서 기반 데이터를 수집하고 이를 활용한 예지 보전 시스템을 구축하여 장비 고장 및 공정 이상을 사전에 감지하였다. 딥러닝 기반 예측 모델을 적용한 결과 설비 가동률 향상과 유지보수 효율 개선에 효과가 있음을 입증하였다.

김희범(2024)은 이차전지 제조에서 YOLO 기반의 불량 검출 시스템을 개발하기 위해 YOLOv5 모델과 YOLOv8 모델을 분석하고, 모델의 하이퍼 파

라미터를 조정하여 성능을 비교·최적화하여 기존의 하이퍼 파라미터로 학습한 모델보다 성능이 향상시켰다.

이승호(2024)는 YOLOv8 알고리즘을 활용하여 토마토 객체 탐지 모델을 개발하였다. 정규화 기법을 적용하여 모델의 정밀도를 향상시켰으며 재현율 (Recall) 기반 성능 분석을 통해 객체 탐지의 세밀성을 개선하였다. 이를 통해 인력 투입 시기를 효율적으로 조절할 수 있게 되었으며 생산량 증가에도 도움이 되었다.

이해구(2024)는 이미지 데이터의 증강과 CNN, ResNet 등의 딥러닝 알고리즘과 JPEG Coefficient 필터, Gabor 필터 등을 사용하여 학습시킨 모델을 비교하였다. 데이터 증강 후 모델의 Recall, F1-Score, Precision의 향상된 점수를 확인하였다.

이러한 선행연구들은 자동화된 불량 검출 시스템의 중요성과 다양한 접근 방식을 제시하고 있고, 초기 알고리즘 기반 자동화 시스템 연구로부터 인공지능 적용 자동화 시스템 연구로 발전하고 있다.

2.4.2 해외 선행연구 분석

해외의 선행연구들을 아래 [표 2-10]과 같이 정리하였다. 선행연구들에서 객체 탐지(Object Detection)와 관련된 다양한 연구가 진행되어 왔음을 확인할 수 있다. 이러한 연구들은 주로 기존 방식과의 비교, 모델 성능 비교, 그리고 전반적인 시스템에 대한 적용 가능성에 초점을 맞추고 있다.

[표 2-10] 해외 선행연구 분석 (연구자 재구성, 2025)

연구자	연구주제	연구방법	연구결과	주제어
Schmidt-Erfurt et al. (2018)	인공지능(AI)을 활용하여 망막 질환의 진단 및 예후 평가	딥러닝, 머신러닝, 패턴 인식, 영상 처리 기술이 망막 진단에 어떻게 적용되었는지 분류 및 정리, 모델 평가 지표(정확도, 민감도, 특이도)와 임상적 유용성 분석	- AI는 망막 질환(예: 황반변성, 당뇨병성 망막병증 등)에서 조기 진단 및 치료 계획 수립에 큰 기여 - 자동화된 병변 탐지와 예후 예측에서 우수한 성능 입증 - 임상 환경에서 AI 기술 도입을 위한 장벽과 해결 과제(데이터 품질, 규제, 윤리 등) 논의	Artificial Intelligence (AI), 망막 질환, 딥러닝, 의학 영상, 진단
Yang et al. (2020)	스마트 제조 환경에서 딥러닝 기반의 결함 탐지 기술	결함을 유형별로 분류하고 분석, 주요 딥러닝 모델의 장단점 정리, 기존 탐지 기술과 딥러닝 기반 탐지 기술 비교	- 딥러닝 탐지 기술의 높은 정확도와 효율성, 소형 객체 탐지 성능 확인 - 스마트 제조 환경에서의 자동화 및 품질 향상을 위해 딥러닝 기반 결함 탐지 기술의 도입이 필수적임을 강조	딥러닝, 결함 탐지, 품질 관리, 스마트 제조, 머신 비전
Park et al. (2022)	스마트 제조 환경에서 딥러닝을 활용한 불량 결함 검출 기술 개발	제조 공정에서 수집된 이미지로 CNN 기반 불량 검출 모델 설계 및 학습	- Precision, Recall, F1-score 등 다양한 지표로 모델 성능 검증 결과 높은 정확도와 신뢰도를 보임 - 스마트 제조 시스템에 적합한 실시간 불량 감지 가능성을 확인	딥러닝, 객체 탐지, 스마트 제조, CNN, 품질관리

연구자	연구주제	연구방법	연구결과	주제어
Zhou et al. (2022)	산업 제조 시스템에서의 컴퓨터 비전 기술	특징 검출, 객체/패턴 인식, 이미지 분할, 3D 모델링 등 정리, 제조 환경 프레임워크 분석	- 라벨링, 전처리 자동화 미비, 벤치마크 데이터셋의 부족, 특화 모델 부족 확인 - 비라벨 데이터 처리를 위한 무지도 학습, 산업 특화 CV 모델 개발, 5G 기반 실시간 의사결정 시스템 구현 가능성 제시	컴퓨터 비전, 산업 제조 시스템, 데이터처리, 라벨링
Hussain, M. (2023)	스마트 제조 및 산업 결함 탐지 분야에서의 YOLO 모델	YOLO 모델의 각 버전의 비교, 실제 산업 현장의 결함 탐지 사례 분석, YOLO 버전별 성능 지표 비교 효율성, 효과성 평가	- 각 버전은 실시간 탐지 성능 향상, 정확도 개선, 모델 경량화 등 산업 환경에 적합한 방향으로 발전 - YOLO 모델은 제한된 리소스를 가진 엣지 장치에서도 효율적으로 동작하며 다양한 산업 분야에 활용 가능	YOLO, 객체 탐지, 스마트 제조, 엣지 컴퓨팅
Raimundo et al. (2023)	MRI에서 유방암을 발견하기 위한 혁신적인 Faster R-CNN 기반 프레임워크 개발	Faster R-CNN 최적화하여 검출 정확도 개선, 유방암 검출을 위해 MRI 이미지 데이터셋 활용, 객체 탐지 방식으로 병변 위치와 종류를 동시에 탐지	- 제안한 모델이 유방암 병변 탐지에서 높은 정확도 및 신뢰성 달성 - MRI 영상에서 다양한 크기와 모양의 병변에 대해 효과적 탐지 가능 - 임상 진단 지원에 활용할 수 있는 가능성 시사	유방암 탐지, Faster R-CNN, MRI, 딥러닝, 객체 탐지, 의학 영상
Choi et al. (2025)	Faster R-CNN을 사용한 산불 감지	Swin Transformer와 결합하여 이미지 내 지역별 특징을 효과적으로 추출, 영역 제안 방식 최적화, 산불 이미지 데이터셋을 구축 및 활용하여 모델 학습 및 평가 수행	- 기존 Faster R-CNN 대비 탐지 정확도와 견고성 향상 - 다중 클래스 산불 탐지에서 높은 성능과 안정적인 결과 도출 - 산불 관리 및 조기 경보 시스템에 활용 가능성 확인 - 실시간 또는 준실시간 탐지 응용에 적합한 모델 제안	Faster R-CNN, Swin Transformer, 객체 탐지, 산불 감지, 컴퓨터 비전

Schmidt-Erfurt et al. (2018)는 인공지능(AI)을 활용한 망막 질환 관련 연구에서 진단 및 예후 평가 방법과 임상 적용 가능성을 종합적으로 분석하여 딥러닝, 머신러닝, 패턴 인식, 영상 처리 기술이 망막 진단에 어떻게 적용되었는지 분류 및 정리하였다. AI가 망막 질환에서 병변 탐지와 예후 예측에서 우수한 성능을 보여 조기 진단 및 치료 계획 수립에 크게 기여할 수 있음을 확인하였으며 이후 데이터 품질, 규제, 윤리 등 논의의 필요성을 강조하였다.

Yang et al. (2020)은 스마트 제조 환경의 딥러닝 기반의 결함 탐지 기술에 관한 연구에서 주요 딥러닝 모델의 장단점을 정리하여 기존 탐지 기술과 딥러닝 기반 탐지 기술 비교하였다. 딥러닝 탐지 기술의 높은 정확도와 효율성, 다양한 배경에서의 소형 객체 탐지 성능을 확인하였고 스마트 제조 환경에서의 자동화 및 품질 향상을 위해 딥러닝 기반 결함 탐지 기술의 도입이 필수적임을 강조하였다.

Park et al. (2022)은 스마트 제조 환경에서 딥러닝을 활용한 불량 결함 검출 기술 개발 연구에서 제조 공정에서 수집된 이미지를 활용하여 CNN 기반으로 모델을 설계하고 학습시켰다. Precision과 Recall, F1-score 등 다양한 지표로 모델 성능을 검증한 결과 높은 정확도와 신뢰도를 보여 스마트 제조 시스템에 적합한 실시간 불량 감지 가능성을 확인하였다.


Zhou et al. (2022)는 산업 제조 시스템에서의 컴퓨터 비전 기술 연구에서 대표 컴퓨터 비전 기술인 특징 검출, 객체 인식, 패턴 인식, 이미지 분할, 3D 모델링 등을 정리하고 제조 환경 프레임워크를 분석하였다. 제조 현장에 적용할 때 데이터 라벨링, 전처리 자동화, 벤치마크 데이터셋의 확보의 중요성을 강조하였으며 비라벨 데이터 처리를 위한 무지도 학습, 산업 특화 컴퓨터 비전 모델 개발의 필요성을 강조하고 5G 기반 실시간 의사결정 시스템 구현 가능성 제시하였다.

Hussain(2023)은 YOLO 모델의 각 버전의 구조적 발전과 특징을 비교하고 실제 산업 현장의 결함 탐지 사례 분석하였다. YOLO 버전별 성능 지표 비교와 효율성, 효과성을 평가하여 각 버전은 실시간 탐지 성능 향상, 정확도 개선, 모델 경량화 등 산업 환경에 적합한 방향으로 발전해왔음을 확인하였

다. 또한 YOLO 모델은 제한된 리소스를 가진 엣지 장치에서도 효율적으로 동작하며 다양한 산업 분야에서의 결함 탐지에 활용할 수 있음을 확인하였다.

Raimundo et al. (2023)는 MRI 이미지에서의 유방암 발견을 위한 Faster R-CNN 기반 모델 개발 연구에서 Faster R-CNN을 최적화하여 검출 정확도 개선하고 병변 위치와 종류를 동시에 탐지하였으며 제안한 모델이 MRI 영상에서의 유방암 병변 탐지에서 높은 정확도 및 신뢰성 달성하여 임상 진단 지원에 활용할 수 있는 가능성을 제시하였다.


Choi et al. (2025)는 Faster R-CNN을 사용한 산불 감지 연구에서 Faster R-CNN과 Swin Transformer를 결합하여 이미지 내 지역별 특징을 효과적으로 추출하고 영역 제안 방식 최적화하였으며 산불 이미지 데이터셋을 구축하여 모델 학습 및 평가를 수행하였다. 기존 Faster R-CNN 대비 탐지 정확도와 견고성 향상을 확인하였으며 산불 관리 및 조기 경보 시스템에 활용 가능성을 제시하였다.



Ⅲ. 연구방법 및 결과

3.1 연구 환경 및 구성

본 연구에서는 부품 검사 시스템의 구축을 위해 데이터 수집, 모델 학습, 추론 과정으로 이루어진 연구 환경을 구성하였다.



[그림 3-1] 서버와 운영 PC의 Workflow (연구자 재구성, 2025)

[그림 3-1]과 같이 운영 PC에서 산업용 카메라를 사용해 자동차 부품의 이미지를 촬영하여 획득하고 운영 PC에 저장한다. 저장된 이미지 데이터들은 서버로 이동시킨 후 라벨링 프로그램인 CVAT에서 각각의 불량들로 라벨링 되어 모델학습용 데이터로 만들어진다. 생성된 라벨들은 원본의 이미지들과 함께 서버의 GPU에서 모델 학습에 사용된다. 서버에서 학습된 모델은 다시 운영 PC로 배포되며 실시간으로 부품의 불량을 탐지하는 데 사용되고 검사

결과를 출력할 수 있다.

[그림 3-2]의 연구 환경 구성도에 제시된 바와 같이 서버시스템과 운영시스템으로 연계하여 운영하게 된다. 서버 시스템은 라벨링을 할 수 있는 툴인 CVAT과 이미지 데이터, 라벨 데이터로 구성되어 있고 운영 시스템에는 자동차 부품을 촬영할 수 있는 카메라와 부품의 불량 상태를 탐지할 수 있는 AI 모델, 부품의 탐지 결과가 저장되는 Database로 구성 되어있다.



[그림 3-2] 연구 환경 아키텍처 (연구자 재구성, 2025)

3.1.1 데이터 수집 장치

불량을 탐지할 제품 특성상 상부, 하부, 측면 모두에서 카메라로 촬영하여 검사를 진행하기 때문에 여러 대의 카메라 필요하다. 상부 촬영용 카메라 1대, 하부 촬영용 카메라 1대, 측면 상단 촬영용 카메라 1대, 측면 하단 촬영용 1대로 구성하였다.

[표 3-1] Basler사의 카메라 사양 (Basler, 2018)

항목	세부 규격	
모델명	acA1440-220uc	acA1920-40uc
외관		
센서	Sony IMX273 CMOS	Sony IMX249 CMOS
해상도	1440 x 1080 픽셀 (1.6 메가 픽셀)	1920 x 1200 픽셀 (2.3 메가 픽셀)
픽셀 크기	3.45 μm x 3.45 μm	5.86 μm x 5.86 μm
프레임 속도	최대 227 fps	최대 41 fps
인터페이스	USB 3.0	USB 3.0
운영 체제	Windows, Linux	Windows, Linux
적용	○	

연구에 활용된 카메라는 위의 [표 3-1]과 같이 최소 1.6메가 픽셀의 해상도를 가지면서 프레임 속도가 높은 제품으로 적용하였다. 회전하는 물체를 촬영하는 과정에서 정확한 이미지를 얻을 수 있도록 프레임 속도가 높은 모델을 우선적으로 선정하였다.

[표 3-2] Basler사의 렌즈 사양 (Basler, 2018)

항목	세부 규격	
모델명	C125-0418-5M f4mm	C125-1218-5M f12mm
외관		
마운트	C-mount	C-mount
유형	고정 초점 렌즈	고정 초점 렌즈
초점거리	4mm	12mm
아이리스	F1.8 - F22	F1.8 - F22
픽셀 피치	2.2 μm	2.2 μm
작업 거리	100mm	200 mm
센서 형식	1/2.5"	1/2.5"
적용	○	

연구에 활용된 렌즈는 위의 [표 3-2]와 같이 1/2.5"의 센서 형식을 가지면서 작업거리가 짧은 제품으로 적용하였다. acA1440-220u 카메라에 적용할 수 있는 C-mount를 갖고 있으면서 작업 거리가 짧아 공간 활용도가 비교적 높아 기구 설비의 유연성을 제공할 수 있는 제품을 적용하였다.

3.1.2 서버 및 운영 PC 구성

본 연구에서 학습용 서버는 모델 학습 시에 대량의 이미지 데이터를 로딩하고 처리할 수 있도록 충분한 메모리를 적용하였고 학습이 효율적으로 진행될 수 있도록 고성능의 GPU를 사용하였다. 그리고 운영 PC 사양은 다음 [표 3-3]과 같다. 모델 추론을 위해 CUDA를 지원하는 GPU와 연산 이외에 다중 작업에 유리하도록 높은 용량의 메모리가 필요하며 빠른 데이터 입출력을 위한 SSD와 CUDA 지원 환경에 적합한 ubuntu OS가 요구된다.

[표 3-3] 학습용 서버와 운영 PC의 사양 (연구자 재구성, 2025)

항목	Server	Operating
CPU	AMD Ryzen Threadripper PRO 5955WX	Intel® Core™ i7 processor 14700K
Memory	DDR4 256GB	DDR4 32GB
GPU	GeForce RTX4090	GeForce RTX4060
스토리지	SSD 2TB	SSD 1TB
OS	ubuntu 22.04.3 LTS	ubuntu 22.04.3 LTS
cuda version	12.3	12.3

3.1.3 데이터 라벨링 툴


이미지를 라벨링 하기 위한 어노테이션 툴로 CVAT(Computer Vision Annotation Tool)을 사용하였다. CVAT은 Intel사에서 개발한 오픈소스 웹 기반 주석 도구이다. 영상 및 이미지 데이터에 대해 바운딩 박스, 폴리곤, 키 포인트 등의 다양한 형태의 주석을 지원한다. 본 도구는 객체 탐지, 분할, 추적 등 컴퓨터 비전 과제에 필요한 학습 데이터를 생성하는 데 활용되며 다중 사용자 협업, 자동 주석 기능, 다양한 데이터 포맷(YOLO, COCO 등) 내보내기를 지원하여 대규모 데이터셋 구축에 적합하다. 웹서비스로 제공되는 온라인 버전은 사용에 제약이 많아 로컬 스토리지에 설치하여 라벨링에 활용하였다. 사용한 CVAT 버전은 [표 3-4]와 같다.

[표 3-4] 어노테이션 툴 CVAT의 환경 (연구자 재구성, 2025)

버전 종류	버전
Server version	2.7.0
Core version	11.0.3
Canvas version	2.17.4
UI version	1.55.4

3.1.4 불량 검출 유형

서스펜션 부싱은 아래의 [그림 3-3]과 같이 서스펜션 암에 장착되는 자동차 부품의 한 종류이다. 서스펜션 부싱은 진동과 충격을 흡수하며 노면의 소음을 감소시키고 차량의 조향 안정성을 유지시키는 역할을 한다(Ambrósio & Verissimo, 2009).



[그림 3-3] 서스펜션 부싱 장착 부위 예시 (Ambrósio et al., 2009)

현재 부품에서 검사하는 불량 유형은 최근 10년 동안 발생한 불량 유형 중에서 빈도수가 높은 유형을 기준으로 선정하였다. 아래 [그림 3-4]는 본 연구의 불량검사를 위한 부품인 서스펜션 부싱의 양품 외관 상태를 보여준다.



[그림 3-4] 검사용 부품 양품 외관 예시 (aftermarket, 2025)

아래 [표 3-5]는 서스펜션 부싱의 불량상태별 외관 상태의 모습을 나타낸 예시이며 AI 모델은 외관 이미지에서 박스로 표시된 부분의 이상 유무를 분석하게 된다.

[표 3-5] 검사용 부품 불량 외관 예시 (연구자 재구성, 2025)

불량 상태	외관	불량 상태	외관
부트 말림		부트 찢어짐	
클램프링 꼬임		클램프링 유무	
O링 꼬임		O링 유무	
소켓 스크래치		필로우볼 찌힘	

[표 3-6]과 같이 불량 유형은 상단 9개 하단 8개로 총 17개이며 각 불량
은 1개 혹은 2개의 카메라에서 탐지를 실행한다.

[표 3-6] 검사 부품에서 발견되는 불량 유형

불량 위치	불량 명	탐지 카메라 배치
상단	부트 찢어짐	상부, 측면 상단
	부트 말림	측면 상단
	그리스 누유	상단, 측면 상단
	필로우볼 찌힘	상부
	클램프링 꼬임	측면 상단
	클램프링 유무	측면 상단
	O링 꼬임	측면 상단
	O링 유무	측면 상단
	소켓 스크래치	측면 상단
하단	부트 찢어짐	하부, 측면 하단
	부트 말림	측면 하단
	그리스 누유	하부, 측면 하단
	필로우볼 찌힘	하부
	클램프링 꼬임	측면 하단
	클램프링 유무	측면 하단
	O링 꼬임	측면 하단
	O링 유무	측면 하단

3.2 연구 결과 및 분석

3.2.1 데이터 수집

검사 환경의 빛의 세기나 방향, 카메라 각도와 초점 등의 환경 변화에 따른 모델 성능 하락을 방지하기 위해 실제로 사용될 검사 환경을 먼저 설정한 뒤에 데이터 수집을 진행하였다. 부품을 1번 촬영할 때 부품의 상부와 하부는 각각 1장씩 촬영하고 부품의 측면은 부품을 수평 방향으로 90° 씩 회전 시켜가며 촬영하여 측면 상단 카메라에서 4장, 측면 하단 카메라에서 4장의 이미지를 획득하여 부품 하나당 총 10장의 이미지를 획득하였다. 1개의 부품이라도 다양한 각도에서 촬영될 수 있도록 돌려가며 10번씩 촬영하였다. 촬영은 총 3회차 동안 진행되었으며 아래 [표 3-7]과 같이 1회차에는 각 불량 유형별로 부품을 12개씩 확보하여 총 204개, 2회차에는 1회차에서 충족하지 못한 13개 불량 유형의 부품들을 7개씩 확보하여 총 91개, 3회차에는 2회차에서 충족하지 못한 11개 불량 유형의 부품들을 4개씩 확보하여 총 44개의 데이터를 수집하였다. 따라서 수집한 이미지 데이터는 상단 16,950개, 하단 16,950개, 총 33,900개의 이미지 데이터를 수집하여 실증연구를 진행하였다.

[표 3-7] 수집한 이미지 데이터 수량

구분	촬영 위치	회차별 수량 (개)			촬영 위치별 수량 (개)	
		1차	2차	3차		
상단	상부	2,040	910	440	3,390	16,950
	좌측면	2,040	910	440	3,390	
	우측면	2,040	910	440	3,390	
	전면	2,040	910	440	3,390	
	후면	2,040	910	440	3,390	
하단	하부	2,040	910	440	3,390	16,950
	좌측면	2,040	910	440	3,390	
	우측면	2,040	910	440	3,390	
	전면	2,040	910	440	3,390	
	후면	2,040	910	440	3,390	
합계		20,400	9,100	4,400	33,900	33,900

김진(2023)의 연구와 같이 본 연구에서도 수집된 이미지에 대해 밝기 조절, 노이즈 제거, 히스토그램 평활화, CLAHE 알고리즘 등의 다양한 전처리 기법을 적용해 보았으나 오히려 모델의 성능이 저하되는 결과를 보여 최종적으로는 원본 이미지를 사용하는 방식으로 연구를 진행하였다.



3.2.2 데이터 수집 결과

총 3차례의 데이터 수집을 위한 기간을 두고 실증연구를 진행했으며 라벨링 결과 아래 [표 3-8]과 같이 총 8,713개의 라벨을 생성하였다.

[표 3-8] 작업 차수별 불량 라벨 수 (연구자 재구성, 2025)

불량 위치	불량 명	1차 (M)		2차 (M+1)		3차 (M+2)		라벨 수량 (합계)	
		라벨	충족률	라벨	충족률	라벨	충족률		
상단	부트 찢어짐	114	48.9%	66	77.3%	53	100%	233	4,583
	부트 말림	354	66.8%	115	88.5%	61	100%	530	
	그리스 누유	457	56.6%	245	87.0%	105	100%	807	
	필로우볼 찍힘	247	50.1%	187	88.0%	59	100%	493	
	클램프링 꼬임	177	55.3%	110	89.7%	33	100%	320	
	클램프링 유무	475	100%	-	-	-	-	475	
	오링 꼬임	200	50.0%	200	100%	-	-	400	
	오링 유무	476	100%	-	-	-	-	476	
	소켓 스크래치	447	52.7%	329	91.4%	73	100%	849	
하단	부트 찢어짐	219	37.2%	166	65.5%	203	100%	588	4,130
	부트 말림	335	69.4%	90	88.0%	58	100%	483	
	그리스 누유	320	56.0%	147	81.8%	104	100%	571	
	필로우볼 찍힘	245	41.1%	177	70.8%	174	100%	596	
	클램프링 꼬임	256	65.5%	83	86.7%	52	100%	391	
	클램프링 유무	418	100%	-	-	-	-	418	
	오링 꼬임	300	55.5%	241	100%	-	-	541	
	오링 유무	542	100%	-	-	-	-	542	
합계		5582	65%	2156	89.7%	975	100%	8,713	8,713

1차 라벨링 작업은 2024년 8월 4일 ~ 2025년 1월 5일 (약 5개월) 동안 진행되었으며 2차 라벨링 작업은 2025년 1월 6일 ~ 2월 25일 (약 2개월), 3

차 라벨링 작업은 2025년 2월 26일 ~ 3월 31일 (약 1개월) 동안 진행되었다. 1차 기간 중 평균 약 64.4% 충족률을 나타냈으며, 2차 기간 동안 평균 약 89% 충족률을 나타내었다. 3차 기간 동안 100%의 충족률을 나타내었다. 이를 통해 이미지 수가 증가할수록 모델 성능이 향상됨을 확인하였으며 이는 강광훈(2024)의 연구 결과와 동일한 경향을 보여준다.

서상원(2020), 이민균(2023), 이재승(2023), 조춘묵(2022), 하정혁(2022)의 연구에서 데이터 증강을 활용한 것처럼 본 연구에서도 데이터 증강을 고려하였으나 YOLOv10 모델의 기본 증강 기능으로도 충분한 성능이 확인되어 본 연구에서는 fliplr을 제외한 데이터 증강 관련 하이퍼 파라미터의 기본값만 사용하여 모델 학습을 진행하였다. 학습에 사용된 데이터 증강 관련 하이퍼 파라미터의 정보는 아래의 [표 3-9]와 같다.

[표 3-9] 데이터 증강 관련 하이퍼 파라미터 (연구자 재구성, 2025)

하이퍼 파라미터	수치
hsv_h	0.015
hsv_s	0.7
hsv_v	0.4
translate	0.1
scale	0.5
mosaic	1.0

YOLOv10m와 YOLOv10b 모델로 상부 카메라 모델, 하부 카메라 모델, 측면 상단 카메라 모델, 측면 하단 카메라 모델을 각각 학습시켜 총 8개의 모델을 만들어 평가했다. 모델 최적화를 위해 최낙훈(2023)의 연구에서와 같이 하이퍼 파라미터 조정을 하여 적용하였으며 해당 파라미터는 8개 모델 모두에 동일하게 적용되었다. 사용된 하이퍼 파라미터의 정보는 [표 3-10]과 같다.

[표 3-10] 모델 학습용 하이퍼 파라미터 (연구자 재구성, 2025)

하이퍼 파라미터	수치
Epoch	300
Batch size	16
Image size	640
fliplr	0.0
lr0	0.01
lrf	0.001

Batch size는 기본값인 16을 사용하고 Epoch는 300회를 사용했다. Image size는 모델의 성능을 위해 최대한 640을 사용하였고 방향성이 중요한 불량이 부품에 존재하기 때문에 이미지를 좌우 반전을 시켜 학습하게 하는 fliplr에 0.0을 사용하였다. 학습이 진행된 모델의 성능이 다시 낮아지는 것을 방지하기 위해 lrf를 0.001로 설정하여 학습을 진행하였다. 학습이 완료된 YOLOv10m의 상부, 하부, 측면 상단, 측면 하단 모델별 성능은 [표 3-11]과 같다.

[표 3-11] YOLOv10m 모델의 성능 (연구자 재구성, 2025)

모델	mAP@0.5	mAP@0.5:0.95
상부	0.995	0.953
하부	0.995	0.869
측면 상단	0.992	0.881
측면 하단	0.983	0.879

학습이 완료된 YOLOv10b의 상부, 하부, 측면 상단, 측면 하단 모델별 성능은 [표 3-12]와 같다.

[표 3-12] YOLOv10b 모델의 성능 (연구자 재구성, 2025)

모델	mAP@0.5	mAP@0.5:0.95
상부	0.994	0.960
하부	0.994	0.911
측면 상단	0.992	0.893
측면 하단	0.995	0.888

YOLOv10m 모델과 YOLOv10b 모델의 mAP@0.5 지표는 큰 차이 없이 서로 비슷한 결과를 나타냈지만, mAP@0.5:0.95 지표에서 상부 모델은 0.007, 하부 모델은 0.042, 측면 상단 모델은 0.012, 측면 하단 모델은 0.009의 성능 차이를 보여 YOLOv10b 모델이 YOLOv10m 모델에 비해 더 정밀하게 불량을 탐지하는 결과를 냈기 때문에 YOLOv10b 모델을 최종 모델로 선정하였다.

HANSUNG
UNIVERSITY

3.2.3 연구 결과 검증

모델 학습이 완료된 후 YOLOv10b 모델의 불량 탐지 성능을 실제 생산 환경과 유사한 환경에서 수집한 실증 데이터를 기반으로 검증하였다. 이미지 데이터셋은 상부, 하부, 측면 상단, 측면 하단에서 수집된 자동차 부품 이미지로 구성되었다. 검증 과정은 학습에 사용되지 않은 테스트 전용 이미지 데이터셋을 사용하여 진행함으로써 모델의 성능을 객관적으로 평가할 수 있도록 하였다. 테스트용 데이터셋의 불량 별 이미지 수량은 [표 3-13]과 같다.

[표 3-13] 테스트용 데이터셋 수량 (연구자 재구성, 2025)

불량 위치	불량 명	수량
상단	부트 찢어짐	20
	부트 말림	25
	그리스 누유	20
	필로우볼 찍힘	20
	클램프링 꼬임	30
	클램프링 유무	5
	O링 꼬임	10
	O링 유무	5
	소켓 스크래치	40
하단	부트 찢어짐	20
	부트 말림	25
	그리스 누유	10
	필로우볼 찍힘	30
	클램프링 꼬임	20
	클램프링 유무	5
	O링 꼬임	10
	O링 유무	5
양품		300

검증을 하기 위해 구현한 시스템은 Python 3.11로 작성하였으며 구현한

코드는 아래와 같다.

YOLO를 사용하고 이미지를 처리할 수 있도록 관련 라이브러리들을 불러온다.

```
import cv2
import torch
from ultralytics import YOLO
import math
import copy
import numpy as np
from PIL import Image, ImageDraw, ImageFont
```

학습된 모델을 사용할 수 있도록 각각 선언하고 추론에 사용되는 device를 cuda로 설정하여 추론할 때 cpu 대신 운영 PC에 장착된 GPU를 사용하도록 한다.

```
model_top = YOLO('models/top.pt')
model_bottom = YOLO('models/bottom.pt')
model_topside = YOLO('models/topside.pt')
model_bottomside = YOLO('models/bottomside.pt')

device = 'cuda' if torch.cuda.is_available() else 'cpu'

model_top.to(device)
model_bottom.to(device)
model_topside.to(device)
model_bottomside.to(device)
```

predict 함수를 통해 모델이 탐지하고 불량률의 정보를 가져와 draw_text 함수를 사용해 이미지에 바운딩 박스와 confidence 값을 그린다.

```
def predict(model_type, image_filename):
    source = image_filename
    img_image = copy.deepcopy(source)
    results = model(img_image)

    for box in results[0].boxes:
        data = box.data[0].cpu().numpy()
```

```

xyxy = data[:4].astype(int)
x1, y1, x2, y2 = xyxy[0], xyxy[1], xyxy[2], xyxy[3]
x, y, w, h = x1, y1, x2-x1, y2-y1
cls = data[5].astype(int)
conf = int(round(data[4], 2)*100)
cls_name = results[0].names[cls]
ng_image = draw_text(ng_image, cls_name, x, y, w, h,
conf=conf)

return ng_image

```

모델이 예측한 불량 범위의 x, y, width, height 값으로 바운딩 박스를 그리고 예측한 불량명과 confidence를 표시한다.

```

def draw_text(image, text, x, y, w, h, conf=0):
    image = cv2.cvtColor(image, cv2.COLOR_RGB2BGR)
    overlay = copy.deepcopy(image)

    if conf > 0:
        text = f"{text}({conf}%)"

    cv2.rectangle(image, (x, y), (x+w, y+h))
    cv2.rectangle(overlay, (x, y), (x+w, y+h))
    alpha = 0.2
    image_new = cv2.addWeighted(overlay, alpha, image, 1 - alpha, 0)

    cv2.rectangle(image_new, (x,y-text_h), (x + text_w + 4, y))

    pil_image = Image.fromarray(image_new)
    draw = ImageDraw.Draw(pil_image)
    draw.text((x+3, y-text_h ), text)
    final_image = cv2.cvtColor(np.array(pil_image), cv2.COLOR_RGB2BGR)

    return final_image

```

위의 코드로 수행된 테스트 결과는 아래의 [표 3-14]와 같다. 테스트용 데이터셋을 기반으로 하는 불량품 검사 결과를 볼 때 YOLOv10b 모델은 높은 정확도를 보였다. 전체 실증 테스트 이미지 600장 중 실제 불량 이미지 300개 모두를 정확히 탐지하였으며 이는 YOLOv10b 모델이 단순히 높은 mAP 수치를 기록한 것뿐만 아니라 실제 생산 공정에서 발생할 수 있는 다양

한 불량 상황에 대해서도 안정적으로 대응할 수 있다는 것을 보여준다.

[표 3-14] 불량품 검사 결과 (연구자 재구성, 2025)

불량 위치	불량 명	탐지 성공		탐지 실패	
		정탐	오탐	1차	2차(육안)
상단	부트 찢어짐	20		0	0
	부트 말림	25	3	0	0
	그리스 누유	20		0	0
	필로우볼 찍힘	20	3	0	0
	클램프링 꼬임	30		0	0
	클램프링 유무	5		0	0
	오링 꼬임	10		0	0
	오링 유무	5		0	0
	소켓 스크래치	40	9	0	0
하단	부트 찢어짐	20		0	0
	부트 말림	25		0	0
	그리스 누유	10		0	0
	필로우볼 찍힘	30	1	0	0
	클램프링 꼬임	20		0	0
	클램프링 유무	5		0	0
	오링 꼬임	10		0	0
	오링 유무	5		0	0

다만 [표 3-15]의 오탐 항목에서 확인할 수 있듯이 양품 이미지 300개 중 16개가 불량으로 잘못 분류되었다. 해당 이미지들은 대부분 필로우볼의 미세한 찍힘, 소켓 부위의 짧은 스크래치, 부트의 미세한 말림 등 비정형적이고 경미한 결함이었다. 육안으로는 양품과의 구별되는 차이가 존재하지만 그 정도가 불량 기준에는 미치지 못해 양품으로 분류되는 경우였다.

[표 3-15] 양품 검사 결과 중 오탐 비율 (연구자 재구성, 2025)

판정 결과	수량	전체 양품 대비 비율
양품	284	94.66%
불량	16	5.33%

오탐지된 항목의 세부 수량은 [표 3-16]과 같이 소켓 스크래치 9건, 필로우볼 찍힘 4건, 부트 말림 3건이었다. 오탐지된 결함들은 육안 검사에서는 양품으로 판단하는 경우였으며 이는 추가적인 학습 또는 후처리 알고리즘을 통해 개선될 가능성이 있다.

[표 3-16] 세부 오탐 비율 (연구자 재구성, 2025)

판정 결과	수량	전체 양품 대비 비율
소켓 스크래치	9	3%
필로우볼 찍힘	4	1.33%
부트 말림	3	1%

또한 모델의 평균 추론 시간은 약 5.7ms로 측정되었으며 이는 초당 약 175장의 이미지가 처리될 수 있는 속도로 생산 라인의 실시간 검사 요건을 충족시키기에 충분한 수준이다.

IV. 결 론

4.1 결론 및 시사점

본 연구에서는 딥러닝 기반 객체 탐지 모델인 YOLOv10을 활용하여 자동차 부품의 불량 여부를 자동으로 판별하는 비전 검사 시스템을 설계하고 구현하였다. 연구에 사용된 YOLOv10 모델은 Faster R-CNN과 MobileNet 등 다른 딥러닝 객체 탐지 모델에 비해 우수한 성능을 보임을 확인하였으며 제안된 시스템은 높은 정확도와 빠른 처리 속도를 바탕으로 기존의 수작업 중심 검사 방식을 효과적으로 대체할 수 있음을 확인하였다.

33,900장의 이미지와 8,713개의 라벨로 학습된 모델의 평균 정확도(mAP)는 mAP@0.5에서 0.994, mAP@0.5:0.95에서는 0.913을 기록하였으며 추론 시간은 약 5.7ms로 매우 빠른 실시간 처리가 가능함을 확인하였다. 본 연구에서 테스트 데이터셋으로 수행한 실증 테스트에서 YOLOv10b 모델은 600장의 테스트 이미지 중 300장의 실제 불량 이미지를 모두 정확히 탐지하여 우수한 탐지 성능을 나타냈으며 육안으로는 구별하기 힘든 경미한 손상도 민감하게 인식함을 확인하였다. 이는 단순한 수치적 평가를 넘어 실제 자동차 부품 생산 현장에서도 다양한 불량 상황에 안정적으로 대응할 수 있음을 의미한다.

또한 본 연구에서 개발된 비전 검사 시스템은 중소 제조업체의 품질 관리 효율성을 높일 수 있을 것이다. 검사 결과 데이터를 자동으로 데이터베이스에 저장하고 이상 상황 발생 시 자동으로 기록하는 구조를 도입하면 단순히 불량률을 줄이는 수준을 넘어서 생산 공정에서 문제가 발생하는 구체적인 위치를 확인하고 이를 개선하는 데 활용할 수 있을 것이다. 궁극적으로 제품의 일관된 품질 유지와 고객 신뢰도 향상에도 긍정적인 역할을 할 것으로 보이며 장기적으로는 제조 현장의 품질 경쟁력을 높이는 데에도 도움이 될 수 있다.

4.2 연구의 한계점 및 향후 연구 방향

본 연구의 실증 실험은 통제된 환경에서 수집된 이미지 데이터셋을 활용하여 수행되었기 때문에 실제 산업 현장에서 발생할 수 있는 조명 변화, 배경의 다양성, 부품의 배치 조건 등의 변수들에 대한 고려가 이루어지지 않은 한계가 존재하여 이후 실험에는 다양한 조명과 배경 환경에서 수집된 데이터를 학습에 활용함으로써 객체 탐지 모델이 실제 현장에서 제대로 작동할 수 있도록 해야 한다.

실험에 사용된 자동차 부품은 서스펜션 부싱이라는 특정 자동차 부품에 한정되어 있어 향후 다양한 부품이나 다른 분야의 제조 공정으로의 확장 가능성에 관한 후속 연구도 병행되어야 한다.

그리고 비전 검사 시스템과 실제 생산라인과 직접 연동된 실시간 불량 검사 환경에서의 실험이 포함되지 않았기 때문에 실제 제조 현장에서 모델이 안정적으로 작동하는지를 검증하는 절차 또한 필요하다. 이를 위해 실시간 처리 성능, 시스템 안정성, 유지보수 용이성 등 실용성 전반에 대한 종합적인 평가가 이루어져야 한다. 탐지율 및 오탐율에 대한 분석도 제한적으로 이루어졌기 때문에 모델의 신뢰도에 대해 보다 더 정밀한 평가가 요구된다. 특히 오탐율을 줄이기 위해 정밀한 하이퍼 파라미터 튜닝, 라벨링 오류 수정, 불량 이미지의 일관성 있는 데이터 구성 등 후처리 작업이 병행되어야 한다.

앞에서 제시된 연구 방향들이 충실히 반영되고 보완된다면 딥러닝 기반 비전 검사 기술은 단순한 결함 탐지를 넘어 제조 공정 전반의 품질 향상과 운영 효율성 제고에 실질적인 기여를 할 수 있을 것이다.

참 고 문 헌

1. 국내문헌

- 강광훈. (2024). 인공지능 비전을 이용한 자동차 조립 불량 검출 시스템 설계 및 구축. 부산대학교, 석사학위논문.
- 김용민. (2022). 자동차 부품 사출제조공정의 AI 기반 Vision 불량검출 연구. 한국공학대학교, 석사학위논문.
- 김진. (2023). 자동차 커버 렌즈 공정에서 One-Class CNN 적용 불량 검출. 건국대학교, 석사학위논문.
- 김희범. (2024). 이차전지 제조에서 YOLO 기반의 불량 검출 시스템 개발. 순천향대학교, 석사학위논문.
- 박창업. (2019). 자동차 힌지 브라켓의 용접너트 누락 방지를 위한 비전 검사 시스템 개발에 관한 연구. 공주대학교, 석사학위논문.
- 서상원. (2020). 하이브리드 CNN을 이용한 영상기반 부품 불량 검출 시스템 설계. 전북대학교, 박사학위논문.
- 양홍모. (2020). 머신비전과 딥러닝 기법을 결합한 새로운 LED 조명등 평판 방열장치 검사방법. 한밭대학교, 석사학위논문.
- 우상진. (2023). YOLOv5를 이용한 PCB 불량 검출. 충북대학교, 석사학위논문.
- 유익수. (2024). 머신러닝 기법을 활용한 MCT 가공 제품의 품질 예측 모델 개발에 대한 연구. 호서대학교, 박사학위논문.
- 이동열. (2024). PCB 제조 산업 예지보전 시스템 구축 연구. 한국공학대학교, 박사학위논문.
- 이민균. (2023). YOLO 개선을 통한 PCB 불량 검출 시스템 설계 및 구현. 한양대학교, 석사학위논문.

- 이재승. (2023). EGR쿨러 제조 공정의 불량 예측 모델의 성능 분석. 부산대학교, 석사학위논문.
- 이승현, 김락우, 정득영, & 박대현. (2022). ICT 기술을 적용한 농업분야의 연구 동향. 한국통신학회지 (정보와통신), 39(10), 3-12.
- 이승호. (2024). YOLO 알고리즘을 이용한 토마토 객체탐지 연구. 전주대학교, 석사학위논문.
- 이해구. (2024). 딥러닝 기반 반도체 Packaging공정 비전 검사 정확도 향상 연구. 호서대학교, 박사학위논문.
- 정동규. (2017). 인공지능 기술과 주요 적용 산업 동향. 한국정보기술학회지, 15(2), 21-28.
- 조춘묵. (2022). 인공지능을 이용한 실시간 튜브 결함 검출 시스템 개발. 강원대학교, 석사학위논문.
- 최낙훈. (2023). 자동차 내장 부품 제조공정의 불량 예측 모델에 관한 연구. 공주대학교, 석사학위논문.
- 하승재. (2021). 반도체 장비의 센서 데이터를 활용한 딥러닝 기반 불량 예측 모델에 관한 연구. 숭실대학교, 박사학위논문.
- 하정혁. (2022). 딥러닝을 이용한 초소형전지 제조 공정을 위한 비전 검사. 한국산업기술대학교, 석사학위논문.

2. 국외문헌

- Ambrósio, J., & Verissimo, P. (2009). Improved bushing models for general multibody systems and vehicle dynamics. *Multibody System Dynamics*, 22(4), 341–365.
- Binford, T. (1975). Visual perception by computer. In *Proc. IEEE Conf. on Systems and Control*, 1975.
- Buchanan, B. G., & Smith, R. G. (1988). Fundamentals of expert systems. *Annualreview of computer science*, 3(1), 23–58.
- Canny, J. (1986). A computational approach to edge detection. *IEEE Transactions on pattern analysis and machine intelligence*, (6), 679–698.
- Carion, N., Massa, F., Synnaeve, G., Usunier, N., Kirillov, A., & Zagoruyko, S. (2020, August). End-to-end object detection with transformers. In *European conference on computer vision* (pp. 213–229). Cham: Springer International Publishing.
- Cemenska, J., Rudberg, T., & Henscheid, M. (2015). Automated in-process inspection system for AFP machines. *SAE International Journal of Aerospace*, 8(2015-01-2608), 303–309.
- Chandola, V., Banerjee, A., & Kumar, V. (2009). Anomaly detection: A survey. *ACM computing surveys (CSUR)*, 41(3), 1–58.
- Choi, S., Kim, S., & Jung, H. (2025). Optimized Faster R-CNN with Swintransformer for Robust Multi-Class Wildfire Detection. *Fire*, 8(5), 180.
- Dodge, H. F. (1943). A sampling inspection plan for continuous production. *The Annals of mathematical statistics*, 14(3),

264–279.

- Everingham, M., Van Gool, L., Williams, C. K., Winn, J., & Zisserman, A. (2010). The pascal visual object classes (voc) challenge. *International journal of computer vision*, 88, 303–338.
- Girshick, R. (2015). Fast r-cnn. In *Proceedings of the IEEE international conference on computer vision* (pp. 1440–1448).
- Girshick, R., Donahue, J., Darrell, T., & Malik, J. (2014). Rich feature hierarchies for accurate object detection and semantic segmentation. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 580–587).
- Hinckley, C. M. (1997). Defining the best quality-control systems by design and inspection. *Clinical chemistry*, 43(5), 873–879.
- Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., ... & Adam, H. (2017). Mobilenets: Efficient convolutional neural networks for mobile vision applications. *arXiv preprint arXiv:1704.04861*.
- Howard, A., Sandler, M., Chu, G., Chen, L. C., Chen, B., Tan, M., ... & Adam, H. (2019). Searching for mobilenetv3. In *Proceedings of the IEEE/CVF international conference on computer vision* (pp. 1314–1324).
- Huang, C., Zhang, Z., Mao, B., & Yao, X. (2022). An overview of artificial intelligence ethics. *IEEE Transactions on Artificial Intelligence*, 4(4), 799–819.
- Hussain, M. (2023). YOLO-v1 to YOLO-v8, the rise of YOLO and its complementary nature toward digital manufacturing and industrial defect detection. *Machines*, 11(7), 677.

- Jamil, F., Iqbal, N., Ahmad, S., & Kim, D. H. (2020). Toward accurate position estimation using learning to prediction algorithm in indoor navigation. *Sensors*, 20(16), 4410.
- Kelly, S., Kaye, S. A., & Oviedo-Trespalacios, O. (2023). What factors contribute to the acceptance of artificial intelligence? A systematic review. *Telematics and Informatics*, 77, 101925.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *nature*, 521(7553), 436–444.
- Lin, T. Y., Dollár, P., Girshick, R., He, K., Hariharan, B., & Belongie, S. (2017). Feature pyramid networks for object detection. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 2117–2125).
- Malamas, E. N., Petrakis, E. G., Zervakis, M., Petit, L., & Legat, J. D. (2003). A survey on industrial vision systems, applications and tools. *Image and vision computing*, 21(2), 171–188.
- Miotto, R., Wang, F., Wang, S., Jiang, X., & Dudley, J. T. (2018). Deep learning for healthcare: review, opportunities and challenges. *Briefings in bioinformatics*, 19(6), 1236–1246.
- Oh, C., Lee, T., Kim, Y., Park, S., Kwon, S., & Suh, B. (2017, May). Us vs. them: Understanding artificial intelligence technophobia over the google deepmind challenge match. In *Proceedings of the 2017 CHI conference on human factors in computing systems* (pp. 2523–2534).
- Padilla, R., Passos, W. L., Dias, T. L., Netto, S. L., & Da Silva, E. A. (2021). A comparative analysis of object detection metrics with a companion open-source toolkit. *Electronics*, 10(3), 279.

- Pang, G., Shen, C., Cao, L., & Hengel, A. V. D. (2021). Deep learning for anomaly detection: A review. *ACM computing surveys (CSUR)*, 54(2), 1–38.
- Park, S. H., Lee, K. H., Park, J. S., & Shin, Y. S. (2022). Deep learning-based defect detection for sustainable smart manufacturing. *Sustainability*, 14(5), 2697.
- Patel, K. K., Kar, A., Jha, S. N., & Khan, M. A. (2012). Machine vision system: a tool for quality inspection of food and agricultural products. *Journal of food science and technology*, 49, 123–141.
- Piccinini, G. (2004). The First computational theory of mind and brain: a close look at mcculloch and pitts's "logical calculus of ideas immanent in nervous activity". *Synthese*, 141, 175–215.
- Qin, D., Leichner, C., Delakis, M., Fornoni, M., Luo, S., Yang, F., ... & Howard, A. (2024, September). MobileNetV4: universal models for the mobile ecosystem. In *European Conference on Computer Vision* (pp. 78–96). Cham: Springer Nature Switzerland.
- Rabbi, J., Ray, N., Schubert, M., Chowdhury, S., & Chao, D. (2020). Small-object detection in remote sensing images with end-to-end edge-enhanced GAN and object detector network. *Remote Sensing*, 12(9), 1432.
- Raimundo, J. N. C., Fontes, J. P. P., Gonzaga Mendes Magalhães, L., & Guevara Lopez, M. A. (2023). An innovative faster R-CNN-based framework for breast Cancer detection in MRI. *Journal of Imaging*, 9(9), 169.
- Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You only look once: Unified, real-time object detection. In *Proceedings of*

- the IEEE conference on computer vision and pattern recognition (pp. 779–788).
- Rousseeuw, P. J., & Hubert, M. (2011). Robust statistics for outlier detection. *Wiley interdisciplinary reviews: Data mining and knowledge discovery*, 1(1), 73–79.
- Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning representations by back-propagating errors. *nature*, 323(6088), 533–536.
- Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., & Chen, L. C. (2018). Mobilenetv2: Inverted residuals and linear bottlenecks. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 4510–4520).
- Sapkota, R., Flores–Calero, M., Qureshi, R., Badgujar, C., Nepal, U., Poullose, A., ... & Karkee, M. (2025). YOLO advances to its genesis: a decadal and comprehensive review of the You Only Look Once (YOLO) series. *Artificial Intelligence Review*, 58(9), 1–83.
- Schmidt–Erfurth, U., Sadeghipour, A., Gerendas, B. S., Waldstein, S. M., & Bogunović, H. (2018). Artificial intelligence in retina. *Progress in retinal and eye research*, 67, 1–29.
- See, J. E., Drury, C. G., Speed, A., Williams, A., & Khalandi, N. (2017, September). The role of visual inspection in the 21st century. In *Proceedings of the Human Factors and Ergonomics Society Annual Meeting* (Vol. 61, No. 1, pp. 262–266). Sage CA: Los Angeles, CA: SAGE Publications.
- Silver, D., Huang, A., Maddison, C. J., Guez, A., Sifre, L., Van Den

- Driessche, G., ... & Hassabis, D. (2016). Mastering the game of Go with deep neural networks and tree search. *nature*, 529(7587), 484–489.
- Silver, D., Schrittwieser, J., Simonyan, K., Antonoglou, I., Huang, A., Guez, A., ... & Hassabis, D. (2017). Mastering the game of go without human knowledge. *nature*, 550(7676), 354–359.
- Siva, P., Pujitha, G. B., Krishna, G. S., Hemanth, G., & Teja, B. M. S. (2025). Smart Surveillance Systems Using YOLOv8: A Scalable Approach for Crowd and Threat Detection. *International Journal of Recent Advances in Engineering and Technology*, 14(1), 51–62.
- Sokolova, M., & Lapalme, G. (2009). A systematic analysis of performance measures for classification tasks. *Information processing & management*, 45(4), 427–437.
- Stark, J. A. (2000). Adaptive image contrast enhancement using generalizations of histogram equalization. *IEEE Transactions on image processing*, 9(5), 889–896.
- Toosi, A., Bottino, A. G., Saboury, B., Siegel, E., & Rahmim, A. (2021). A brief history of AI: how to prevent another winter(a critical review). *PET clinics*, 16(4), 449–469.
- Ul Islam, R., Hossain, M. S., & Andersson, K. (2018). A novel anomaly detection algorithm for sensor data under uncertainty. *Soft Computing*, 22(5), 1623–1639.
- Urgo, M., Terkaj, W., & Simonetti, G. (2024). Monitoring manufacturing systems using AI: A method based on a digital factory twin to train CNNs on synthetic data. *CIRP Journal of Manufacturing Science and Technology*, 50, 249–268.

- Wang, A., Chen, H., Liu, L., Chen, K., Lin, Z., & Han, J. (2025). Yolov10: Real-time end-to-end object detection. *Advances in Neural Information Processing Systems*, 37, 107984–108011.
- Wang, B., Zhong, S., Lee, T. L., Fancey, K. S., & Mi, J. (2020). Non-destructive testing and evaluation of composite materials/structures: A state-of-the-art review. *Advances in mechanical engineering*, 12(4), 1687814020913761.
- Wang, Q., Wu, B., Zhu, P., Li, P., Zuo, W., & Hu, Q. (2020). ECA-Net: Efficient channel attention for deep convolutional neural networks. In *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition* (pp. 11534–11542).
- Yang, J., Li, S., Wang, Z., Dong, H., Wang, J., & Tang, S. (2020). Using deep learning to detect defects in manufacturing: a comprehensive survey and current challenges. *Materials*, 13(24), 5755.
- Young, T., Hazarika, D., Poria, S., & Cambria, E. (2018). Recent trends in deep learning based natural language processing. *IEEE Computational intelligence magazine*, 13(3), 55–75.
- Zhang, S., Yao, L., Sun, A., & Tay, Y. (2019). Deep learning based recommender system: A survey and new perspectives. *ACM computing surveys (CSUR)*, 52(1), 1–38.
- Zhou, L., Zhang, L., & Konz, N. (2022). Computer vision techniques in manufacturing. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 53(1), 105–117.

3. 정부기관 및 연구기관

대한상공회의소, 「국내기업 AI기술 활용 실태조사」, 2024.08.28. AI기술 주요 활용 분야.

중소기업중앙회, 「중소기업 기술 통계 조사」, 2024.12.31. 인공지능(AI) 기술도입 의향

한국산업기술진흥협회, 글로벌 제조업 AI 시장 동향 「기술과 혁신」, 2024.03



4. 기타 참고자료

ACA1440-220uc. (2018). Basler Product Documentation.

<https://docs.baslerweb.com/aca1440-220uc>

Babic, M., Farahani, M. A., & Wuest, T. (2021). Image based quality inspection in smart manufacturing systems: A literature review. *Procedia CIRP*, 103, 262-267.

Basler Lens C125-0418-5M-P. (2016). Basler Product Documentation.

<https://docs.baslerweb.com/c125-0418-5m-p>

Bostrom, N. (2016). The control problem. Excerpts from *superintelligence: Paths, dangers, strategies*. *Science Fiction and Philosophy: From Time Travel to Superintelligence*, 308-330.

Doshi-Velez, F., & Kim, B. (2017). Towards a rigorous science of interpretable machine learning. *arXiv preprint arXiv:1702.08608*.

Ferguson, M., Ak, R., Lee, Y. T. T., & Law, K. H. (2018). Detection and segmentation of manufacturing defects with convolutional neural networks and transfer learning. *Smart and sustainable manufacturing systems*, 2(1), 137-164.

Kamran, S. S., Haleem, A., Bahl, S., Javaid, M., Prakash, C., & Budhhi, D. (2022). Artificial intelligence and advanced materials in automotive industry: Potential applications and perspectives. *Materials Today: Proceedings*, 62, 4207-4214.

Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems*, 25.

Montgomery, D. C. (2020). *Introduction to statistical quality control*.

John wiley & sons.

Mounting, control/trailing arm. (2025). aftermarket.

<https://aftermarket.zf.com/en/catalog/products/13208%2001/?country=KR>

Ray, P. P. (2023). ChatGPT: A comprehensive review on background, applications, key challenges, bias, ethics, limitations and future scope. *Internet of Things and Cyber-Physical Systems*, 3, 121–154.

Ren, S., He, K., Girshick, R., & Sun, J. (2015). Faster r-cnn: Towards real-time object detection with region proposal networks. *Advances in neural information processing systems*, 28.

Rojas, R. (1996). The backpropagation algorithm. *Neural networks: a systematic introduction*, 149–182.

Simonyan, K., & Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*.

Tan, C. F. (2008). An Expert Fault Diagnosis System for Auto Wire Bond Machine. *Jurnal Teknologi (Sciences & Engineering)*, 55–73.

van den Herik, H. J. (2019). Computer chess: From idea to DeepMind. *ICGA Journal*, 40(3), 160–176.

YOLOv10: Real-Time End-to-End Object Detection. (2024). Ultralytics. <https://docs.ultralytics.com/models/yolov10/#performance>

Yu, J., Jiang, Y., Wang, Z., Cao, Z., & Huang, T. (2016, October). Unitbox: An advanced object detection network. In *Proceedings of the 24th ACM international conference on Multimedia* (pp. 516–520).

ABSTRACT

An Empirical Study on the Improvement of Defective Parts Inspection System Using Vision AI Based on Deep Learning

– Focusing on Automotive Parts Manufacturing –

Kim, Si-Young

Major in Smart Convergence

Technology Consulting

Dept. of Smart Convergence Consulting

Graduate School of Knowledge Service

& Consulting

Hansung University

The manufacturing industry has recently been integrated into a production process where advanced technologies such as artificial intelligence (AI), big data, and IoT have not been applied before through rapid automation and digital transformation. This change resulted in a new manufacturing paradigm focused on maximizing production efficiency and enhancing competitiveness. In particular, the focus is on adopting AI technology as an important tool for innovating the quality control process.

This study presents an empirical approach to improve the quality inspection process of the automotive parts manufacturing sector by utilizing vision-based AI technology. Previously, defect detection relied heavily on manual visual inspection, and there were several challenges. Skilled inspectors played an important role in maintaining inspection quality, but frequent retirement and turnover reduced the transfer of experienced personnel, leading to lower defect detection rates and lower productivity. In addition, human judgment was prone to errors and contradictions, and the effectiveness of quality control was limited as the inspection time increased. The cost of maintaining experienced inspectors was also considerable.

To address these problems, a rule-based defect inspection system using computer vision was introduced. These systems have the benefits of automation, but they suffer from complex defect patterns, are sensitive to environmental changes, and require costly updates whenever new defect types emerge.

Therefore, this study aims to improve competitiveness by increasing inspection speed and automation using AI technology. The object detection model was applied to overcome the limitations of manual inspection, enable accurate detection of defective parts in real time, eventually improve inspection accuracy, and promote automation of quality control processes.

In an automated inspection environment, fast and automatic defect identification is essential. Recently, deep learning models such as YOLO, Faster R-CNN, and MobileNet have been proposed, each providing high detection accuracy and real-time processing capabilities, contributing

greatly to automating manufacturing workflows.

This study focused on the development of a fully automated defect inspection system that replaces traditional manual inspection. We collected data on the target products of our partners and compared the performance of YOLO, Faster R-CNN, and MobileNet models in terms of detection accuracy and processing speed. Experimental results showed that the YOLO model is superior to other models in both respects. Overall, this study confirmed that deep learning-based object detection technology is practical for real-time inspection and defect identification in automotive component manufacturing.

【Keywords】 Smart Manufacturing, AI-based Quality Inspection,
Automotive Parts Manufacturing, Deep Learning