



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

인공신경망 기반 머신비전 시스템 개발 및 적용 사례



한성대학교 지식서비스&컨설팅대학원

스마트융합컨설팅학과

스마트팩토리컨설팅전공

오 창 배

석사학위논문
지도교수 송거영

인공신경망 기반 머신비전 시스템 개발 및 적용 사례

Design and Implementation of an Artificial
Neural Network-Based Machine Vision System
for Industrial Defect Inspection



HANSUNG
UNIVERSITY

2025년 6월 일

한성대학교 지식서비스&컨설팅대학원

스마트융합컨설팅학과

스마트팩토리컨설팅전공

오 창 배

석사학위논문
지도교수 송거영

인공신경망 기반 머신비전 시스템 개발 및 적용 사례

Design and Implementation of an Artificial
Neural Network-Based Machine Vision System
for Industrial Defect Inspection

위 논문을 공학 석사학위 논문으로 제출함

2025년 6월 일

한성대학교 지식서비스&컨설팅대학원

스마트융합컨설팅학과

스마트팩토리컨설팅전공

오 창 배

오창배의 공학 석사학위 논문을 인준함

2025년 6월 일



심사위원장 박현성 (인)

심사위원 임황용 (인)

심사위원 송거영 (인)

국 문 초 록

인공신경망 기반 머신비전 시스템 개발 및 적용 사례

한성대학교 지식서비스&컨설팅대학원

스 마 트 융 합 컨 설 팅 학 과

스 마 트 팩 토 리 컨 설 팅 전 공

오 창 배

최근 4차 산업혁명으로 공정 자동화에 대한 요구가 중소 제조업 분야에서 빠르게 확산하고 있다. 이에 따라 정확도가 낮은 육안 검사나 외부 환경 요인에 적응력이 낮은 규칙 기반(rule-based) 시스템이 가진 한계를 극복하고, 정밀도를 높이고 생산 현장 적응력을 갖춘 품질검사 시스템의 필요성이 제기되었다. 하지만 대부분의 중소 제조업체는 여전히 수작업 중심 검사방법에 의존하고 있다. 이는 고가의 장비 도입, 기술 인프라 구축, 전문 인력 확보 등의 구조적인 어려움을 가지고 있는 중소기업의 현실이다. 특히 규칙 기반(Rule-based) 검사 방식은 조명 조건 변화, 포장재의 굴절 특성, 제품 표면의 반사 등 다양한 환경 요인에 민감하게 반응하여 일관된 검사 결과를 기대하기 어렵고, 생산 제품 품질 신뢰성 확보에 어려움을 드러낸다.

본 연구에서는 이러한 규칙 기반 검사의 한계점을 극복하기 위해, 인공신경망(Artificial Neural Network, ANN)을 기반으로 품질검사 시스템을 설계하고, 이를 실제 중소 제조업체의 생산 현장에 적용하는 것을 목표로 하였다. ANN은 사람이 직접 규칙을 정하지는 않고, 취득한 다양한 영상 데이터를 가지고 학습을 통해 복잡한 결함 패턴을 스스로 탐지할 수 있는 능력을 갖추게 된다. 이 인

공지능 품질검사 시스템은 다양한 외부 환경 요인으로 사람이 식별하기 어려운 미세 결함이나 비정형 이상까지도 효과적으로 탐지가 가능하도록 구성되었다.

본 연구에서는 원통형 제품을 360도 회전시켜 표면 영상을 자동으로 획득하고, 수집된 영상 데이터를 기초로 인공지능 시스템이 학습을 통해 결함 여부를 스스로 탐지할 수 있도록 하였다. 영상 데이터는 실제 생산 환경에서 수집되었고, 학습에는 오염, 이물질, 주름 등 다양한 결함 유형이 포함되었다. 실험 결과, 실제 설치된 ANN 기반 검사 시스템은 기존의 규칙 기반 방식에 비해 결함 탐지 능력이 월등히 높았으며, 다양한 외부 환경에도 안정적인 성능을 유지하였다. 특히 기존 머신비전 시스템은 단순 조도 차이 또는 입력된 규칙에만 의존하여 예외적인 결함 탐지에 취약했다. 반면, 본 연구의 인공지능 기반 시스템은 다양한 외부 환경 조건에서도 유연하게 대응하며 과 검출률과 오류율을 현저히 감소시켰다. 이러한 결과는 중소 제조업체에서도 비교적 경량화 구조의 인공지능 모델을 통해 기존 품질검사 방식의 한계를 극복할 수 있었다. 본 연구는 실제 제품 생산 환경에 적합한 구축 사례를 제시하였다는 점에서 의의가 있으며, 앞으로 다양한 제품, 다양한 산업 분야에서 인공지능 기반 품질 관리 시스템의 도입을 확대하는 데 자료로 활용될 수 있을 것이다.

【주요어】 인공신경망, 머신비전, 결함 탐지, 품질검사, 영상 데이터 처리

목 차

제 1 장 서론	1
제 1 절 연구 배경 및 필요성	1
제 2 절 연구 목적	3
제 2 장 이론적 배경 및 선행연구	4
제 1 절 인공신경망(Artificial Neural Network) 개요 및 구조	4
제 2 절 머신비전 기술의 개념과 활용 현황	9
제 3 절 딥러닝 기반 객체 탐지 모델	14
제 4 절 중소기업의 품질검사 자동화 수용 특성	16
제 5 절 기존 연구의 한계와 본 연구의 차별성	18
제 3 장 연구 방법	21
제 1 절 연구 설계 개요 및 접근 방법	21
제 2 절 사례 기업 특성 및 선정 배경	22
제 3 절 시스템 구성	24
제 4 절 데이터 수집 및 전처리	26
제 5 절 분석 모델 및 알고리즘	29
제 6 절 연구 신뢰성 및 윤리적 고려 사항	31

제 4 장 시스템 개발 및 현장 적용	33
----------------------------	----

제 1 절 시스템 요구사항 분석 및 설계 목표	33
---------------------------------	----

제 2 절 데이터셋 구성, 라벨링, 전처리 과정	34
----------------------------------	----

제 3 절 인공신경망 기반 모델 설계 및 학습 절차	36
------------------------------------	----

제 4 절 시스템 구현 및 아키텍처 구성	38
------------------------------	----

제 5 절 시스템 적용 결과	41
-----------------------	----

제 5 장 결론	48
----------------	----

제 1 절 연구 결과 요약 및 논의	48
---------------------------	----

제 2 절 시사점	49
-----------------	----

제 3 절 후속 연구에의 제언	51
------------------------	----

참 고 문 헌	56
---------------	----

[부록] 최종 결과 이미지	68
----------------------	----

ABSTRACT	77
----------------	----

표 목 차

[표 2-1] 대표 활성화 함수의 특성 비교	7
[표 2-2] Rule-based 시스템과 ANN 기반 시스템의 특성 비교	12
[표 2-3] 주요 산업 분야별 머신비전 적용 사례	13
[표 2-4] 머신비전 기술 진화 방향 비교	14
[표 2-5] 자동화 품질검사 수용에 영향을 미치는 주요 제약 요인 ...	17
[표 2-6] 정량 지표	20
[표 3-1] 현장 시스템 구성	25
[표 3-2] 불량 유형	28
[표 3-3] 라벨링 형식 비교표	28
[표 4-1] 측정 결과 비교	43
[표 4-2] Rule-based 기반 시스템과 ANN 기반 시스템 성능 비교	43
[표 4-3] 모델 학습에 따른 성능 개선	45

그림 목 차

[그림 2-1] 생물학적 신경세포(뉴런)	4
[그림 2-2] 생물학적 뉴런 구성	4
[그림 2-3] McCulloch-Pitts 모델	5
[그림 2-4] ANN 구조	6
[그림 2-5] CNN image classification pipeline	8
[그림 2-6] Basic architecture of a rule-based system	10
[그림 2-7] 머신비전 구성요소	11
[그림 3-1] ANN 학습 및 적용 절차도	22
[그림 3-2] 실제 원단 이미지	23
[그림 3-3] 5MP Vision Camera	25
[그림 3-4] Eyevision 4.4 Software	25
[그림 3-5] Detailed ANN-based Machine Vision Analysis Structure	30
[그림 4-1] CNN 영상 처리 과정	41

제 1 장 서 론

제 1 절 연구 배경 및 필요성

제조 산업은 4차 산업혁명의 흐름 속에서 디지털 전환과 스마트 팩토리 기술을 중심으로 빠르게 변화하고 있으며, 이는 생산성과 유연성을 동시에 향상시키기 위한 전략적 혁신으로 자리잡고 있다(오주환, 김지대, 2019). 품질 관리 체계의 지능화와 자동화는 단순히 효율 향상만을 위한 개념을 넘어 기업의 핵심 경쟁력을 좌우하는 요소가 되었다. 특히 위생 문제에 민감한 소비재를 생산하는 중소 제조업체의 경우, 품질 이상은 고객 신뢰도 하락으로 직결되기 때문에, 실시간 품질 검출 시스템의 필요성이 더욱 강조되고 있다(김병기 외, 2024; 이중수 외, 2024).

현실적으로 많은 중소 제조업체는 품질검사를 위해 머신비전 시스템을 구축하기 위한 장비 등 기반 시설과 전문 인력 확보에 어려움이 있다. 이 때문에 육안검사와 같은 수작업 기반의 검사 방식이나 임계값(Threshold)에 의한 심플한 규칙 기반(Rule-based) 알고리즘을 적용하는 중소 제조업체가 대부분이다. 이러한 전통 방식의 검사 시스템은 조명 밝기, 반사, 포장 필름의 굴절, 검사 대상의 비정형성 등 다양한 외란 요인에 민감하게 반응함으로써 검출 및 누락 오류가 많이 발생하며, 특히 반투명하거나 표면 구조가 복잡한 제품에서는 실시간 품질 검출의 신뢰성이 떨어지는 한계가 있다(이해나, 2020; 최성욱, 2016).

이 같은 한계를 극복하기 위한 대안으로 최근 주목받고 있는 기술이 인공 신경망(Artificial Neural Network, ANN)을 기반으로 한 머신비전 기술이다. ANN은 비정형 이미지 데이터를 반복적으로 학습하면서 고차원의 시각적 패턴을 인식할 수 있으며, 외부 조도 변화나 표면 상태 등의 환경 변화에도 높은 적응력을 보이는 특징을 가진다(LeCun et al., 2015; Goodfellow et al., 2016). 이러한 특성은 기존의 규칙 기반(Rule-based) 알고리즘이 조명 밝기 변화나 표면 반사, 배경 노이즈에 민감하다는 외부 환경에 대한 문제점을

효과적으로 극복할 수 있는 기반이 될 수 있다(Park et al., 2022).

그럼에도 불구하고 기존의 머신비전 및 딥러닝 기반 품질검사 연구들은 다음과 같은 한계를 가지고 있다.

첫째, 대부분의 연구는 CNN, YOLO, VGGNet, ResNet 등 특정 딥러닝 모델의 탐지 성능 향상이나 구조 최적화에 집중되어 있으며, 다양한 외란 조건에 유연하게 대응할 수 있는 ANN 기반 확장 설계는 제한적이다(이성주 외, 2022).

둘째, 적용 사례가 금속, PCB, 식품 포장재 등 구조가 정형화된 산업군에 편중되어 있으며, 반투명 부직포와 같이 비정형성이 높은 소재에 관한 실증적 연구는 미비하다(Benbarrad et al., 2021).

셋째, 결함 유형이 단일한 균열, 이물, 마모 등에 한정된 연구가 많고, 실제 산업현장에서 빈번하게 발생하는 복합 결함의 동시 검출 또는 적응형 알고리즘 설계는 부족하다(Bhatt et al., 2021).

넷째, 분석 대부분이 정제된 데이터셋을 기반으로 한 실험실 환경에서 수행되어 현장의 외란 조건을 충분히 반영하지 못하며(Saqlain et al., 2020), 마지막으로 성능 평가 또한 대부분 정량 지표(Precision, Recall, F1-score)에 국한된다(Hand et al., 2021).

이런 인식을 바탕으로, 본 연구는 전통적인 규칙 기반 시스템보다 단순히 정확도만을 개선한 시스템을 넘어서, ANN 기반 머신비전 기술이 제조 산업 현장 다양한 외부 환경 요인에 대한 적응력과 대응력 등을 키워 종합적인 품질검사 시스템으로 확장할 수 있는 이론 및 실증 사례를 만들어 규명하고자 한다.

제 2 절 연구 목적

본 연구의 인공지능망(Artificial Neural Network, ANN)을 활용한 머신비전 검사 시스템을 요구사항에 맞게 제안 및 설계하고, 이를 중소 제조업체의 실제 생산 현장에 설치함으로써 이전 품질검사 방식, 즉 샘플링 육안검사 문제점을 해결할 방법을 제시하는 데 목적이 있다. 특히 비교 대상인 이전 규칙 기반(Rule-based) 시스템의 탐지 방법은 조명 반사, 표면 굴곡, 검사 각도 변화 등 외부 환경에 민감하게 반응해 검사 신뢰도 확보에 한계점을 가지고 있다. 따라서 상대적으로 외부 환경에 덜 민감한 ANN의 학습 기반 시스템의 탁월한 이미지 해석 능력이 다양한 외부 환경 조건에 어떻게 적응할 수 있는지를 분석하고자 한다(Goodfellow et al., 2016; 정석진, 2023).

이를 위해 본 연구는 첫째, 실제 생산 공정에서 외부 환경 조건의 변경 없이, 그 상태로 촬영한 이미지 데이터를 기반으로, 유형별로 결함 데이터셋을 구성한다.

둘째, 다층 퍼셉트론¹⁾ 기반의 ANN²⁾ 모델을 활용하여 결함 분류 정확도를 향상시키는 학습 구조로 설계한다.

셋째, 실제 설계된 검사 시스템을 해당 제조업체에 설치한 후, 취득한 이미지 데이터를 이용하여 기존 Rule-based 방식과의 성능 비교를 통해 정량적 성능 평가를 수집하고 분석한다.

본 연구의 차별성은 실험실에서 알고리즘의 우수성 입증하는 학문적 성취에 만족하지 않고, 부족한 자원과 생산 환경의 제약이 뚜렷한 중소 제조 현장의 현실적 요구사항을 반영한 인공지능 AI 검사 시스템을 구현하고 산업적 가치를 데이터로 뒷받침한다. 본 연구의 결과는 인공지능 머신비전 기술이 생산 현장에 성공적으로 구현되기 위해서는 기술적 성능과 현장 수용성을 함께 확보해야 한다. 이는 관련 후속 연구 및 기술 개발에 중요한 지침이 될 것이다.


1) 입력층, 은닉층, 출력층으로 구성된 인공지능망 구조이며, 각 뉴런은 앞 층의 출력을 받아 가중합 후 비선형 함수로 처리한다. 이 구조는 분류와 예측 문제에 폭넓게 활용된다.

2) ANN (Artificial Neural Network) : 인공지능망, 기계학습과 인지과학에서 생물학의 신경망에서 영감을 얻은 알고리즘.

제 2 장 이론적 배경 및 선행 연구

제 1 절 인공신경망(Artificial Neural Network)의 개요 및 구조

인공신경망(Artificial Neural Network, ANN)은 생물학적 신경세포의 전기·화학적 반응 메커니즘을 수학적으로 모사한 계산 체계로, 다차원 데이터의 패턴을 학습하여 예측 및 분류 등의 복잡한 작업을 수행하는 데 사용된다(He et al., 2023; Tang et al., 2019). 인간의 신경계는 뉴런 간 시냅스를 통해 자극을 전달하며 반응하는 구조로 되어 있으며, 이러한 생물학적 원리는 인공 뉴런 모델의 기반이 되었다(Maass, 1997).




[그림 2-1] 생물학적인 신경세포(뉴런)

[그림 2-2] 생물학적 뉴런 구성


인공신경망(ANN)의 초기 수학적 기반은 McCulloch와 Pitts가 1943년에 제안한 이진 논리 기반의 신경망 모델에서 시작되었으며, 이후 Rosenblatt는 1958년에 퍼셉트론 구조를 통해 이를 구체화하였다(McCulloch et al., 1943; Rosenblatt, 1958). 퍼셉트론은 단일 계층에서의 선형 분류 문제 해결에는 유효했으나, 비선형 문제(XOR 문제 등)에 대해서는 구조적 한계를 지니고 있었으며(Minsky et al., 1969), 이는 다층 퍼셉트론(Multilayer Perceptron, MLP)과 역전파(backpropagation) 알고리즘의 필요성을 제기하게 되었다. 초기 인공신경망 학습의 발전은 McCulloch과 Pitts의 이진 논리 기반 모델[그

림 2-3]에서 출발하였으며, 이후 Rosenblatt의 퍼셉트론 모델을 통해 구조화되었다. 특히 Rumelhart, Hinton, Williams가 1986년에 제안한 역전파(backpropagation) 알고리즘은 다층 은닉층을 활용하여 복잡한 입력과 출력 간의 관계를 효과적으로 학습할 수 있도록 하였으며, 이는 현대 딥러닝 기술의 핵심 기반으로 자리 잡았다(Rumelhart et al., 1986).



[그림 2-3] McCulloch-Pitts 모델

일반적으로 인공신경망(Artificial Neural Network, ANN)은 입력층(input layer), 은닉층(hidden layer), 출력층(output layer)의 3단계 구조로 되어 있다([그림 2-4]).



[그림 2-4] ANN 구조

각 층에서는 입력 신호와 가중치의 선형 결합 결과에 비선형 활성화 함수가 적용되어 출력값이 계산된다(Goodfellow et al., 2016). 입력층은 데이터를 모델 내부로 전달하는 통로 역할을 하며, 이때 데이터는 정규화 또는 표준화 과정을 통해 입력 범위를 조정한다. 은닉층은 네트워크의 주요 연산이 이루어지는 부분으로, 각 뉴런은 이전 층으로부터 전달받은 값에 가중치와 편향을 적용한 후, 비선형 활성화 함수를 통해 정보를 변환한다. 대표적인 활성화 함수에는 Sigmoid, Tanh³⁾, ReLU(Rectified Linear Unit), Leaky ReLU 등이 있으며, 각 함수는 출력 범위, 학습 수렴 속도, 기울기 소실 완화 측면에서 서로 다른 특성을 가진다. 특히 ReLU는 빠른 수렴 속도와 희소 표현 능력을 장점으로 가지며, Leaky ReLU는 죽은 뉴런 문제를 완화하여 모든 음수 입력에 작은 기울기를 부여함으로써 학습 중 뉴런이 비활성화되는 현상을 방지한다(Glorot et al., 2010; Xu et al., 2015). 이러한 함수의 비교는 [표 2-1]에 요약되어 있다.

3) 딥러닝에서 사용되는 비선형 활성화 함수 중 하나로, 입력값을 -1부터 +1 사이로 압축해 주는 함수이다.

[표 2-1] 대표 활성화 함수의 특성 비교


함수	장점	단점
Sigmoid	출력 해석 용이	기울기 소실
Tanh	중심화된 출력	학습 속도 저하
ReLU	빠른 수렴, 희소 표현	죽은 뉴런 문제
Leaky ReLU	죽은 뉴런 방지	파라미터 설정 필요

ANN은 문제 유형에 따라 출력층에서 이진 분류, 다중 분류, 회귀 등 다양한 구조로 확장 가능하며, 모델의 학습은 오차 역전파(backpropagation) 알고리즘⁴⁾과 경사하강법(gradient descent)⁵⁾을 기반으로 수행된다. 손실 함수(loss function)는 출력과 정답 간의 차이를 수치화하여 모델 학습을 유도하는 기준으로, 이진 분류⁶⁾에서는 크로스 엔트로피(Binary Cross-Entropy)가 사용되고, 회귀 문제⁷⁾에서는 평균제곱오차(Mean Squared Error, MSE)가 주로 사용된다. 최적화 기법으로는 초기의 확률적 경사하강법(SGD)에서 발전된 Adam(Kingma & Ba, 2015), RMSprop, Adagrad 등의 알고리즘이 도입되었고, 학습률(learning rate), 에폭(epoch), 배치 크기(batch size)⁸⁾ 등 하이퍼파라미터의 설정이 모델 성능에 결정적인 영향을 미친다(Kingma, 2014; Goodfellow, 2016).

인공신경망(ANN)은 다층 퍼셉트론(Multilayer Perceptron, MLP)⁹⁾ 구조

- 4) 인공신경망에서 사용되는 학습 기법으로 출력층에서 발생한 오차(error)를 입력층 방향으로 역방향 전달하면서 가중치를 조정하여 신경망을 학습시키는 방법
- 5) 손실 함수(Loss function)의 최솟값을 찾기 위해 반복적으로 매개변수를 업데이트하는 최적화 기법
- 6) 출력값이 두 가지 클래스 중 하나(예: 정상 vs 불량, 참 vs 거짓 등)로 분류되는 문제이다. 출력층에서는 이를 위해 1개의 뉴런과 Sigmoid 함수를 사용하는 것이 일반적이다.
- 7) 정해진 수치를 예측하는 문제이다(예: 온도, 매출, 제품 결함 크기 예측 등). 이진 분류처럼 0 또는 1이 아니라, 연속적인 실숫값을 출력한다.
- 8) 학습률: 가중치를 얼마나 빠르게/크게 업데이트할지 결정하는 값, 에폭: 전체 학습 데이터를 한 번 모두 학습시키는 횟수, 배치 크기: 한 번에 모델이 학습하는 데이터의 양
- 9) 여러 층으로 구성된 인공신경망(ANN)의 기본 형태입니다. 입력층, 은닉층(1개 이상), 출력층으로 구성되며, 각 뉴런은 가중치와 활성화 함수를 통해 연결된다.

를 기반으로 다양한 문제에 적용할 수 있다. 하지만 고차원 이미지 데이터에서 지역적인 공간 특성을 효과적으로 추출하는 데에는 구조적 한계가 존재한다(Goodfellow et al., 2016). 이런 한계 극복을 위해 제안된 구조가 바로 컨볼루션 신경망(Convolutional Neural Network, CNN)¹⁰⁾이다. [그림 2-5]의 CNN image classification pipeline에서 보듯이, CNN은 이미지 내의 지역 패턴을 학습할 수 있도록 설계된 네트워크로, 합성곱 계층(convolution layer)을 통해 입력 데이터의 국소 수용 영역(local receptive field)을 처리하고, 풀링(pooling) 계층을 통해 특징 맵(feature map)의 차원을 줄여 계산 자원의 효율성을 높인다(LeCun et al., 2015; Krizhevsky et al., 2012). CNN의 기본 처리 흐름은 입력 이미지에 합성곱 필터를 적용하여 특징 맵을 추출하고, 풀링을 통해 차원을 축소한 뒤, 완전 연결 계층에서 분류를 수행하는 방식이다(LeCun et al., 2002; Rawat et al., 2017).



[그림 2-5] CNN image classification pipeline

이와 같은 CNN 구조는 LeNet(LeCun et al., 1998)¹¹⁾,

10) 이미지나 영상 같은 2차원 데이터 처리에 특화된 딥러닝 모델로 사람의 시각 피질 구조에서 영감을 받아 설계되었으며, 패턴 인식, 객체 탐지, 영상 분류 등에 주로 사용된다.

11) 초기 CNN 모델로, MNIST 손 글씨 인식 데이터셋에서 뛰어난 성능을 보이며 CNN의 가능성을 최초로 입증

AlexNet(Krizhevsky et al., 2012)¹²⁾, VGGNet¹³⁾, ResNet(He et al., 2016)¹⁴⁾ 등으로 진화해 왔으며, 각 아키텍처는 층의 깊이, 필터 수, 잔차 연결¹⁵⁾ 여부 등에 따라 차별화된다. 영상 기반 품질검사와 같은 분야에서는 CNN의 성능이 월등히 잘 발휘되며, 기존의 규칙 기반 영상 처리 방식(rule-based vision)과 비교했을 때 조명 변화, 노이즈, 곡률 등의 비정형 조건에도 상대적으로 더 높은 적응력을 보인다(LeCun et al., 1998; Krizhevsky et al., 2012; Simonyan et al., 2014; He et al., 2016).

제 2 절 머신비전 기술의 개념과 활용 현황


머신비전(Machine Vision)은 광학 장비와 디지털 영상 처리 기술이 결합하여, 인간의 시각 기능을 대체하거나 보조하는 형태로 설계된 자동화 검사 기술이다(Redmon et al., 2016). 이는 산업용 카메라, 렌즈, 조명 장치, 프레임 그래버, 이미지 처리 알고리즘, 사용자 인터페이스(UI)로 구성되며([그림 2-6]), 물체 인식, 결함 감지, 위치 결정, 문자식별 등 다양한 작업을 수행한다(Mohammed et al., 2025; Molefe et al., 2025). 특히 반복적이고 고속의 검사 공정이 요구되는 제조 현장에서 머신비전은 품질검사의 자동화를 실현하는 핵심 수단으로 자리매김하고 있다(Liu et al., 2025).

12) 2021년 ImageNet 챌린지에서 우승하며, GPU 가속화, ReLU 활성화 함수, Dropout 등 현대 CNN 구조의 기반을 마련

13) 작은 크기의 3*3 컨볼루션 필터를 반복적으로 적용하여 네트워크 깊이를 효과적으로 늘려 이미지 분류 성능을 크게 향상


14) 깊은 신경망 학습에서 발생하는 경사 소실 문제를 해결하여 초심층 네트워크 설계에 혁신을 가져옴

15) 입력값을 출력값에 직접 더해주는 연결 구조.



[그림 2-6] 머신비전 구성요소

초기 머신비전 시스템은 고속 촬영 장비를 활용해 대상 물체의 이미지를 획득하고, 이를 디지털 영상 데이터로 변환한 후, 사전에 정의된 알고리즘이나 규칙 기반 분석 기법(Rule-based Vision)을 통해 물체의 외형, 색상, 위치, 결함 여부 등을 자동으로 판별하는 방식으로 작동한다(Szeliski, 2010; Kang et al., 2021). 일반적으로 임계값(Thresholding), 에지 검출(Edge Detection), 히스토그램 분석, 패턴 매칭(Pattern Matching) 등의 전통적 영상 처리 기법이 활용되며, 이는 사람이 사전에 정의한 규칙을 중심으로 동작한다(Zheng et al., 2025). [그림 2-7]은 머신비전 전문가가 정의한 규칙을 기반으로 판단 과정을 수행하는 규칙 기반 시스템의 일반적인 구조를 나타낸다. 지식 기반 시스템에서 초기 사실과 규칙은 각각 사실 저장소와 규칙 저장소에 보관되며, 실행 모듈은 패턴 일치와 규칙 활성화 절차를 통해 작동한다. 이 과정은 제어 모듈과의 지속적인 상호작용을 통해 시스템 상태를 동적으로 갱신한다(Grosan et al., 2011).



[그림 2-7] Basic architecture of a rule-based system(Automation in Construction, 2017).

그러나 이런 Rule-based 접근법은 처리 속도가 빠르고 구현이 간단하다는 장점이 있으나, 외부 환경 변화나 대상의 복잡성에 대한 적응력이 떨어지는 근본적 한계를 지닌다(Elhendawy et al., 2025). 실제로 규칙 기반(Rule-based) 머신비전 시스템은 조도 변화, 표면 반사, 회전, 위치 변경 등과 같은 외부 변수에 매우 민감하다. 예를 들면, 포장 필름의 굴절, 조명 불균형, 원단의 주름 등은 이미지 내 결함 인식률을 크게 저하하는 요인으로 작용하며, 이런 이유로 오검출 또는 미검출의 비율이 높아지는 문제가 빈번하게 발생한다(Li et al., 2021; Song et al., 2013). 특히 비정형적이고 다층 구조의 표면을 가진 대상에서는 단일 임계값이나 단순 매칭 기반 알고리즘만으로는 안정적인 품질검사를 수행하기 어렵다(Monti et al., 2025).

기존의 규칙 기반 머신비전 시스템의 한계를 극복하기 위해, 최근에는 딥러닝을 포함한 인공지능 기반 영상 인식 기술이 산업현장에 빠르게 도입되며, 품질검사 시스템의 정확도와 적응력을 크게 향상시키고 있다(Belkheldar et al., 2023). 딥러닝 기반 모델은 방대한 라벨링 이미지 학습을 통해 복잡한 산업 환경에서도 결함을 안정적으로 탐지할 수 있는 성능을 확보한다”(Yoon, 2024).

[표 2-2] Rule-based 시스템과 ANN 기반 시스템의 특성 비교

항목	Rule-based 시스템	ANN 기반 시스템
유연성	낮음	높음
외란 적응력	낮음	높음
유지보수	간편	고급 인력 요구
오검출률	높음	낮음
확장성	제한적	전이 학습 및 증강 가능

[표 2-2]는 Rule-based 시스템과 인공신경망(ANN) 기반 시스템의 주요 특성을 비교한 것으로, 유연성과 외란 적응력, 오검출률 등에서 ANN 기반 방식이 우수한 성능을 보이며, 확장성 측면에서도 전이 학습과 데이터 증강을 통해 높은 확장 가능성을 가진다 (Benbarrad et al., 2021; Li et al., 2021; Song et al., 2013).

머신비전 기술은 제조, 식품, 전자 등 다양한 산업군에 걸쳐 널리 활용되고 있으며, 각 산업 특성에 맞는 검사 항목에 적용된다. 예를 들어, 반도체 분야에서는 웨이퍼 표면의 미세 흠집이나 패턴 정렬 오류를 검출하는 데 사용되고, 식음료 제조업에서는 포장 불량, 밀봉 상태 이상, 이물질 혼입 여부를 자동으로 감지하는 데 활용된다(Shin et al., 2020; Zhang, 2021). 섬유나 부직포 제조에서는 원단의 주름, 오염, 패턴 정렬 문제 등을 모니터링하고 있으며, 전자부품 및 제약 산업에서도 납땜 결함, 용기 이상 등을 자동 감지하기 위해 활용되고 있다(Gupta et al., 2022; Xu et al., 2024; Chen et al., 2023). 주요 산업 분야별 머신비전 적용 사례는 [표 2-3]과 같다.

[표 2-3] 주요 산업 분야별 머신비전 적용 사례

산업 분야	검사 대상	활용 목적
반도체	웨이퍼, 회로 패턴, 미세 스크래치	정밀 결함 탐지, 패턴 정렬
식음료	포장 인쇄, 라벨, 밀봉 상태	불량 인쇄 감지, 이물질 탐지
섬유 및 부직포	원단 주름, 오염, 패턴 정렬 오류	주름 탐지, 품질 균일성 확인
전자부품	납땜 상태, 단선, 오염	신뢰성 검증, 결함 사전 제거
제약·화장품	용기 결함, 이물 혼입	소비자 안전 확보, 클레임 방지

[표 2-3]은 머신비전 기술이 반도체, 식음료, 섬유, 전자부품, 제약·화장품 등 다양한 산업 분야에서 정밀 결함 탐지, 품질 검증, 소비자 안전 확보 등의 목적으로 활용되고 있음을 보여준다(Gupta et al., 2022; Xu et al., 2024; Chen et al., 2023).

하지만 중소 제조업체 측면에서 보면, 고성능 머신비전 시스템 도입에는 금전적인 면 등 여전히 다양한 제약이 존재한다. 고해상도 산업용 카메라, 정밀 조명 장치, 고속 영상 처리용 소프트웨어나 하드웨어는 높은 초기 투자 비용을 요구하며, 이러한 시스템을 안정적으로 운용하는 데 필요한 숙련된 기술 인력의 확보 또한 쉽지 않다(Kang et al., 2022; He, Li et al., 2023). 이에 따라 중소기업 다수는 여전히 수작업 또는 저해상도 단순 검사 시스템에 의존하고 있으며, 품질 변동성, 인건비 증가, 불량 누락 등 구조적 문제를 지속적으로 경험하고 있다(이성희 외, 2017).

이러한 기술적 요구를 반영하여 최근 머신비전 시스템은 두 가지 주요 방향으로 발전하고 있다. [표 2-4]는 이러한 머신비전 기술 진화 방향을 비교하여 제시한다.

[표 2-4] 머신비전 기술 진화 방향 비교

방향	핵심 내용	기대 효과
AI 융합형 비전 시스템	CNN 기반 특징 추출, 분류 통합	적응성 향상, 복합 결함 탐지 가능
엣지 기반 머신비전	현장 단말에서 실시간 분석 및 판정 수행	지연 최소화, 에너지 효율 향상

자료: Mohammed & Hussain(2025), Zheng et al.(2025)를 기반으로 연구자 재구성

특히 본 연구와 같이 제한된 환경에서도 고정밀 품질검사가 필요한 중소기업체의 환경에서는, 기존 수작업 또는 Rule-based 기반 머신비전 시스템 방식에서 벗어나 ANN 기반으로 전환될 때 품질 안정성과 생산성 모두 획기적인 개선이 가능하다. ANN은 불규칙한 패턴, 반사 조명, 다층 텍스처 등의 문제를 반복 학습을 통해 극복할 수 있으며, 이는 기존 머신비전 기술이 해결하지 못했던 문제를 해결할 수 있는 실질적인 대안이 된다(형성웅 외, 2024).

요약하면, 머신비전 기술은 제조 산업 전반에서 디지털 품질 관리의 핵심 수단으로 자리매김하고 있으며, 특히 인공지능(AI) 기술과 결합한 형태로 빠르게 진화하고 있다(LeCun et al., 2015; He et al., 2023). 중소기업의 자원 제약을 고려한 경량형 ANN 기반 비전 시스템의 설계 및 현장 적용은 머신비전 기술의 실질적 확산과 생산 공정의 스마트화에 이바지할 수 있는 현실적 대안으로 평가된다(Tercan et al., 2022).

제 3 절 딥러닝 기반 객체 탐지 모델

객체 탐지 모델은 머신비전 분야에서 핵심적인 역할을 하며, 단순한 이미지 분류를 넘어 이미지 내의 관심 영역을 신속하게 식별하고 해당 영역에서 객체의 종류를 정확히 판별하는 기능을 수행한다(Diwan et al., 2023). 이 기술은 처리 방식 또는 구조에 따라 둘로 나뉜다. 후보 영역을 먼저 탐색하고 객체를 식별하는 Two-stage Detector와 직접 객체 탐지를 수행하는

One-stage Detector로 나눌 수 있습니다(Jiao et al., 2019).

Two-stage Detector는 이름대로 두 단계의 과정을 거친다. 첫 단계는 객체가 있을 법한 후보 영역을 먼저 추출하고, 두 번째 단계는 각 후보 영역에 대한 클래스 분류와 바운딩 박스 회귀를 순차적으로 진행하는 방식이다. 이 접근법은 R-CNN, Fast R-CNN, Faster R-CNN으로 발전하며 그 성능이 입증되었다(Ren et al., 2015). 초기 모델인 R-CNN은 선택적 탐색으로 생성된 많은 후보 영역 각각에 대해 CNN 연산을 독립적으로 수행하는 구조 때문에, 높은 정확성에도 극심한 연산 중복으로 속도 저하라는 한계가 있습니다. 이러한 비효율성 때문에 Fast R-CNN에서 이미지 전체에 대한 특징 맵을 한 번만 계산한 뒤, RoI Pooling(Region of Interest Pooling)이라는 기법으로 각 후보 영역의 특징을 공유하는 방식으로 연산 효율성을 획기적인 개선 하였다(Girshick, 2015). Ren et al.(2015)는 Region Proposal Network(RPN)를 도입하여 기존 객체 탐지 프레임워크를 개선한 Faster R-CNN을 제안하였다. 이 접근 방식은 후보 영역 추출과 분류 과정을 하나의 통합된 딥러닝 모델로 구성함으로써, 객체 탐지의 효율성과 정확도를 크게 향상시켰으며 이후 관련 분야에서 널리 채택되었다.

One-stage Detector 방식은 별도의 후보 영역 생성 과정을 생략하고, 단일 신경망을 통해 이미지 내 객체의 위치와 종류를 동시에 예측함으로써 빠른 처리 속도와 효율성이 특징이다. 대표 모델은 YOLO와 SSD가 있다. YOLO는 Redmon et al.(2016)에 의해 처음 제안된 후 다양한 버전으로 발전하면서 실시간 탐지에서 우수한 성능을 보여주었다. SSD는 Liu et al.(2016)이 개발한 모델로, 다양한 해상도의 특징 맵을 활용하여 작은 객체 탐지 능력을 향상시켜, 속도와 정확도 면에서 YOLO와 경쟁력을 갖는다(Redmon et al., 2016; Liu et al., 2016).

본 연구에서는 직접 YOLO, SSD, Faster R-CNN과 같은 고성능 객체 탐지 모델을 활용하지 않았다. 이는 중소 제조업체의 기술적 환경을 고려할 때, 이 모델들은 고성능 GPU와 대규모 라벨링 데이터셋이 필요하며, 모델의 복잡성으로 유지보수 및 최적화에 전문 인력이 필요하다는 현실적 제약이 존재한다(He et al., 2023). 또한, 본 연구의 대상인 위생용 원단에서는 비정형

적인 불량 패턴(주름, 노이즈, 오염 등)의 분류와 오염지 최소화가 고성능 객체 탐지보다 중요하였다. 고성능의 복잡한 객체 탐지 모델은 단순한 이진 분류 및 이상 감지 작업에서 과도한 구조적 부담과 연산 부하를 유발할 수 있다.

이에 중소 제조업체의 부족한 기술 인프라를 고려, 연산 효율성과 실용성을 동시에 충족할 수 있는 경량형 CNN-ANN 하이브리드 모델을 제안하였다. 제안된 모델은 실제 생산 환경에 적용되었다. 이에 품질검사 자동화의 가능성을 실증적으로 검증했고, 시스템 구축 및 운영 비용 면에서 좋은 효율성을 확보하면서도 높은 정확도를 보여주었다.

제 4 절 중소기업의 품질검사 자동화 수용 특성

디지털 전환과 스마트 팩토리 기술이 제조 산업 전반에 빠르게 확산하면서, 제품 품질검사 공정 역시 고도화된 자동화 기술의 도입이 요구되고 있다(Chong et al., 2020). 특히 소비재 중심의 위생 제품 제조업체는 제품에 대한 민감성과 고객 신뢰도 간의 밀접한 연관성으로 인해, 불량률 관리가 기업 경쟁력에 직결되는 핵심 요인으로 작용한다(강성규 외, 2022). 그러나 많은 중소 제조업체는 첨단 품질검사 시스템 도입에 있어 구조적인 제약이 있다. 이는 단순히 기술적 기반 시설의 부족을 넘어, 전반적인 조직 역량과 자원의 한계로 인해 복합적인 문제로 나타난다(이정련 외, 2022).

먼저 기술적 측면에서 중소기업은 고해상도 영상 센서, 정밀 조명 장치, GPU 기반의 연산 하드웨어 등 머신비전 기반 검사 시스템을 구성하는 필수 요소들을 확보하는 데 상당한 제약을 받는다. 전통적인 규칙 기반(Rule-based) 머신비전 시스템은 상대적으로 비용 부담이 적고 구현이 단순하다는 장점이 있으나, 조명 변화, 포장재 반사, 원단의 물리적 굴곡 등 외부 환경 요인에 매우 취약하다는 치명적인 한계를 지닌다. 이에 따라 동일한 설정 조건에서도 제품마다 검사 정확도가 달라지고, 불량 검출률이 낮아 품질 관리의 일관성을 확보하기 어렵다(임병인 외, 2022; 정분도 외, 2018; 장수환 외, 2019).

두 번째로 인력 운영 측면에서, 머신비전 알고리즘, 특히 인공신경망(ANN) 기반의 AI 시스템은 다층 구조의 신경망 학습, 하이퍼파라미터 튜닝, 데이터 전처리 및 라벨링 등 고도의 기술 역량이 있어야 하며, 시스템 유지 보수 역시 일정 수준 이상의 전문성이 요구된다(LeCun et al., 2015). 하지만 다수의 중소 제조기업은 인공지능(AI) 기반 시스템의 설계와 최적화를 담당할 수 있는 숙련된 기술 인력을 안정적으로 확보하는 데 어려움을 겪고 있으며, 이에 따라 외부 용역이나 단기 계약 인력에 의존하는 사례가 빈번하다. 이런 인력 시스템으로는 장기적인 유지, 보수와 기능 고도화에 제약을 초래한다. 결과적으로 기술 내재화의 어려움으로 이어진다(김정래 외, 2020; 윤선중 외, 2021). 자동화 품질검사 수용에 영향을 미치는 주요 제약 요인은 [표 2-5]와 같다.

[표 2-5] 자동화 품질검사 수용에 영향을 미치는 주요 제약 요인

제약 범주	구체적 문제	영향 및 한계
기술적 요인	- 고해상도 센서와 조명 확보 어려움	- 검사 정확도 저하
	- 환경 변화(반사, 굴곡)에 취약	- 불량 검출의 일관성 확보 어려움
인력적 요인	- AI/ANN 전문가 부족	- 시스템 도입 및 운용 어려움
	- 하이퍼파라미터 최적화 및 유지보수 인력 부족	- 외부 의존도 증가, 지속가능성 저하
경제적 요인	- 초기 고비용 장비 및 데이터셋 확보 부담	- 자동화 도입 결정 지연 또는 포기
	- ROI 확보 불확실성	- 수작업 및 저성능 시스템 지속 의존

자료: 이성희, 김재영, 이원희(2017). 스마트 공장 문헌 연구 및 향후 추진 전략. 정보기술 응용연구, 24(4), 133-152. 본 연구에서 재구성함.

이러한 맥락에서 국내 중소 제조업체의 실제 현장 적용 사례를 살펴보면, 여전히 품질검사의 상당 부분을 수작업 방식에 의존하고 있으며, 일부 기업은 규칙 기반(Rule-based) 머신비전 시스템을 도입했음에도 불구하고 낮은 검출 정확도로 인해 수작업 검사를 병행하거나 사후 점검을 통해 결과를 보

완하고 있다(허승진, 2023; 정석진, 2023). 예를 들어, 대형 원단을 자동으로 포장하는 기업의 경우, 공정 중 제품 회전 및 반사 따라서 발생하는 영상 노이즈로 인해 자동 검사가 불안정하여, 결국 제품 출하 후 고객 클레임을 통해 결함이 인지되는 구조가 형성되었다(노세리 외, 2020; 양은경, 2024).

앞에서 언급한 기술적 한계, 전문 인력 부족, 경제적 부담 요인을 종합적으로 고려할 때, 중소 제조업체가 고정밀 자동화 검사 시스템을 실제로 적용하기 위해서는 단순한 알고리즘 성능 향상을 넘어 시스템 전체의 구조적 설계와 운용 전략이 현실적이고 유연하게 구성되어야 한다(김정래 외, 2020; Kwon et al., 2022). 특히 최소 인력 자원으로 운영이 가능하고, 다양한 생산 환경의 변화에 능동적으로 대처할 수 있는 지능형·경량형 검사 시스템의 개발이 시급한 과제로 드러났다.

본 연구는 이런 산업현장의 실질적 조건을 반영하여, ANN 기반 검사 시스템을 중소 제조업체의 제조공정에 맞게 설계하고 직접 적용함으로써 기술 실현 가능성과 운용 효율성을 실증적으로 검토하였다. 이는 단순한 알고리즘 검증 차원을 넘어서, 중소기업 제품의 품질 관리 자동화의 적용 가능성을 제시하는 사례 연구로서의 의의가 있다.

제 5 절 기존 연구의 한계와 본 연구의 차별성

기존의 규칙 기반 머신비전과 딥러닝 기반 품질검사 기술은 높은 정확도를 달성한 사례가 많지만, 실제 산업 환경에 적용하면 조명 변화, 배경 잡음, 데이터 다양성 부족 등으로 인해 구조적인 제약이 존재한다(Jia et al., 2024).

첫째, 기술적 구조 측면에서 대부분의 연구는 CNN, YOLO, ResNet 등 특정 모델의 탐지 정확도 향상이나 속도 개선에 초점을 맞추어 왔으며, 실제 산업현장의 다양한 외란 조건에 적응할 수 있는 유연한 구조 설계에는 소극적이었다(이성주 외, 2022). 반면 본 연구에서는 실제 생산 현장에서 수집된 데이터를 기반으로, 낮은 조도, 반사, 굴절, 영상 노이즈 등 다양한 외란 조건에 적절하게 대응할 수 있는 ANN 기반 시스템과 전처리 알고리즘을 통합

하여, 생산 현장에서 시스템의 환경 유연성과 적응성을 동시에 확보하였다.

둘째, 적용 분야의 측면에서 기존 연구들은 금속, PCB, 반도체, 농산물 등 규칙성이 강한 정형 소재에 집중되어 있으며(Benbarrad et al., 2021), 위생용 부직포나 투명 필름과 같은 비정형적이고 불투명한 재질에 관한 연구는 제한적이다. 본 연구는 실제 생산 공정에서 제조되는 위생용 원단을 대상으로, 비정형 결함(예: 이물, 섬유 뭉침, 점 오염, 미세 주름 등)에 대한 인공 신경망 기반 탐지 알고리즘의 실효성을 실증적으로 검토하였다.

셋째, 결함 검출 범위의 측면에서 선행 연구들은 균열, 오염, 이물 등 단일 결함의 탐지에 국한되는 경향을 보였으며, 복합적이고 불규칙한 결함 유형의 탐지에 관한 연구는 드물다(Bhatt et al., 2021). 본 연구는 실제 생산 현장에서 발생할 수 있는 다중 결함 유형을 통합 탐지할 수 있도록 모델 구조를 설계하고, 다중 객체 검출 성능을 평가하였다.

넷째, 데이터 기반의 실증성 측면에서 기존 연구들은 공개 이미지셋이나 실험실 내 촬영 조건을 활용하는 경우가 많아, 실제 산업현장에서 발생하는 조명 반사, 포장 필름 굴절, 카메라 위치 변화 등 외란 요인을 충분히 반영하지 못하였다(Saqlain et al., 2020). 본 연구는 현장 설비로부터 직접 수집된 실데이터를 기반으로 하여, 산업적 외란을 반영한 실증 분석을 수행하였다.

다섯째, 성능 평가의 관점에서 대부분의 선행 연구는 정밀도(Precision), 재현율(Recall), F1-score 등 정량 지표[표 2-6] 중심으로 성능을 검증하였으나, 실시간 운용성, 유지보수 용이성, 중소기업 적용 가능성과 같은 실무적 지표는 소홀히 다루었다(Hand et al., 2021).

[표 2-6] 정량 지표

지표	정의	공식
정밀도 (Precision)	모델이 결함이라고 예측한 것 중 실제 로 결함인 비율	$Precision = \frac{TP}{(TP + FP)}$
재현율 (Recall)	실제 결함 중 모델 이 정확히 찾아낸 비율	$Recall = \frac{TP}{(TP + FN)}$
F1-score	정밀도와 재현율 조 화 평균	$F1-score = \frac{2 * (Precision * Recall)}{(Precision + Recall)}$

TP¹⁶⁾, FP¹⁷⁾, FN¹⁸⁾

이처럼 본 연구는 기존 연구들과 달리 기술적 유연성, 비정형 소재에 대한 적용 가능성, 다중 결함에 대한 대응력, 실 환경 기반의 원본 데이터 활용, 실무 중심의 성능 평가지표 반영 등에서 차별화된 접근을 시도하였다. 이러한 결과는 향후 유사한 생산 환경을 가진 중소 제조기업이 스마트 품질 관리 시스템을 도입하는 데 있어 실질적 참조 자료로 활용될 수 있다.(Kwon et al., 2022; He et al., 2023).

16) True Positive: NG를 정확히 탐지

17) False Positive: OK인데 NG로 잘못 탐지

18) False Negative: NG인데 탐지 못함

제 3 장 연구 방법

제 1 절 연구 설계 개요 및 접근 방법

본 연구는 인공지능망(ANN)을 활용한 머신비전 시스템이 중소 제조업체의 실제 생산 환경에 효과적으로 적용될 수 있는지를 실증적으로 분석하는 것을 주요 목표로 한다(김정태, 2020). 특히 위생용 고기능성 원단을 생산하는 제조공정에 ANN 기반 검사 시스템을 도입하고, 규칙 기반(Rule-based) 검사 방식과의 성능 차이를 정량적으로 비교함으로써, 인공지능 기반 품질관리 기술의 실용성과 산업현장 내 확장 가능성을 분석하고자 하였다(He et al., 2023; 김정래 외, 2020). 이러한 목적을 달성하기 위해, 사례 중심의 실증적 접근을 적용하였다(Creswell et al., 2018).

본 연구는 사례 기업의 검사 공정과 작업 환경에 대한 현장 조사 및 문헌 분석을 통해 인공지능 기반 검사 시스템의 기능적 요구사항을 도출하고, 이를 바탕으로 기술적 설계 방향을 체계적으로 제시하였다(김진주 외, 2025). 이후 ANN을 기반으로 머신비전 시스템을 설계 및 실제 생산라인에 구축하고, 새로이 구축된 ANN 기반 시스템의 검출 성능을 동일한 제품에 대해 규칙 기반 검사 방식과 비교 평가하였다. 이 과정에서 정량적으로는 정밀도(Precision), 재현율(Recall), F1-score 등 핵심 성능 지표를 활용하였다(Saito et al., 2015).

이러한 연구 설계는 이론 검토에만 제한하지 않고 실제 현장 적용 가능성을 반영하여, 기존 딥러닝 기반 품질검사 연구들이 특정 모델의 탐지율 증가에만 초점을 두고 정제된 데이터셋 기반으로 실험을 수행해 온 것과는 차별성이 있다. 본 연구는 산업적 현실성과 기술적 정교함을 동시에 확보하기 위해 (1) 요구 분석, (2) 시스템 설계, (3) 데이터 수집 및 가공, (4) 모델 학습 및 적용, (5) 성능 평가 및 비교 실험의 5단계 절차에 따라 연구를 수행하였다(송대웅, 2021)

첫째, 요구 분석 단계에서는 사례 기업의 공정 특성, 불량 유형, 검사 조건, 제약 요건 등을 인터뷰와 작업 매뉴얼 분석을 통해 도출하였다. 둘째, 시스템 설계 단계에서는 수집된 요구사항을 바탕으로 카메라 배치, 조명 설정, 이미지 획득 방식 등 하드웨어 구성과 함께, 영상 처리, ANN 기반 분류, 사용자 인터페이스 등의 소프트웨어 모듈 구조를 정의하였다. 셋째, 데이터 수집 및 가공 단계에서는 다양한 결함 유형을 포함하는 생산 제품 이미지 데이터를 실제 생산 환경에서 확보하였으며, 이를 정제 및 전처리하여 학습용, 검증용, 테스트용으로 나누었다. 넷째, 모델 학습 및 적용 단계에서는 CNN 기반 특징 추출기를 결합한 ANN 분류 모델을 설계하고, 하이퍼파라미터 조정, 정규화, 클래스 불균형 보정 등의 기법을 통해 모델 학습을 수행하였다([그림 3-1]). 마지막으로, 성능 평가 및 비교 실험 단계에서는 기존 수작업 검사 및 기존 머신비전 시스템과 ANN 기반 시스템의 결함 탐지 성능을 비교하였으며, 정량적 지표뿐 아니라 현장 사용자 피드백을 통해 실효성을 종합적으로 검토하였다.

본 연구의 설계는 기술적 성능뿐만 아니라 실용성과 지속가능성 측면까지 통합적으로 검토할 수 있는 분석 틀을 제공하며, 이는 단순한 기능 검증을 넘어 학문적 가치와 산업적 활용 가능성을 동시에 확보하는데 이바지한다(김상진 외, 2021).



[그림 3-1] ANN 학습 및 적용 절차도

제 2 절 사례 기업 특성 및 선정 배경

본 연구의 실증 대상으로 선정된 기업은 위생용 고기능성 원단을 제조하는 국내 중소기업으로 선정되었으며, 해당 기업은 다품종, 대용량 생산 체제를 가지고 있다. 이 기업에서 생산되는 원단은 사람의 피부에 직접 접촉하여 사용되기 때문에 위생적 안전성과 품질의 균일성에 대하여 고객의 요구 수준이

매우 높다. 이런 특성으로 인해, 외관상의 아주 작은 결함도 소비자의 신뢰 하락, 불만족, 나아가 리콜로 이어질 수 있다. 이와 같은 특수성을 고려하여 본 연구가 ANN 기반 머신비전 검사 시스템을 생산 현장에 적용하기 위한 당위성을 제공한다. 실제 원면 이미지는 [그림 3-2]와 같다.



[그림 3-2] 실제 원단 이미지

사례 기업의 품질검사 방식은 샘플링 검사방법으로 사람이 직접 육안 검사로 운영되었다. 이 방식은 검사자의 주관적인 판단 또는 환경 요인에 따라 다른 결과를 나타내고 검사자마다 판단 기준이 다를 수 있다. 그 때문에 검사 누락, 과 검출, 오판단의 가능성이 있는 구조적 한계가 있다. 이에 따라 규칙 기반(rule-based) 머신비전 시스템의 도입을 검토하고자, 실제 생산 현장을 대상으로 사전 조사 및 테스트를 시행하였다. 그 결과, 낮은 조도, 반사, 포장 필름의 굴절, 접힘등의 제품 표면의 비정형 구조 때문에 다양한 외

란 요인으로 규칙 기반 알고리즘에서는 과 검출 및 누락 현상이 빈번하게 발생하는 것이 확인되었다. 이런 문제는 제품의 품질 신뢰도 하락뿐만 아니라 생산 효율 측면에서도 부정적인 영향을 미칠 수 있다. 특히 제품의 자동 포장 이후에는 현장 구조상 사람이 눈으로 수동 검사조차 할 수 없는 상황이 된다.

이러한 상황은 품질검사 시스템의 신뢰성 확보와 실시간 검출 역량이 생산 효율성 개선을 넘어 기업 생존과 직결되는 핵심 전략 과제로 작용한다. 이 때문에 본 연구는 해당 기업으로 선정하였다. 선정 이유는 다음과 같다.

첫째, 위생 소비재 산업은 제품 품질에 대한 민감도가 매우 높아 단일 결함이 전체 생산 로트의 폐기로 이어질 수 있으며, 이는 브랜드 신뢰도와 직결된다. 이러한 특성은 인공지능 기반 머신비전 시스템의 도입 필요성을 강하게 시사한다(강선우 외, 2024, p. 637).

둘째, 해당 산업의 공정 구조는 자동 포장 공정이 즉시 진행되어 OQC 수행이 어렵기 때문에, 생산 중 또는 포장 직전의 실시간 품질검사가 필수적이다. 이는 본 연구의 실증적 접근과 일치한다(강선우 외, 2024, p. 638).

셋째, 사례 기업은 소규모 IT 인력을 보유하고 있음에도 머신비전 시스템 도입에 대한 조직적 수용성이 높고, 기술 실험이 가능한 유연한 구조를 갖추고 있어 ANN 기반 시스템의 실증 적용에 적합한 환경을 제공한다 (강선우 외, 2024, p. 641).

결론적으로, 본 연구의 사례 기업은 품질 민감도가 높은 산업적 특성과 실시간 검사 요구, 그리고 기술 수용성이 높은 조직 구조를 동시에 갖추고 있어 ANN 기반 머신비전 시스템의 실증 적용 대상으로서 타당성을 지닌다. 이러한 특성은 연구의 현장 적합성과 일반화 가능성을 높이는 기반이 된다 (강선우 외, 2024, p. 644).

제 3 절 시스템 구성

현장 시스템 구성에 있어, 검사 대상은 지름 1m, 높이 3m 원통형 부직포를 대상으로 하였으며, 회전 방식은 30도 간격 회전으로 12면 검사를 진행하였다. 카메라는 5MP 12대를 6대씩 180도 방향으로 마주 보게 배열로 배


치하고, 조명은 내장형 LED, 반사판을 최소화하여 설계하였다. 서버는 영상 저장, 모델 추론, 이력 관리 기능을 수행하고, 모니터는 실시간 시각화 및 사용자 인터페이스 도구로 활용하였다. 설치 환경으로 조도 변화, 진동, 먼지 등 외란을 고려하였다([표 3-1], [그림 3-3], [그림 3-4]).

[표 3-1] 현장 시스템 구성

항목	내용
검사 대상	지름 1m, 높이 3m 원통형 부직포
회전 방식	30도 간격 회전 (12면 검사)
카메라	5MP 12대 (6대씩 180도 방향에서 마주 보게 배열)
조명	내장형 LED, 반사 최소화 설계
서버	영상 저장, 모델 추론, 이력 관리
모니터	실시간 시각화 및 사용자 인터페이스
설치 환경	조도 변화, 진동, 먼지 등 외란 고려



[그림 3-3] 5MP Vision Camera



[그림 3-4] Eyevision 4.4 Software

제 4 절 데이터 수집 및 전처리

본 연구에서는 실제 산업 환경에서 인공신경망(Artificial Neural Network, ANN)을 이용한 머신비전 기반 품질검사 시스템의 실용성과 안정성을 평가하기 위해, 검사 난도가 높은 위생용 원면 생산 공정을 선정하였다. 이를 위해 영상 데이터를 수집 및 처리하는 과정은 단순한 학습 데이터 구축에 그치지 않고, 다양한 형태의 결함과 외부 노이즈 상황을 포함하여 모델이 갖추어야 할 일반화 능력과 산업현장 적용의 가능성을 종합적으로 평가할 수 있도록 설계하였다.

위생 제품용 원면은 표면의 곡면 구조, 비정형의 주름, 반투명한 소재 특성, 질감의 불균일성 등으로 인해 영상 촬영 시 상당한 광학적 왜곡과 간섭이 나타나는 특성이 있다. 이를 극복하기 위하여 영상 획득 장치를 다각도 시야 확보와 광원의 변화에 따른 밝기 편차를 최소화할 수 있도록 설계하였다. 보다 구체적으로는 해상도가 2560×1936 픽셀인 5메가픽셀 CMOS 기반 산업용 머신비전 카메라 총 12대를 활용하였다. 각 카메라는 생산 설비의 좌우 양 측면에 각각 6대씩, 180도 방향에서 마주 보게 배치되었으며, 카메라 간의 FOV¹⁹⁾가 일부 겹쳐 보일 수 있는 간격을 두어 회전하는 원면의 전체 표면을 빠짐없이 촬영할 수 있게 하였다. 이러한 다중 각도의 카메라 배치 구조는 제품 표면의 불규칙적 결함을 다양한 시점에서 효과적으로 포착하여, 수집되는 학습 데이터의 대표성을 높이고 인공신경망 모델의 성능 안정성 향상에 중요한 임무를 수행하였다.

영상 취득 시 사용된 조명은 비전 카메라 내장형 백색 LED 조명으로, 생산 현장의 간섭을 최소화하기 위함이다. 초기에 촬영된 원본 이미지는 약 20,000장이었으며, 흐림 현상, 저 조도, 반사 등의 주변 환경 요인으로 품질 저하된 이미지는 필터링을 통해 제외하고, 최종적으로 약 15,000장의 적합

19) FOV(Field of View)는 카메라 또는 센서가 한 번에 관찰할 수 있는 시야 범위를 의미

이미지로 데이터셋을 구축하였다.

모델 학습의 효율성과 일반화 성능을 높이기 위해 정제된 이미지 데이터셋은 학습용(60%), 검증용(20%), 테스트용(20%)으로 분할되었으며, 각 결합 유형이 균등하게 반영되도록 층화 샘플링 기법이 적용되었다. 이 방식은 모집단을 기준에 따라 여러 층으로 나눈 뒤, 각 층에서 비례적으로 샘플을 추출함으로써 클래스 불균형에 따른 학습 편향을 효과적으로 줄일 수 있다(정화민 외, 2025).

이미지 전처리 단계에서는 Gaussian Blur²⁰⁾ 필터를 활용하여 고주파 노이즈를 제거하고 경계를 부드럽게 처리하였으며, Histogram Equalization²¹⁾ 기법을 통해 조도 불균형 및 명암 대비 저하 문제를 개선하였다. 이후 모든 이미지를 [0, 1] 범위로 정규화함으로써 모델의 학습 안정성과 수렴 속도를 향상했으며, 특히 ANN 기반 모델에서는 입력값의 정규 분포 유지를 통해 학습 편향을 최소화할 수 있었다(김민성 외, 2025).

모델의 일반화 성능 향상과 과적합 방지를 위해 데이터 증강 기법을 병행 적용하였다. 회전, 좌우 반전, 밝기 조절, 중심 크롭 등의 변형을 통해 다양한 입력 조건을 시뮬레이션함으로써, 결합 형태의 다양성과 환경 변화에 대한 대응력을 강화하였다(이수아 외, 2022).

데이터 라벨링 작업은 영상 기반 결합 검출의 정밀도를 좌우하는 핵심 과제로, 총 5가지 결합 유형([표3-2])에 대해 품질 관리 담당 2인이 수작업 라벨링을 수행하였다. 라벨링 도구는 CVAT 및 LabelImg를 병용하여, 결합 객체를 Bounding Box²²⁾ 형태로 지정하였고, 라벨 포맷은 Pascal VOC(.xml)²³⁾ 및 YOLO(.txt)²⁴⁾ 형식을 병행 생성하였다. 두 사람 간의 불

20) 가우시안 함수를 기반으로 노이즈 제거 및 경계를 부드럽게 처리하는 필터

21) 이미지의 명암 대비를 향상하기 위한 전처리 기법으로 특히 조도가 불균형하거나 어두운 이미지에 서 세부 정보를 더 잘 드러내기 위해 사용

22) 이미지 내 객체의 위치와 크기를 사각형 영역으로 지정하는 방식으로, 객체 탐지 및 분류 모델의 학습을 위한 대표적인 라벨링 형식

23) 객체 탐지용 라벨링 포맷 중 하나로, 이미지 파일명, 객체 클래스, Bounding Box 좌표(xmin, ymin, xmax, ymax)등의 정보를 XML 구조로 저장하며, 다양한 딥러닝 프레임워크에서 호환

24) 객체 탐지 모델 YOLO(You Only Look Once)에서 사용하는 라벨 포맷으로, 각 객체를 한 줄로 표현하며 클래스 ID와 함께 정규화된 중심 좌표(x_center, y_center) 및 너비, 높이를 순서대로 기록

일치율이 10%를 초과하면 제3자가 개입하여 최종 라벨을 확정하는 교차 검토(cross-validation) 절차를 도입함으로써, 데이터 신뢰성을 제고하였다. 두 라벨 포맷의 형식 비교표[표 3-3]는 다음과 같다.

[표 3-2] 불량 유형

이물 이미지	이물 유형	설명
	가늘고 긴 형태 이물	머리카락 같은 형태, 랩이 접혀 그림자와 구분
	벌레 형태의 이물	벌레 같은 형태, 랩이 뭉쳐진 부분과 구분
	열게 퍼진 형태 이물	퍼진 형태의 이물, 색상의 밝기로 구분
	나무 조각 같은 이물	두께가 있는 이물, 구분이 쉬움

[표 3-3] 라벨링 형식 비교표

항목	Pascal VOC(.xml)	YOLO(.txt)
파일 형식	XML	텍스트
객체 클래스 지정	<name> 태그 내에 명시	한 줄의 첫 번째 숫자로 클래스 ID 지정
바운딩 박스 좌표	<xmin>, <ymin>, <xmax>, <ymax> ,	정규화된 값으로 (x_center, y_center, width, height) 지정
이미지 크기	<width>, <height> 태그로 포함	포함되지 않음
다중 객체 지원	하나의 XML 파일에 여러 객체 가능	하나의 텍스트 파일에 여러 줄로 표현 가능
가독성	구조화된 XML로 사람이 읽기 쉬움	간결한 텍스트 형식
호환성	다양한 프레임워크에서 사용 가능	YOLO 기반 프레임워크에서 주로 사용

자료: Roboflow. (2022, March 15). How to Convert Annotations from PASCAL VOC to YOLO Darknet. Roboflow Blog. Retrieved June 20, 2025, from <https://blog.roboflow.com/how-to-convert-annotations-from-pascal-voc-to-yolo-darknet/>를 기반으로 연구자 재구성


결과적으로 자료수집 및 전처리 절차는 자료를 단순하게 준비하는 것이 아니다. 이것은 ANN 기반 머신비전 시스템의 학습 능력을 극대화하고, 분류된 결함 유형을 가지고 실무적으로 생산 현장에 적용 가능 등 다목적을 동시에 이루었다. 특히 중소 제조업체의 제한된 기술력 고려하면, 이러한 절차는 앞으로 비슷한 제품 또는 제조 환경에서 자체적으로 품질검사 시스템을 도입할 수 있을 것으로 기대된다.

제 5 절 분석 모델 및 알고리즘

본 연구는 중소 제조업체의 실제 생산 환경에 적합한 결함 검출 시스템을 구현하기 위해, 인공신경망(Artificial Neural Network, ANN) 기반의 머신비전 분석 구조를 설계하였다. 기존 규칙 기반 품질검사 시스템의 한계는 비정형 외란 조건(예: 조도 변화, 포장 반사, 표면 주름 등)에 대한 적응력 부족

과 결합 유형 간 불균형으로 인한 학습 편향에 있다. 특히, 기존의 CNN 단독 모델은 이미지 특징 추출에는 강점을 보이나, 복합적인 외란에 따른 의미적 분류(semantic decision)에서의 성능 저하가 보고됐다(He et al., 2016; Tan et al., 2019). 이에 본 연구는 CNN 기반의 다층 ANN 기반의 분류 구조를 결합하여 하이브리드 모델을 구현하였다.

모델의 구조는 크게 세 가지 단계로 구성된다. 첫째, 고해상도 이미지로부터 시각적 특징을 추출하기 위해 CNN(Convolutional Neural Network) 모듈을 도입하였다. 둘째, CNN을 통해 추출된 특징 벡터는 ANN(Artificial Neural Network)으로 전달되어 다층 퍼셉트론 형태로 구성된 분류기를 통해 이진 분류 작업을 수행한다. 셋째, 최종 출력층에는 시그모이드(Sigmoid) 함수²⁵⁾를 적용하여 결합 여부를 확률적으로 출력하도록 설계하였다. 이러한 구조는 외란 조건이 존재하더라도 특징 추출과 판단 과정을 분리함으로써 전체적인 학습 안정성과 일반화 성능을 확보하는 데 목적이 있다. ANN 기반 머신비전 분석 구조의 세부 설계는 [그림 3-5]와 같다.



[그림 3-5] Detailed ANN-based Machine Vision Analysis Structure

학습은 PyTorch 프레임워크²⁶⁾를 기반으로 수행되었으며, Optimizer로는

25) 시그모이드 함수는 입력값을 0과 1 사이의 확률적 출력으로 변환하는 S자 형태의 비선형 활성화 함수로, 주로 이진 분류 문제에서 출력층 또는 은닉층 활성화 함수로 사용된다. $\sigma(x) = \frac{1}{1 + e^{-x}}$

26) 동적 계산 그래프와 직관적인 인터페이스를 제공하는 오픈소스 딥러닝 프레임워크로, 연구와 실무 모두에서 널리 사용된다.(Paszke et al. 2019).

Adam²⁷⁾을 사용하였다. 손실 함수는 Binary Cross Entropy²⁸⁾를 채택하였으며, 클래스 간 불균형 문제를 보완하기 위해 class_weight 매개변수를 자동 조정하여 불량 샘플의 상대적 중요도를 반영하였다.

본 모델의 batch size를 32로 고정하여 150 epoch 동안 학습이 수행되도록 실험을 진행했다. 검증 데이터셋에서의 F1-score 변화를 통해 학습 수렴 여부를 판단하였고, 가장 높은 F1-score를 기록한 시점의 모델 가중치를 저장하여 테스트셋 성능 평가에 활용하였다.

모델의 학습 성능은 정량적 평가지표인 정밀도(Precision), 재현율(Recall), F1-score를 통해 평가되었으며, 각 결함 유형별을 분석하여 오탐율(FP)과 누락률(FN)을 비교하였다.

결론적으로, 본 연구에서 제안한 분석 모델은 단순한 알고리즘 구현을 넘어, 중소 제조기업의 인프라 환경과 결함 특성을 반영한 ANN 기반의 실용적 품질검사 구조를 제시한다는 점에서 의미가 있으며, 향후 유사 산업현장에서도 적용 가능성이 높은 구조로 평가된다(김동현 외, 2023).

제 6 절 연구 신뢰성 및 윤리적 고려 사항

본 연구의 목표는 중소 제조업체의 제한된 생산 환경 현장에 실제로 적용할 수 있는 인공지능 기반 머신비전 검사 시스템을 구축하는 것이다. 이러한 연구의 성격상, 분석의 객관성을 확보하고 결과의 타당성을 검증하기 위해 데이터의 신뢰성과 윤리적 관리가 핵심 전제 조건으로 요구된다(Tahir, 2024). 따라서 연구의 신뢰도와 당위성 확보를 위해 필요한 조치와 해당 업체의 내부 데이터를 활용하는 방법 및 범위에 대한 윤리적으로 문제 되지 않도록 한다.

먼저 높은 정확도의 데이터 라벨링을 위해, 결함 이미지에 대한 수작업 라벨링은 품질 관리 담당자에 의해 정의 되고 수행되었다. 라벨 불일치율이

27) 학습률을 자동으로 조정하면서 1차 및 2차 모멘트를 활용해 빠르고 안정적으로 최적화를 수행하는 알고리즘이다(Kingma & Ba, 2015).

28) 이진 분류 문제에서 예측 확률과 실제 정답 간의 차이를 측정하는 손실 함수로, 모델이 출력한 확률이 실제 레이블과 얼마나 일치하는지를 평가한다(Goodfellow, Bengio, & Courville, 2016).

10%를 초과하면 분류를 배제한 후, 제 3자를 통해 최종 라벨을 확정하였다. 이중 검토 절차는 ANN 모델 학습 과정에서 틀린 라벨로 오류 판정을 방지하고, 학습 데이터의 정확성을 높이는데 이바지한다.

정량 분석은 Precision, Recall, F1-score와 같은 핵심 성능 지표를 기준으로 기존 검사 방식과의 성능 차이를 분석하였다(하승재 외, 2021). 또한 연구 대상 기업의 기밀성 보호와 개인정보 노출을 피하고자 모든 수집 데이터는 비식별화되었고, 기업명, 제품 제원, 공정 조건 등 민감 정보는 논문 전반에서 익명 처리되었다. 영상 데이터는 암호화된 저장 환경에서 관리·분석되었다.

아울러 ANN 기반 시스템의 현장 수용성을 높이기 위해 사용자 인터페이스(UI)의 직관성, 유지보수의 용이성, 실시간 피드백 기능 등 사용자 친화적 설계 요소를 반영하였으며, 이는 Human-Machine Interaction(HMI) 원칙에 기반한 전략적 설계 결정으로 볼 수 있다(Wickens et al., 2015). 이는 시스템 도입 시 나타날 수 있는 조직 내 저항이나 인력 적응 문제를 최소화하기 위한 실용적 접근이다.

이처럼 본 연구에서는 기술 성능 평가와 더불어 데이터 신뢰성 확보, 기업의 윤리적 책임까지 통합적 관점을 기반으로 설계하고 진행되었다. 이러한 접근은 향후 유사한 산업 환경에서 AI 기반 품질 관리 시스템을 설계하고 평가하는 데 있어 실질적인 기준과 참고 자료로 활용될 수 있을 것이다(안성일 외, 2022).

제 4 장 시스템 개발 및 현장 적용

제 1 절 시스템 요구사항 분석 및 설계 목표

제조 현장에서 머신비전 기반 품질검사는 제품의 외관 이상을 자동으로 탐지하며, 공정의 일관성과 자동화를 실현하는 데 있어 핵심 기술로 작용한다. 특히 인력 의존도가 높은 중소 제조기업에서는 검사 품질의 균일성 확보, 생산성 향상, 비용 절감 등을 목적으로 머신비전 기술의 도입 필요성이 지속적으로 제기되고 있다(Reichenstein et al., 2022). 그러나 기존의 규칙 기반(Rule-Based) 머신비전 시스템은 복잡한 조명 반사, 제품 표면의 곡률 변화, 포장 필름 간섭 등 다양한 환경적 변수에 취약하여 실제 현장에서는 검사 신뢰도 확보에 한계를 보이는 경우가 많다(Malamas et al., 2003).

이에 본 연구의 목표는 인공신경망(Artificial Neural Network, ANN)을 기반으로 머신비전 검사 시스템을 설계하고, 다양한 외부 환경 변화에 적응할 수 있는 실시간 비접촉 정밀 품질검사가 가능한 머신비전 시스템을 구축하는 것이다. 이 시스템은 정밀한 결함 탐지와 더불어 사용자 친화적인 UI, 자동 이력 저장 및 추적 등을 포함한 종합적인 검사 환경을 제공해야 한다. 이를 달성하기 위해서는 제조 현장에서 요구되는 사항들을 분석하고, 요구 사항들을 반영한 설계 목표를 설정하였다.

제조 현장의 요구사항은 핵심 다섯 가지 요소로 요약된다. 첫째, 제품이 30도씩 회전하는 동안 실시간 촬영 및 분석이 가능해야 한다. 둘째, 포장된 상태의 제품에서 접촉하지 않고 외관 검사할 수 있어야 한다. 셋째, 조도 변화, 반사광, 포장 필름의 굴곡 등 외부 환경의 민감하게 반응하지 않고 일관된 성능 유지가 가능해야 한다. 넷째, 분류 시스템과의 연동을 통해 NG 제품을 자동 식별과 분리 동작이 가능해야 한다. 마지막으로, 이력 관리를 위해 판정 결과는 제품 단위로 자동 저장되어 클레임 대응이 가능해야 한다.

이러한 요구조건을 충족하기 위해 본 연구는 하드웨어와 소프트웨어가 유기적으로 연동되는 통합 아키텍처의 설계를 중심 목표로 설정하였다. 하드웨

어 구성 측면에서는 5MP 해상도의 산업용 머신비전 카메라 12대를 활용하여, 제품의 양 측면에 즉 180도 방향으로 각 6대씩 배치하고, 카메라 간의 FOV가 일부 겹쳐 보일 수 있는 간격으로 설정함으로써 회전 중인 제품의 전 표면을 누락 없이 포착할 수 있는 구성을 구현하였다. 이 구조를 통해 제품 1개당 평균 72장의 고해상도 이미지를 확보할 수 있었으며, 백색 LED를 내장형 조명으로 채택하여 조명 반사로 인한 노이즈를 최소화하고 조도의 균일성도 확보하였다.

소프트웨어 측면에서는 PyTorch 프레임워크를 기반으로 한 인공신경망(ANN) 모델을 핵심으로 구성하고, OpenCV를 활용한 영상 전처리 → CNN 계층 기반 특징 추출 → 완전 연결 층(Dense Layer)을 통한 결함 분류 → 결과 시각화 및 저장까지의 전체 흐름을 자동화된 구조로 설계하였다. 사용자 인터페이스(UI)는 EyeVision 플랫폼과 연동되어 작업자가 실시간으로 결함의 위치를 화면상에서 확인할 수 있도록 구성되었으며, 판별된 결과는 시리얼 번호를 기준으로 자동 저장되어 품질 이력 추적 및 사후 대응에 활용할 수 있게 하였다.

결론적으로, 본 절에서 제시한 아키텍처 설계 전략은 ANN 기반 머신비전 시스템이 실제 제조업 환경에 적용될 수 있도록 실용적 기준을 제시하며, 특히 중소 제조기업의 인프라 제약과 기술 역량을 고려한 자동화 수준, 실시간 처리 성능, 환경 적응력, 품질 데이터 관리 등의 요소를 균형 있게 반영함으로써 실용성과 확장성을 동시에 확보하고자 하였다(오윤환 외, 2023).

제 2 절 데이터셋 구성, 라벨링, 전처리 과정

인공신경망 기반 머신비전 시스템의 성능은 학습에 사용되는 데이터셋의 품질과 다양성에 직접적으로 영향을 받는다(Havrilla et al., 2024; Budach et al., 2022). 특히 제조 현장에서 실시간 검사를 수행하는 시스템의 경우, 실제 환경을 반영한 영상 수집 및 정제 과정은 시스템의 일반화 성능 확보를 위한 핵심 요소라 할 수 있다(UnitX Labs, 2025). 본 연구에서는 국내 중소 제조업체의 위생용 원단 생산 공정을 대상으로 대규모 고해상도 이미지 데이

터를 수집하고, 이를 필터링 및 라벨링 함으로써 효과적인 학습 데이터셋을 구축하였다.

본 연구에서 구축한 데이터셋은 영상 수집 단계에서는 제품 외관을 획득하기 위해 5MP(2560×1936 해상도) 급 CMOS 기반 비전용 카메라 12대를 활용하였다. 이 카메라는 6대씩 수직 배열되어 생산 설비의 양 측에 FOV가 겹치게 배열되었으며, 원단은 30도씩 회전하는 원통형 제품의 전체 표면이 누락 없이 촬영하도록 설계되었다. 컨베이어벨트에서 운송 중 검사를 위해 별도의 회전 원반에서 원단이 촬영되었고, 단위 제품당 72장의 이미지가 수집되었다. 전체 영상은 20,000장 이상으로 구성되었으며, 중복, 왜곡, 노이즈가 심한 프레임은 제거하고 총 15,000장의 유효 이미지를 정제하였다.

이러한 데이터는 학습(60%), 검증(20%), 테스트(20%)로 분할되었고, 계층적 샘플링을 활용해 클래스 간 비율을 유지하였다. 이는 데이터 불균형에 따른 성능 왜곡을 방지하고, 모델의 일반화 능력을 향상하려는 조치이다 (Buda et al., 2018). [표 3-2] 불량 유형을 기본으로 불량 라벨링을 정의하고 그 외 기타 이상을 포함 총 5가지 결함 유형으로 정의하였다. 품질 관리자가 Bounding Box 기반의 수작업 라벨링을 독립적으로 수행하였다. 라벨 간 불일치율이 10%를 초과하는 경우, 제3자가 교차 검토하여 최종 라벨을 확정하였다. 모든 라벨은 Pascal VOC(.xml)와 YOLO(.txt) 형식으로 병행 저장하여 다양한 딥러닝 프레임워크와의 호환성을 고려하였다.

결함 검출을 위한 전처리 과정은 Gaussian Blur 필터로 고주파 노이즈를 제거하고, Histogram Equalization 기법을 적용해 조도 불균형을 개선하였다. 이후 모든 이미지는 [0, 1] 범위로 정규화되었고, 신경망 입력 형식에 맞춰 224×224 픽셀로 크기 조정되었다. 모델의 일반화 성능을 높이고 과적합을 방지하기 위해 회전, 좌우 반전, 밝기 조절, 크롭 등의 데이터 증강 기법도 함께 적용되었다.

본 연구에서 구축한 데이터셋은 제조 환경의 곡률, 반사, 포장 상태 등 복합적인 변수들을 반영한 고품질 영상 기반 자료로, ANN 기반 머신비전 모델의 학습 효율성과 현장 적응성을 높이는 기반 인프라로 기능한다. 또한 라벨링의 정확성과 데이터의 다양성, 구조화된 처리 절차는 후속 연구 및 실증

시스템 개발 과정에서 높은 재현성과 일관성을 확보하는데 이바지할 것으로 기대된다(서호진 외, 2021).

제 3 절 인공신경망 기반 모델 설계 및 학습 절차

본 연구는 고해상도 영상 데이터를 이용하여 효과적으로 다양한 결함을 구분할 수 있는 인공신경망(Artificial Neural Network, ANN) 모델을 설계하고, 실제 결함 사례를 반영한 학습 과정을 수행하였다. 설계된 모델은 제조 현장에서 빈번하게 발생하는 반사광, 곡면 구조, 표면 주름 등과 같은 비정형 외란 요소에도 오류 없이 동작하도록 구성되었다. 다양한 환경적 변수에서도 높은 결함 검출 정확도를 유지할 수 있도록 설계되었다.

본 모델은 입력층, 은닉층, 출력층으로 구성된 다층 인공신경망 구조를 기반으로 하며, 주요 구성요소로는 합성곱 계층, 풀링 계층, 완전 연결 계층, 드롭아웃 계층, 그리고 시그모이드 활성화 함수를 사용하는 출력층이 포함된다(김미숙 외, 2018). 특히 CNN(Convolutional Neural Network) 기반의 특징 추출부를 ANN과 통합함으로써, 영상 내에서의 저차원 결함 패턴을 고차원적 특징 벡터로 추출하고 이를 효과적으로 분류할 수 있도록 설계되었다(Goodfellow et al., 2016; Albawi et al., 2018).

입력 영상은 전처리 과정에서 신경망 입력 구조에 맞춰 224×224 픽셀로 리사이징되었으며, 각 픽셀의 값은 $[0, 1]$ 범위로 정규화되어 모델 학습의 수렴 안정성과 연산 효율을 높였다. 모델의 입력부에는 3×3 크기의 필터를 갖는 두 개의 합성곱 계층(Conv2D)이 순차적으로 배치되었으며, 필터 수는 각각 32개와 64개로 설정되었다. 각 합성곱 계층 뒤에는 2×2 크기의 맥스 풀링(MaxPooling) 계층을 삽입하여 공간 차원을 축소하고, 특징 맵의 연산량을 줄였다(Chollet, 2018). 이후 Flatten 계층을 통해 다차원 출력을 1차원 벡터로 변환하였고, 128개의 유닛으로 구성된 완전 연결 층(Dense Layer)을 통과하도록 설계하였다. 과적합 방지를 위해 드롭아웃(Dropout) 기법을 적용하였으며, 비율은 0.3으로 설정하였다(Srivastava et al., 2014). 출력층은 단일 뉴런 구조로 구성하였으며, 이진 분류 문제 특성에 따라 활성화 함수로

시그모이드(Sigmoid)를 적용하여 결함 유무를 확률적으로 판단하도록 하였다.

학습은 PyTorch 프레임워크를 기반으로 수행되었으며, 손실 함수로는 Binary Cross Entropy를, 최적화 알고리즘으로는 Adam Optimizer(학습률 0.0001)를 적용하였다(Kingma et al., 2015). 전체 학습 과정은 총 100 epoch 수행되었으며, 학습 모델의 성능을 유지하고 과적합을 방지하기 위해 일정 기준 이상의 성능 향상이 없으면 학습을 조기 종료 전략을 수행하였다. 모델 학습 과정에서는 epoch마다 검증용 데이터셋을 활용하여 손실 함수값과 정확도를 평가하였으며, 가장 높은 성능을 기록한 시점의 파라미터를 기준으로 모델을 저장하였다. 이 방식은 학습 효율을 높이고 불필요한 반복 학습으로 인한 자원 낭비를 줄이는 데 효과적이었다(김도영 외, 2023). 데이터 불균형 문제에 대응을 위해 클래스 가중치 조정을 적용하였다. 이는 결함 클래스의 수가 현저히 적은 상황에서도 모델이 학습 편향을 최소화하고, 전반적인 탐지 민감도(Recall)와 정밀도(Precision)를 균형 있게 확보할 수 있도록 하는 전략이다(Zheng et al., 2025). 또한 데이터 증강 기법은 학습 데이터의 다양성을 향상시키고, 모델의 일반화 성능을 높이는 데 역할을 하였다. 증강 기법으로 회전, 반전, 밝기 변화, 중심 크롭 등은 결함 형태나 배경 변화에 높은 적응력을 보였고, 이후 실제 환경에서 높은 탐지 성능이 확인되었다.

본 모델은 학습 완료 후 ANN 알고리즘을 내포한 EyeVision 소프트웨어를 통해 머신비전 플랫폼과 통합되어, 영상 입력부터 판단, 시각화, 이력 저장까지의 전 과정이 자동화를 구현하였다. 특히, 분류 결과는 UI 상에 Bounding Box 형태로 시각화되었다. 이 결과 데이터는 제품의 시리얼 번호와 연계되어 이력 관리를 위해 서버에 자동 저장되도록 구성되었다.

종합적으로 인공신경망(ANN) 기반 머신비전 모델은 실제 제조 환경의 물리적 제약 조건과 데이터 특성을 반영하여 설계되었으며, 이를 통해 높은 학습 효율성과 실시간 추론 능력을 동시에 갖춘다. 특히 합성곱 신경망(CNN)을 기반으로 한 특징 추출 구조와 일반화 성능을 고려한 학습 전략은 다양한 결함 유형이나 제품 공정 변화에 대한 유연한 대응을 가능하게 한다

(Chollet, 2018). 이러한 강점은 자동 품질검사 시스템을 도입하고자 하는 중소 제조업체에 기술적으로 실현할 수 있음과 더불어 현실적으로 도입할 수 있음을 제공할 수 있는 사례로서의 의미가 있다.

제 4 절 시스템 구현 및 아키텍처 구성

본 연구는 인공신경망(Artificial Neural Network, ANN) 기반의 머신비전 모델을 실제 중소기업 제조 현장에서 통합 시스템으로 운용할 수 있는 구조로 구현하였다. 이 시스템은 영상 수집, 결함 탐지, 사용자 인터페이스(UI), 품질 이력 관리 등 주요 기능을 하나의 자동화 파이프라인으로 통합하였으며, 하드웨어와 소프트웨어의 융합을 통해 생산 현장에서 직관적인 판단을 지원한다. 특히 중소 제조업체의 숙련 인력 부족과 AI 기술 적용의 어려움, 자동화 설비 간 간섭 문제를 고려하여, 고해상도 영상 획득, 경량화된 분석 모델, 직관적 UI, 결함 및 이력 추적이 가능한 데이터 저장 구조를 포함한 실용적 머신비전 시스템을 구현하였다(김정태, 2020).

하드웨어 아키텍처는 원단의 전체 표면을 빠짐없이 균일한 영상 취득을 위해 12대의 비전 카메라를 구조적으로 연결하고, 원단을 회전시켜 이미지를 획득한다. 이 12대의 5메가픽셀 산업용 머신비전 카메라는 원단의 좌우 방향, 즉 컨베이어의 횡 방향 양측 중앙 지점에 각각 6대씩 수직으로 배열하였다. 화각의 중첩으로 사각을 미리 방지하여 검사 영역을 완벽하게 촬영하고, 원단별로 72장의 이미지를 확보할 수 있도록 한다. 조명은 카메라 내장 백색 LED 조명을 선택했고, 이유는 비전 검사 시스템 공간을 최소화하여 생산 환경에서 발생할 수 있는 간섭을 줄이기 위함이다.

소프트웨어 아키텍처는 다섯 단계의 모듈화로 영상 취득, 전처리, 분류 판단, 시각화, 이력 저장으로 이루어졌었으며, PyTorch 기반의 ANN 모델을 중심으로 전체 프로세스가 자동화되었다. 제조 환경에서 획득된 영상은 OpenCV 기반의 필터링 기법을 활용하여 노이즈 제거, 밝기 정규화, 대비 향상 등의 전처리 과정을 거친 후, ANN 모델의 입력으로 전달되었다. 이러한 전처리 절차는 영상의 품질을 개선하고 모델의 학습 안정성을 높이는 데 이

마지하였다(유원중 외, 2018). 모델은 CNN 계층을 통해 결함 특징을 추출하고, 최종적으로 결함 여부를 이진 분류 결과로 출력한다(O'Shea & Nash, 2015; Wikipedia contributors, 2025; Dataquest, 2025). [그림 4-1]에 이런 영상 처리 과정이 제시되었으며, 각 단계는 임무 수행은 다음과 같다. (a) 고해상도 카메라로 원본 이미지 수집되는 영상 취득 단계, (b) 크롭, 노이즈 제거, 밝기 보정을 통해 원본 이미지에 포함된 다양한 외란을 제거하고 이미지 품질을 최적화하는 전처리 단계. (c) ANN 모델이 NG로 판단한 영역을 시각적으로 강조하여 작업자가 결함의 위치와 형태를 직관적으로 파악하고 시스템이 신속한 판단을 할 수 있게 하는 마스킹 단계. 마지막으로 (d) 시각화 단계로 마스킹 된 결함 이미지가 UI에 실시간으로 표시되어 작업자가 검사 결과를 쉽고 빠르게 인지하고 정확한 조치를 할 수 있게 한다. 본 시스템의 성능을 평가하는 가장 중요한 과정은 영상 전처리와 시각화이다.

이러한 전처리 단계는 최종 결함 탐지 성능의 약 30~50%를 좌우할 만큼 중요하며, 본 연구에서 적용된 전처리 기법은 실제 제조 현장의 낮은 조도 및 다양한 외부 노이즈와 같은 현실적인 문제점들을 효과적으로 극복할 수 있다. 이를 통해 노이즈에 강한 대응력을 가지고, 결함 특징이 명확하게 추출된 이미지를 ANN 모델에 제공할 수 있었으며, 이는 제5절에서 보고된 98.7%의 높은 정확도 및 6.1%의 낮은 과 검출률 달성에 핵심적인 기반이 되었다. 또한, 결함 영역의 직관적인 마스킹 및 시각화는 기존 수동 검사나 단순 규칙 기반 시스템의 한계를 넘어서 판단 오류를 최소화하고, 생산 설비의 가동 중단 시간을 최소화하고 인력 의존도를 낮추는 등 중소 제조업체 생산 현장의 생산 효율성과 제품 신뢰성을 극대화할 수 있다.



모니터를 통해 출력된 분석 결과는 UI 상에서 실시간 시각화되며, 탐지된 결함의 해당 위치는 Bounding Box 형태로 화면에 표시된다. 사용자는 화면을 통해 결함 유형 및 위치를 직관적으로 파악할 수 있으며, 동시에 결과 데이터는 제품 시리얼 번호와 함께 서버에 자동 저장된다. 이 이력 데이터는 향후 품질 분석, 클레임 대응, 리콜 추적 등에 활용이 된다. 시스템 전반은 산업용 네트워크 환경에서의 안정적 운용을 고려하여 구성되었으며, ① 영상 취득부, ② 영상 분석부, ③ 시각화 및 사용자 인터페이스부, ④ 검사 결과

이력 저장부의 4개 모듈로 구성되었다(Ren et al., 2022). 특히 UI는 작업자가 쉽게 사용할 수 있도록 조작 절차를 최소화하였으며, 또한 시스템은 기존 생산 설비와의 간섭을 최소화하기 위해 독립형 구조로 설계되었으며, 유지보수 및 업그레이드가 쉽도록 일반적인 하드웨어 규격과 API²⁹⁾ 기반 연동 방식으로 구현되었다.

결과적으로, 본 절에서 구현된 시스템 아키텍처는 ANN 기반 판단 모델과 고해상도 영상 처리 기술을 통합함으로써, 실시간, 고정밀, 고신뢰의 품질검사 수행을 가능하게 한다. 이러한 구조는 단지 알고리즘 성능을 실증할 뿐만 아니라, 실제 제조 환경에서 이러한 기술이 적용 가능하다는 것을 보여주고, 산업적으로 활용 가능성이 높다는 것을 입증하는 계기가 된다. 앞으로 다른 제품군이나 다양한 생산 환경에 대한 시스템 확장도 유연하게 대응할 수 있을 것이다.



29) API(Application Programming Interface)는 서로 다른 소프트웨어 시스템 간의 상호작용을 가능하게 하는 인터페이스로, 특정 기능이나 데이터를 외부에서 접근하고 활용할 수 있도록 정의된 명령어 집합.





[영상 취득]

고해상도 카메라로 원본 영상이 수집된 초기 단계

[전처리(크롭, 노이즈제거, 보정)]

불필요한 영역 제거, 노이즈 감소, 밝기 및 대비 최적화를 통해 결함 특징을 명확히 하는 과정



[마스킹]

ANN 모델이 결함으로 판단한 영역을 시각적으로 강조 (마스킹)

[전 이미지 적용]

마스킹된 결함이 최종적으로 사용자 인터페이스에 표시되는 예시

[그림 4-1] CNN 영상 처리 과정

제 5 절 시스템 적용 결과

본 연구에서 개발된 인공신경망(Artificial Neural Network, ANN) 기반의 머신비전 검사 시스템은 국내 중소 제조업체의 위생용 원단 생산 공정에 실제로 적용되었다. 기존의 규칙 기반(Rule-Based) 검사 방식과 성능 비교를 통해 기술적 타당성과 실효성을 정량적 평가하였다. 시스템은 약 10개월 간의 동일한 환경 안에서 취득한 동일한 이미지를 가지고, 두 방식으로 대표되는 규칙 기반과 ANN 학습 방식으로 테스트하게 되었으며, 약 20,000건의 제품 영상이 수집되었고, 이 중 1,205의 동일한 영상이 분석에 활용되었다.

우선 결과적으로 정량적 성능 평가로 보면 ANN 기반 검사 시스템이 기존 Rule-based 시스템 대비 대부분의 성능 지표에서 우수한 결과를 나타냈다. 다음 [표 4-2]는 대표적인 분류 성능 지표, 정밀도, 재현율, F1-score를 기준으로 양 시스템의 성능을 비교한 결과를 나타낸다.

[표 4-1] 측정 결과 비교

판정 결과	구분	Rule based 기반 시스템		ANN 기반 시스템	
		변들 개수	비율	변들 개수	비율
Total 검사 수		1205		1205	
적중률			68.2%		98.7%
판정 오류			31.8%		1.3%
OK 적중	OK 판정	809	67.1%	1176	97.6%
NG 적중	이물 검출	13	1.1%	13	1.1%
판정오류상세	배경	81	6.7%	3	0.2%
	주름	158	13.1%	7	0.6%
	라벨화살표	35	2.9%	2	0.2%
	상면부	34	2.8%	1	0.1%
	센터링장치	19	1.6%	0	0%
	etc	56	4.6%	3	0.2%
모델링 컨셉		다양한 NG 규칙 적용		7차 과검출 CASE 학습	
적용 결과		주름, 밝기, 기타 외부 환경에 따라 오탐지 많음		목표치 달성 (95%이상)	

[표 4-2] Rule-based 기반 시스템과 ANN 기반 시스템 성능 비교

지표	Rule-based 기반 시스템	ANN 기반 시스템	설명
TP	13	13	[표 4-1]의 NG 적중 수
FP	383	16	[표 4-1]의 판정오류상세 합
FN	0	0	없음(NG인데, OK로 탐지)
정밀도 %	3.28	44.83	$Precision = \frac{TP}{(TP + FP)}$
재현율 %	100	100	$Recall = \frac{TP}{(TP + FN)}$
F1-score%	6.36	61.9	$F1-score = \frac{2 * (Precision * Recall)}{(Precision + Recall)}$

위의 [표 4-2]는 정량 지표를 얻기 위해, 제2장의 [표 2-6] 정량 지표의 공식을 활용하여 계산한 결과값을 정리한 것이다.

본 연구에서는 Rule-based 시스템과 ANN 기반 시스템의 품질검사 성능을 비교 평가하기 위해 정밀도, 재현율, F1-score를 주요 평가지표를 사용했고, 각각의 정밀도, 재현율, F1-score는 [표 4-2]의 결과값을 보여주었다.

두 시스템에서 재현율이 100%로 나타난 이유는 과 탐지의 오류는 있지만, 실제 NG인 제품은 두 시스템에서 모두 잘 탐지되었음을 의미한다. 하지만 정밀도에서는 Rule-based 기반 시스템은 다양한 상황에서 OK 제품을 NG로 인식하는 경우가 아주 많아 상대적으로 정밀도가 매우 낮았다. 이에 따라 F1-score도 낮게 되었다. 이것은 낮은 조도, 표면 주름, 반사 등 환경 변수의 영향을 많이 받는 Rule-based 기반 시스템의 한계를 보여준다.

반면 ANN 기반 시스템은 동일한 재현율을 유지하면서도 정밀도와 F1-score가 높게 나타났다. 이는 ANN 기반 시스템이 다양한 환경 조건에서도 정밀한 학습을 통하여 오류를 최소화함으로써, 품질 관리 측면에 더 적합한 기술임을 실증적으로 보여준다.

[표 4-3]은 ANN 기반 시스템에서 모델링 컨셉을 설정 후 회차별 문제점을 정리하고, 보완된 학습을 통해 목표치에 접근하는 데이터를 보여준다. 초기 모델은 제한된 이미지 데이터를 기반으로 학습되었고, 1차 테스트에서

는 87%의 적중률을 보였다. 하지만 판정 오류율이 12.8%로 높게 나타났다. 2회차부터 8회차에 걸쳐 수정된 모델로 재학습을 진행하였다. 각 회차에서는 이전 사례를 기반으로 라벨링 오류를 수정하고, NG 검출 항목 중 이물, 배경, 주름 등의 세부 요소를 정리하여 학습 데이터에 반영하였다.

이런 이유로 4차 이후부터는 오류 판정률이 급격히 감소하여, 8차에서는 적중률이 99%에 이르렀다. 이는 반복 학습을 통해 진화한 ANN 기반 시스템이 점진적으로 성능 향상을 할 수 있다는 지표이다.

이러한 결과를 보여주는 데이터는 [표 4-3]의 모델 학습에 따른 성능 개선에서 잘 나타나 있다.

실험을 통해 확인된 성능 개선과 현장 피드백은, ANN 기반 검사 기술이 단순한 정확도 향상을 넘어 제조 환경의 효율성과 품질 관리의 디지털화를 실현할 수 있음을 보여준다. 본 연구는 이러한 자동화 기술이 중소기업의 스마트 제조 전환을 위한 실질적 대안으로 작용하며, 지속 가능한 생산 시스템 구축에 이바지할 수 있음을 제안한다(Seo et al., 2022).

본 시스템은 향후 다양한 제품군에의 적용 확장과 유연한 다품종소량생산 대응, 그리고 학습 기반 피드백 기능의 통합을 통해 더욱 정교화될 수 있다. 이러한 발전은 제조업의 디지털 전환을 촉진하며, 스마트팩토리 실현을 위한 핵심 기술로 자리 잡을 수 있다(Yong, 2022).

[표 4-3] 모델 학습에 따른 성능 개선

판정 결과	구분	1차		2차		3차		4차		5차		6차		7차		8차	
		2/20 ~ (11days)		3/28 ~ (4days)		4/25 ~ (2days)		7/16 ~ (4days)		8/13 ~ (10days)		9/1 ~ (3days)		11/1 ~ (6days)		11/19 ~ (7days)	
		변들 개수	배율 %	변들 개수	배율 %	변들 개수	배율 %	변들 개수	배율 %	변들 개수	배율 %	변들 개수	배율 %	변들 개수	배율 %	변들 개수	배율 %
Total 검사수		3254		396		721		1338		3827		875		1524		2095	
적중률			87		67		78		95		93		94		89		99
판정오류			12.8		33.1		22.2		4.9		6.6		6.2		11.1		1.0
OK 적중	OK 판정	2800	86.0	180	45.5	426	59.1	1160	86.7	3542	92.6	683	78.1	1246	81.8	2025	96.7
NG 적중	이물 검출	38	1.2	85	21.5	135	18.7	113	8.4	32	0.8	138	15.8	109	7.2	49	2.3
판정오류 상세	배경	103	3.2	3	0.8	20	2.8	15	1.1	79	2.1		0	14	0.9		0
	주름	156	4.8	101	25.5	11	1.5	13	1.0	122	3.2	37	4.2	98	6.4	9	0.4
	라벨화살표	99	3.0	24	6.1	20	2.8	18	1.3	7	0.2	5	0.6	22	1.4		0
	상면부	33	1.0	2	0.5	47	6.5	2	0.1	45	1.2	12	1.4	35	2.3	10	0.5
	센터링장치	10	0.3		0	62	8.6		0		0		0		0		0
	etc	15	0.5	1	0.3		0	17	1.3		0		0		0	2	0.1
모델링 컨셉		운전 초기 이미지로 학습		1차 과검출 CASE 학습반영		2차 과검출 CASE 학습반영		3차 과검출 CASE 학습반영 검사환경 변화 고려, 정상이미지 학습		4차 과검출 CASE 학습, AI 프로그램 버전 UP, 신규모델 생성		5차 과검출 CASE 학습		6차 과검출 CASE 학습		7차 과검출 CASE 학습	
적용 결과		NG 검출 중, 결점의 과검출 비율 89%		과검출 비율 개선, 주름/라벨 등 정상인식 학습 필요		물 라벨 개선관련 검사환경 변화, 과검출 증가		과검출 비율 개선, NG신호중 이물적중률 63%		과검출 비율 과도하게 높음		주름형태의 과검 비율 높음		주름형태, 상면부의 과검출 비율 높음		목표치 달성 (95%이상)	

제 5 장 결론

제 1 절 연구 결과 요약 및 논의

본 연구는 중소 제조기업의 품질검사 자동화 및 검사 정밀도 향상을 목적으로, 인공신경망(Artificial Neural Network, ANN) 기반 머신비전 시스템을 개발하고, 실제 생산 현장에 적용함으로써 기술적 타당성과 실무적 유효성을 실증적으로 검토하였다. 대상 기업은 위생용 부직포를 자동 포장하는 중소 제조기업으로, 기존에는 사람이 직접 육안 검사를 수행해 왔다. 그러나 기존 시스템은 조명 반사, 곡면 굴절, 포장 필름 등의 외란에 취약하여 결함 검출 누락이나 과 검출 사례가 빈번하였다.

이에 대응하여, 본 연구에서는 총 20,000장의 고해상도 영상 자료를 수집하고, 이 중 15,000장을 학습(60%), 검증(20%), 테스트(20%)용으로 활용하여 CNN 기반 ANN 모델을 PyTorch 프레임워크로 학습시켰다. 모델 학습 과정에는 Binary Cross Entropy 손실 함수, Adam Optimizer(learning rate = 0.0001), ReLU 활성화 함수, Early Stopping 등이 적용되었다.

정량적 성능 비교 결과, ANN 기반 시스템은 기존 시스템 대비 모든 주요 지표에서 우수한 성능을 기록하였다. ANN 시스템의 평균 정확도는 98.70%로, 기존 시스템의 68.20%에 비해 30.5% 향상되었으며, 정밀도(Precision)는 0.91로 기존(0.65)보다 0.26 높았다. 재현율(Recall)은 ANN이 0.88, 기존 시스템은 0.72를 기록하였으며, F1-score는 ANN이 0.89, 기존은 0.68로 ANN 모델이 약 30.9%의 성능 향상을 보였다. 특히 과 검출률(False Positive Rate)은 ANN 시스템이 6.10%로, 기존 시스템의 22.40%에 비해 약 16.3% 감소하여, 불필요한 검사 개입과 오작업 가능성을 현저히 줄였다.

이러한 수치는 ANN 모델이 다양한 물리적 외란 조건 속에서도 강인한 일반화 성능을 보이며, 실제 생산 환경에서의 운영 안정성과 정확성을 확보할 수 있음을 입증한다. 특히 섬유 주름, 오염, 패턴 밀림 등과 같은 복잡한

결함 유형에 대해서도 높은 탐지율을 유지한 것으로 나타났다.

정성적 측면에서도 사용자의 만족도는 높게 평가되었다. 반구조화 인터뷰에 참여한 현장 작업자 및 품질 관리자들은 시각화 UI의 직관성, 결함 위치 표시의 명확성, 이력 저장의 실용성 등을 언급하며 기존 시스템 대비 명확한 개선 효과를 체감했다고 응답하였다. 특히 실시간 결함 알림과 시각적 표시 기능은 작업자의 판단 피로도를 줄이고 생산 효율성을 높이는 데 이바지하였다.

다만, 일부 제한점도 함께 식별되었다. 첫째, 데이터셋 내 결함 유형 간 불균형으로 인해 일부 희귀 결함 클래스의 탐지 성능은 상대적으로 낮았다. 둘째, 포장 필름 반사 및 조명 불균형 등의 조건에서 영상 품질 저하가 발생하면 탐지 정확도 역시 하락하는 현상이 나타났다. 셋째, ANN 시스템의 유지보수 및 재학습에는 일정 수준 이상의 AI 기술 역량이 요구되어, 중소기업 내부 역량만으로는 장기적 자율 운영에 한계가 있다는 점도 확인되었다.

결론적으로, 본 연구의 ANN 기반 머신비전 시스템은 제한된 자원 환경에서도 고정밀, 고신뢰도의 검사 성능을 발휘하며, 실제 현장에서의 적용성과 수용 가능성을 입증하였다. 이는 중소 제조기업의 품질 관리 혁신을 위한 실질적인 대안으로 기능할 수 있으며, 향후 스마트 제조로의 전환에 이바지할 수 있는 기반 기술로 평가된다.

제 2 절 시사점

본 연구는 중소 제조업체의 자동화 품질검사를 위한 인공지능 기반 머신비전 시스템의 도입 및 생산 현장 적용 가능성을 실제 시스템 구축을 통해 입증한 사례로써, 이론적 탐색과 실무적으로 의미 있는 시사점을 제공한다.

먼저, 학문적으로 본 연구는 인공신경망(Artificial Neural Network, ANN) 기반 머신비전 시스템의 실제 생산 현장 적용을 수행한 선행 사례로서 의의가 있다. 기존 인공지능 기반 머신비전 연구가 주로 제한된 실험실에서의 알고리즘 성능 최적화에 집중하고, 정형화된 데이터셋을 활용한 이론적 검증에 집중하였다. 본 연구는 실제 생산 환경에서 발생하는 다양한 제약 조

건들 예를 들면, 비정형 결함, 포장 필름의 반사, 조도 변화 등에서도 ANN 기반 품질검사 시스템이 안정적인 성능을 유지할 수 있음을 실제 검증하였다. 특히, 경량화된 신경망 구조를 활용하여 오탐지 및 과 검출을 최소화하고, 다양한 외란 조건에서도 견고한 성능을 유지할 수 있었다(Zhang et al., 2023; Xu et al., 2025). 이러한 결과는 인공지능 기반 머신비전 검사 기술이 제조 산업에 적용 가능성을 입증하였다.

또한, 본 연구는 데이터의 수집부터 라벨링, 전처리, 신경망 학습, 시스템 적용 및 성능 평가까지 전 과정을 포괄하는 엔드투엔드(end-to-end) 방식의 통합적 연구 설계를 기본으로, 품질검사 시스템의 구현 방안을 제시하였다. 특히 인공신경망(ANN)의 구조와 입력 데이터의 품질 간 상호작용을 정량적으로 분석함으로써, 데이터 전처리가 모델링 과정에서 성능에 미치는 결정적 영향을 강조하였다. 이런 접근 방법은 인공지능 기반 제조, 생산 응용 연구에서 데이터 준비 과정이 단순 사전 단계가 아니고, 이론적·실무적 측면 모두에서 핵심 요인으로 인식될 수 있을 것이다.

나아가, 복잡적이고 비정형적인 결함(예: 미세 주름, 조명 난반사 오류 등)에서는 기존의 Rule-based 방식으로는 감지하기 어렵거나 오 탐지율이 높았지만, ANN 기반 시스템에서는 이러한 결함에 대해 훨씬 높은 탐지 성능이 있음을 증명하였다. 이는 생산 품질 관리 측면에서 비정형 결함 데이터 학습의 효용성을 제시한 사례로 평가될 수 있고, 앞으로 스마트 품질 관리 시스템 설계에 있어 ANN 기반 기술의 활용 가능성을 제공한다. 규칙으로 정할 수 없는 다양한 결함 유형에 대한 자동화된 품질 관리 역량 강화에 이 용할 수 있는 토대를 제공한다.

실무적 관점에서, 본 연구는 중소기업이 처한 자원 부족 상태에서도 인공지능 기반 머신비전 시스템을 실제 도입하고 운용할 수 있음을 경제적이고 현실적 가능성을 입증하였다. 본 시스템은 고가의 특수 장비 대신 범용 산업 용 카메라와 공개된 오픈소스 프레임워크(PyTorch, OpenCV 등)를 활용하여 구축되었고, 이는 중소기업 현장의 높은 비용 민감성과 상대적인 기술 인프라 제약을 현실적으로 고려한 접근이다. 특히 영상 취득부터 분석, 결과 저장, 시각화까지의 통합 시스템 구조는 운영 복잡성을 최소화하고 유지보수

를 편리하게, 실무적 강점을 제공하며 중소기업의 디지털 전환에 대한 부담을 덜어 준다. 아울러, ANN 기반 시스템은 기존 Rule-based 시스템 대비 [표 4-1]에서 보듯이 적중률이 30% 이상의 정확도 개선을 보였으며, 특히 과 검출을 획기적으로 감소시켜 현장 작업자의 시스템에 대한 신뢰와 만족도를 크게 향상시켰다. 이는 품질검사 자동화 시스템이 단순히 사람의 판단을 대체하는 것이 아니라, 인공지능 기술이 사람의 판단 능력을 보조하고 증강하는 형태로 설계되었기 때문에 가능한 결과였다. 이러한 사용자 중심 설계는 중소기업과 같이 기술 수용에 대한 거부감이 있을 수 있는 현장에서 신기술 도입의 성공적인 확산과 지속적인 활용을 고려하는 핵심 요소로 작용하였다.

더불어, 본 시스템은 검사 결과의 이력 관리 시스템을 갖추고 있어, 불량 발생 시간 및 위치 정보, 시리얼번호 등이 기록됨과 동시에 체계적으로 데이터베이스화되어 저장된다. 이는 생산 현장에서 단순한 검사 도구로만 취급받지 않고, 품질개선, 고객 클레임 대응, 리콜 추적 등 품질 관리 전반의 정보화와 지능화를 지원하는 실무 도구로서의 가치를 입증한 것이다. 또한 EyeVision 소프트웨어와의 연계는 기존 공정 제어 시스템과 자연스러운 통합성을 높여, 현장 투입 시의 이질적인 요소를 줄이고 실효성 및 확장성을 강화하는 중요한 조건으로 작용하였다. 마지막으로, 본 연구 결과는 머신비전 시스템이 규칙화, 정형화된 결함 탐지를 넘어, 예측 불가능하거나 비정형적인 결함, 열악한 외부 환경에 대한 대응력을 강화함으로써, 스마트팩토리 실현의 핵심 기술 요소로 자리매김할 수 있음을 강력히 시사한다. 이는 데이터 기반의 지능형 품질 관리 시스템 구축을 통해 제조 현장의 생산성과 제품의 품질 경쟁력을 근본적으로 향상할 수 있는 방향성을 제시한다.

제 3 절 후속 연구의 제언

본 연구는 인공신경망(Artificial Neural Network, ANN) 기반 머신비전 기술이 중소 제조업체의 생산 환경하에서 품질검사 적용이 가능한가에 대한 실증적 검토를 중심으로 수행되었으며, 결과적으로 기대 수준 이상의 검사

성과 실무적으로 적용할 수 있는 것을 입증하였다. 하지만 여러 가지 기술적 한계와 운용에 대한 한계가 발견되었으며, 이러한 한계들은 향후 연구에서 심층적으로 다루어야 주제로 제시된다.

첫 번째로 고려해야 할 핵심 과제는, 데이터 학습 기반 시스템의 일반화 가능성을 확보하는 것이다. 본 연구는 단일 제조업체의 특정 제품을 중심으로 ANN 기반 머신비전 모델을 설계하고 실험을 수행하였기 때문에, 제품 종류가 변경되거나 생산 공정의 조건이 달라지면 기존 설계 모델의 적용에 제한이 있을 수밖에 없다. 이러한 한계는 실제 산업현장에서의 다양성과 복잡성을 반영하지 못하는 구조적 문제로 이어질 수 있다. 따라서 후속 연구에서는 다양한 산업군과 공정 조건을 적절히 만족하는 다중 사례 기반의 비교 분석이 필요하다. 예를 들어, 의류 제조, 식품 포장재 생산, 정밀 전자 소재 가공 등 다양한 제품 특성과 결합 유형을 가진 산업 도메인을 대상으로 공통 적용할 수 있는 범용적 머신비전 학습 모델을 개발함으로써, ANN 기반 품질검사 시스템의 중소 제조 산업의 확장성과 적응 가능성을 이론적으로 검증할 수 있을 것이다(Picard et al., 2025).

둘째, 지속적으로 발전하는 최신 고도화된 딥러닝 구조와의 성능 비교 및 실험적 검증은 향후 연구에서 반드시 수행되어야 할 과제이다. 본 연구에서는 현장 적용 가능성을 우선으로 고려하여 경량화된 다층 ANN 구조와 일부 CNN 필터 기반 모델을 기반으로 품질검사 시스템을 설계하였으나, 최근 영상 기반 결합 탐지 분야에서는 ResNet, DenseNet, EfficientNet, Vision Transformer(ViT) 등 복잡하고 고성능의 딥러닝 아키텍처가 활발히 활용되고 있다. 이러한 최신 딥러닝 아키텍처들은 다양한 시각적 조건과 결합 유형에 대해 높은 표현력과 일반화 성능을 제공하며, 특히 제조 환경에서 실질적으로 적용 가능한가에 대한 평가가 요구된다. 후속 연구에서는 이러한 모델들을 실제 생산 조건에 적용하여 기존 시스템과의 성능 차이를 분석하고, 정확도뿐 아니라 모델 경량화 수준, 학습 및 추론 속도, 시스템 사용량, 파라미터 수 등 비기능적 성능 지표를 포함한 다각적 능력 비교 분석을 수행해야 한다. 이를 통해 각 구조의 장단점을 파악하고, 제조 환경에 따른 최적화된 선택 모델을 제시할 수 있을 것이다(IEEE TNNLS, 2025; Springer, 2025).

셋째, 지속적으로 변화하는 제조 환경에 대응하기 위해, 전이 학습과 온라인 학습을 활용하여 다양한 환경에 적응성 향상을 위한 연구가 더욱더 중요해지고 있다. 실제 생산 현장에서는 신제품 출시, 다양한 결함 유형, 조도 및 환경 조건의 변화 등 복잡다단한 요인들이 작동하며, 이러한 유동적 조건들은 기존의 규칙 기반 학습 모델로는 대응하기에 효과적이지 않다. 특히, 새로운 학습 모델을 초기 단계부터 대규모 데이터셋으로 학습시키는 방식은 시간과 비용 측면에서 비효율적이며, 실제 현장에 적용 제약을 줄 수 있다. 이에 따라, 사전 학습된 대형 모델을 특정 환경에 맞게 미세 조정하거나, 적은 샘플만으로도 빠르게 재적응시킬 수 있는 전이 학습 기반 품질검사 시스템의 개발이 핵심 과제로 떠오르고 있다. 더 나아가, 생산 현장에서 지속적으로 수집되는 검사 데이터를 실시간으로 반영하여 적용 모델을 자동으로 보정, 업데이트할 수 있는 온라인 학습 구조의 도입은 시스템의 적응성과 최적 상태를 유지하는 데 필수적인 요소로 평가된다. 이러한 접근은 다양한 도메인 간의 지식 이전과 실시간 반응성을 동시에 확보할 수 있는 전략으로, 제조 AI의 실용성과 확장성을 높이는 데 이바지할 수 있다(Zhao et al., 2025).

넷째, ANN 기반 품질검사 시스템의 실효성과 지속적인 개선을 위해서는 Closed-loop 품질 관리 구조에 대한 종합적 접근이 필요하다. 본 연구에서는 결함 탐지 결과를 시각화하고 저장하는 수준에서 기능이 제한되었다, 사용자 피드백을 실시간으로 수집하거나 이를 학습 과정에 반영하는 완전한 순환 구조는 구현되지 못했다. 향후 연구에서는 작업자의 오류 판정 수정, 오탐지 라벨의 재지정, 새로운 결함 유형의 추가 등 현장에서 발생할 수 있는 다양한 피드백 정보를 시스템에 통합하여, 지속적으로 학습 정확도를 높일 수 있는 자율적 품질 관리 구조 체계가 필요하다. 이러한 구조는 전문가의 판단과 기계학습 알고리즘 간의 상호작용을 기반으로 하는 하이브리드 학습 체계로 발전할 수 있으며, 특히 중소 제조업체의 제한된 운영 환경에서도 동시에 높은 적응성과 안정성을 확보할 수 있는 전략적 접근이 될 수 있다. 최근 컨퍼런스 발표에서는 LLM 기반의 품질검사 시스템이 인간 피드백을 통합하여 실시간 결함 탐지와 정보 해석을 동시에 수행하는 구조를 제안

하며, 이러한 페루프 시스템의 산업적 확장 가능성을 강조하고 있다 (Bianchini et al., 2025).

다섯째, 효율적이고 정밀한 품질검사를 위해서는 데이터 라벨링의 자동화 및 고도화에 관한 연구가 반드시 동반되어야 한다. 본 연구에서는 초기 데이터셋 구축 시 사람의 수작업에 의존한 Bounding Box 방식이 사용되었는데, 이 방식은 대규모 데이터셋을 구성하는 데 있어 너무나도 많은 시간과 비용이 소요될 뿐만 아니라, 작업자의 주관적 판단에 따른 라벨링 오류가 발생할 수 있는 구조적 한계를 내포하고 있다. 앞으로는 결함 영역을 더 세밀하게 구분할 수 있는 세그멘테이션 기반 자동 라벨링 알고리즘과 최소한의 라벨링으로도 효과적인 학습이 가능한 weak supervision 및 active learning 기반의 자동화 기법이 도입되어야 한다. 특히 제조 현장에서 결함 발생 빈도가 낮은 경우, 데이터 불균형 문제를 극복하기 위한 소수 샘플 기반 학습 전략이나 데이터 증강 기법을 활용한 접근이 필요하다. 최근 연구에서는 YOLO 및 Faster R-CNN을 활용한 자동 결함 분류 시스템이 다양한 결함 유형을 구조화하여 분류하고, 이를 기반으로 공정 개선을 위한 처방적 피드백까지 제공하는 페 루프 품질 관리 구조를 제안하고 있다(Alvares et al., 2025).

여섯째, ANN 기반 품질검사 시스템의 경량화와 실시간 반응성 향상은 제조 현장 적용하기 위한 핵심 기술 과제이다. 현재 구성된 모델은 고정된 비전 카메라에서 영상을 취득하고 고정된 서버 환경에서 학습 및 추론이 이루어지고 있으며, 이는 시스템의 유연한 운영을 제한하고 현장 설치 시 물리적 제약을 초래할 수 있다. 이러한 한계를 극복하기 위해, 향후 연구에서는 모델 구조를 경량화하여 엣지 컴퓨팅 장치나 임베디드 시스템에서도 실시간 추론이 가능하도록 최적화 전략이 필요하다. 또한, 클라우드 기반 스트리밍 분석 구조를 활용하여 분산 환경에서도 안정적인 응답성을 확보할 수 있는 시스템 설계가 요구된다. 더불어, 작업자의 이동성과 현장 접근성을 고려한 모바일 인터페이스 연동 및 경량화된 사용자 UI 개발을 통해 실무 활용도를 높이는 방안도 함께 검토되어야 한다. 최근 연구에서는 경량화된 딥러닝 모델을 엣지 환경에 최적화하여 실시간 품질검사에 적용한 사례가 보고되고 있으며, 이는 제조 AI의 현장 적용 가능성을 크게 확장하는 방향성을 제시

한다(Springer, 2025).

마지막으로, 인공지능 기반 품질검사 시스템의 플랫폼화 및 상용화에 관한 지속적인 연구가 필요하다. 본 연구는 단일 구축 사례를 중심으로 한 초기 수준의 시스템을 제안 및 시스템 구축을 하였으며, 광범위한 산업 적용과 플랫폼 확장성에 대한 논의는 아직 제한적이다. 향후 연구에서는 품질검사 기능을 넘어 생산 모니터링, 데이터 통합 분석, 경보 시스템 연동, 생산 계획 최적화 등 다양한 기능을 통합할 수 있는 다기능 플랫폼 개발을 목표로 설정해야 한다. 이를 위해 모듈화된 시스템 구조, 표준화된 API 인터페이스, 효율적인 유지보수 전략이 포함된 설계가 필요하다. 이러한 요소들은 중소 제조업체에 특화된 AI 기반 품질 관리 서비스(Quality-as-a-Service, QaaS)로의 확산 가능성을 높이는데 이바지할 수 있다. 궁극적으로 이러한 플랫폼화 전략은 제조업 전반의 디지털 전환을 가속화하고, 인공지능 기술의 산업적 실용성을 강화하는 기반이 될 것이다(Bianchini et al., 2025).

결론적으로, 본 연구는 인공지능망(ANN) 기반 품질검사 기술이 실제 제조 현장에 적용할 수 있음을 실증적으로 보여주었다. 중소 제조업체의 스마트 제조 전환을 위한 실질적인 기술 대안을 제시했다는 점에서 의미 있는 기초 연구로 인정될 수 있다. 그러나 스마트 제조의 본격적인 실현과 산업 전반으로의 확산을 위해서는 본 연구에서 확인된 여러 기술적·운영적 문제점을 해소하고, 다양한 제조 환경과 사용자 요구를 포괄할 수 있는 기술적 확장성과 정책적·제도적 지원이 병행되어야 한다. 향후 연구에서는 이러한 복합적인 후속 과제를 중심으로, 인공지능 기반 품질 관리 시스템의 실용성과 확장성을 높이는 방향으로 연구가 지속되어야 하며, 이는 제조업의 디지털 전환을 가속화하고 산업 경쟁력을 강화하는 데 이바지할 수 있다(Bianchini et al., 2025).

참 고 문 헌

1. 국내문헌

- 『』
- 강선우, 오성현, 김정곤, 이용수. (2024). AI 기반 검사장비 교체주기 예측 플랫폼. 『한국통신학회논문지』, 49(4), 636-644.
- 강성규, 박현준, 최원용. (2022). 코로나19 시대 마켓컬리의 경영전략 분석: VRIO 분석법과 전략적 혁신, 문화를 중심으로. 『문화산업연구』, 22(4), 105-114.
- 김동현, 이재훈, 박성우. (2023). AHP를 활용한 제조데이터, AI기반 중소 제조 기업 혁신을 위한 핵심 정책의 전략적 우선순위 도출에 관한 연구. 『한국산업경영시스템학회지』, 46(1), 1-20
- 김미숙, 강태원. (2018). 다층신경망의 다양한 연결구조와 학습 성능 분석. 『한국정보기술학회논문지』, 16(4), 1-10.
- 김민성, 곽수영. (2025). 고주파 보강 및 스타일 전이를 적용한 GLEAN 기반 위성 영상 초해상화 기법. 『한국학술지 인용색인』 (KCI).
- 김병기, 이종수. (2024). 중소 제조업의 품질관리 디지털 전환 전략. 『*산업정보연구*』, 29(2), 112-123.
- 김상진, 차우창. (2021). 시스템엔지니어링 기술 프로세스를 적용한 지속 가능 평가모델 설계 연구: 모바일 산업 중심으로. 『한국시스템엔지니어링학회지』, 17(2), 9-22.
- 김정래, 이상직. (2020). 스마트팩토리 기술수용에 영향을 미치는 요인에 관한 연구. 『Journal of Information Technology Applications & Management』, 27(1), 75-95.
- 김정태. (2020). 스마트 팩토리를 위한 지능형 머신 비전 시스템 (최종보고서). 이화여자대학교. 『한국연구재단』.
- 김진주, 전진우. (2025). 공작물의 치수 측정 자동화를 위한 인공지능 적용 검사 로봇시스템. 『한국산학기술학회논문지』, 26(3), 508-515.

- 노세리, 박지성, 이가현. (2020). 제조업의 서비스화 (Servitization) 와 인력관리. 『한국노동연구원』 .
- 서호진, 변재현, 김도현. (2021). 품질 4.0: 개념, 요소, 수준 평가와 전개 방향. 한국품질경영학회 『추계학술발표논문집』 , 2021권, 9.
- 송대웅, (2021). “ITS 기반의 적응형 학습 추천 시스템 설계 및 구현” 광운대학교 대학원 석사학위논문.
- 안성일, 박재영, 김민천, 허민지, 박정란, 한동훈, 최서희, 오종민. (2022). AI 신뢰성 제고를 위한 성능/윤리 인증체계 구축 연구. 『지능정보산업협회』 .
- 양은경. (2024). 인공지능 기반 디자인 플랫폼 사례 연구-패션디자인 프로세스 활용성을 중심으로. 『복식』 , 74(6), 69-93.
- 오윤환, 강태원, 이용수. (2023). 제조기업의 신기술 도입 전략 분석: 국내 스마트생산 사례를 중심으로. 『한국혁신학회지』 , 18(1), 97-117.
- 오주환, 김지대. (2019). 스마트 팩토리의 전략적 활용 연구: 구축 목적 및 내용이 지속적 활용에 미치는 영향. 『중소기업연구』 , 41(4), 1-36.
- 유원중, 강성현, 이용구, 이영진. (2018). Total Variation (TV) 노이즈 제거 알고리즘의 정규화 변수 변화에 따른 영상의 특성 평가: 시뮬레이션 연구. 『전자공학회논문지』 , 55(3), 144-148.
- 윤선중, 서종현. (2021). 기술 중소기업의 경영 특성에 대한 고성장 기업 결정 영향 요인 분석: 4 차 산업혁명기업과 일반 중소기업을 중심으로. 『벤처창업연구』 , 16(6), 157-175.
- 이성주, 박영준, 이용수. (2022). 딥러닝 모델 파티션 자동화 및 최적화 기법. 『한국정보과학회 학술발표논문집』 , 1127-1129.
- 이성희, 김재영, 이원희. (2017). 스마트 공장 문헌연구 및 향후 추진전략. 『Journal of Information Technology Applications & Management』 , 24(4), 133-152.
- 이수아, 한지형. (2022). 객체 탐지를 위한 객체 복사 기반의 적대적 생성 신경망 활용 이미지 데이터 증강 기법. 『정보과학회논문지』 , 49(12), 1056-1061.

- 이정련, 이창원. (2022). 스마트팩토리의 핵심성공요인이 경영성과에 미치는 영향에 관한 연구. 『로고스경영연구』, 20(2), 93-108.
- 이종수, 김영수, 장금용, 유승훈. (2024). 자동차 부품 산업의 디지털 혁신을 위한 AI 기반 DX 플랫폼 개발 사례. 『정보 및 제어 논문집』, 109-110.
- 하승재, 김동훈, 구기영, 신영택 (2021). 반도체 설비 센서 데이터를 활용한 딥러닝 기반 불량 예측 모델 연구. 『한국산업정보학회논문지』, 13(2), 2375-2379.
- 이해나. (2020). “딥러닝 기반의 비정형 결함 표면 검사 시스템 구축” Doctoral dissertation, 서울대학교 대학원 박사학위논문.
- 임병인, 김성태, 박주현, 이상돈. (2022). 과학기술 R&D 투자가 고용에 미치는 효과: 인공지능 및 빅데이터 기술 분야의 R&D 투자를 중심으로. 『한국노동연구원 고용영향평가센터』.
- 장수환, 정종필. (2019). 중소기업 스마트공장 구축을 위한 OpenCV 기반 재고 관리 시스템의 설계 및 구현. 『한국인터넷방송통신학회 논문지』, 19(1), 161-170.
- 정분도, 홍미선. (2018). 인공지능산업의 주요국 현황에 따른 경쟁력 분석. 『e-비즈니스연구』, 19(5), 215-229.
- 정석진. 2022. "표면 균열감지를 위한 딥러닝 모델 범용성 관한 연구." 국내석사학위논문 아주대학교.
- 정석진. (2023). 산업현장 머신비전에서의 외란 민감도 저감기술에 관한 연구. 『*한국전자과학회논문지*』, 34(1), 17-26.
- 정화민, 박수용, 권택원. (2025). 여론조사를 위한 신뢰수준과 표본오차 자동 산출 및 다중층화 샘플링 방법에 관한 연구. 『한국산학기술학회논문지』, 26(2), 522-529.
- 최성욱. (2016). “도금된 금속 및 플라스틱 제품 표면의 불량 검출”, 서울대학교 대학원, 박사학위논문.
- 허승진. (2023). “딥러닝을 활용한 핀 비전 검사 검출력 강화 및 추론 속도 향상에 관한 연구”, 서울대학교 대학원, 박사학위논문.

- 형성웅, 김경휘, 임재형, 최현석, 이동천. (2024). 항공 라이다 점군 분류를 위한 기하학적 특성정보 기반 딥러닝. 『한국측량학회지』, 42(5), 395-409.
- Seo, P., Kim, D., & Moon, T. (2022). 국내 중소기업의 스마트공장 구축을 위한 조직역량과 조직성파에 관한 연구. 『*정보시스템연구*』, 31(1), 197-218.
- Yong, L. (2022). “다품종소량생산기업의 스마트공장화가 생산성 향상에 미치는 영향에 대한 연구: 3D프린팅 및 협동로봇 중심으로.” 상명대학교 일반대학원 기술경영공학과 석사논문.
- Yoon, S. (2024). “이미지 기반의 딥 러닝을 활용한 제품 분류 및 불량 검출 모델 개발.” 인하대학교 대학원 석사학위논문.



2. 국외문헌

- Albawi, S., Bayat, O., Al-Azawi, S., & Ucan, O. N. (2018). Social touch gesture recognition using convolutional neural network. *Computational Intelligence and Neuroscience*, 2018(1), 6973103.
- Alvares, A. J., Figueroa Betancourth, B. S., Cabral, J. V. A., & Lacroix, I. (2025). Automated defect classification in additive manufacturing LMD-wire using deep learning. *Journal of the Brazilian Society of Mechanical Sciences and Engineering*.
- Belkheldar, G., & Lyhyaoui, A. (2023). Automated quality inspection using computer vision: A review. In J. Kacprzyk et al. (Eds.), *AI2SD 2022: Artificial Intelligence and Computer Vision for Sustainable Development* (pp. 686–697).
- Benbarrad, T., Bouzouane, A., & Bouchard, B. (2021). A hybrid intelligent system for fault detection in industrial processes. *Expert Systems with Applications*, 168, 114361. <https://doi.org/10.1016/j.eswa.2020.114361>
- Bhatt, P. M., Malhan, R. K., Rajendran, P., Shah, B. C., Thakar, S., Yoon, Y. J., & Gupta, S. K. (2021). Image-based surface defect detection using deep learning: A review. *Journal of Computing and Information Science in Engineering*, 21(4), 040801.
- Bianchini, F., Calamo, M., Marinacci, M., Rossi, J., & Mecella, M. (2025). Automating industrial quality control: A multimodal LLM and RAG framework for anomaly detection. *IArtificial Intelligence Applications and Innovations*(pp. 253–266).
- Budach, L., Feuerpfeil, M., Ihde, N., Nathansen, A., Noack, N., Patzlaff, H., ... & Harmouch, H. (2022). The effects of data quality on machine learning performance.
- Chen, M., Lee, J., & Park, S. (2023). Vision-based defect detection in

- pharmaceutical and cosmetic packaging. *Computers in Industry*, 145, 103812.
- Chen, X., Wu, Y., He, X., & Ming, W. (2023). A comprehensive review of deep learning-based PCB defect detection. *IEEE Access*, 11, 139017–139038.
- Chollet, F. (2018). **Deep learning with Python**. Manning Publications.
- Chong, H. R., Bae, K. H., Lee, M. K., Kwon, H. M., & Hong, S. H. (2020). Quality strategy for building a smart factory in the fourth industrial revolution. *Journal of Korean Society for Quality Management*, 48(1), 87–105.
- Diwan, T., Anirudh, G., & Tembhurne, J. V. (2023). Object detection using YOLO: Challenges, architectural successors, datasets and applications. *Multimedia Tools and Applications*, 82, 9243–9275.
- Elhendawy, G. A., & El-Taybany, Y. (2025). Machine Vision-Assisted Welding Defect Detection System with Convolutional Neural Networks. *International Journal of Precision Engineering and Manufacturing*, 1–10.
- Girshick, R. (2015). Fast R-CNN. In *Proceedings of the IEEE international conference on computer vision* (pp. 1440–1448).
- Glorot, X., & Bengio, Y. (2010, March). Understanding the difficulty of training deep feedforward neural networks. In *Proceedings of the thirteenth international conference on artificial intelligence and statistics* (pp. 249–256). *JMLR Workshop and Conference Proceedings*.
- Goodfellow, I., Bengio, Y., Courville, A., & Bengio, Y. (2016). *Deep learning* (Vol. 1, No. 2). Cambridge: MIT press.
- Grosan, C., & Abraham, A. (2011). Rule-Based Expert Systems. In *Intelligent Systems* (pp. 149–185).
- Gupta, A., Barari, A., Damini, D., Jagannathachar, K. K., Lee, S., Oh, J.,

- ... & Kim, M. (2022, February). Identifying combination of defects and unknown defects on semiconductor wafers using deep learning and hierarchical reclustering. In 2022 35th International Conference on VLSI Design and 2022 21st International Conference on Embedded Systems (VLSID) (pp. 150–155). IEEE.
- Gupta, A., Singh, R., & Kumar, P. (2022). Machine vision applications in industrial automation: A comprehensive review. *Journal of Manufacturing Processes*, 75, 1–15.
- Hand, D. J., Christen, P., & Kirielle, N. (2021). F*: An interpretable transformation of the F-measure. *Machine Learning*, 110, 451–456.0.
- Havrilla, A., Dai, A., O'Mahony, L., Oostermeijer, K., Zisler, V., Albalak, A., ... & Meyerson, E. (2024). Surveying the Effects of Quality, Diversity, and Complexity in Synthetic Data From Large Language Models.
- He, K., Wang, C., He, Y., Su, J., & Chen, X. (2023). Artificial neuron devices. *Chemical Reviews*, 123(23), 13796–13865.
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 770–778).
- He, Y., Li, J., & Wang, Z. (2023). A review of artificial neural network applications in industry. **Journal of Industrial Intelligence**, 39(2), 77–91.
- IEEE Transactions on Neural Networks and Learning Systems. (2025). Recent advances in deep learning architectures for industrial defect detection. *IEEE Xplore*.
- Jiao, L., Zhang, F., Liu, F., Yang, S., Li, L., Feng, Z., & Qu, R. (2019). A survey on deep learning for object detection. *Neurocomputing*, 340, 92–116.

- Kingma, D. P. (2014). Adam: A method for stochastic optimization.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). ImageNet classification with deep convolutional neural networks. *Advances in Neural Information Processing Systems (NeurIPS)*, 25, 1097–1105.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *nature*, 521(7553), 436–444.
- LeCun, Y., Bottou, L., Bengio, Y., & Haffner, P. (2002). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278–2324.
- Li, Y., Zhang, Y., & Wang, J. (2021). Deep learning-based defect detection for industrial quality inspection. *Journal of Manufacturing Systems*, 59, 451–460.
- Li, Z., Liu, F., Yang, W., Peng, S., & Zhou, J. (2021). A survey of convolutional neural networks: analysis, applications, and prospects. *IEEE transactions on neural networks and learning systems*, 33(12), 6999–7019.
- Liu, W., Anguelov, D., Erhan, D., Szegedy, C., Reed, S., Fu, C.-Y., & Berg, A. C. (2016). SSD: Single Shot MultiBox Detector. *European Conference on Computer Vision (ECCV)*, 21–37.
- Liu, W., Hu, J., & Qi, J. (2025). Coarse-to-fine vision-based welding spot anomaly detection in production lines of body-in-white. *Journal of Manufacturing Systems*, 81, 144–154.
- Maass, W. (1997). Networks of spiking neurons: the third generation of neural network models. *Neural networks*, 10(9), 1659–1671.
- 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.
- McCulloch, W. S., & Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics*,

5(4), 115–133.

Minsky, M., & Papert, S. (1969). *Perceptrons* cambridge. MA: MIT Press. zbMATH.

Mohammed, A., & Hussain, M. (2025). Advances and Challenges in Deep Learning for Automated Welding Defect Detection: A Technical Survey. *IEEE Access*.

Molefe, M. E., Tapamo, J. R., & Vilakazi, S. S. (2025). A Comparative Study of Image Processing and Machine Learning Methods for Classification of Rail Welding Defects. *Journal of Sensor and Actuator Networks*, 14(3), 58.

Monti, F., Marinacci, M., Leotta, F., & Mecella, M. (2025). Die-vis: an automated visual inspection system for cardboard box manufacturing. In *European Conference on Computer Vision* (pp. 259–275).

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. <https://doi.org/10.3390/su14052697>

Picard, C., Edwards, K. M., Doris, A. C., Man, B., Giannone, G., Alam, M. F., & Ahmed, F. (2025). From concept to manufacturing: Evaluating vision-language models for engineering design. *Artificial Intelligence Review*, 58, Article 288.

Rawat, W., & Wang, Z. (2017). Deep convolutional neural networks for image classification: A comprehensive review. *Neural computation*, 29(9), 2352–2449.

Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You Only Look Once: Unified, Real-Time Object Detection. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 779–788.

Reichenstein, T., Raffin, T., Sand, C., & Franke, J. (2022). Implementation

- of machine vision based quality inspection in production: an approach for the accelerated execution of case studies. *Procedia CIRP*, 112, 596–601.
- 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, 91–99.
- Rosenblatt, F. (1958). The perceptron: A probabilistic model for information storage and organization in the brain. *Psychological Review*, 65(6), 386–408.
- Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning representations by back-propagating errors. *nature*, 323(6088), 533–536.
- Saito, T., & Rehmsmeier, M. (2015). The precision–recall plot is more informative than the ROC plot when evaluating binary classifiers on imbalanced datasets. *PLoS ONE*, 10(3), e0118432.
- Saqlain, M., Abbas, Q., & Lee, J. Y. (2020). A deep convolutional neural network for wafer defect identification on an imbalanced dataset in semiconductor manufacturing processes.
- Simonyan, K., & Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition.
- Song, K., & Yan, Y. (2013). A noise robust method based on completed local binary patterns for hot-rolled steel strip surface defects. *Applied Surface Science*, 285, 858–864.
- Song, Q., & Yan, X. (2013). Comparative study of rule-based and neural network approaches for fault diagnosis. *International Journal of Automation and Computing*, 10(6), 541–548.
- Springer. (2025). Energy-efficient neural network training for scientific datasets with NAS optimization. In *Lecture Notes in Computer Science* (Vol. 14432).

- Tahir, G. A. (2024). Ethical Challenges in Computer Vision: Ensuring Privacy and Mitigating Bias in Publicly Available Datasets.
- Tan, M., & Le, Q. (2019, May). Efficientnet: Rethinking model scaling for convolutional neural networks. In International conference on machine learning (pp. 6105–6114). PMLR.
- Tang, J., Yuan, F., Shen, X., Wang, Z., Rao, M., He, Y., ... & Wu, H. (2019). Bridging biological and artificial neural networks with emerging neuromorphic devices: fundamentals, progress, and challenges. *Advanced materials*, 31(49), 1902761.
- Tercan, H., & Meisen, T. (2022). Machine learning and deep learning based predictive quality in manufacturing: a systematic review. *Journal of Intelligent Manufacturing*, 33, 1879–1905.
- UnitX Labs. (2025). AI-Based Visual Inspection for Quality Assurance
- Xu, B., Wang, N., Chen, T., & Li, M. (2015). Empirical evaluation of rectified activations in convolutional network.
- Xu, C., Xu, L., Luo, K., Zhang, J., Sitahong, A., Yang, M., & Zhang, C. (2024). The essence and applications of machine vision inspection for textile industry: a review. *The Journal of The Textile Institute*, 1–25.
- Xu, L., Wang, H., & Zhao, Y. (2024). Deep learning-based visual inspection for food and beverage packaging. *Food Control*, 154, 109123.
- Xu, W., Wan, Y., & Zhao, W. (2025). ELA: Efficient location attention for deep convolution neural networks. *Journal of Real-Time Image Processing*.
- Zhang, D., Hao, X., Wang, D., Qin, C., Zhao, B., Liang, L., & Liu, W. (2023). An efficient lightweight convolutional neural network for industrial surface defect detection. *Artificial Intelligence Review*, 56, 10651–10677.

- Zhang, Y. (2021). Machine vision-based inspection for food packaging defects. *International Journal of Food Engineering*, 45(2), 93–101.
- Zheng, L., & McKenna, E. (2025). Machine Learning with Administrative Data for Energy Poverty Identification in the UK. *Energies*, 18(12), 3054.
- Zheng, S., Zhao, Y., Chen, X., & Luo, S. (2025). An LCD Defect Image Generation Model Integrating Attention Mechanism and Perceptual Loss. *Symmetry*, 17(6), 833.




[부록] 최종 결과 이미지


본 연구의 최종 결과 이미지는 실제 제조 현장에서 인공지능 기반 머신비전 시스템을 적용한 결과를 시각적으로 나타낸 것이다. 각 이미지 사례에서는 시스템이 검출한 결함 영역을 명확한 경계 박스로 표시하여 AI의 탐지 능력을 시각적으로 확인할 수 있도록 구성되었다. ANN 기반 시스템은 투명 랩 포장, 조명 반사, 미세 이물 등 실제 현장에서 빈번하게 발생하는 난해한 환경적 조건에서도 안정적으로 불량 이미지를 식별하였다. 특히, 기존의 규칙 기반(Rule-based) 검사에서는 외란의 영향으로 쉽게 간과되었던 미세 머리카락, 섬유 뭉침, 미세 먼지와 같은 결함을 AI가 효과적으로 검출했음을 보여준다. 하지만 일부 이미지에서는 랩 포장의 접힘이나 반사광으로 인해 오탐지가 발생한 예도 있다. 이는 향후 조명 각도 조정, 카메라의 위치 변경 등 및 반사 보정 알고리즘, 학습 데이터 변경 등의 하드웨어적, 소프트웨어적인 보완이 필요함을 시사한다. 전체적으로 최종 결과 이미지 자료는 본 연구가 제안한 ANN 기반 머신비전 시스템이 제조 현장의 열악한 외부 환경에서도 품질 관리에서 신뢰할 수 있는 도구로 실질적 적용 가능성을 명확히 입증하고 있다.

아래 이미지 중 “OK Results”는 이물과 배경을 분리하지 못해 수정이 필요한 영상이고, “NG Results”는 정상적으로 제품에 포함된 이물을 열악한 외란 상황에서도 구분해 내는 결과 영상입니다.


OK Results



OK Results



OK Results




백그라운드와 이물의 구분이 어려움

OK Results




백그라운드가 항상 이물로 검출되어, 백그라운드를 조정 함

OK Results




OK Results



이물과 백그라운드 영상이 가까움

OK Results




백그라운드 이미지가 가까움




HANSUNG
UNIVERSITY

NG Results




이물 검출(정상 이물 검출 영상)

NG Results




NG Results



NG Results




NG Results



NG Results



NG Results



NG Results



ABSTRACT

Design and Implementation of an Artificial Neural Network-Based Machine Vision System for Industrial Defect Inspection


Oh, Chang-Bae

Major in Smart Factory Consulting

Dept. of Smart Convergence Consulting

Graduate School of Knowledge Service &
Consulting

Hansung University

The logo of Hansung University is located on the left side of the page. It features a stylized blue and white emblem. A large, light blue watermark of the university's name, 'HANSUNG UNIVERSITY', is overlaid diagonally across the middle of the page.

With the acceleration of the Fourth Industrial Revolution, the demand for process automation in the manufacturing sector has been rapidly increasing. Consequently, there is a growing need for quality inspection systems that offer higher precision and adaptability to real-world production environments, surpassing the limitations of manual visual inspection and rule-based methods. However, many small and medium-sized enterprises (SMEs) still rely on traditional manual inspection processes due to challenges such as the high cost of automation equipment, lack of technical infrastructure, and shortage of skilled personnel. Rule-based inspection systems, in particular, are highly sensitive to external factors such as lighting conditions, packaging

material refraction, and surface curvature, resulting in inconsistent inspection outcomes and limited reliability in quality assurance.

To address these issues, this study proposes an artificial neural network (ANN)–based intelligent inspection system and applies it to actual SME production sites. Unlike conventional methods, ANN models can autonomously learn from diverse image data and identify complex defect patterns without predefined rules. The proposed system is designed to detect subtle and irregular defects that are difficult to identify through human inspection, even under challenging environmental conditions.

In this study, product surfaces were automatically captured while rotating 360 degrees, and the collected image data were used to train the AI model to determine defect presence. The dataset was gathered from real production environments and included various defect types such as contamination, foreign substances, and wrinkles. Experimental results showed that the developed system achieved higher defect detection accuracy than rule–based methods and maintained stable performance despite environmental variations. While traditional machine vision systems often struggle with exceptional defects due to their reliance on brightness differences and fixed rules, the proposed AI system demonstrated flexible adaptability and significantly reduced false positives and error rates.

These findings indicate that even SMEs can overcome the limitations of conventional inspection methods by adopting relatively simple AI models. This study not only introduces a technical solution but also presents a practical application case tailored to real–world manufacturing conditions, offering valuable insights for the broader adoption of AI–based quality inspection systems across various industrial sectors.

【Key words】 Artificial Neural Network (ANN), Machine Vision, Defect

