

Development and Performance Evaluation of an AI Vision-Based Defect Detection System for Manufacturing Processes

Hyun-Ju Oh*, Jae-Gwan Choi*, Wan-Jin Ko**

*Senior Researcher, Gumi Electronics & Information Technology Research Institute, Gumi, Korea

**Principal Researcher, Gumi Electronics & Information Technology Research Institute, Gumi, Korea

[Abstract]

This paper proposes an AI vision-based defect detection system designed for manufacturing processes and presents its performance evaluation under realistic industrial conditions. The proposed system integrates image acquisition, automatic labeling, defect detection, and result analysis into a unified framework, and is implemented on an edge computing platform to enable real-time processing.

To evaluate the performance of the proposed system, a total dataset of 1,000 images was constructed, and each repeated experiment was conducted using 100 test samples under identical conditions. The evaluation metrics include defect recognition accuracy, defect type classification accuracy, object detection rate, and detection speed. Experimental results show that the proposed system achieves an average defect recognition accuracy of 94.6%, a defect type classification accuracy of 100%, and an object detection rate of 97.86%. In addition, the average defect detection time was measured as 0.073 seconds, demonstrating its suitability for real-time industrial applications.

However, limitations of vision-based inspection were observed when applied to diverse and complex industrial environments, particularly due to insufficient variability in training data. To address this issue, additional experiments were conducted using synthetic images generated from normal and defective samples collected from consortium partners. The results indicate that the use of synthetic data can enhance data diversity and improve model generalization performance.

The proposed system demonstrates high potential for practical deployment in manufacturing environments. Future work will focus on expanding the dataset, improving synthetic data generation techniques, and integrating MLOps-based continuous learning frameworks for adaptive process optimization.

▶ **Key words:** AI Vision, Defect Detection, Manufacturing Process, Edge Computing, Synthetic Data

-
- First Author: Hyun-Ju Oh, Corresponding Author: Hyun-Ju Oh
 - *Hyun-Ju Oh (hjoh@geri.re.kr), Gumi Electronics & Information Technology Research Institute
 - *Jae-Gwan Choi (uest37@geri.re.kr), Gumi Electronics & Information Technology Research Institute
 - **Wan-Jin Ko (kwj@geri.re.kr), Gumi Electronics & Information Technology Research Institute
 - Received: 2026. 04. 15, Revised: 2026. 06. 07, Accepted: 2026. 06. 09.

[요 약]

본 논문에서는 제조 공정 적용을 위한 AI 비전 기반 결함 검출 시스템을 제안하고, 실제 산업 환경을 고려한 조건에서 성능을 평가하였다. 제안 시스템은 영상 취득, 자동 라벨링, 결함 검출 및 결과 분석을 통합한 구조로 설계되었으며, 엣지 컴퓨팅 기반에서 실시간 처리가 가능하도록 구현되었다.

제안 시스템의 성능을 검증하기 위해 전체 데이터셋을 1,000장으로 구성, 각 반복 실험은 테스트 샘플 100장을 기준으로 수행하였다. 평가 지표로는 결함 인식률, 결함 유형 식별률, 결함 객체 검출률 및 결함 검출 속도를 적용하였다. 실험 결과, 평균 결함 인식률은 94.6%, 결함 유형 식별률은 100%, 결함 객체 검출률은 97.86%로 나타났으며, 결함 검출 시간은 평균 0.073초로 측정되어 실시간 공정 적용 가능성을 확인하였다.

한편, 실제 산업 현장에 적용하는 과정에서 다양한 결함 유형과 공정 환경의 변동성으로 인해 비전 기반 검사 성능의 한계가 일부 확인되었다. 이러한 문제를 해결하기 위해, 컨소시엄 참여 기관으로부터 확보한 양품 및 불량 샘플을 기반으로 합성 이미지 데이터를 생성하여 추가 실험을 수행하였다. 이를 통해 학습 데이터의 다양성을 확보하고 모델의 일반화 성능을 향상시킬 수 있음을 확인하였다.

본 연구에서 제안한 시스템은 제조 공정에서 활용 가능한 실용적인 AI 기반 결함 검출 솔루션으로서 높은 적용 가능성을 보인다. 향후 연구에서는 데이터셋 확장, 합성 데이터 생성 기법의 고도화 및 MLOps 기반 지속 학습 구조를 적용하여 공정 최적화까지 확장할 계획이다.

▶ **주제어:** AI 비전, 결함 검출, 제조 공정, 엣지 컴퓨팅, 합성 데이터

I. Introduction

최근 제조 산업에서는 제품 품질에 대한 요구 수준이 지속적으로 증가함에 따라, 미세 결함까지 정밀하게 검출할 수 있는 고도화된 검사 기술의 필요성이 증대되고 있다. 기존의 수작업 검사 또는 전통적인 머신비전 기반 검사 방식은 검사 정확도와 편차, 인건비 증가, 그리고 불량 검출 누락과 같은 한계를 가지며, 대량 생산 환경에서 안정적인 품질 확보에 어려움을 초래한다.

이러한 문제를 해결하기 위한 대안으로 최근 딥러닝 기반 AI 비전 기술이 제조 공정에 적극적으로 도입되고 있다 [1]. AI 기반 검사 시스템은 영상 데이터로부터 자동으로 특징을 학습하고 결함을 식별할 수 있어 기존 방식 대비 높은 정확도와 일관성을 제공한다. 또한, 실시간 데이터 처리와 자동화된 의사결정을 통해 공정 효율성과 품질 관리 수준을 동시에 향상시킬 수 있다.

그러나 기존 AI 기반 비전 검사 시스템은 실제 산업 현장 적용 측면에서 여전히 여러 한계를 가진다. 특히 대규모 학습 데이터 구축 및 라벨링 비용 문제, 클라우드 기반 처리에 따른 지연 시간, 그리고 공정 환경 변화에 따른 일반화 성능 저하 등의 문제가 지속적으로 제기되고 있다[1].

또한, 기존 연구의 상당수는 알고리즘 성능 향상에 초점을 맞추고 있으며, 실제 제조 공정에 적용 가능한 통합형 시스템 구조 및 실시간 운영 환경에 대한 고려는 상대적으로 부족한 실정이다.

이에 본 연구에서는 산업 현장 적용을 고려한 엣지 컴퓨팅 기반 AI 비전 결함 검출 시스템을 제안한다. 제안 시스템은 영상 취득, 자동 라벨링, 결함 검출, 결과 분석까지 통합된 구조로 설계되었으며, 실시간 처리가 가능하도록 최적화하였다. 또한, 자동 라벨링 기능과 데이터 재학습 구조를 통합하여 데이터 구축 효율성과 현장 적용성을 향상시키고자 하였다.

아울러 실제 제조 환경을 모사한 조건에서 성능 평가를 수행하여 시스템의 실용성을 검증하였으며, 합성 데이터 기반 추가 실험을 통해 일반화 성능 개선 가능성을 분석하였다.

본 논문의 주요 기여점은 다음과 같다.

- 엣지 기반 실시간 AI 비전 검사 시스템 설계
- 자동 라벨링 기반 데이터 구축 비용 절감 구조 제안
- 실제 산업 환경을 고려한 통합형 결함 검출 프로세스

구현

- 합성 데이터 기반 추가 실험을 통한 일반화 성능 개선 가능성 검증

이를 위해 다음 장에서는 AI 기반 비전 검사 시스템에 사용되는 주요 기술과 관련 연구를 설명한다.

II. Preliminaries

2.1 AI-based Vision Inspection

AI 비전 기반 검사 시스템은 영상 데이터를 입력으로 받아 딥러닝 모델을 통해 결함을 탐지하고 분류하는 기술이다. 일반적으로 CNN 기반 객체 검출 모델이 활용되며, 최근에는 ResNet 기반 특징 추출 구조를 활용한 딥러닝 모델이 다양한 산업 비전 분야에 적용되고 있다[2]. 또한, YOLO 계열 모델은 실시간 성능과 정확도를 동시에 만족시키는 대표적인 객체 검출 방법으로 널리 사용되고 있다[3], [4]. 또한, Faster R-CNN과 같은 객체 검출 기법 역시 높은 정확도를 제공하는 대표적인 방법으로 활용된다[5].

이러한 시스템은 크게 데이터 수집, 라벨링, 모델 학습, 추론의 단계로 구성되며, 각 단계의 품질이 전체 시스템 성능에 큰 영향을 미친다. 특히, 라벨링 데이터의 정확성과 다양성은 모델의 일반화 성능을 결정짓는 핵심 요소이다.

2.2 Edge-based AI Processing

산업 현장에서의 AI 적용에서는 클라우드 기반 처리보다 엣지 컴퓨팅 기반 처리가 중요한 역할을 한다[6]. 엣지 환경에서는 데이터 전송 지연을 최소화하고, 실시간 처리를 통해 즉각적인 공정 대응이 가능하다.

본 연구에서 사용된 시스템은 NVIDIA Jetson AGX Orin 기반으로 구성되며, 고성능 GPU 연산을 통해 실시간 영상 처리 및 AI 추론을 수행한다. 이는 고속 생산 라인에서도 안정적인 결함 검출을 가능하게 한다.

3장에서는 제조 공정 내 AI 비전 검사 시스템과 관련된 기존 연구들을 분석하고, 기존 연구의 한계점을 정리한다.

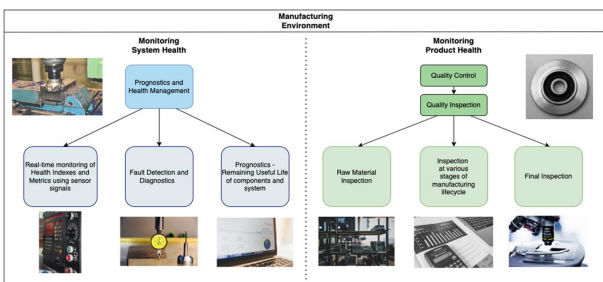


Fig. 1. Overview of AI-based Vision Inspection Process

III. Related Works

전통적인 머신비전 방식은 특정 규칙 기반 알고리즘을 활용하여 결함을 검출하지만, 조명 변화나 제품 다양성에 취약한 한계를 가진다[7], [8]. 최근에는 딥러닝 기반 표면 결함 검출 기술이 다양한 산업 분야에 적용되고 있으며, 높은 검출 성능을 보이고 있다[9].

최근 연구에서는 YOLO, Faster R-CNN 등의 객체 검출 모델을 활용하여 제조 공정 내 결함을 실시간으로 검출하는 방법이 제안되고 있다[3], [4], [5], [6]. 또한, 제한된 학습 데이터 환경을 극복하기 위해 데이터 증강 기법을 활용한 연구가 활발히 진행되고 있으며[10], 최근에는 생성형 AI 기반 합성 데이터 생성 기술을 활용하여 산업용 비전 시스템의 데이터 부족 문제를 해결하려는 연구도 확대되고 있다[11].

그러나 기존 연구들은 다음과 같은 한계를 가진다.

- 실시간 처리 성능 부족
- 라벨링 비용 및 데이터 구축 문제
- 현장 적용을 고려하지 않은 시스템 구조

기존 연구들이 주로 알고리즘 정확도 향상에 초점을 맞춘 반면, 본 연구는 실시간 처리, 자동 라벨링, 데이터 재학습 구조 및 산업 현장 적용성을 고려한 통합형 시스템 구현에 초점을 두었다[12].

Table 1. Comparison of Existing Methods

Method	Features	Limitations
Rule-based vision	Fast, Simple	Sensitive to environmental changes
CNN-based	High Accuracy	Requires large dataset
YOLO-based	Real-time Processing	Labeling cost
Proposed	Real-time, Auto-Labeling	Limited by vision performance

IV. The Proposed Scheme

본 연구에서 제안하는 시스템은 제조 공정 내 결함 검출을 위한 AI 비전 통합 시스템으로, 영상 취득부터 결과 분석까지 전 과정을 자동화한 구조를 가진다.

4.1 System Architecture

제안 시스템은 다음과 같은 구성 요소로 이루어진다.

- 비전 카메라: 고속 영상 데이터 취득

- 데이터 처리 장치: AI 모델 추론 및 제어
- AI 오토라벨링 소프트웨어: 데이터 라벨링 및 학습 지원
- 운영 대시보드: 실시간 모니터링 및 결과 분석

영상 데이터는 카메라를 통해 획득되며, AI 모델을 이용하여 결함 검출이 수행된다. 검출 결과는 사용자 인터페이스를 통해 시각화되고 데이터베이스에 저장된다. 데이터 흐름은 영상 수집 → AI 검출 → 라벨링 → 결과 분석 → 재학습의 순환 구조를 따른다.

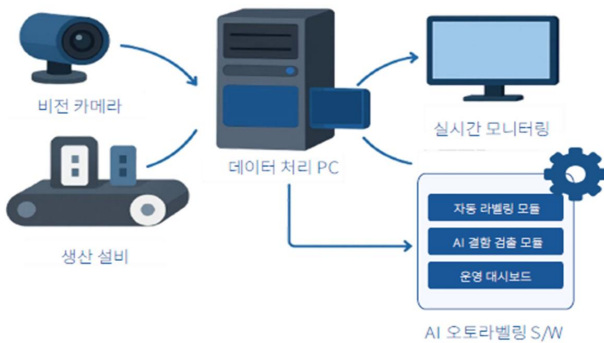


Fig. 2. Architecture of the Proposed AI Vision Inspection System

4.2 AI Model Configuration

본 연구에서는 실시간 결함 검출을 위해 YOLO 기반 객체 검출 모델을 활용하였다. 모델은 사전학습(pre-trained)가 중추를 기반으로 산업용 결함 이미지 데이터셋에 대해 추가 학습을 수행하였으며, 결함 객체의 위치와 유형을 검출하도록 구성하였다. 학습된 모델은 NVIDIA Jetson AGX Orin 기반 엣지 환경에 배포되어 실시간 추론에 활용되었다. 또한, 산업 환경 특성을 고려하여 데이터 다양성 확보를 위한 데이터 증강 기법을 적용하였다.

4.3 AI-based Defect Detection Process

제안 시스템의 결함 검출 과정은 다음과 같이 구성된다.

- (1) 영상 데이터 입력
- (2) 객체 검출 모델을 통한 결함 영역 탐지
- (3) 결함 유형 분류
- (4) 자동 라벨 생성 및 사용자 보정
- (5) 데이터 저장 및 재학습

본 연구의 자동 라벨링 기능은 사전 학습된 객체 검출 모델의 초기 예측 결과를 기반으로 결함 영역을 자동 생성하고, 사용자가 이를 검토 및 수정하는 반자동(semi-automatic) 방식으로 구현하였다.

이러한 반자동 라벨링 구조를 통해 기존 수작업 기반 라벨링 과정에서 발생하는 시간 및 비용 부담을 줄일 수 있

으며, 반복적인 데이터 구축 과정의 효율성을 향상시킬 수 있다. 또한, 사용자 보정 과정을 포함함으로써 잘못된 라벨 데이터로 인한 학습 오류를 최소화하고 데이터 품질을 향상시킬 수 있다.

이 과정에서 자동 라벨링 기능을 활용하여 데이터 구축에 필요한 시간과 비용을 절감할 수 있으며, 사용자 보정을 통해 학습 데이터의 품질을 향상시킬 수 있다.

4.4 Key Features

제안 시스템의 주요 특징은 다음과 같다.

- 실시간 처리 성능: 제안 시스템은 영상 취득 장치와 AI 추론 모듈을 동일 엣지 디바이스 내에서 통합 처리하도록 구성하였다. 이를 통해 클라우드 기반 처리 과정에서 발생할 수 있는 데이터 전송 지연을 최소화하였으며, 고속 프레임 기반 실시간 결함 검출이 가능하도록 하였다.

- 자동 라벨링 기능: 기존 비전 검사 시스템에서는 학습 데이터 구축을 위한 수작업 라벨링 과정에 많은 시간과 비용이 소요된다. 반면, 제안 시스템은 AI 기반 자동 라벨링 기능을 포함함으로써 데이터 구축 효율성을 향상시키고 반복 학습 기반 성능 개선이 가능하도록 설계되었다.

- 엣지 기반 운영: 제안 시스템은 NVIDIA Jetson AGX Orin 기반의 엣지 환경에서 독립적으로 동작하도록 구현되었다. 이를 통해 네트워크 의존성을 최소화하고, 산업 현장에서 요구되는 안정성과 실시간성을 동시에 확보할 수 있다.

- 확장성: 제안 시스템은 영상 취득, 결함 검출, 데이터 저장 및 재학습 기능을 모듈화된 구조로 설계하였다. 따라서 MES/ERP 등 기존 제조 시스템과의 연계가 용이하며, 다양한 제조 공정으로 확장이 가능하다.

또한, 제안 시스템은 산업 환경에서도 안정적으로 동작하도록 설계되었으며, 장시간 운용 및 다양한 조건에서도 일관된 성능을 유지할 수 있도록 최적화되었다.



Fig. 3. Workflow of the Proposed Defect Detection Process

4.5 Evaluation Metrics

본 연구에서는 제안한 AI 비전 기반 결함 검출 시스템의 성능을 정량적으로 평가하기 위해 결함 인식률, 결함 유형 식별률, 결함 객체 검출률, 결함 검출 속도를 주요 평가 지표로 정의하였다. 각 지표는 다음과 같이 정의된다.

(1) 결함 인식률

결함 인식률은 전체 입력 이미지 중에서 올바르게 분류된 비율을 의미하며, 다음과 같이 계산된다.

$$\text{인식률}(\%) = \frac{N_{total} - N_{error}}{N_{total}} \times 100$$

여기서 N_{total} 은 전체 테스트 이미지 수를 의미하며, N_{error} 는 오인식된 이미지 수를 의미한다.

또한, 반복 실험을 통해 평균 결함 인식률은 다음과 같이 계산된다. 여기서 K 는 실험 반복 횟수를 의미한다.

$$\text{평균 인식률} = \frac{1}{K} \sum_{i=1}^K \text{인식률}_i$$

(2) 결함 유형 식별률

결함 유형 식별률은 각 결함 유형을 정확하게 분류한 비율을 의미하며, 다음과 같이 정의된다.

$$\text{유형 식별률}(\%) = \frac{N_{correct}}{N_{total}} \times 100$$

여기서 $N_{correct}$ 는 정확하게 분류된 결함 유형의 수를 의미한다.

(3) 결함 객체 검출률

결함 객체 검출률은 실제 존재하는 결함 객체 대비 시스템이 검출한 객체의 비율을 의미하며, 다음과 같이 계산된다.

$$\text{검출률}(\%) = \frac{N_{detected}}{N_{groundtruth}} \times 100$$

여기서 $N_{detected}$ 는 검출된 결함 객체 수, $N_{groundtruth}$ 는 실제 결함 객체 수를 의미한다.

(4) 결함 검출 속도

결함 검출 속도는 단일 이미지에 대해 결함을 검출하는데 소요되는 시간을 의미하며, 평균 검출 속도는 다음과 같이 계산된다.

$$\text{평균 검출 속도} = \frac{1}{K} \sum_{i=1}^K T_i$$

여기서 T_i 는 각 실험에서 측정된 결함 검출 시간이며, K 는 반복 실험 횟수를 의미한다.

V. Experimental Results

5.1 Hardware and System Specifications

본 연구에서는 제안한 AI 비전 기반 결함 검출 시스템의 성능 검증을 위해 산업 환경 적용이 가능한 하드웨어 및 소프트웨어 구성으로 실험 환경을 구축하였다. 시스템은 실시간 영상 처리 및 AI 추론이 가능한 엣지 컴퓨팅 기반으로 구성되며, 고속 데이터 처리와 안정적인 운영을 목표로 설계되었다.

데이터 처리 장치는 NVIDIA Jetson AGX Orin 플랫폼을 기반으로 하며, 최대 275 TOPs의 연산 성능을 제공하여 고속 딥러닝 추론이 가능하다. 또한, 산업용 비전 카메라는 2.4MP 해상도와 최대 159FPS의 프레임 속도를 지원하여 고속 생산 공정에서도 안정적인 영상 취득이 가능하다.

AI 기반 라벨링 및 결함 검출 소프트웨어는 GUI 기반 인터페이스로 구현되어 사용자 편의성을 확보하였으며, 자동 라벨링 및 재학습 기능을 통해 지속적인 성능 향상이 가능하도록 설계되었다.

5.2 System Configuration

본 실험에서 사용된 시스템 구성은 Table 2와 같다.

Table 2. Hardware and Software Specifications of the Proposed System

Component	Specification
Edge Device	NVIDIA Jetson AGX Orin (275 TOPs, 64GB LPDDR5)
GPU	2048-core NVIDIA Ampere GPU(64 Tensor Cores)
CPU	12-core ARM Cortex-A78AE
Camera	2.4MP Industrial Camera (Global Shutter CMOS)
Frame Rate	Up to 159 FPS
Interface	USB 3.0 / Ethernet
OS	Ubuntu 20.04
AI Software	Auto-labeling + Defect Detection(GUI-based)

5.3 Experimental Environment

실험 환경은 실제 제조 공정과 유사한 조건을 고려하여 구성되었으며, 실시간 영상 스트리밍 및 연속 데이터 처리 환경에서 시스템의 안정성을 확인하였다.

또한, 시스템은 단일 엣지 디바이스에서 독립적으로 동작하도록 설계되어 네트워크 의존성을 최소화하였으며, 장시간 연속 운용이 가능한 구조로 구현되었다.

본 실험은 제조 공정 내 외관 품질 검사가 필요한 강판 샘플을 대상으로 수행되었다. 대상 공정은 생산 완료 후

외관 이상 여부를 판별하는 검사 공정으로 구성되었으며, 실시간 영상 기반 결함 검출이 가능하도록 시스템을 적용하였다.

대상 제품에서는 이물(Contamination), 덴트(Dent), 돌기(Protrusion) 등의 외관 결함이 주요 불량 유형으로 확인되었다. 이러한 결함은 제품 품질 저하 및 기능 이상을 유발할 수 있어 정밀한 검출이 요구된다.

기존 공정에서는 작업자 육안 검사 및 일부 규칙 기반 비전 검사를 통해 불량 여부를 판별하였다. 그러나 검사 정확도의 편차와 환경 변화에 따른 성능 저하 문제가 존재하였다.

학습 데이터는 산업용 비전 카메라를 활용하여 실제 생산 환경에서 수집하였다. 데이터는 정상 제품 및 불량 제품 영상을 포함하며, 실제 생산 조건 기반으로 구축되었다. 그러나 산업 현장의 특성상 다양한 결함 패턴 및 환경 조건을 충분히 확보하는 데에는 한계가 존재하였다. 이에 따라 일부 데이터는 자동 라벨링 및 사용자 보정 과정을 통해 학습 데이터셋으로 구축하였다.

전체 데이터셋은 학습(train), 검증(validation), 테스트(test) 데이터로 각각 70:15:15 비율로 분할하여 사용하였으며, 5회 반복 실험은 동일 테스트 데이터셋에 대해 반복 추론을 수행하여 시스템의 안정성을 평가하는 방식으로 진행하였다.

Table 3. Dataset Type

Dataset Type	Count
Normal	600
Contamination	150
Dent	130
Protrusion	120
Total	1,000

5.4 Overview of Experimental Results

본 연구에서는 제조 공정에서의 품질 검사 성능과 실시간 처리 성능을 종합적으로 평가하기 위하여 결함 인식률, 결함 유형 식별률, 결함 객체 검출률 및 결함 검출 속도를 평가 지표로 사용하였다.

- AI 기반 결함 인식률
- AI 기반 결함 유형 식별률
- 결함 객체 검출률
- 결함 검출 속도

전체 데이터셋은 총 1,000장의 이미지로 구성되었으며, 각 반복 실험은 동일 조건의 테스트 샘플 100장을 기준으로 5회 수행하였다. 평균값을 기반으로 시스템의 성능을

평가하였으며, 실험은 실제 공정 환경과 유사한 조건에서 수행되었다. 또한 온도(20±10°C), 습도(50±30%) 조건에서 시스템의 안정성을 확인하였다.

5.5 Defect Recognition Accuracy

AI 기반 결함 인식을 실험 결과는 Table 4와 같고, 각 반복 실험은 테스트 샘플 100장을 기준으로 수행하였다.

Table 4. Defect Recognition Accuracy (Based on 100 test samples)

Trial	Misclassified Images	Accuracy(%)
#1	14	86.0
#2	3	97.0
#3	5	95.0
#4	3	97.0
#5	2	98.0
Average		94.6

실험 결과, 평균 결함 인식률은 94.6%로 나타났으며, 반복 실험 간 성능 편차는 비교적 낮은 수준을 유지하였다. 특히 초기 학습 조건 및 데이터 분포에 따라 일부 실험(#1)에서 성능 저하가 발생하였으나, 이후 실험에서는 97% 이상의 높은 정확도를 유지함을 확인하였다. 이는 제안 시스템이 학습 데이터 누적에 따라 성능이 안정적으로 향상됨을 의미한다.



Fig. 4. Experimental Setup for Defect Recognition

Table 5. Defect Recognition Accuracy Test #1

Trial	Image	Test	Result
1		Normal	Normal

2		Defective	Defective
3		Defective	Defective
4		Defective	Defective
5		Defective	Defective

5.6 Defect Type Classification Accuracy

결함 유형 식별률 실험 결과는 Table 6과 같다.

Table 6. Defect Type Classification Accuracy

Trial	Type1	Type2	Type3	Average
#1	100	100	100	100
#2	100	100	100	100
#3	100	100	100	100
#4	100	100	100	100
#5	100	100	100	100

결함 유형 식별률 평가 결과, 모든 실험에서 100%의 정확도를 기록하였다. 이는 본 시스템이 학습된 결함 유형 (이물, 덴트, 돌기)에 대해 매우 높은 분류 성능을 보이며, 클래스 간 구분이 명확하게 이루어졌음을 의미한다. 또한, 동일 조건에서 반복 실험 시에도 성능 저하 없이 안정적인 결과를 유지하였다.

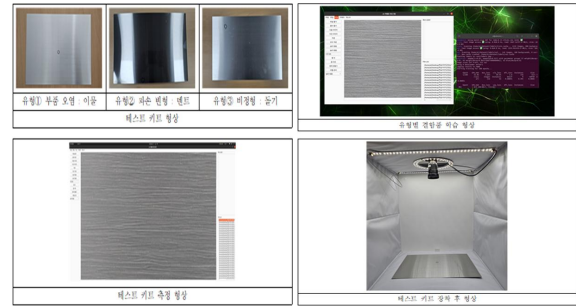


Fig. 5. Examples of Defect Type Classification

Table 7. Defect Type Classification Accuracy Test #1

Trial	Image	Result
1		Contamination
2		Dent
3		Protrusion
4		Dent
5		Protrusion

5.7 Defect Object Detection Rate

결함 객체 검출률 실험 결과는 Table 8과 같다.




Table 8. Defect Object Detection Rate



Trial	Ground Truth	Detected	Detection Rate(%)
#1	212	207	97.6
#2	203	201	99.0
#3	208	203	97.6
#4	204	200	98.0
#5	210	204	97.1
Aver.	-	-	97.86

결함 객체 검출률은 평균 97.86%로 나타났으며, 모든 실험에서 97% 이상의 높은 검출 성능을 유지하였다.

일부 미검출 사례가 존재하였으나, 이는 복잡한 결함 형상 또는 미세 결함에 기인한 것으로 판단된다. 그럼에도 불구하고 전체적으로 높은 검출률을 유지함으로써 실제 산업 현장 적용 가능성을 확인하였다.

Table 9. Defect Object Detection Rate Test #1

Trial	Image	Defects	Detected Defects
1		1	1
2		2	2
3		5	5

4		2	1
5		3	3

5.8 Defect Detection Speed

결함 검출 속도 실험 결과는 Table 10과 같다.


Table 10. Defect Detection Speed




Trial	Detection Time(s)
#1	0.089
#2	0.068
#3	0.059
#4	0.068
#5	0.069
Average	0.073

결함 검출 속도는 평균 0.073초로 나타났으며, 이는 초당 약 13~17 프레임 처리에 해당하는 수준이다.

특히 모든 실험에서 0.1초 이하의 처리 속도를 유지함으로써, 제안 시스템이 실시간 공정 적용에 적합한 성능을 가지는 것으로 확인되었다.

Table 11. Defect Detection Speed Test #1

Trial	Image	Log Data(s)
1		<pre> Start Time: 11:31:50.050 End Time: 11:31:50.223 Type Detection Time: 0.17 seconds 유형 foreign 11:31:50.050~ 11:31:50.223 → 0.17 </pre>
2		<pre> Start Time: 11:33:29.491 End Time: 11:33:29.550 Type Detection Time: 0.06 seconds 유형 foreign 11:33:29.491~ 11:33:29.550 → 0.06 </pre>

3		<pre> Start Time: 11:26:12.244 End Time: 11:26:12.395 Type Detection Time: 0.15 seconds 유형 dent </pre> <p>11:26:12.244~ 11:26:12.395 → 0.15</p>
4		<pre> Start Time: 11:28:26.426 End Time: 11:28:26.486 Type Detection Time: 0.06 seconds 유형 Lump </pre> <p>11:28:26.426~ 11:28:26.486 → 0.06</p>
5		<pre> Start Time: 13:34:05.811 End Time: 13:34:05.857 Type Detection Time: 0.05 seconds 유형 foreign </pre> <p>13:34:05.811~ 13:34:05.857 → 0.05</p>

5.9 Result Analysis

전체 실험 결과를 종합하면 다음과 같은 결과 값을 도출할 수 있다.

- 결함 인식률: 평균 94.6%
- 결함 유형 식별률: 100%
- 결함 객체 검출률: 평균 97.86%
- 결함 검출 속도: 평균 0.073초

제안 시스템은 결함 인식률, 결함 유형 식별률, 결함 객체 검출률 및 결함 검출 속도 측면에서 우수한 성능을 보였다. 실험 결과, 제안 시스템은 다양한 결함 유형에 대해 안정적인 검출 성능을 유지하였으며, 옛지 기반 환경에서도 실시간 처리가 가능한 수준의 성능을 확인하였다. 이는 제안 시스템이 제조 현장 적용을 위한 AI 기반 비전 검사 시스템으로 활용될 수 있음을 보여준다.

5.10 Synthetic Data-based Additional Experiment

최근에는 생성형 AI 기반 합성 데이터 생성 기술을 활용하여 제한된 산업 데이터 환경에서 학습 데이터 다양성을 확보하려는 연구가 활발히 진행되고 있다[12].

본 연구에서는 실제 산업 환경에서 확보한 정상 및 불량 샘플 이미지를 기반으로 회전, 밝기 조절, 위치 이동 등의 데이터 증강 기법을 적용하여 합성 데이터를 생성하였다. 합성 데이터 증강의 효과를 확인하기 위하여 추가 실험을 수행한 결과 Table 12와 같이, 합성 데이터를 학습 데이

터에 추가한 결과 결함 인식률이 기존 94.6%에서 96.1%로 향상되었다.

이는 합성 데이터가 학습 데이터의 다양성 확보에 긍정적인 영향을 줄 수 있음을 확인한 결과이다.

Table 12. Performance Comparison with Synthetic Dataset Augmentation

Dataset	Accuracy
Original Dataset	94.6%
Synthetic Dataset	96.1%

VI. Discussion

본 연구에서는 AI 비전 기반 결함 검출 시스템의 성능을 다양한 평가 지표를 통해 분석하였다. 실험 결과, 결함 인식률은 평균 94.6%, 결함 객체 검출률은 약 97.86%로 나타났으며, 결함 유형 식별률은 100%를 기록하였다. 또한, 평균 결함 검출 속도는 0.073초로 측정되어 실시간 처리 요구사항을 충족하는 수준임을 확인하였다.

이러한 결과는 제안 시스템이 정확도와 처리 속도 측면에서 모두 우수한 성능을 확보하고 있음을 의미한다. 특히, 옛지 디바이스 기반 환경에서도 높은 검출 성능을 유지함으로써, 네트워크 의존성을 최소화한 독립적인 공정 적용 가능성을 확인할 수 있었다.

기존의 수작업 기반 검사 방식은 작업자 숙련도에 따라 검사 정확도의 편차가 발생할 수 있으며, 반복 작업에 따른 피로 누적 문제를 가진다. 또한, 일부 규칙 기반 비전 검사 방식은 조명 변화 및 제품 다양성에 취약하여 실제 산업 환경에서 안정적인 성능 유지에 한계가 존재한다.

반면, 본 연구에서 제안한 시스템은 딥러닝 기반 객체 검출 모델과 옛지 기반 실시간 처리 구조를 적용함으로써 높은 결함 검출 성능과 실시간성을 동시에 확보하였다. 또한, 자동 라벨링 및 재학습 구조를 통해 데이터 구축 효율성과 지속적인 성능 개선 가능성을 제공한다는 점에서 기존 방식 대비 실용적인 장점을 가진다.

그러나 실험 과정에서 몇 가지 한계점도 확인되었다. 우선, 결함 인식률이 일부 실험에서 상대적으로 낮게 나타난 것은 학습 데이터의 다양성 부족 및 결함 패턴의 복잡성에 기인한 것으로 판단된다. 실제 산업 현장에서는 다양한 유형과 형태의 결함이 발생하며, 이러한 변동성을 충분히 반영하지 못할 경우 모델의 일반화 성능이 저하될 수 있다.

또한, 일부 미검출 사례는 미세 결함 또는 배경 패턴과

유사한 특성을 가지는 결함에서 발생하였으며, 이는 기존 비전 기반 검사 시스템의 구조적 한계와도 관련이 있다.

따라서 향후에는 다양한 환경 조건 및 결함 유형을 포함한 데이터셋 구축이 필요하다. 또한, 제안 시스템은 엣지 기반 실시간 처리 구조와 자동 라벨링 기능을 통해 제조 현장에서 요구되는 신속한 품질 검사 및 데이터 구축 효율 향상에 기여할 수 있다. 특히 기존 수작업 기반 검사 대비 검사자의 의존도를 줄이고 품질 관리의 일관성을 확보할 수 있다는 점에서 산업 현장 적용 가능성이 높다.

VII. Conclusions

본 연구에서는 제조 공정 내 결함 검출을 위한 AI 비전 기반 검사 시스템을 제안하고, 실제 공정 환경을 모사한 조건에서 성능을 검증하였다. 제안 시스템은 영상 취득, 자동 라벨링, 결함 검출, 결과 분석까지 통합된 구조로 설계되었으며, 엣지 컴퓨팅 기반에서 실시간 처리가 가능하도록 구현되었다.

실험 결과, 결함 인식을 94.6%, 결함 객체 검출률 약 97.86%, 결함 유형 식별률 100%를 달성하였으며, 평균 0.073초의 처리 속도를 통해 실시간 공정 적용 가능성을 확인하였다. 이는 제안 시스템이 기존 검사 방식 대비 높은 정확도와 효율성을 제공할 수 있음을 의미한다.

한편, 본 연구에서는 실제 산업 현장 적용을 고려하는 과정에서 비전 기반 검사 성능의 한계도 확인되었다. 특히, 다양한 결함 유형과 불균일한 공정 조건이 존재하는 실제 환경에서는 학습 데이터의 부족으로 인해 일부 검출 성능 저하가 발생할 수 있음을 확인하였다.

이를 보완하기 위해, 본 연구에서는 컨소시엄 참여 기관으로부터 양품 및 불량 샘플 데이터를 확보하고, 이를 기반으로 합성 이미지 데이터를 생성하여 추가 실험을 수행하였다. 이러한 접근은 제한된 실제 데이터 환경에서도 학습 데이터의 다양성을 확보하고, 모델의 일반화 성능을 향상시키는 데 효과적인 방법으로 판단된다.

향후 연구에서는 다양한 산업 환경에서의 데이터 확보 및 합성 데이터 생성 기법 고도화를 통해, 보다 안정적이고 범용적인 AI 비전 검사 시스템으로 확장할 계획이다. 또한, 디지털 트윈 및 MLOps 기반의 지속적 학습 구조를 도입하여 공정 최적화까지 연계하는 방향으로 연구를 확장할 수 있을 것으로 기대된다. 본 연구에서 제안한 시스템은 제조 공정의 품질 검사 자동화 및 데이터 기반 품질 관리 체계 구축을 위한 실용적인 AI 비전 솔루션으로 활용될 수 있을 것으로 기대된다.

ACKNOWLEDGEMENT

This research was supported by the Ministry of Trade, Industry and Energy(MOTIE) and the Korea Institute for Advancement of Technology(KIAT) through the “Support for Mid-sized Enterprises and Regional Innovation Alliances (R&D, RS-2024-00421022)” program.

REFERENCES

- [1] S. Sundaram and A. Zeid, “Artificial Intelligence-Based Smart Quality Inspection for Manufacturing,” *Micromachines*, vol. 14, no.3, p. 570, 2023, doi: 10.3390/mi14030570.
- [2] K. He, X. Zhang, S. Ren, and J. Sun, “Deep Residual Learning for Image Recognition,” in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 770–778, 2016, doi: 10.1109/CVPR.2016.90.
- [3] J. Redmon, S. Divvala, R. Girshick, and A. Farhadi, “You Only Look Once: Unified, Real-Time Object Detection,” in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 779–788, 2016, doi: 10.1109/CVPR.2016.91.
- [4] J. Redmon and A. Farhadi, “YOLOv3: An Incremental Improvement,” *arXiv preprint arXiv:1804.02767*, 2018.
- [5] S. Ren, K. He, R. Girshick, and J. Sun, “Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks,” *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 39, no. 6, pp. 1137–1149, 2017, doi: 10.1109/TPAMI.2016.2577031.
- [6] H. Du Nguyen and T. Dang, “Artificial Intelligence for Smart Manufacturing in Industry 5.0,” *Studies in Systems, Decision and Control*, vol. 481, pp. 29–55, 2023, doi: 10.1007/978-3-031-30510-8_2.
- [7] X. Xie, “A Review of Recent Advances in Surface Defect Detection Using Texture Analysis Techniques,” *Electronic Letters on Computer Vision and Image Analysis*, vol. 7, no. 3, pp. 1–22, 2008, doi: 10.5565/rev/elcvia.2008.99.
- [8] D. Tsai and Y. Hsieh, “Automated Surface Inspection for Statistical Textures,” *Image and Vision Computing*, vol. 21, no. 4, pp. 307–323, 2003, doi: 10.1016/S0262-8856(98)00043-2.
- [9] Y. Chen, K. Ding, R. Zhao, Z. Wang, and H. Gao, “Surface Defect Detection Methods for Industrial Products: A Review,” *Applied Sciences*, vol. 11, no. 16, p. 7657, 2021, doi: 10.3390/app11167657.
- [10] C. Shorten and T. M. Khoshgoftaar, “A Survey on Image Data Augmentation for Deep Learning,” *Journal of Big Data*, vol. 6,

no. 60, pp. 1-48, 2019, doi: 10.1186/s40537-019-0197-0.

- [11] Y. He, X. Li, and J. Zhang, "A Survey on Surface Defect Inspection Based on Generative Models," *Applied Sciences*, vol. 14, no. 15, p. 6774, 2024, doi: 10.3390/app14156774.
- [12] J. Wang, Y. Ma, L. Zhang, R. Gao, and D. Wu, "Deep Learning for Smart Manufacturing: Methods and Applications," *Journal of Manufacturing Systems*, vol. 48, pp. 144-156, 2018, doi: 10.1016/j.jmsy.2018.01.003.

Authors



Hyun-Ju Oh received the B.S. degree from Uiduk University in 2011 and the M.S. degrees in Computer Science from Kyungpook National University in 2013. Hyun-Ju Oh joined the Gumi Electronics &

Information Technology research Institute, Gumi, Korea, in 2018.



Jae-Gwan Choi received the B.S. degrees in medical computer science from EULJI university, M.S. and Ph.D. degrees in electronics from Kwangwoon University, Korea, in 2012, 2014, 2018, respectively.

Dr. Choi joined the Gumi Electronics & Information Technology research Institute, Gumi, Korea, in 2019.



Wan-Jin Ko received the B.S. and M.S. degrees in information and communication engineering from Sejong university Korea, in 2000, 2002, respectively. Wan-Jin Ko joined the Gumi Electronics & Information

Technology research Institute, Gumi, Korea, in 2014.