

생성형 AI 기반 데이터 증강과 ROI 치수 측정을 결합한 철강 표면 품질 검사 자동화 시스템

(An Automated Steel Surface Quality Inspection System Combining Generative AI-Based Data Augmentation and ROI-Based Dimensional Measurement)

고유진*, 정희자*, 김남호**

(YuJin Ko, HeeJa Jeong, NamHo Kim)

요약

본 논문에서는 철강 표면 품질 검사에서 작업자가 수행하던 결함 탐색, 치수 측정, 합불 판정 과정을 자동화하기 위해 생성형 AI 기반 데이터 보완과 ROI 기반 치수 측정을 결합한 YOLOv11 기반 검사 시스템을 제안한다. 학습 데이터는 기존 철강 결함 데이터, OAK 카메라 기반 자체 촬영 데이터 및 Google Flow 기반 합성 데이터를 활용하여 구축하였다. 제안 시스템은 YOLOv11 기반 검출 모델로 스크래치, 홀, 너트 결손 등의 결함 ROI를 검출하고, ROI 영역에서 영상처리 기반 치수 측정을 수행한 뒤 사전 기준값에 따라 OK, WARNING, NG를 판정한다. 실험 결과, 제안 시스템은 제한된 조건에서 결함 ROI 검출, 치수 측정, 합불 판정 및 검사 결과 표시 절차를 자동화할 수 있음을 확인하였다. 또한 실제 데이터에 합성 데이터를 보조적으로 포함한 학습 구성은 검출 성능 개선 가능성을 보였으며, ROI 기반 치수 측정 결과는 제한된 실험 조건에서 허용 기준 이내의 오차를 나타냈다. 다만 합성 데이터의 독립적 효과와 산업 현장 일반화 성능은 추가 검증이 필요하다.

■ 중심어 : 철강 표면 결함 ; 생성형 AI 데이터 보완 ; YOLOv11 ; ROI 치수 측정 ; 합불 판정 ; 검사 자동화

Abstract

This paper proposes a YOLOv11-based inspection system that combines generative AI-based data supplementation and ROI-based dimensional measurement to automate defect detection, dimensional measurement, and quality judgment in steel surface quality inspection. The training dataset was constructed using existing steel defect data, OAK camera-based self-acquired images, and Google Flow-based synthetic data. The proposed system detects defect ROIs, including scratches, holes, and missing nuts, using a YOLOv11-based detection model. It then performs image-processing-based dimensional measurement within each ROI and determines OK, WARNING, or NG status according to predefined criteria.

Experimental results show that the proposed system can automate defect ROI detection, dimensional measurement, quality judgment, and inspection result visualization under limited experimental conditions. In addition, the training configuration that supplementarily included synthetic data showed the potential to improve detection performance, and the ROI-based dimensional measurement results were within the allowable error range under limited experimental conditions. However, the independent effect of synthetic data and the generalization performance in industrial field environments require further validation.

■ Keywords: Steel Surface Defect ; Generative AI Data Supplementation ; YOLOv11 ; ROI-Based Dimensional Measurement ; Quality Judgment ; Inspection Automation

I. 서론

철강 제품의 표면 품질은 제조 공정에서 제품의 외관 품질과 기능적 신뢰성을 결정하는 중요한 관리

* 정회원, (주)휴넷가이아

** 정회원, 호남대학교 컴퓨터공학과

본 연구는 중소벤처기업부의 스마트 제조혁신 기술개발사업(R&D)의 일환으로 수행하였음. [RS-2024-00434706, 소량 데이터의 증강 기술을 활용한 딥러닝 기반 자동차 부품 품질 검사 기술 개발]

접수일자 : 2026년 04월 23일

수정일자 : 2026년 05월 15일

게재확정일 : 2026년 06월 05일

교신저자 : 김남호 e-mail: nhkim@honam.ac.kr

항목이며, 비전 기반 철강 표면 검사 기술은 수동 검사 한계를 보완하기 위한 주요 방법으로 연구되어 왔다[1]. 스크래치, 홀, 체결부품 결손과 같은 표면 결함은 제품 성능 저하, 조립 불량 및 외관 품질 저하로 이어질 수 있으므로 생산 공정에서 지속적인 검사가 요구된다.

기존 수동 검사 방식에서는 작업자가 결함 위치를 육안으로 탐색하고, 필요 시 결함 크기를 확인한 뒤, 사전에 정의된 기준에 따라 합불 여부를 판단하고 결과를 기록한다. 이러한 방식은 작업자 숙련도, 피로도, 조명 조건 및 검사 환경에 따라 결과가 달라질 수 있다는 한계를 가진다.

최근 철강 표면 결함 검출 연구는 전통적인 영상처리 기반 방법에서 딥러닝 기반 방법으로 전환되고 있으며, 금속 표면 결함 벤치마크 기반 검출 네트워크와 스마트 산업 모니터링 기반 결함 검사 연구 등이 제안되었다[2][3]. 그러나 실제 품질 검사 현장에서는 결함 존재 여부를 검출하는 것만으로는 충분하지 않다. 스크래치의 길이와 폭, 홀의 직경, 체결부품의 유무와 같이 합불 판정에 필요한 정량적 정보가 함께 요구되며, 이를 기준값과 비교하여 OK, WARNING, NG와 같은 판정 결과로 연결하는 구조가 필요하다.

또한 산업 결함 데이터는 실제 발생 빈도가 낮고, 결함 유형별 균형 잡힌 데이터를 확보하기 어렵다. 특히 스크래치와 같이 저대비·비정형 특성을 갖는 결함은 수집과 라벨링이 어렵고, 홀이나 체결부품 결손과 같이 형태학적으로 다른 결함과 함께 학습할 경우 검출 성능이 저하될 수 있다. 이에 본 연구에서는 기존 철강 결함 데이터, OAK 카메라 기반 자체 촬영 데이터 및 Google Flow 기반 생성형 AI 합성 데이터를 함께 활용하여 학습 데이터를 구축하였다.

따라서 본 연구는 새로운 객체 검출 알고리즘 자체를 제안하는 것이 아니라, 철강 표면 품질 검사에서 부족한 결함 데이터를 생성형 AI 기반 합성 데이터로 보완하고, YOLOv11 기반 검출 결과를 ROI로 활용하여 스크래치 길이·폭 및 홀 직경을 자동 측정 한 뒤, 합불 판정까지 연결하는 검사 자동화 시스템

을 구현하는 데 목적이 있다. 연구 범위는 기존 철강 결함 데이터, 자체 촬영 데이터 및 Google Flow 기반 합성 데이터를 활용한 학습 데이터 구축, YOLOv11 기반 결함 ROI 검출, ROI 기반 치수 측정, OK/WARNING/NG 판정 및 결과 표시·설비 연계로 한정하였다.

본 연구의 주요 기여는 다음과 같다. 첫째, 실제 결함 데이터 확보가 제한적인 철강 표면 검사 환경에서 공개 데이터, 자체 촬영 데이터 및 생성형 AI 기반 합성 데이터를 결합하여 학습 데이터 구성을 체계화하였다. 둘째, YOLOv11 기반 검출 결과를 단순 시각화에 그치지 않고 후속 ROI 기반 치수 측정 절차와 연결하여 스크래치 길이·폭 및 홀 직경을 자동 산출하는 검사 절차를 구현하였다. 셋째, 산출된 치수 정보를 사전 품질 기준과 비교하여 OK, WARNING, NG 판정 및 GUI 결과 표시까지 연결함으로써 수동 검사 절차를 자동화하는 통합 파이프라인을 제시하였다. 넷째, 검출 성능, 치수 측정 오차 및 중단간 검사 시간을 함께 평가하여 제안 시스템의 초기 산업 적용 가능성을 확인하였다.

다만 본 연구는 합성 데이터의 독립적 효과를 입증하거나 산업 현장 전반의 일반화 성능을 검증하는 것을 목적으로 하지 않으며, 해당 사항은 향후 연구 범위로 둔다.

II. 기존 연구

1. 철강 표면 결함 검출 및 검사 자동화

철강 표면 결함 검출 연구는 전통적인 영상처리 기반 방법에서 CNN 및 객체 검출 기반 딥러닝 방법으로 전환되고 있으며, 금속 표면 결함 벤치마크와 검출 네트워크, 스마트 산업 모니터링 기반 철강 결함 검사 연구 등이 제안되었다[2][3]. 기존 연구들은 결함 위치 검출 및 클래스 분류 성능 향상에 초점을 두고 있으나, 실제 품질 검사 공정에서 요구되는 치수 측정, 합불 판정, 결과 기록 및 설비 연계까지 포함한 자동화 연구는 상대적으로 제한적이다. 따라서 검출된 결함 영역을 ROI로 활용하고, ROI 내부에서 치수 정보를 산출하여 판정 기준과 연계하는 구조가 필요하다.

최근 스마트미디어 및 산업 응용 분야에서도 딥러닝 기반 영상 분석 기술을 활용하여 현장 상황을 인식하고 관리 시스템과 연계하려는 연구가 수행되고 있다[4]. 또한 YOLO 계열 객체 검출 모델을 활용하여 영상 내 불량 또는 결함 영역을 자동으로 탐지하고 품질 선별에 적용하려는 연구도 제안되었다[5]. 한편, 제한된 학습 데이터 환경에서는 영상처리 기반 자동 라벨링과 같은 데이터 구축 보조 기법이 활용될 수 있다[6]. 이러한 연구들은 영상 기반 인식, 결함 탐지 및 데이터 구축 자동화 측면에서 본 연구와 관련성을 가지나, 본 연구는 철강 표면 결함 ROI 검출 이후 치수 측정, OK/WARNING/NG 판정, GUI 표시 및 설비 연계까지 포함하는 검사 자동화 파이프라인을 구성한다는 점에서 차별성을 가진다.

2. 생성형 AI 데이터 증강과 ROI 기반 치수 측정

산업 결함 데이터는 실제 발생 빈도가 낮고, 결함 유형별로 충분한 데이터를 확보하기 어렵다는 문제가 있다. 또한 결함 이미지는 촬영 조건, 표면 재질, 조명, 결함 방향 및 크기에 따라 시각적 특성이 달라지므로, 제한된 실제 데이터만으로 다양한 현장 조건과 결함 변이를 모두 반영하기 어렵다. 이러한 데이터 부족 문제를 완화하기 위해 GAN 등 생성 모델을 활용한 합성 데이터 생성 기법이 연구되어 왔다[7].

합성 데이터는 실제 데이터에서 부족한 결함 형태, 표면 질감 및 조명 조건 등을 보완하고, 모델이 다양한 패턴을 학습할 수 있도록 돕는 장점이 있다. 다만 합성 데이터를 추가할 경우 성능 향상이 나타나더라도, 그 효과가 합성 데이터 자체의 도메인 다양성 때문인지 단순히 학습 이미지 수 증가 때문인지를 완전히 분리하기 어렵다. 따라서 본 연구에서는 합성 데이터 실험을 성능 향상 입증보다는 데이터 부족 상황에서의 보완 가능성 확인이라는 관점에서 해석하였다.

기존 연구들이 주로 검출 성능 지표를 중심으로 결함 탐지 성능을 평가한 것과 달리, 본 연구는 YOLOv11 기반 결함 ROI 검출, ROI 기반 치수 측정,

OK/WARNING/NG 판정 및 결과 표시를 하나의 검사 파이프라인으로 구성하였다. 또한 검출 성능뿐 아니라 치수 측정 정확도와 중단간 검사 시간을 함께 평가함으로써 실제 품질 검사 자동화 관점에서의 적용 가능성을 확인하고자 하였다.

기존 연구들은 주로 결함 검출 정확도 향상에 초점을 두었으나, 실제 품질 검사 공정에서는 결함 위치 검출 이후 치수 측정, 판정 기준 적용, 결과 기록 및 설비 제어 연계가 함께 요구된다. 특히 스크래치와 같이 방향성이 있는 비정형 결함은 단순 바운딩 박스 크기만으로 실제 길이와 폭을 산출하기 어렵고, 홀과 같은 원형 결함은 별도의 형상 기반 측정 절차가 필요하다. 따라서 본 연구는 검출 모델의 성능 비교에만 머무르지 않고, 검출된 ROI를 기반으로 결함 유형별 치수 측정 알고리즘을 적용하고, 이를 품질 판정 및 검사 결과 표시 절차와 연결한 점에서 기존 검출 중심 연구와 차별성을 가진다.

III. 제안 시스템

1. 전체 시스템 구성

본 연구에서 제안하는 시스템은 철강 표면 품질 검사에서 작업자가 수행하던 결함 탐색, 치수 측정, 합불 판정 및 결과 확인 절차를 자동화하기 위한 검사 파이프라인이다. 제안 시스템은 결함 ROI 검출부, ROI 기반 치수 측정부, 합불 판정부, 결과 표시 및 설비 연계부로 구성된다.

그림 1은 제안 시스템의 전체 처리 흐름을 나타낸다. 입력 영상은 YOLOv11 기반 검출 모델을 통해 스크래치, 홀, 너트 결손 등의 결함 ROI로 검출되며, 검출된 ROI에는 결함 유형별 치수 측정 절차가 적용된다. 스크래치는 길이와 폭을 산출하고, 홀은 직경을 산출한다. 산출된 치수 정보는 사전 기준값과 비교되어 OK, WARNING, NG로 판정되며, 최종 결과는 GUI 표시, 결과 저장 및 Modbus TCP 기반 설비 제어와 연계될 수 있도록 구성하였다.

본 연구에서 YOLOv11은 최종 합불 판정을 직접 수행하는 모델이 아니라, 후속 치수 측정 알고리즘이

적용될 결합 ROI를 제공하는 검출기로 활용된다. 따라서 제안 시스템의 핵심은 결합 검출 결과를 단순 시각화에 그치지 않고, ROI 기반 치수 측정 및 판정 절차와 연결하여 수동 검사 과정을 자동화하는 데 있다.

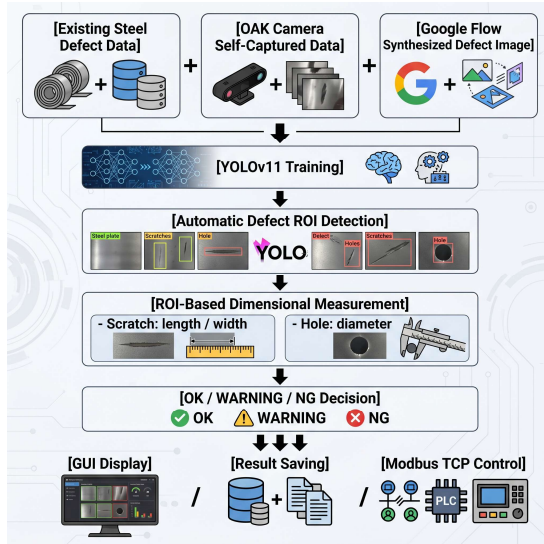


그림 1. 전체 시스템 구성도

2. YOLOv11 기반 ROI 검출 및 Dual-Detector 구조

제안 시스템은 YOLOv11 기반 검출 모델을 이용하여 입력 영상에서 스크래치, 홀, 너트 결손의 위치와 클래스를 추정한다. 검출 결과는 바운딩 박스, 클래스 정보, 신뢰도 점수로 출력되며, 바운딩 박스 영역은 후속 치수 측정을 위한 ROI로 사용된다.

철강 표면 결함은 유형에 따라 형태학적 특성이 다르다. 스크래치는 길고 얇은 선형 구조를 가지는 반면, 홀과 너트 결손은 상대적으로 원형 또는 블록형 형상을 갖는다. 이러한 차이를 고려하여 본 연구에서는 단일 모델에 모든 결함 유형을 통합하기보다, 스크래치 검출기와 홀·너트 결손 검출기를 분리 운영하는 dual-detector 기반 시스템 구성을 적용하였다. 이는 새로운 검출 알고리즘을 제안하기 위한 목적이 아니라, 결함군별 형태 차이를 반영하여 후속 ROI 기반 치수 측정에 필요한 후보 영역을 안정적으로 확보하기 위한 구현 전략이다. 두 검출기는 독립적으로 학습된 후 추론 단계에서 결과를 병합하여 최종 ROI 후보를 생성한다.

기존 객체 검출 앙상블 연구에서는 WBF나

Soft-NMS와 같이 예측 결과를 후처리 단계에서 융합하는 방식이 활용되어 왔다[8][9]. 반면 본 연구의 dual-detector 구조는 일반적인 ensemble 평균화 방식이라기보다, 스크래치와 홀·너트 결손의 형태학적 차이를 반영하여 결함군별 ROI 검출을 분리 수행하기 위한 시스템 구성이다. 따라서 본 논문에서는 해당 구조를 단일 통합 모델 대비 일반적 우월성을 주장하기 위한 알고리즘 기여가 아니라, 후속 ROI 기반 치수 측정에 필요한 결합 영역을 확보하기 위한 구현적 접근으로 해석한다.

3. ROI 기반 치수 측정 및 합불 판정

제안 시스템은 YOLOv11 기반 검출 모델이 추출한 ROI 영역을 입력으로 하여 결함 유형별 치수 측정을 수행한다. 이는 작업자가 결함을 육안으로 확인한 후 직접 길이 또는 직경을 측정하던 절차를 영상처리 기반 자동 측정 절차로 대체하기 위한 것이다.

스크래치 결함은 방향이 일정하지 않고 형상이 불규칙하기 때문에 단순한 축 정렬 바운딩 박스만으로 실제 길이와 폭을 산출하기 어렵다. 따라서 본 연구에서는 스크래치 ROI에 대해 적응적 가우시안 이진화, 모폴로지 클로징, 윤곽선 추출 및 minAreaRect를 적용하였다. minAreaRect를 통해 회전 보정된 최소 외접 사각형을 산출하고, 장축은 스크래치 길이, 단축은 스크래치 폭으로 사용하였다.

홀 결함은 원형 형상에 가까운 특성을 가지므로 Hough 변환 기반 원 검출을 우선 적용하였다[10]. 원 검출이 안정적으로 수행되지 않는 경우에는 fitEllipse를 보조적으로 적용하여 직경을 산출하였다. 픽셀 단위 측정값은 카메라 캘리브레이션 계수를 이용하여 mm 단위로 변환하였다.

$$\begin{aligned} L_{mm} &= L_{pixel} / CP_{calib} \\ W_{mm} &= W_{pixel} / CP_{calib} \\ D_{mm} &= D_{pixel} / CP_{calib} \end{aligned} \quad (1)$$

여기서 L_{mm} 과 W_{mm} 은 각각 스크래치 길이와 폭, D_{mm} 은 홀 직경을 의미하며, CP_{calib} 는 카메라별 픽셀-밀리미터 변환 계수이다. CP_{calib} 는 기준 길이를 갖는 캘리브레이션 타깃을 동일 촬영 거리와 동일 해상도 조건에서 촬영한 후, 기준 길이에 해당

하는 픽셀 수를 측정하여 산출하였다. 본 연구에서는 카메라 위치, 촬영 거리 및 해상도를 고정한 상태에서 픽셀-밀리미터 변환 계수를 적용하였으며, 카메라 높이, 렌즈 초점, 촬영 각도 또는 해상도 조건이 변경될 경우 CP_calib를 재산정하도록 하였다.

ROI 기반 치수 측정 결과는 사전 기준값과 비교하여 OK, WARNING, NG로 판정하였다. 스크래치는 3mm 이하를 OK, 3mm 초과 7mm 미만을 WARNING, 7mm 이상을 NG로 판정하였고, 홀은 5mm 이상일 경우 NG로 판정하였다. 너트 결손은 필수 체결부품이 검출되지 않는 경우 NG로 처리하였으며, NG 판정 시 Modbus TCP 기반 릴레이 제어 신호를 전송할 수 있도록 구성하였다.

IV. 학습 데이터 구축

1. 데이터 소스 및 정제

본 연구에서는 스크래치, 홀, 너트 결손 검출을 위해 NEU surface defect dataset, OSPD, OAK 카메라 기반 자체 촬영 데이터 및 Google Flow 기반 합성 데이터를 함께 활용하였다. NEU 데이터는 스크래치 기본 패턴 학습에, OSPD는 스크래치 및 홀 결함 패턴 확보에 사용하였다. OAK 자체 촬영 데이터는 실제 시스템 운용 환경을 반영하기 위해 활용하였으며, Google Flow 합성 데이터는 결함 방향, 크기, 조명 조건 및 표면 질감의 다양성을 보완하기 위한 보조 데이터로 사용하였다.

표 1. 학습 데이터 구성 및 활용 목적

데이터 소스	이미지 수	대상 클래스	활용 목적 및 출처
NEU surface defect dataset [15]	1,486	scratch	공개 열연강판 결함 데이터셋, 스크래치 기본 패턴 학습
OSPD [16]	3,437	scratch, hole	공개 프레스 금속 부품 결함 데이터셋, 스크래치 및 홀 패턴 확보
Google Flow 합성 데이터	3,400	scratch, hole, nut	프롬프트 기반 합성 이미지, 결함 다양성 보완
Grounding DINO[11]	1,064	scratch, hole, nut	자동 라벨링 후보 생성 후 수동 검수
OAK 자체 촬영	2,355	scratch	자체 촬영 데이터. 실제 시스템 운용 환경 반영

표 1은 학습 데이터 소스와 활용 목적을 나타낸다. 각 데이터는 중복 제거, 저품질 샘플 제외, 라벨 정합성 검토를 거쳐 학습 후보 데이터로 구성하였다. Grounding DINO 기반 후보 라벨 생성 방식[11]은 자동 라벨링 보조에 활용하였으며, 최종 학습 전 라벨 위치, 클래스 오류 및 결함 누락 여부를 수동 검수하였다. 정제 전 후보 데이터는 총 11,742장이다.

2. Google Flow 기반 합성 데이터 생성

본 연구에서는 실제 철강 표면 결함 데이터에서 부족한 결함 방향, 크기, 조명 조건 및 표면 질감의 다양성을 보완하기 위해 Google Flow 기반 생성형 AI를 활용하였다. 합성 데이터 생성에는 철강 표면, 촬영 각도, 조명 조건, 결함 유형 및 결함 형태를 명시한 텍스트 프롬프트를 사용하였으며, 생성된 이미지는 결함 형태의 명확성, 금속 표면 질감의 적절성, 라벨링 가능성, 과도한 비현실성 여부를 검수한 뒤 학습 후보 데이터에 포함하였다.

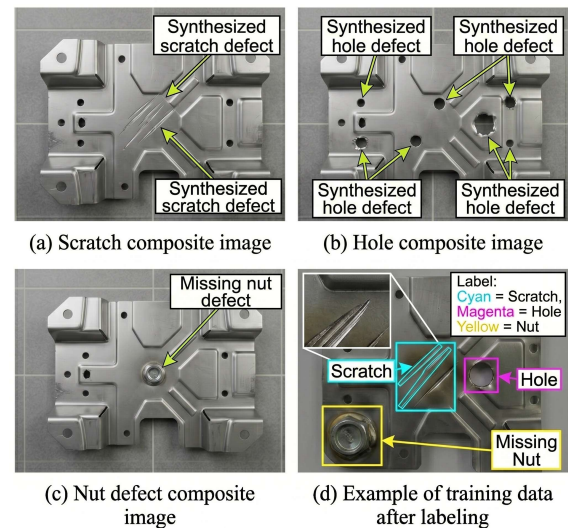


그림 2. Google Flow 기반 합성 데이터 생성 예시

그림 2는 생성된 합성 결함 이미지와 라벨링 후 학습 데이터 예시를 나타낸다. (a)는 스크래치, (b)는 홀, (c)는 너트 결손 합성 이미지이며, (d)는 생성된 이미지에 대해 결함 영역을 바운딩 박스로 라벨링한 예시이다. 본 연구에서는 합성 이미지를 실제 데이터의 대체재가 아니라, 학습 데이터 다양성을 보완하기 위한 보조 데이터로 사용하였다.

3. 합성 데이터 포함 학습 구성의 성능 변화

Google Flow 기반 합성 데이터가 학습 구성에 미치는 영향을 확인하기 위해 scratch_v5 데이터셋을 대상으로 비교 실험을 수행하였다. 비교 조건은 실제 데이터만 사용한 경우와 실제 데이터에 합성 데이터를 포함한 경우로 설정하였으며, 두 조건 모두 동일한 YOLOv11n 기반 학습 설정을 적용하였다. 평가 지표는 Precision, Recall, mAP50, mAP50-95를 사용하였다.

다만 두 조건은 학습 이미지 수가 동일하지 않으므로, 본 실험은 합성 데이터의 독립적 효과를 분리하기 위한 ablation 실험이 아니라 합성 데이터 포함 학습 구성의 성능 변화 경향을 확인하기 위한 실험으로 설정하였다. 따라서 본 결과는 합성 데이터 자체의 성능 향상 효과를 입증한 결과가 아니라, 실제 결합 데이터가 부족한 조건에서 학습 데이터 다양성을 보완할 수 있는 가능성을 확인한 결과로 해석한다.

표 2. 합성 데이터 포함 여부에 따른 검출 성능 변화

학습 데이터 구성	학습 이미지 수	Precision	Recall	mAP50	mAP50-95
실제 데이터만 사용	1,480	0.7812	0.6521	0.7423	0.4830
실제 + 합성 데이터 사용	2,114	0.8271	0.7070	0.7991	0.5072

표 2에서 실제+합성 데이터 조건은 실제 데이터만 사용한 조건보다 Precision, Recall, mAP50, mAP50-95에서 모두 높은 값을 보였다. Precision은 0.7812에서 0.8271로, Recall은 0.6521에서 0.7070으로, mAP50은 0.7423에서 0.7991로 향상되었다. 이는 실제 데이터가 제한된 조건에서 합성 데이터를 보조적으로 포함한 학습 구성이 검출 성능 개선에 기여할 가능성을 보여준다. 다만 본 비교는 학습 이미지 수가 동일하게 통제된 실험이 아니므로, 성능 향상의 원인을 합성 데이터 자체의 효과로 단정하기는 어렵다.

V. 실험 결과

1. 검출 성능 비교

본 연구에서는 YOLOv11n을 결합 ROI 검출기로 적용하기 위해 YOLOv5n[12], YOLOv8n[13], YOLOv11n[14]을 동일한 scratch_v5 데이터셋과 학습 조건에서 비교하였다. 평가 지표는 Precision, Recall, mAP50, mAP50-95 및 파라미터 수로 설정하였다.

표 3은 경량 검출 모델별 성능 비교 결과를 나타낸다. 본 연구의 모델 비교 목적은 최고 정확도 모델 선정이 아니라, 후속 ROI 기반 치수 측정에 필요한 검출 안정성, 경량성 및 처리 효율의 균형을 확인하는데 있다.

표 3. 경량 검출 모델 성능 비교

모델	Params	Precision	Recall	mAP50	mAP50-95
YOLOv5n	2.50M	0.8450	0.6740	0.7760	0.4830
YOLOv8n	3.01M	0.7936	0.7299	0.7986	0.5072
YOLOv11n	2.58M	0.8271	0.7070	0.7991	0.5130

표 3에서 YOLOv11n은 YOLOv8n과 비교하여 mAP50 차이는 크지 않았으나, 더 적은 파라미터 수와 상대적으로 높은 mAP50-95를 보였다. 따라서 본 연구에서는 YOLOv11n을 단순 최고 성능 모델이 아니라, 경량성, 처리 효율 및 ROI 검출 성능의 균형 측면에서 제안 시스템에 적합한 모델로 판단하였다.

dual-detector 구조는 스크래치와 홀-너트 결손의 형태학적 차이를 고려하여 후속 ROI 기반 치수 측정에 필요한 결합 영역을 확보하기 위한 구성으로 적용하였으며, 그 결과는 본 연구의 데이터 구성과 결합 형태 조건에 한정하여 해석하였다.

2. ROI 기반 치수 측정 정확도

제안 시스템은 YOLOv11 기반 검출 모델이 추출한 ROI 영역에서 스크래치 길이, 스크래치 폭, 홀 직경을 자동 측정한다. 치수 측정 정확도는 버니어 캘리퍼스 기반 기준 측정값과 ROI 기반 자동 측정값의 차이를 비교하여 평가하였다.

정량 평가 지표로는 평균절대오차(MAE), 평균제

곱근오차(RMSE), 오차의 표준편차 및 최대오차를 사용하였다. MAE와 RMSE는 전체 오차 수준과 큰 오차의 영향을 확인하기 위해, 표준편차와 최대오차는 측정 오차의 분산 및 최대 편차를 확인하기 위해 사용하였다.

표 4. ROI 기반 치수 측정 정확도 평가 결과

측정 대상	n	MAE (mm)	RMSE (mm)	표준 편차 (mm)	최대 오차 (mm)	허용 기준	판정
스크래치 길이	50	1.12	1.36	0.78	2.41	±3.0 mm	충족
스크래치 폭	50	0.84	1.05	0.61	1.92	±3.0 mm	충족
홀 직경	50	0.96	1.18	0.69	2.08	±5.0 mm	충족

표 4에서 ROI 기반 자동 측정 결과는 모든 측정 항목에서 허용 기준 이내의 오차를 보였다. 스크래치 길이의 MAE는 1.12mm, 스크래치 폭의 MAE는 0.84mm, 홀 직경의 MAE는 0.96mm였으며, 최대오차 역시 각 허용 기준 이내로 확인되었다. 이는 제한된 실험 조건에서 ROI 기반 측정 절차가 수동 치수 확인을 보조할 수 있음을 보여준다. 다만 본 실험은 n=50 규모의 제한된 시료를 대상으로 수행되었으며, 카메라 위치, 촬영 거리 및 조명 조건이 고정된 환경에서 산출된 결과이다. 실제 생산라인에서는 표면 반사, 오염, 조명 변화, 결함 깊이, 결함 방향, 재질 및 카메라 각도 변화에 따라 측정 정확도가 달라질 수 있다. 따라서 본 결과는 산업 현장 전반의 일반화 성능을 의미하기보다는, ROI 기반 치수 측정 절차의 초기 적용 가능성을 확인한 결과로 해석한다.

3. 검사 시간 및 시스템 운용 결과

제안 시스템의 검사 자동화 효과를 분석하기 위해 수동 검사 기준 시나리오와 제안 시스템의 종단간 검사 시간을 비교하였다. 본 연구에서는 처리 시간을 결함 검출, 치수 측정 및 판정 로직 수행에 소요되는 AI 파이프라인 처리 시간과, 영상 획득, ROI 검출, 치수 측정, 합불 판정, GUI 표시 및 결과 저장을 포함한 시스템 종단간 검사 시간으로 구분하였다.

AI 파이프라인 처리 시간은 평균 13.5±5.0ms, 최대 31.4ms로 측정되었으며, 수동 검사와의 비교는 실제

검사 절차를 반영한 시스템 종단간 검사 시간을 기준으로 수행하였다.

수동 검사 기준 시간은 특정 산업 현장의 표준 작업시간을 대표하는 값이 아니라, 본 연구에서 자동화 대상 절차와 비교하기 위해 정의한 기준 시나리오이다. 기준 시나리오는 결함 탐색, 치수 확인, 합불 판단 및 결과 기록 절차로 구성하였으며, 각 절차의 기준 시간을 합산하여 60초/개로 설정하였다. 표 5는 수동 검사 기준 시나리오의 절차별 시간 산정 기준을 나타낸다.

표 5. 수동 검사 시나리오 절차별 시간 산정 기준

절차	내용	기준 시간
결함 탐색	표면 결함 여부 육안 확인	20초
치수 확인	길이, 폭 또는 직경 확인	20초
합불 판단	기준값 비교 및 판정	10초
결과 기록	검사 결과 기록 또는 입력	10초
합계	수동 검사 기준 시나리오	60초

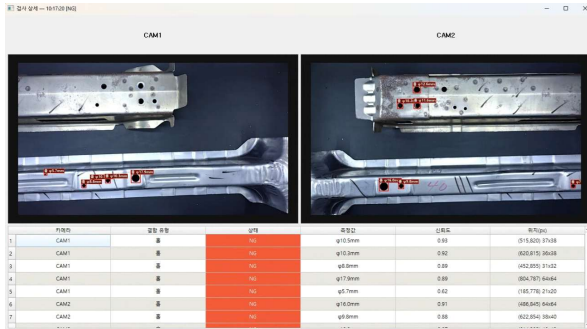
표 5에서 정의한 수동 검사 기준 시나리오를 바탕으로 제안 시스템의 종단간 검사 시간과 비교하였다. 제안 시스템의 검사 시간은 영상 획득, ROI 검출, 치수 측정, 자동 판정, GUI 표시 및 결과 저장까지 포함한 전체 처리 시간을 기준으로 측정하였다. 표 6은 본 연구 조건에서의 수동 검사 기준 시나리오와 제안 시스템의 종단간 검사 시간을 비교한 결과이다.

표 6. 본 연구 조건에서의 수동 검사 기준 시나리오와 제안 시스템 종단간 검사 시간 비교

구분	포함 절차	시간	해석
수동 검사 기준 시나리오	육안 결함 탐색, 치수 확인, 합불 판정, 결과 기록	약 60.0초/개	본 연구에서 정의한 비교 기준
제안 시스템	영상 획득, ROI 검출, 치수 측정, 자동 판정, GUI 표시, 결과 저장	약 2.5초/개	실제 시스템 운용 절차 기준
시간 단축 가능성	동일 절차 범위 비교	약 95.8%	본 연구 조건에서의 참고 지표

표 6에서 제안 시스템의 종단간 검사 시간은 약 2.5초/개로 측정되었으며, 표 5에서 정의한 수동 검사 기준 시나리오 60.0초/개와 비교할 때 약 95.8%의 시간 단축 가능성을 보였다. 이는 제안 시스템이 결함

탐색, 치수 측정, 합불 판단 및 결과 기록 절차를 자동화함으로써 검사 시간을 줄일 수 있음을 보여준다. 다만 수동 검사 기준 시간은 작업자 숙련도, 검사 대상 형상, 결함 유형, 측정 도구 및 결과 기록 방식에 따라 달라질 수 있으므로, 본 결과는 모든 산업 현장에 일반화되는 절대값이 아니라 본 연구 조건에서의 참고 지표로 해석해야 한다.



번호	카메라	결함 유형	판정	위치	크기	신뢰도	위치(픽셀)
1	CAM1	불	NG	x10.0mm	0.89	0.15, 0.20, 0.1418	
2	CAM1	불	NG	x17.0mm	0.92	0.02, 0.13, 0.0486	
3	CAM1	불	NG	x8.0mm	0.89	0.02, 0.03, 0.1432	
4	CAM1	불	NG	x7.0mm	0.89	0.04, 0.11, 0.0464	
5	CAM1	불	NG	x5.7mm	0.82	0.18, 0.18, 0.1420	
6	CAM2	불	NG	x16.0mm	0.91	0.05, 0.04, 0.0464	
7	CAM2	불	NG	x8.0mm	0.89	0.02, 0.04, 0.0464	

그림 3. GUI 기반 결함 ROI 검출, 치수 측정 및 판정 결과 화면

그림 3은 제안 시스템의 GUI 운용 결과 예시이다. 검출된 결함 ROI의 측정값, 신뢰도, 위치 및 판정 결과가 결과 테이블에 표시되며, 작업자는 OK/NG 판정을 한 화면에서 확인할 수 있다.

VI. 고찰 및 한계

합성 데이터를 포함한 학습 구성은 실제 데이터만 사용한 조건보다 Precision, Recall, mAP50에서 향상되는 경향을 보였으나, 두 조건의 학습 이미지 수가 동일하지 않으므로 합성 데이터 자체의 독립적 효과로 단정하기는 어렵다. 또한 dual-detector 구조와 ROI 기반 치수 측정 결과는 본 연구의 데이터 구성과 n=50 규모의 제한된 시료 조건에서 확인된 결과이므로, 산업 현장 전반의 일반화 성능을 보장하기에는 한계가 있다. 수동 검사 기준 시나리오 대비 약 95.8%의 시간 단축 가능성 역시 본 연구에서 정의한 비교 조건에 따른 참고 지표로 해석해야 한다. 향후에는 동일 데이터 수 조건의 합성 데이터 비교, 다양한 실제 결함 시료 기반 반복 실험, 설계 홀과 결함 홀 구분 및 품질관리 시스템 연계를 통해 현장 적용성을 높일 필요가 있다.

VII. 결론

본 논문에서는 생성형 AI 기반 데이터 증강과 ROI 기반 치수 측정을 결합한 YOLOv11 기반 철강 표면 품질 검사 자동화 시스템을 제안하였다. 제안 시스템은 기존 철강 결함 데이터, 자체 촬영 데이터 및 Google Flow 기반 합성 데이터를 활용하여 학습 데이터를 구축하고, 검출된 결함 ROI에서 스크래치 길이·폭과 홀 직경을 산출한 뒤 OK, WARNING, NG 판정으로 연결하였다.

실험 결과, 제안 시스템은 제한된 조건에서 결함 ROI 검출, 치수 측정, 합불 판정 및 검사 결과 표시 절차를 자동화할 수 있음을 확인하였다. 합성 데이터 포함 학습 구성은 검출 성능 향상 경향을 보였으며, ROI 기반 치수 측정 결과는 허용 기준 이내의 오차를 나타냈다. 향후에는 동일 데이터 수 조건의 합성 데이터 비교 실험, 다양한 실제 결함 시료 기반 반복 검증, 정상 홀과 결함 홀의 구분 로직 및 품질관리 시스템 연계를 추가함으로써 제안 시스템의 현장 적용 가능성을 단계적으로 검증할 계획이다.

REFERENCES

- [1] N. Neogi, D. K. Mohanta, and P. K. Dutta, "Review of vision-based steel surface inspection systems," *EURASIP Journal on Image and Video Processing*, vol. 2014, no. 50, pp. 1-19, Dec. 2014.
- [2] X. Lv, F. Duan, J.-j. Jiang, X. Fu, and L. Gan, "Deep metallic surface defect detection: The new benchmark and detection network," *Sensors*, vol. 20, no. 6, pp. 1-16, Mar. 2020.
- [3] R. Hao, B. Lu, Y. Cheng, X. Li, and B. Huang, "A steel surface defect inspection approach towards smart industrial monitoring," *Journal of Intelligent Manufacturing*, vol. 32, no. 7, pp. 1833-1843, Oct. 2021.
- [4] S.Y. Jeon, J.H. Park, S.B. Yoon, Y.S. Kim, Y.S. Lee, and J.H. Jeon, "Development of Real-time Worker Safety Management System using Deep Learning-based Image Analysis Algorithm," *Smart Media Journal*, vol. 9, no. 3, pp. 25-30, Sept. 2020.
- [5] H.S. Choi, H.G. Lim, and H.S. Son, "Detection of

Defective Parts of Fruits using YOLO V4 Deep Learning Intelligence Technology,” *Smart Media Journal*, vol. 11, no. 4, pp. 46-55, May 2022.


- [6] S.W. Kang, H.G. Lim, and H.S. Son, “Automatic Labeling Method for Overlapping Flatfish Object Detection based on Image Processing Techniques,” *Smart Media Journal*, vol. 13, no. 11, pp. 59-70, Nov. 2024.
- [7] I. J. Goodfellow, J. Pouget-Abadie, M. Mirza, B. Xu, D. Warde-Farley, S. Ozair, A. Courville, and Y. Bengio, “Generative adversarial nets,” *Proc. of Advances in Neural Information Processing Systems*, pp. 2672-2680, Montreal, Canada, Dec. 2014.
- [8] R. A. Solovyev, W. Wang, and T. Gabruseva, “Weighted boxes fusion: Ensembling boxes from different object detection models,” *Image and Vision Computing*, vol. 107, pp. 1-10, Mar. 2021.
- [9] N. Bodla, B. Singh, R. Chellappa, and L. S. Davis, “Soft-NMS: Improving object detection with one line of code,” in *Proc. of IEEE International Conference on Computer Vision*, pp. 5561-5569, Venice, Italy, Oct. 2017.
- [10] R. O. Duda and P. E. Hart, “Use of the Hough transformation to detect lines and curves in pictures,” *Communications of the ACM*, vol. 15, no. 1, pp. 11-15, Jan. 1972.
- [11] S. Liu, Z. Zeng, T. Ren, F. Li, H. Zhang, J. Yang, Q. Jiang, C. Li, J. Yang, H. Su, J. Zhu, and L. Zhang, “Grounding DINO: Marrying DINO with grounded pre-training for open-set object detection,” in *Proc. of European Conference on Computer Vision*, pp. 38-55, Milan, Italy, Sept. 2024.
- [12] Ultralytics, “YOLOv5,” 2020. <https://github.com/ultralytics/yolov5> (accessed May., 13, 2026).
- [13] Ultralytics, “YOLOv8,” 2023. <https://docs.ultralytics.com/models/yolov8/> (accessed May., 13, 2026).
- [14] Ultralytics, “YOLO11,” 2024. <https://docs.ultralytics.com/models/yolo11/> (accessed May., 13, 2026).
- [15] K. Song and Y. Yan, “A noise robust method based on completed local binary patterns for hot-rolled steel strip surface defects,” *Applied Surface Science*, vol. 285, pp. 858-864, Nov. 2013.
- [16] S. Antiles and S. S. Talathi, “Open Stamped Parts Dataset,” arXiv preprint arXiv:2403.10369, Mar. 2024.

저자 소개



고유진(정회원)

2021년~현재 (주)휴넷가이아 부장
2026년 호남대학교 컴퓨터공학 박사 졸업
2024년 호남대학교 소프트웨어공학 석사
<주관심분야: 인공지능, 응용 SW>



정희자(정회원)

2018년~현재 (주)휴넷가이아 대표
2018년 호남대학교 경영학 박사
2014년 호남대학교 소프트웨어공
학과 석사
<주관심분야: 응용 SW, 정보통신,
경영정보시스템>



김남호(정회원)

1997년 포항공과대학교 정보통신
학과 석사 졸업
2013년 전남대학교 전산통계 박사
1991년~1997 포스코ICT(주) 연
구원
1998년~현재 호남대학교 컴퓨터
공학과 부교수

<주관심분야: 사물인터넷, 인공지능, 응용 SW>