

멀티모달 AI 기반 불량 탐지·원인 분석 시스템

Multi-modal AI-based defect detection and cause analysis system

2026-06-16 ~ 2026-07-01

목차

01
팀원소개

02
제안 배경

03
구현방안

04
기술설명

05
파이프라인

06
기대효과

프로젝트 팀 및 역할 분담

4명의 팀원이 각자의 전문 역할을 기반으로 협업합니다.



신우영

PM | 이진분류모델, DB(NoSQL)



안재윤

객체탐지모델(SD), CI/CD(GitHub)




구성윤

MLOps, 객체탐지모델(PR)



노희용

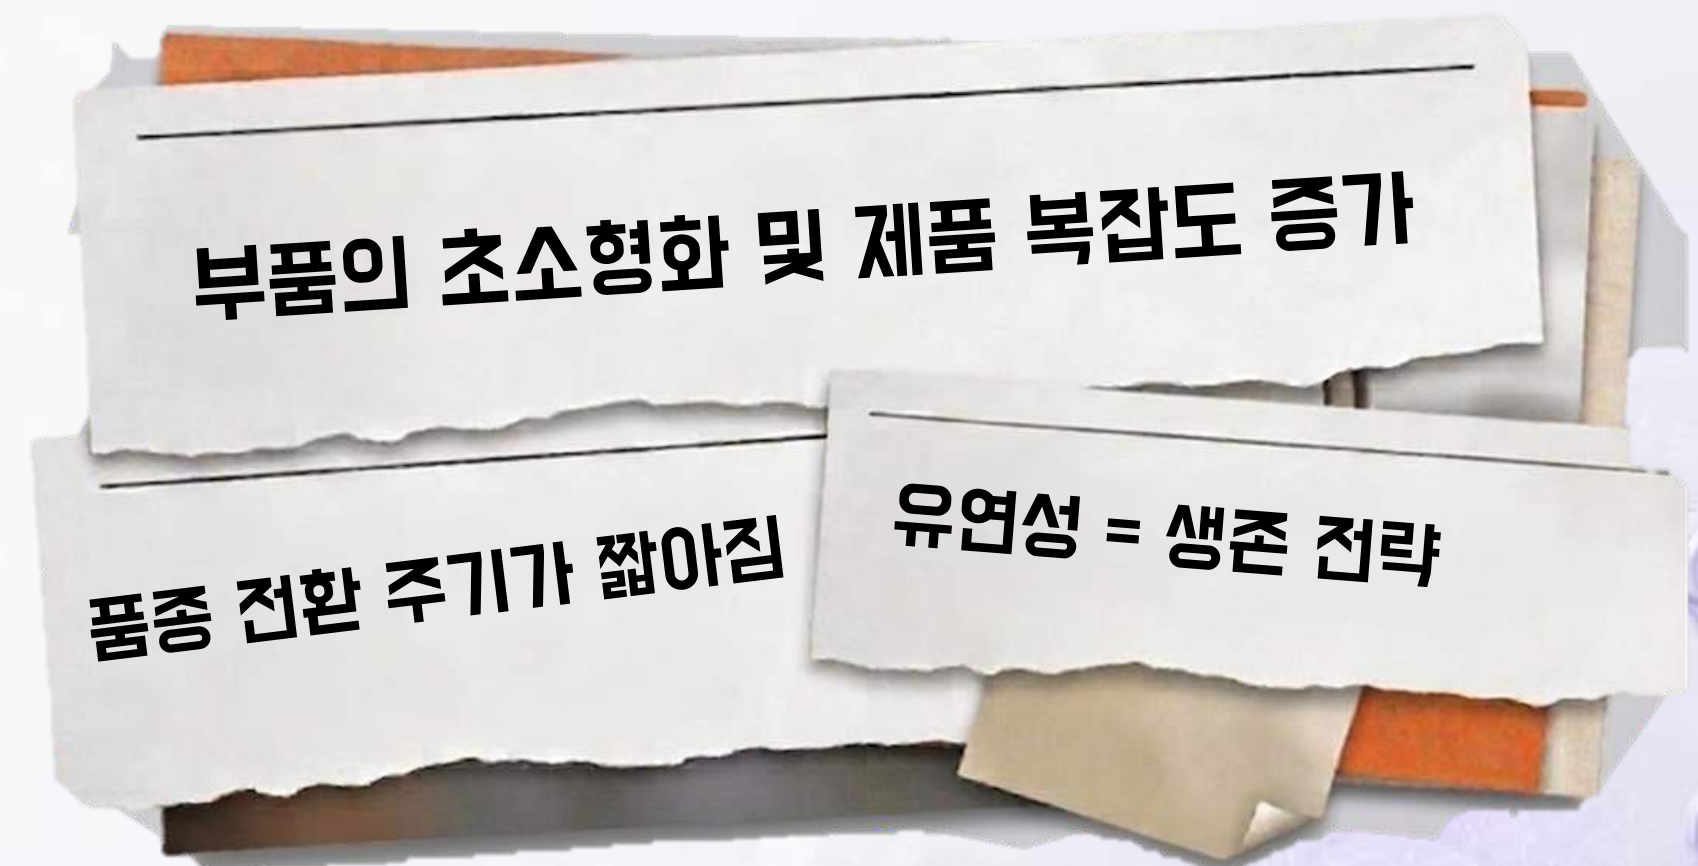
원인도출모델, 웹(Full Stack)



SMT 공정 및 도메인 개요

SMT(Surface Mount Technology) : PCB 기판 위에 전자 부품을 자동으로 실장하는 핵심 제조 기술.



1. 글로벌 및 국내 SMT 시장 패러다임



SMT 공정 및 도메인 개요

SMT(Surface Mount Technology) : PCB 기판 위에 전자 부품을 자동으로 실장하는 핵심 제조 기술.

2. 기존 품질 관리 방식의 한계와 리스크 (AS-IS)



Reflow 이후 불량을 발견할 경우

→ 폐기 및 재작업 비용이 기하급수적으로 증가

False call의 병목 현상

→ 기존 검사 장비의 오탐률이 장비 가동률을 저하시키는 원인

SMT 공정 및 도메인 개요

SMT(Surface Mount Technology) : PCB 기판 위에 전자 부품을 자동으로 실장하는 핵심 제조 기술.

SMT 공정 5단계 흐름

부품 준비
Preparation



SPI(PR 공정)
solder paste



SD 공정
Solder Dip



AOI 검사
Inspection



실장 완성
Mounting

PCB 기판 및
부품 공급·정렬

솔더 페이스트
인쇄 및 부품 배치

납땀·리플로우
및 접합 형성

자동 광학 검사
불량 위치 탐지

최종 품질 확인
및 출하 승인

SPI, AOI 분석이 왜 중요한가?

SPI (초기 검사): 납이 제대로 발렸는지 미리 확인하여, 부품이 완전히 굳어버린 뒤에 발생하는 막대한 수리 비용을 예방하는 검사

AOI (최종 검사): 조립이 끝난 제품의 미세한 불량을 AI로 정확하게 찾아내는 검사 이때 축적된 데이터는 전체 공정의 불량률을 낮추는 핵심 자료

주요 문제점 및 도전 과제

SMT 공정 현장에서 발생하는 핵심 문제점과 AI 도입 필요성

후공정 불량 비용 급증

후공정에서 불량 수정 시 추가 공정 및 작업 비용이 증가합니다. 조기 탐지 없이는 생산 비용 구조 전체가 위협받습니다.

기계적 오차의 누적

칩 마운터나 스크린 프린터는 기계이기 때문에 진동이나 온도 변화로 인해 시간이 지날수록 미세하게 축이 틀어지는 설비 오차(Drift)가 발생

Downtime 유발 및 장비 효율성 하락


지속적인 불량이 감지되면, 더 이상의 불량품 생산을 막기 위해 전체 SMT 라인의 가동이 강제로 중단됩니다.

데이터 파편화 및 품질 추적성

데이터가 앞뒤 공정으로 피드백되지 않고 파편화될 경우, 무결점이 요구되는 산업에서 대규모 리콜 발생 시 책임 소재 파악과 선제적 공정 개선이 원천적으로 불가능해집니다.

멀티모달 AI 기반 불량 탐지·원인 분석 파이프라인

공정 이미지와 설비 센서 데이터를 활용한 통합 AI 분석 흐름





데이터 구조



이미지 + 라벨링 정보 + 센서 시계열 데이터를 통합한 학습 데이터셋

1 원천 이미지 데이터

납땜 공정(SD)



사전 공정(PR)



- SMT 공정 이미지 샘플
- 해상도 : 512 x 512
- 정상 / 불량 데이터 포함
- 부품 및 납 상태 확인 가능

2 라벨링 / Annotation 데이터

JSON 파일

```
{  "categories": [    {      "id": 1,      "name": "정상_미납"    },    {      "id": 2,      "name": "정상_납부족"    },    {      "id": 3,      "name": "정상_납소트"    },    {      "id": 4,      "name": "정상_납물"    },    {      "id": 5,      "name": "정상_납좌표미림"    }  ],  "images": [    {      "id": 3,      "width": 512,      "height": 512,      "file_name": "SD_DEF_CC_A_20250807-100945_00003.JPG"    },    {      "id": 6,      "image_id": 3,      "category_id": 23,      "segmentation": [],      "area": 36711.3631,      "bbox": [        199, 19,        87, 22,        128, 33,        286, 97      ]    }  ]}
```

```
{  "id": 3,  "width": 512,  "height": 512,  "file_name": "SD_DEF_CC_A_20250807-100945_00003.JPG",  "annotations": [    {      "id": 6,      "image_id": 3,      "category_id": 23,      "segmentation": [],      "area": 36711.3631,      "bbox": [        199, 19,        87, 22,        128, 33,        286, 97      ]    }  ]}
```

- COCO 형식 기반 구조
- Category ID로 결함 유형 정의
- BBox로 결함 위치 표기
- 정상 / 불량 클래스 관리

3 센서 시계열 데이터

timestamp	temperature (°C)	humidity (%)	vibration (g)	acceleration (g)	noise (dB)
2025-08-07 09:03:40	23.64	77.65	0.2623	0.0364	66.64
2025-08-07 09:03:41	23.71	78.21	0.2664	0.0340	67.47
2025-08-07 09:03:42	23.75	78.73	0.2772	0.0315	67.69
2025-08-07 09:03:43	23.79	79.49	0.2827	0.0287	68.10
2025-08-07 09:03:44	23.77	80.00	0.2947	0.0261	68.70


- 온도 / 습도 / 진동 / 가속도 / 소음 수집
- Timestamp 기반 시계열 데이터
- 이미지 단위로 센서 시퀀스 연결
- defect_detected로 정상 / 불량 상태 매칭



시각 정보와 공정 상태 정보를 결합하여 결함 탐지 성능을 향상

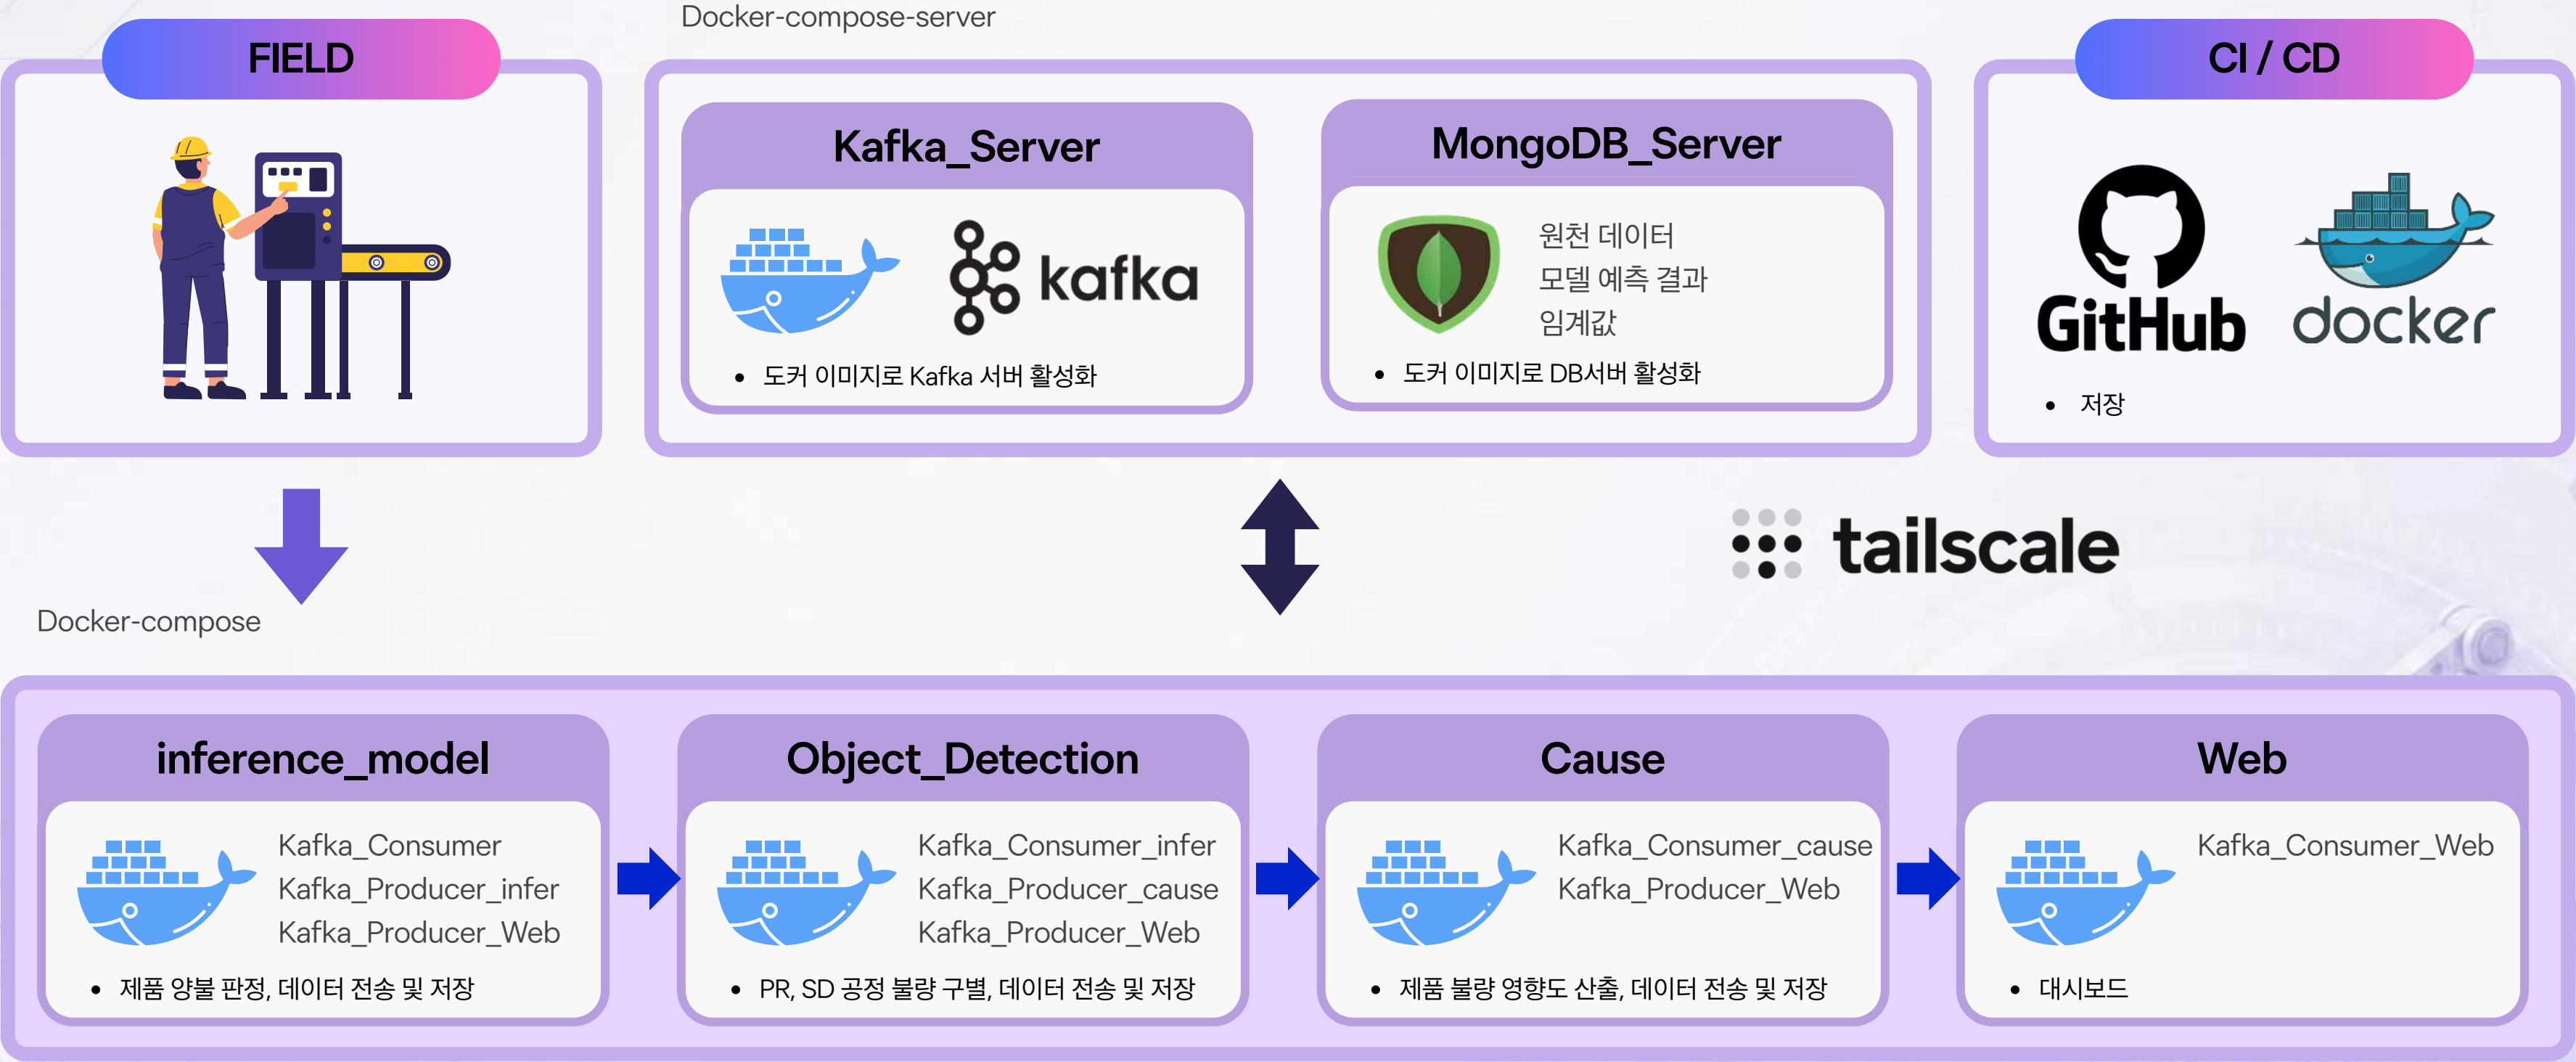
서비스 플로우

이미지·센서 데이터 기반 실시간 AI 서비스 흐름




System Architecture

이미지와 센서 데이터를 결합한 4단계 AI 시스템 구조



아키텍처 정의서


이미지와 센서 데이터를 결합한 4단계 AI 시스템 구조



1. Classification

TimesNet + Swin Transformer 기반 멀티모달 융합 분류 모델

1.1 Model Architecture




1. Classification


TimesNet + Swin Transformer 기반 멀티모달 융합 분류 모델

1.2 Model Evaluate

1 혼동 행렬



2 ROC 곡선




3 테스트 데이터수 : 5156 건

	precision	recall	f1-score	support
normal	0.99	1	0.99	2026
defect	1	0.99	1	3130
accuracy			0.99	2156
macro_avg	0.99	1	0.99	5156
weighted_avg	1	0.99	0.99	5156

2. Detection

YOLOv11 기반 PR(사전),SD(납땜) 공정 불량 탐지 모델 - 유형 탐지 다이어그램

2.1 Model Architecture




PR SD 공정 이미지를 입력받아 YOLOv11 기반으로 불량 위치 · 유형을 탐지하고, 그 결과를 원인 분석 단계로 전달

2. Detection

TimesNet + Swin Transformer 기반 멀티모달 융합 분류 모델

2.1 defect type




사전공정 6정 + 납땜 공정 12종 = 주요 불량 유형 통합 관리


2. Detection

YOLOv11 기반 SMT 공정 불량 탐지 모델

2.3 bbox 이미지 데이터와 예측 이미지 비교



라벨링 데이터(bbox 좌표)
와 PCB 기판 이미지 사진을
결합하여 생성한 이미지



학습된 YOLOv11 모델을 활용
하여 생성한 이미지




검증 데이터에 대해 원본 라벨 이미지와 모델 예측 이미지를 비교한 결과, Detection 모델은 납 도포 영역과 주요 결합 위치를 전반적으로 유사하게 검출. Batch 단위 추론을 통해 여러 이미지를 동시에 처리하며, 실제 SMT 라인에서의 실시간 결함 탐지 적용 가능성을 확인.

2. Detection

YOLOv11 기반 SMT 공정 불량 탐지 모델


2.4 공정별 모델 성능 비교 분석(Model Performance Comparison)

SD 공정 불량 탐지 모델




- ✓ mAP 0.882@0.5로 안정적인 검출 성능 확보
- ✓ Precision - Recall 균형을 통해 오탐 · 미탐 최소화 확인
- ✓ 대부분의 결함 클래스가 대각선에 집중되어 안정적 분류 성능 확인

PR 공정 불량 탐지 모델



- ✓ mAP 0.935@0.5로 SD 대비 높은 검출 성능 확보
- ✓ 주요 결함 유형을 비교적 정확하게 구분
- ✓ 일부 유사 결함은 추가 데이터 확보 및 증각으로 개선 가능




SD와 PR 공정 모두 안정적인 결함 검출 성능을 보였으며,
PR 공정 모델은 mAP 기준 더 우수한 성능을 확인

3. SHAP분석 및 z-score 임계값 설정

게임이론의 사폴리 값을 이용하여 각 특성이 예측에 기여한 정도를 보여주는 AI

3.1 Model Architecture


✓ SHAP 동작 과정



✓ z-score 기반 설비 환경 센서의 임계값 지정

$$Z = \frac{x - \mu}{\sigma}$$

x : 관측값
μ : 평균
σ : 표준편차
z : Z-score




4. Docker

어디서나 동일하게 실행할 수 있게 해주는 컨테이너 관리 도구.

4.1 Docker Architecture

Docker는 애플리케이션과 실행에 필요한 환경을 컨테이너라는 독립된 실행 단위로 묶어 동일한 실행 환경으로 배포할 수 있도록 구성해주는 컨테이너 관리 도구입니다.




5. Kafka를 통한 실시간 통신구조

게임이론의 사폴리 값을 이용하여 각 특성이 예측에 기여한 정도를 보여주는 AI

5.1 Kafka Flow



센서 및 이미지 데이터



정상 / 불량 추론




이미지 데이터 및 불량여부



불량 유형 탐지



센서 데이터 및 불량 유형



SHAP기반 피쳐 영향도 추출



센서별 기여도



대시보드 시각화

6. 실시간 모니터링 대시보드

실시간 검사 결과 및 신뢰도 시각화

총 처리량

총 처리량
652건
정상 처리 569건

정상 처리

정상 처리
569건
Normal Processing

불량 감지

불량 감지
83건
최근 불량률 12.73%

불량률

불량률
12.73%
Defect Rate

모델 가동

모델 가동
4/4
AI Model Status

- 1 실시간 제품리스트 표시
- 2 실시간 AI 객체 확인
- 3 실시간 센서데이터 그래프 표시
- 4 불량 판정 확인

실시간 제품 리스트

공정

정상/불량

전체

전체

공정	제품명	정상/불량
PR	PR_NOR_NS_A_20250902-183202_01418	정상
SD	SD_NOR_WS_B_20250904-174636_00276	정상
PR	PR_NOR_NS_A_20250902-183145_01417	정상
SD	SD_NOR_WS_B_20250904-174511_00275	정상
PR	PR_NOR_NS_A_20250902-183145_01416	정상
SD	SD_NOR_WS_B_20250904-174412_00274	정상
PR	PR_NOR_NS_A_20250902-183123_01415	정상
SD	SD_NOR_WS_B_20250904-174203_00273	정상
PR	PR_NOR_NS_A_20250902-183037_01414	정상
SD	SD_NOR_WS_B_20250904-173607_00272	정상
PR	PR_NOR_NS_A_20250902-183009_01413	정상
SD	SD_NOR_WS_B_20250904-173433_00271	정상
PR	PR_NOR_NS_A_20250902-183005_01412	정상
SD	SD_NOR_WS_B_20250904-173430_00270	정상
PR	PR_NOR_NS_A_20250902-183002_01411	정상
SD	SD_DEF_FL_D_20250905-171224_01469	불량

실시간 AI 객체 탐지

PR (사전공정) · PR_NOR_NS_A_20250902-183211_01419

정상

SD (납땜공정) · SD_NOR_WS_B_20250904-174851_00278

정상



불량 판정

항목	값
불량 감지	65건
불량률	13.83%
총 처리량	470건

6. 실시간 상세 정보 팝업

✓ 실시간 제품 이미지, 센서 시계열 및 불량 원인 확인

제품 상세 정보

공정 이미지 · 불량 · SD · SD_DEF_FL_D_20250905-173032_01510

1

불량 일어섬 불량 일어섬
불량 일어섬 불량 요산

2

센서 시계열

시간	온도 (°C)	습도 (%)	진동 (m/s ²)	가속도 (g)	소음 (dB)
2025-09-05 17:30:32	25.99	72.01	0.35	0.02	68.48
2025-09-05 17:30:33	25.80	71.89	0.34	0.02	67.06
2025-09-05 17:30:34	25.57	71.74	0.32	0.02	65.94
2025-09-05 17:30:35	25.40	72.08	0.30	0.02	64.91
2025-09-05 17:30:36	25.26	72.18	0.28	0.03	64.28

3

불량 원인 TOP3

1st	humidity [습도]	기여도 33.0%
2nd	vibration [진동]	기여도 22.6%
3rd	noise [소음]	기여도 17.8%

1 객체 탐지 결과

선택 제품의 PCB 이미지 출력 불량 위치와 유형 Bounding Box

2 센서 시계열


촬영 당시의 온도, 습도, 진동, 가속도, 소음 값
시계열 제공

3 불량 원인 TOP 3

불량 판정에 영향을 준 센서 항목 기여도 순으로 제시

6. 공정 별 불량 현황

✓ 공정 별 불량 유형, 원인 및 추이 시각화



6. 불량 검수

✓ 제품 검수 및 상세 미리보기

1

검수 대기열

제품명	공정	유형	신뢰도	상태	승인/반려
SD_DEF_CC_C_20250906-174225...	SD	냉납	69.2%	대기	☒ ☐
PR_DEF_MF_A_20250902-182721...	PR	납형성불량	42.1%	대기	☒ ☐
PR_DEF_MF_A_20250902-182757...	PR	납형성불량	65.1%	대기	☒ ☐
PR_DEF_MF_A_20250902-182840...	PR	납형성불량	68.4%	대기	☒ ☐
PR_DEF_MF_A_20250902-183000...	PR	납형성불량	61.1%	대기	☒ ☐
PR_DEF_MF_A_20250902-183426...	PR	납형성불량	69.4%	대기	☒ ☐
PR_DEF_MF_A_20250902-183510...	PR	납형성불량	63.1%	대기	☒ ☐
PR_DEF_MF_A_20250902-183637...	PR	납형성불량	53.2%	대기	☒ ☐
PR_DEF_MF_A_20250902-183838...	PR	납형성불량	68.6%	대기	☒ ☐
PR_DEF_MF_A_20250902-184206...	PR	납형성불량	42.5%	대기	☒ ☐
SD_DEF_FL_D_20250905-172536...	SD	뒤집힘	69.5%	대기	☒ ☐

2

상세 미리보기

제품명

PR_DEF_MF_A_20250902-182757_01637

공정

PR

유형

납형성불량

신뢰도

65.1%

상태

대기

3

승인 · 반려

1 **검수 대기열**

신뢰도가 낮은 결과 리스트화

2 **상세 미리보기**


선택한 제품의 이미지 및 정보 제공

3 **승인 · 반려**

승인 반려 처리하여 품질 이력 및 재학습 데이터 활용

CI / CD GitHub 기반 파이프라인

어디서나 동일하게 실행할 수 있게 해주는 컨테이너 관리 도구.



품질 & 안전성 확보

- 자동 Lint / 테스트 실행
- 빌드 검증으로 결함 조기 발견
- 일관된 빌드 환경 보장

개발 생산성 향상

- 반복 업무 자동화
- 빠른 피드백으로 개발 속도 향상
- PR 기반 협업 프로세스 강화

컨테이너 기반 배포

- Docker 이미지 표준화
- Registry를 통한 안전한 배포
- 환경 일관성 및 이식성 확보

운영 가시성 & 안전성

- 모니터링 및 로그 수정
- 이상 감지 및 알림
- 롤백으로 서비스 연속성 보장

핵심 구성 요소

GitHub
형상관리 / 협업

Actions
CI 자동화

Docker
컨테이너 / 이미지

Deploy
배포 / 운영

모델 · API · 대시보드 버전 관리



GitHub 기반 CI / CD를 통해 코드 변경 후 테스트 · 빌드 · 배포를 자동화하여
개발 효율성과 운영안정성을 확보합니다

기대 효과

AI 기반 SMT 시스템 도입을 통한 측정 가능한 핵심 성과 지표

후공정 불량 비용 70% 절감



AI 기반 모델을 통해 불량을 조기에 탐지하여 불량 PCB의 후공정 유입을 차단합니다. 이를 통해 후공정 검사에 발생하는 비용을 대폭 절감할 수 있습니다.

설비 다운타임 60% 감소



실온도, 습도, 진동, 가속도, 소리 등 센서 데이터의 임계값을 지속적으로 모니터링하고, SHAP 분석을 통해 이상 발생의 주요 원인을 함께 제시합니다.

생산 수율 및 고객 신뢰도 향상



공정별 특화 탐지 모델(Detection_PR / Detection_SD)과 원인 도출 모델을 통한 정밀 품질 관리로 불량 발생 구간을 빠르게 격리 하고 공정 조건을 신속히 보정 할 수 있습니다.

검사 시간 단축 및 현장 대응력 향상



AI 객체 탐지 모델이 이미지 기반 불량 여부와 불량 유형을 자동 판정 하고, SHAP 값이 센서별 영향도를 제공하여 원인 분석을 지원합니다. 이를 통해 작업자의 육안 검사 판단 시간을 줄이고, 공정별 조치 우선 순위를 빠르게 결정 할 수 있습니다.

불량비용 70% 절감 (연간 약 2억원) 및 **생산성 30% 향상!**


활용 방안 및 향후 계획

AI 기반 SMT 품질 검사 시스템의 산업 확장성과 지속적 모델 운영 방안을 제시합니다..



예지보전으로 확장

설비 환경·센서 데이터를 통합 분석하여 이상 징후를 사전에 감지하고, 최적 운전 조건을 제시하는 예지보전 모델로 확장 가능



다양한 산업으로 확장

제조 산업 전반의 다양한 공정 및 설비환경 뿐만 아니라, 스마트팜과 같은 환경·센서 데이터에도 활용 가능



향후 계획 및 확대

데이터 드리프트 감지와 Jenkins 기반 자동 재학습·재배포 파이프라인을 구축하여 변화하는 설비 환경에 대응하고 활용 범위를 확대.

감사합니다.

Q&A

궁금하신 점이 있으시면 편하게 질문해 주세요.