

AOI 결함 검출 알고리즘 파이프라인 및 AI 통합 검사 솔루션 분석 보고서

문서번호 CRSM-AI-2026-AUTO

작성일 2026-06-15

작성 Cressem AI 시스템 (자동 생성)

보안등급 사내 비밀 (Confidential)

버전 v1.0

목 차

AOI 결함 검출 알고리즘 파이프라인 및 AI 통합 검사 솔루션 분석 보고서	3
개요/배경	3
AOI 시스템 아키텍처 및 하드웨어 구성	4
AI 기반 결함 검출 알고리즘 파이프라인	5
딥러닝 기반 결함 분류 및 과검(Over-kill) 방지 기술	7
HBM 및 차세대 패키징 특화 검사 프로세스	9
데이터 통합 및 수율 피드백 시스템	12
결론/시사점	14

AOI 결함 검출 알고리즘 파이프라인 및 AI 통합 검사 솔루션 분석 보고서

본 보고서는 자동 광학 검사(AOI) 시스템의 핵심인 결함 검출 알고리즘 파이프라인을 단계별로 분석하고, 최신 AI 및 딥러닝 기술이 통합된 차세대 검사 프로세스를 제안합니다. 데이터 전처리부터 AI 기반 결함 분류, 그리고 수율 개선을 위한 피드백 루프까지의 전체 워크플로우를 상세히 다룹니다.

개요/배경

1. AOI(Automated Optical Inspection) 기술의 정의 및 진화

자동 광학 검사(Automated Optical Inspection, AOI)는 고해상도 카메라, 정밀 조명 시스템, 그리고 머신 비전(Machine Vision) 알고리즘을 통합하여 제조 공정 중 발생하는 결함을 인간의 눈을 대신하여 자동으로 검출하는 기술을 의미합니다 [출처: jlcpcb.com]. 현대의 반도체 제조 공정은 육안 검사가 불가능할 정도로 미세화되었으며, 이에 따라 AOI 시스템은 단순한 이미지 획득을 넘어 광학(Optics), 기계(Mechanics), 전자 제어(Electronic Control) 및 고도화된 소프트웨어(Software)가 유기적으로 결합된 통합 솔루션으로 진화하였습니다 [출처: jlcpcb.com].

전통적인 AOI 방식은 사전에 정의된 규칙(Rule-based)에 따라 이미지 내의 밝기 차이, 색상 변화, 또는 패턴의 일치 여부를 판단하는 방식을 취해왔습니다. 그러나 반도체 소자의 집적도가 높아지고 패키징 구조가 복잡해짐에 따라, 단순한 규칙 기반 검사만으로는 정상 제품을 불량으로 판정하는 과검(Over-kill) 문제와 미세 결함을 놓치는 미검(Under-kill) 문제를 동시에 해결하기 어려워졌습니다. 최근의 AOI 기술은 이러한 한계를 극복하기 위해 딥러닝(Deep Learning) 기반의 AI 알고리즘을 통합하여, 결함과 정상적인 노이즈를 정밀하게 구분하고 검사의 정확도와 효율성을 동시에 확보하는 방향으로 발전하고 있습니다 [출처: calib.tistory.com].

2. 반도체 후공정(Advanced Packaging) 내 검사의 중요성

반도체 산업의 패러다임이 전공정(Front-end)의 미세 공정(Scaling) 중심에서 후공정(Back-end), 특히 어드밴스드 패키징(Advanced Packaging) 중심으로 이동함에 따라 검사 기술의 중요성은 그 어느 때보다 높아지고 있습니다. 과거의 패키징이 단순히 칩을 보호하고 외부 단자와 연결하는 역할에 그쳤다면, 현재의 기술은 칩 간의 대역폭(Bandwidth)을 극대화하고 전력 효율을 높이는 핵심적인 역할을 수행합니다.

특히 HBM(High Bandwidth Memory)과 FC-BGA(Flip Chip Ball Grid Array)와 같은 고성능 메모리 및 로직 반도체 분야에서는 다음과 같은 이유로 고도화된 AOI 검사가 필수적입니다.

- **HBM(High Bandwidth Memory)의 복잡성:** HBM은 수십 개의 TSV(Through-Silicon Via)와 마이크로 범프(Micro-bump)를 통해 다이(Die)를 수직으로 적층하는 3D 구조를 가집니다. 이러한 고집적 구조는 적층 과정에서 미세한 정렬 오류(Misalignment), 범프 형성 불량(Missing Bump), 또는 층간 분리(Delamination)와 같은 치명적인 결함을 유발할 수 있으며, 이는 제품 전체의 신뢰성에 직결됩니다 [출처: 매뉴얼HBM검사및테스트공정가이드라인20260509001.pdf].
- **FC-BGA 및 고밀도 기판의 미세화:** FC-BGA와 같은 고밀도 기판(High-Density Substrate)은 미세한 솔더 볼(Solder Ball)과 복잡한 회로 패턴을 포함합니다. 기판 위의 미세 범프 높이 불균형이나 패턴의 단선/단락은 전기적 신호 전달을 방해하므로, 이를 실시간으로 고속 스캔하여 검출하는 기술이 수율 확보의 핵심입니다 [출처: 분석_크레셈CRESSEM20260509001.pdf].

3. 수율(Yield) 확보 및 경제적 가치

반도체 제조에서 수율(Yield)은 기업의 수익성을 결정짓는 가장 결정적인 지표입니다. 특히 HBM과 같이 공정 단계가 많고 적층 단수가 높은 제품의 경우, 후공정 단계에서 발견되는 결함은 이미 투입된 웨이퍼와 다이(Die)의

비용을 모두 손실로 만드는 막대한 경제적 타격을 입힙니다.

AOI 검사 솔루션은 다음과 같은 메커니즘을 통해 수율 극대화에 기여합니다.

1. **결함 조기 발견(Early Detection):** 적층 전(Pre-stacking) 단계에서 개별 웨이퍼 및 칩의 결함을 차단함으로써, 불량품이 상위 공정으로 유입되어 발생하는 매몰 비용(Sunk Cost)을 최소화합니다 [출처: 매뉴얼HBM검사및테스트공정가이드라인20260509001.pdf].

2. **데이터 기반의 공정 제어(Feedback Loop):** AOI를 통해 수집된 결함 데이터는 단순히 Pass/Fail을 판정하는 것에 그치지 않고, 전공정(Fab)의 결함 원인을 역추적(Root Cause Analysis)하는 핵심 데이터로 활용됩니다. 이를 통해 공정 변수를 실시간으로 제어하고 최적화함으로써 근본적인 불량 발생률을 낮출 수 있습니다 [출처: 분석_크레셈CRESSEM20260509001.pdf].

3. **품질 신뢰성 보장:** 극한의 환경(Hot/Cold Test 등)에서 작동해야 하는 고성능 반도체의 특성상, 검사 단계에서의 완벽한 결함 제거는 최종 고객사(SK하이닉스, 삼성전자, TSMC 등)가 요구하는 엄격한 신뢰성 기준을 충족하는 유일한 방법입니다 [출처: 매뉴얼HBM검사및테스트공정가이드라인20260509001.pdf].

결론적으로, AOI 기술은 단순한 검사 도구를 넘어 차세대 반도체 공급망(Supply Chain) 내에서 제품의 성능과 신뢰성을 보장하고, 제조사의 수익성을 극대화하는 핵심적인 전략 자산으로 자리매김하고 있습니다. 본 보고서에서는 이러한 배경을 바탕으로 최신 AI 기술이 통합된 차세대 AOI 검사 알고리즘의 파이프라인과 그 실무적 적용 방안을 심도 있게 분석하고자 합니다.

AOI 시스템 아키텍처 및 하드웨어 구성

자동 광학 검사(Automated Optical Inspection, AOI) 시스템은 반도체 및 PCB 제조 공정에서 인간의 눈을 대체하여 미세 결함을 정밀하게 식별하는 핵심 장비이다. AOI 시스템은 단순히 이미지를 획득하는 것을 넘어, 광학(Optics), 기계(Mechanics), 전자 제어(Electronic Control) 및 소프트웨어(Software)가 유기적으로 통합된 복합적인 아키텍처를 가진다 [2]. 특히 HBM(High Bandwidth Memory)이나 FC-BGA(Flip Chip Ball Grid Array)와 같이 초미세 패턴이 적용되는 고밀도 패키징 환경에서는 하드웨어 구성 요소의 정밀도가 검사 성능(Resolution)과 처리 속도(Tact Time)를 결정짓는 결정적인 요소가 된다.

1. 광학 엔진 및 이미지 획득 모듈 (Optical Engine & Image Acquisition)

AOI 시스템의 심장부인 광학 엔진은 검사 대상의 표면 특징을 고해상도 디지털 데이터로 변환하는 역할을 수행한다.

- **고해상도 카메라(High-Resolution Camera):** 미세한 결함을 검출하기 위해 고해상도 CMOS/CCD 센서가 탑재된다. 반도체 패키징의 미세 피치(Fine Pitch)를 검사하기 위해서는 픽셀 크기가 극도로 작은 센서가 필요하며, 이는 결함의 크기가 수 μm 단위인 경우에도 명확한 에지(Edge)를 구분할 수 있게 한다.
- **렌즈 시스템(Lens System):** 고배율 및 고해상도 이미지를 얻기 위해 저왜곡(Low Distortion) 설계가 적용된 광학 렌즈를 사용한다. 특히 3D AOI의 경우, 표면의 높이 정보(Height Profile)를 추출하기 위해 스테레오 비전(Stereo Vision) 방식이나 프로파일러(Profiler) 기술이 결합된 특수 렌즈 아키텍처가 활용된다 [10].
- **FPGA 기반 전처리 솔루션:** 고속 스캔 과정에서 발생하는 방대한 양의 이미지 데이터를 실시간으로 처리하기 위해 FPGA(Field Programmable Gate Array)를 활용한다. 이는 데이터 획득 단계에서 이미지 노이즈를 제거하거나, 해상도를 최적화하는 등의 전처리(Preprocessing)를 수행하여 메인 CPU/GPU의 부하를 줄이고 검사 효율을 극대화한다 [3].

2. 지능형 조명 제어 시스템 (Intelligent Illumination Control)

검사 대상의 재질(금속 Bump, 절연체 Substrate 등)과 형상에 따라 빛의 반사 특성이 다르기 때문에, 조명 제어는 AOI의 신뢰성을 좌우하는 핵심 기술이다.

- **다중 광원 구성(Multi-source Illumination):** AOI 시스템은 일반적으로 여러 종류의 광원을 조합하여 사용한다. 동축 조명(Coaxial Lighting), 저각 조명(Low-angle Lighting), 고각 조명(High-angle Lighting) 등을 통해 표면의 평탄도, 긁힘(Scratch), 얼룩(Stain) 등을 각기 다른 방식으로 부각시킨다 [2].
- **조명 패턴 및 색온도 제어:** 특정 결함을 강조하기 위해 조명의 밝기(Intensity)뿐만 아니라 색온도(Color Temperature)와 조사 패턴을 정밀하게 제어한다. 예를 들어, 금속 Bump의 Bridge(Short) 결함을 검출할 때는 난반사를 억제하면서도 접합부의 경계를 명확히 할 수 있는 특수 조명 프로파일이 적용된다 [1].
- **조명-카메라 동기화(Synchronization):** 고속 이동 중인 스테이지(Stage) 위에서 선명한 이미지를 얻기 위해 조명 점멸(Strobe)과 카메라 셔터 타이밍을 마이크로초(μ s) 단위로 정밀하게 동기화하는 제어 기술이 필수적이다.

3. 정밀 구동 및 기계적 구조 (Precision Motion & Mechanical Structure)

검사 대상물을 광학계 아래로 정확하게 위치시키고 스캔하는 기계적 아키텍처는 검사의 재현성(Repeatability)을 보장한다.

- **고정밀 스테이지(High-Precision Stage):** nm 단위의 분해능을 목표로 하는 모터 및 구동축 시스템이 적용된다. 특히 HBM과 같이 다단 적층된 구조를 검사할 때는 Die 또는 Substrate의 휨(Warp)에 대응하여 높낮이를 정밀하게 조절할 수 있는 Z축 제어 기술이 중요하다 [4].
- **진동 및 환경 제어:** 미세한 진동도 이미지의 블러(Blur)를 유발하여 검사 오류를 일으킬 수 있으므로, 시스템 전체의 강성(Rigidity) 확보와 진동 감쇄(Damping) 설계가 아키텍처 설계 단계에서부터 반영된다.

[요약] AOI 하드웨어 구성 요소 비교

구성 요소	주요 기능	핵심 요구 사양	비고
광학 엔진	이미지 데이터 획득	고해상도, 저왜곡, 고속 스캔	FPGA 전처리 결합 시 효율 증대 [3]
조명 시스템	결함 특징(Feature) 부각	다중 광원, 정밀 밝기/색온도 제어	재질별 맞춤형 조명 프로파일 필요 [2]
구동부(Stage)	검사 대상 위치 제어	고정밀 정렬(Alignment), 고속 이동	Warpage 대응을 위한 3D 제어 필수 [4]
제어 유닛	시스템 통합 및 데이터 처리	실시간성(Real-time), 고속 데이터 통신	AI 엔진과의 데이터 인터페이스 중요

표 1. [요약] AOI 하드웨어 구성 요소 비교

이와 같은 하드웨어 구성 요소들이 유기적으로 결합되어 안정적인 이미지 데이터를 생성해야만, 이후 단계인 AI 기반의 딥러닝 결함 분류 및 수율 분석이 유의미한 결과를 도출할 수 있다.

AI 기반 결함 검출 알고리즘 파이프라인

현대 반도체 패키징 공정, 특히 HBM(High Bandwidth Memory)과 같이 적층 단수가 높고 미세 피치(Fine Pitch)를 요구하는 환경에서 AOI(Automated Optical Inspection)의 신뢰성은 제품의 수율(Yield)을 결정짓는 핵심 요소입니다. 기존의 Rule-based 검사 방식은 정해진 임계값(Threshold)을 기준으로 결함을 판정하기 때문에, 공정 중 발생하는 미세한 노이즈나 정상적인 패턴의 변동을 결함으로 오인하는 과검(Over-kill) 문제가 빈번하게

발생했습니다. 이를 극복하기 위해 도입된 AI 기반 결함 검출 알고리즘 파이프라인은 데이터 획득(Data Acquisition)부터 최종 판정(Final Decision)에 이르기까지 고도화된 머신러닝/딥러닝 프로세스를 통합하여 운영됩니다.

본 섹션에서는 데이터의 무결성을 확보하는 전처리 단계부터, 고차원 특징을 추출하는 알고리즘, 그리고 최종적으로 결함을 분류하고 관리하는 전체적인 알고리즘 처리 흐름을 상세히 분석합니다.

1. 데이터 획득 및 고도화된 전처리 (Data Acquisition & Pre-processing)

알고리즘의 성능은 입력되는 이미지 데이터의 품질에 직결됩니다. 반도체 검사 환경에서는 초고해상도 카메라와 정밀 조명 시스템을 통해 획득된 원시 데이터(Raw Data)를 분석 가능한 형태로 가공하는 과정이 필수적입니다.

- **이미지 정규화 및 보정(Normalization & Correction):** 조명의 불균일성(Illumination Non-uniformity)이나 렌즈의 왜곡(Lens Distortion)을 제거하기 위한 단계입니다. 특히 3D AOI 환경에서는 휨(Warping) 현상으로 인해 초점 심도(Depth of Field)가 변할 수 있으므로, 이를 보정하여 평면적인 특징을 확보하는 것이 중요합니다 [출처: 매뉴얼HBMAdvancedInspectionSyst20260509001.pdf].
- **노이즈 제거(Noise Reduction):** 센서에서 발생하는 열 잡음(Thermal Noise)이나 이미지 획득 과정에서의 산란광을 제거하기 위해 가우시안 필터(Gaussian Filter) 또는 미디언 필터(Median Filter) 등의 알고리즘이 적용됩니다.
- **FPGA 기반 실시간 전처리:** 고속 스캔 환경에서는 방대한 양의 데이터를 실시간으로 처리해야 하므로, Basler AG 등의 기술 사례와 같이 FPGA(Field Programmable Gate Array)를 활용하여 이미지 전처리를 하드웨어 레벨에서 수행함으로써 시스템의 전체 Tact Time을 단축합니다 [출처: Basler AG].
- **데이터 표준화(Data Standardization):** AOI 이미지와 X-ray 데이터를 통합하여 머신러닝 모델이 학습하기 용이하도록 데이터 형식을 통일하고, 결함 레이블(Defect Label)을 정규화하는 파이프라인이 구축됩니다 [출처: Optimizing Defect Detection: A Machine Learning-Ready Data Processing Pipeline].

2. 특징 추출 및 AI 모델링 (Feature Extraction & AI Modeling)

전처리가 완료된 데이터는 딥러닝 엔진을 통해 유의미한 특징(Feature)을 추출하는 단계로 진입합니다. 이 단계는 단순한 형태 인식을 넘어, 결함의 물리적 특성을 수학적 벡터로 변환하는 과정입니다.

- **Deep Learning 기반 특징 추출:** CNN(Convolutional Neural Network) 구조를 활용하여 이미지 내의 미세한 패턴, 에지(Edge), 색상 대비 등을 자동으로 학습합니다. 특히 합성 데이터(Synthetic Dataset)를 활용한 학습 파이프라인을 통해 실제 공정에서 발생하기 어려운 희귀 결함(Rare Defect)에 대한 모델의 대응력을 높일 수 있습니다 [출처: GitHub - Synthetic Semiconductor AOI Defect Detection].
- **다중 스케일 특징 분석(Multi-scale Feature Analysis):** HBM의 Micro-bump와 같은 미세 구조물은 매우 작은 스케일의 결함(Void, Crack)을 포함하고 있으며, 동시에 기판 전체의 정렬(Alignment)과 같은 거시적 스케일의 결함도 존재합니다. 따라서 모델은 다양한 해상도 층위에서 특징을 추출하여 이들을 통합 분석해야 합니다.
- **3D 프로파일링 데이터 통합:** 2D 광학 이미지뿐만 아니라 3D SPI(Solder Paste Inspection)나 3D AOI를 통해 얻은 높이(Height) 및 형상(Shape) 데이터를 특징 벡터에 포함시킵니다. 이는 Bump의 높이 불균형이나 TSV의 깊이 불량 등을 정확히 판별하는 데 결정적인 역할을 합니다 [출처: 매뉴얼HBM검사및테스트공정가이드라인20260509001.pdf].

3. 결함 분류 및 최종 판정 (Defect Classification & Decision Making)

추출된 특징을 바탕으로 알고리즘은 해당 영역이 결함인지, 아니면 정상적인 노이즈인지를 최종 판정합니다.

- **결함 분류(Defect Classification):** 분류된 특징 벡터를 기반으로 결함의 유형을 정의합니다. HBM 검사의 경우, 주요 분류 항목은 다음과 같습니다 [출처: 매뉴얼HBMAdvancedInspectionSyst20260509001.pdf].

- **Misalignment:** Bump 또는 TSV의 위치가 설계치에서 벗어난 경우.
- **Bridge (Short):** 인접한 Bump 간에 의도치 않은 금속 연결이 발생한 경우.
- **Missing Bump:** 특정 위치에 Bump가 형성되지 않은 경우.
- **Warpage:** Die 또는 Substrate의 심한 휨이 감지된 경우.
- **과검(Over-kill) 방지 알고리즘:** AI 엔진은 단순 Rule-based 검사에서 발생하는 과검률을 획기적으로 낮춥니다. 정상적인 패턴의 미세한 변동(Tolerance)을 학습함으로써, 불량과 노이즈를 명확히 구분하여 불필요한 재검사나 폐기를 방지합니다 [출처: 분석_크레셈CRESSEM20260509001.pdf].
- **결과 리포팅 및 데이터 피드백:** 판정 결과는 Defect Map 형태로 생성되며, Pass/Fail 정보와 함께 결함 종류가 리포트로 출력됩니다 [출처: 매뉴얼HBMAdvancedInspectionSyst20260509001.pdf]. 이 데이터는 단순히 검사 종료로 끝나는 것이 아니라, 전공정(Fab)의 공정 변수를 역추적(Root Cause Analysis)하는 기초 자료로 활용되어 수율 개선의 선순환 구조를 형성합니다 [출처: 분석_크레셈CRESSEM20260509001.pdf].

AI 기반 AOI 결함 검출 알고리즘 파이프라인



그림 1. AI 기반 AOI 결함 검출 알고리즘 파이프라인

딥러닝 기반 결함 분류 및 과검(Over-kill) 방지 기술

반도체 패키징 공정이 HBM(High Bandwidth Memory)과 같이 고집적화되고 미세화됨에 따라, 검사 장비가 마주하는 데이터의 복잡도는 기하급수적으로 증가하고 있습니다. 기존의 자동 광학 검사(AOI, Automated Optical Inspection) 시스템은 주로 정해진 규칙에 따라 결함을 찾아내는 Rule-based 방식을 채택해 왔으나, 이는 미세한 공정 변동이나 정상적인 패턴의 노이즈를 결함으로 오인하는 과검(Over-kill) 문제를 필연적으로 야기합니다. 본 섹션에서는 이러한 한계를 극복하기 위한 딥러닝(Deep Learning) 기반의 결함 분류 기술과 과검률을 획기적으로 낮추는 원리에 대해 심도 있게 분석합니다.

1. Rule-based 검사 방식과 AI 기반 검사 방식의 비교 분석

전통적인 AOI 시스템의 근간인 Rule-based 방식은 설계 데이터(CAD) 또는 정상 제품의 이미지와 현재 검사 중인 이미지를 픽셀 단위로 비교하여 임계값(Threshold)을 벗어나는 영역을 결함으로 정의합니다. 하지만 반도체 후공정의 물리적 특성상 발생하는 미세한 광학적 노이즈, 소재의 미세한 색상 차이, 혹은 정상적인 패턴 내의 미세한 변동은 Rule-based 알고리즘에서 결함으로 오인될 가능성이 매우 높습니다.

다음은 Rule-based 방식과 AI 기반 방식의 핵심 차이점을 비교한 표입니다.

비교 항목	Rule-based (전통적 방식)	AI-driven (딥러닝 기반 방식)
-------	---------------------	-----------------------

판단 근거	명시적 규칙 (임계값, 기하학적 치수 등)	데이터 학습을 통한 특징 추출 (Feature Extraction)
유연성	공정 변화나 환경 변화에 취약 (재설정 필요)	새로운 패턴이나 환경에 대한 적응력 높음
과검(Over-kill)	높음 (노이즈를 결함으로 오인하는 경향)	낮음 (정상 노이즈와 실제 결함을 구분 가능)
미검(Under-kill)	낮음 (엄격한 기준 적용 시)	적절한 학습 데이터 확보 시 매우 낮음
주요 한계	복잡한 비정형 결함 검출의 어려움	양질의 학습 데이터(Dataset) 확보 필수
주요 적용	단순 치수 측정, 패턴 단선/단락 검사	미세 결함 분류, 복합 결함 식별, 과검 필터링

표 2. Rule-based 검사 방식과 AI 기반 검사 방식의 비교 분석

Rule-based 방식은 검사 기준이 명확한 치수(Dimension) 측정이나 단순한 개방 회로(Open Circuit) 검사에는 효율적입니다. 그러나 HBM의 Micro-bump 검사나 FC-BGA의 미세 회로 패턴 검사에서는 조명 조건의 미세한 변화나 기판 표면의 질감 차이만으로도 수많은 '가짜 결함(False Defect)'을 생성합니다. 이는 생산 라인의 가동률을 저하시키고, 육안 검사(Manual Inspection) 인력의 피로도를 높여 최종적으로 수율 관리의 효율성을 떨어뜨리는 주요 원인이 됩니다. [출처: jlcpcb.com]

2. 딥러닝을 통한 과검(Over-kill) 저감의 메커니즘

딥러닝 기반 검사 솔루션의 핵심 목적은 '결함을 찾는 것'을 넘어, '찾아낸 것이 진짜 결함인지(True Defect) 아니면 정상적인 노이즈인지(False Defect)'를 고도로 정밀하게 분류하는 데 있습니다. 이를 통해 과검(Over-kill)을 획기적으로 낮출 수 있습니다.

2.1. 특징 추출(Feature Extraction) 및 고차원 패턴 학습

Rule-based 방식이 픽셀의 밝기 값(Intensity)이나 명암 대비(Contrast)와 같은 저차원적인 정보에 의존한다면, 딥러닝(CNN, Convolutional Neural Networks 등)은 이미지 내의 복잡한 계층적 특징을 스스로 학습합니다. 예를 들어, Bump의 표면에 발생한 미세한 스크래치(Scratch)와 단순한 조명 반사(Reflection)를 구분할 때, AI는 스크래치의 형태적 연속성, 주변 패턴과의 상관관계, 그리고 텍스처의 특성을 종합적으로 분석하여 이를 구분합니다. [출처: github.com/Derick-Liu/learnigsemiaoewithml]

2.2. 결함 분류(Defect Classification)를 통한 2단계 검사 구조

최신 고성능 AOI 시스템은 다음과 같은 2단계(Two-stage) 프로세스를 통해 과검을 방지합니다.

1. 1단계: Candidate Detection (후보군 검출): Rule-based 또는 가벼운 신경망을 사용하여 결함으로 의심되는 영역(Region of Interest, ROI)을 빠르게 스캔하여 후보군을 추출합니다. 이 단계에서는 미검(Under-kill)을 방지하기 위해 기준을 다소 보수적으로 설정합니다.

2. 2단계: Deep Classification (심층 분류): 추출된 후보군 이미지만을 대상으로 고성능 딥러닝 모델이 정밀 분석을 수행합니다. 이 과정에서 모델은 학습된 데이터를 바탕으로 해당 후보가 'Bridge', 'Missing', 'Misalignment', 'Void' 등 실제 결함인지, 아니면 'Normal Noise'인지를 판정합니다. [출처: sciencedirect.com]

이러한 구조를 통해 시스템은 실제 결함에 대해서는 높은 검출력을 유지하면서도, 정상 제품을 불량으로 판정하는 과검률을 획기적으로 낮출 수 있습니다.

3. AI 통합 검사 솔루션의 기술적 도전 과제와 대응 전략

딥러닝 기반 검사 솔루션이 현장에 성공적으로 안착하기 위해서는 몇 가지 기술적 난제를 해결해야 합니다.

첫째, 학습 데이터의 불균형(Data Imbalance) 문제입니다. 반도체 양산 라인에서는 정상 제품의 데이터는 방대하지만, 실제 결함 데이터는 매우 희귀합니다. 결함 데이터가 부족하면 모델은 특정 결함을 학습하지 못하거나 편향된 판정을 내릴 수 있습니다. 이를 해결하기 위해 합성 데이터 생성(Synthetic Data Generation) 기술이나 GAN(Generative Adversarial Networks)을 활용하여 가상의 결함 이미지를 생성하고 학습에 활용하는 기술이 중요하게 다뤄지고 있습니다. [출처: github.com/Derick-Liu/learnigsemiaoiwithml]

둘째, 검사 속도(Tact Time)와 정밀도의 트레이드오프(Trade-off)입니다. 딥러닝 모델이 깊고 복잡할수록 분류 정확도는 높아지지만, 연산량이 증가하여 검사 속도가 느려집니다. 이를 위해 FPGA 기반의 전처리 솔루션이나 Edge AI 기술을 활용하여 실시간으로 대용량 이미지 데이터를 처리할 수 있는 하드웨어 가속 기술이 필수적입니다. [출처: baslerweb.com]

셋째, 모델의 신뢰성 및 설명 가능성(Explainability)입니다. 검사 장비는 '왜 이 제품을 불량으로 판정했는가'에 대한 근거를 제시할 수 있어야 합니다. 단순한 Black-box 모델이 아닌, 결함의 위치와 특징을 시각화하여 보여주는 기술(예: Heatmap, Grad-CAM)이 결합되어야 현장 엔지니어가 검사 결과를 신뢰하고 공정 개선에 활용할 수 있습니다.

4. 결론: 크레셈(CRESSEM)의 기술적 지향점

크레셈은 단순한 Rule-based 검사를 넘어, 하드웨어의 고속 스캔 능력과 소프트웨어의 AI 알고리즘을 통합한 **AI-Driven Machine Vision** 솔루션을 지향합니다. 특히 HBM4와 같은 차세대 패키징 공정에서 요구되는 초미세 결함 검출을 위해, 딥러닝 기반의 결함 분류 알고리즘을 내재화하여 과검(Over-kill)률을 최소화하고 고객사의 수율(Yield)을 극대화하는 데 집중하고 있습니다. 이는 단순한 검사 장비 공급업체를 넘어, 데이터 기반의 공정 최적화를 지원하는 스마트 팩토리 파트너로서의 핵심 경쟁력이 될 것입니다. [출처: 분석_크레셈CRESSEM20260509001.pdf]

HBM 및 차세대 패키징 특화 검사 프로세스

HBM(High Bandwidth Memory)은 수십 개의 DRAM 다이(Die)를 TSV(Through-Silicon Via, 실리콘 관통 전극) 기술을 통해 수직으로 적층하는 고집적 3D 구조를 가집니다 [매뉴얼HBM검사및테스트공정가이드라인20260509001.pdf]. 이러한 구조적 특성으로 인해 기존의 일반적인 반도체 패키징 검사 방식으로는 검출하기 어려운 복합적인 결함이 발생하며, 이를 관리하기 위한 특화된 검사 로직이 필수적입니다. 본 섹션에서는 HBM 및 차세대 패키징(HBM4 등)에서 요구되는 핵심 검사 항목인 TSV, Micro-bump, Warpage를 중심으로 한 고난도 검사 프로세스를 상세히 분석합니다.

1. TSV(Through-Silicon Via) 및 Micro-bump 정밀 검사 로직

HBM의 성능을 결정짓는 핵심 요소는 수천 개의 미세 전극인 TSV와 이를 연결하는 마이크로 범프(Micro-bump)의 신뢰성입니다. 적층 단수가 높아질수록 각 층 간의 전기적 연결을 보장하기 위한 검사 난이도는 기하급수적으로 상승합니다.

1.1. TSV(Through-Silicon Via) 검사

TSV는 웨이퍼를 관통하여 상하 다이를 연결하는 통로 역할을 합니다. 이 단계에서의 검사는 주로 전공정(Wafer Level)과 적층 전 단계에서 집중적으로 이루어집니다 [매뉴얼HBM검사및테스트공정가이드라인20260509001.pdf].

- **위치 및 밀도 검사:** 설계된 좌표값에서 TSV가 미세하게 이탈했는지, 혹은 특정 영역에 TSV가 누락되었는지를 확인합니다.
- **깊이 및 형상 검사:** TSV 내부의 Void(빈 공간)나 Crack(균열)은 전기적 저항을 높이거나 단선(Open)을 유발하므로, 고해상도 광학 시스템을 통해 내부 형상을 정밀하게 스캔해야 합니다 [매뉴얼HBM검사및테스트공정가이드라인20260509001.pdf].
- **검사 기술:** 일반적인 광학 검사 외에도 내부 구조를 파악하기 위해 X-ray 또는 CT 기반의 비파괴 검사(Non-Destructive Testing)가 병행되어야 합니다 [매뉴얼HBM검사및테스트공정가이드라인20260509001.pdf].

1.2. Micro-bump 및 접합부 검사

다이와 다이 사이를 연결하는 Micro-bump는 매우 작은 크기(μm 단위)로 형성되므로, 미세한 공정 변수에도 결함이 발생하기 쉽습니다.

- **높이 및 정렬(Alignment) 검사:** Bump의 높이가 불균일하면 적층 시 압력 불균형을 초래하여 Die Bonding 오류나 Misalignment를 유발합니다 [매뉴얼HBMAAdvancedInspectionSyst20260509001.pdf].
- **주요 결함 유형:**
 - **Bridge (Short):** 인접한 Bump 간에 불필요한 금속 연결이 발생한 상태로, Solder 과다 도포나 Reflow(재가열) 온도 프로파일 불량에 주요 원인입니다 [매뉴얼HBMAAdvancedInspectionSyst20260509001.pdf].
 - **Missing Bump:** 특정 위치에 Bump가 형성되지 않은 상태로, Dispenser 노즐 불량이나 세정 공정의 문제로 추정됩니다 [매뉴얼HBMAAdvancedInspectionSyst20260509001.pdf].
 - **Void:** Bump 내부 또는 접합 계면에 형성된 기포로, 이는 열팽창 시 Delamination(층간 분리)의 시발점이 됩니다.

HBM 적층 구조 및 검사 대상 단면도




그림 2. HBM 적층 구조 및 검사 대상 단면도

2. Warpage(휨) 및 구조적 안정성 분석

HBM은 적층 단수가 높아짐에 따라 전체 패키지의 두께가 증가하고, 열처리(Annealing) 과정에서 발생하는 열팽창 계수(CTE) 차이로 인해 심각한 Warpage(휨) 현상이 발생합니다 [분석HBM4세대전환에따른크레셈CRESSEM의검사장20260509001.pdf].

2.1. Warpage 발생 원인 및 영향

- **원인:** 적층된 다이와 기판(Substrate) 사이의 소재 특성 차이, 혹은 적층 공정 중 가해지는 열/압력의 불균형이 주요 원인입니다 [매뉴얼HBMAdvancedInspectionSyst20260509001.pdf].
- **영향:** Warpage가 심화되면 검사 장비의 초점(Focus)을 벗어나 검사 정밀도가 저하될 뿐만 아니라, 후속 공정인 Bonding 단계에서 물리적 접촉 불량을 야기하여 수율(Yield)을 급격히 떨어뜨립니다 [분석HBM4세대전환에따른크레셈CRESSEM의검사장20260509001.pdf].

2.2. 3D 프로파일링 기반 측정 솔루션

크레셈은 이러한 문제를 해결하기 위해 고정밀 스테이지 제어 기술과 3D 프로파일링 기술을 결합한 검사 솔루션을 제공합니다 [분석HBM4세대전환에따른크레셈CRESSEM의검사장20260509001.pdf].

- **3D Scan 방식:** 단순 2D 이미지가 아닌, 광학 센서를 이용해 표면의 높낮이를 입체적으로 측정하여 Die의 휨 정도를 수 μm 단위로 정밀하게 산출합니다.

- **실시간 데이터 추출:** 변형된(Warped) 상태에서도 정확한 결함 데이터를 추출할 수 있도록 알고리즘이 최적화되어 있어, 검사 신뢰성을 유지합니다 [분석HBM4세대전환에따른크레셈CRESSEM의검사장20260509001.pdf].

3. 차세대 기술 대응: Hybrid Bonding (Cu-to-Cu)

HBM4 세대로 전환됨에 따라 기존의 Bump 방식은 한계에 봉착하고 있으며, 구리를 직접 접합하는 **Hybrid Bonding** 기술이 도입될 예정입니다. 이는 검사 프로세스에 근본적인 변화를 요구합니다.

- **초미세 정렬(Alignment) 요구:** Hybrid Bonding은 Bump가 없는 상태에서 구리(Cu) 패드끼리 직접 맞닿아야 하므로, 기존 방식보다 훨씬 높은 수준의 정렬 정밀도가 요구됩니다 [분석HBM4세대전환에따른크레셈CRESSEM의검사장20260509001.pdf].
- **크레셈의 전략적 대응:** 크레셈은 초고해상도 3D AOI(Automated Optical Inspection) 기술을 고도화하여, 접합부의 미세한 간극(Gap)이나 이물질(Particle)을 검출할 수 있는 전용 솔루션을 개발함으로써 차세대 시장을 선점하고자 합니다 [분석HBM4세대전환에따른크레셈CRESSEM의검사장20260509001.pdf].

4. 요약: HBM 특화 검사 항목 비교

검사 대상	핵심 검사 항목	주요 결함 (Defect)	권장 검사 장비/기술
TSV	위치, 깊이, 밀도, 내부 형상	Void, Crack, 연결 불량	Wafer Probe, X-ray/CT
Micro-bump	높이, 정렬, 납땜 상태	Bridge, Missing, Misalignment	3D AOI, High-Precision Optical
Warpage	적층 구조의 물리적 휨	Die/Substrate 휨, Tilt	3D 프로파일링, 정밀 옵티컬
Hybrid Bonding	Cu-to-Cu 접합면 정밀도	미세 간극, 이물질(Particle)	초고해상도 3D AOI

표 3. 요약: HBM 특화 검사 항목 비교

데이터 통합 및 수율 피드백 시스템

단순히 개별 제품의 Pass/Fail을 판정하는 전통적인 검사 방식을 넘어, 현대의 반도체 제조 공정은 검사 과정에서 생성되는 방대한 데이터를 자산화하여 공정 전체의 최적화를 도모하는 **스마트 팩토리(Smart Factory)** 체계로 진화하고 있습니다. 특히 HBM(High Bandwidth Memory)과 같이 적층 구조가 복잡하고 공정 난이도가 극도로 높은 제품군에서는, 검사 장비가 단순한 '수문장' 역할을 넘어 전공정(Fab)의 결함 원인을 역추적할 수 있는 **데이터 분석 플랫폼(Data Analysis Platform)**으로서의 기능이 필수적입니다.

1. 결함 원인 역추적(Root Cause Analysis, RCA) 구조

검사 단계에서 발견된 결함 데이터는 단순한 불량 통계에 그치지 않고, 해당 결함이 발생한 물리적/화학적 원인을 규명하기 위한 핵심 지표로 활용됩니다. 크레셈의 차세대 검사 솔루션은 검사 데이터를 분석하여 전공정(Fab)의 결함 원인을 역추적(Feedback)할 수 있는 통합 데이터 분석 플랫폼을 지향합니다 [출처: 분석_크레셈CRESSEM20260509001.pdf].

이러한 역추적 프로세스는 다음과 같은 메커니즘을 통해 수행됩니다.

- **데이터 상관관계 분석:** 특정 공정 단계(예: Solder Dispensing, Reflow, Die Bonding)에서 발생하는 파라미터 변동과 검사 장비에서 검출된 결함 유형(Bridge, Missing, Misalignment 등) 간의 상관계수를 산출합니다 [출처: 매뉴얼HBMAAdvancedInspectionSyst20260509001.pdf].

- **결함 패턴 매칭:** AI 알고리즘을 통해 검출된 결함의 형상(Morphology)을 분석하여, 이것이 웨이퍼 레벨의 오염인지, 혹은 적층(Stacking) 과정에서의 압력 불균형에 의한 것인지 구분합니다. 예를 들어, Bridge(Short) 결함이 반복적으로 발생할 경우, 이를 Solder 과다 도포 또는 Reflow 온도 프로파일의 불량으로 즉각 매칭하여 공정 엔지니어에게 알람을 제공합니다 [출처: 매뉴얼HBMAdvancedInspectionSyst20260509001.pdf].

2. 수율(Yield) 개선을 위한 데이터 기반 의사결정

반도체 제조사(SK하이닉스, 삼성전자 등) 및 패키징 업체(TSMC 등)에게 있어 수율 향상은 수익성과 직결되는 가장 중요한 지표입니다. 검사 데이터를 기반으로 한 수율 관리 전략은 다음과 같은 가치를 제공합니다.

구분	전통적 검사 방식 (Traditional)	데이터 통합 피드백 방식 (Smart Factory)
주요 목적	불량품 선별 및 폐기 (Sorting)	공정 변수 제어 및 수율 최적화 (Optimization)
데이터 활용	개별 검사 결과의 Pass/Fail 기록	공정 파라미터와 결함 데이터의 통합 분석
대응 방식	불량 발생 후 사후 조치	데이터 기반의 사전 예방 및 실시간 피드백
기대 효과	폐기 비용 절감	전공정 수율(Yield) 극대화 및 공정 안정화

표 4. 수율(Yield) 개선을 위한 데이터 기반 의사결정

크레셈의 솔루션은 검사 데이터를 실시간으로 수집하고 이를 관계형 데이터베이스(Relational Database)에 자동 저장 및 분석하여, 공정 변수를 실시간으로 제어할 수 있는 기반을 제공합니다 [출처: PDF Optimizing Defect Detection: A Machine Learning-Ready Data Processing Pipeline]. 이는 고객사가 공정상의 결함 원인을 즉각적으로 파악하여 조치할 수 있게 함으로써, 장비의 교체 주기를 단축시키고 생산성을 극대화하는 핵심 경쟁력이 됩니다 [출처: 분석_크레셈CRESSEM20260509001.pdf].

3. 스마트 팩토리 구현을 위한 데이터 파이프라인

효율적인 수율 피드백을 위해서는 하드웨어에서 발생하는 로우 데이터(Raw Data)부터 상위 분석 시스템까지 이어지는 견고한 데이터 파이프라인이 구축되어야 합니다.

1. **Data Acquisition (데이터 획득):** 고해상도 광학 엔진 및 센서를 통해 검사 대상(HBM, FC-BGA 등)의 이미지를 및 3D 프로파일 데이터를 획득합니다.

2. **Preprocessing & Standardization (전처리 및 표준화):** AOI 및 X-ray 출력 데이터를 머신러닝 모델이 학습하기 용이하도록 표준화하고, 결함 라벨(Defect Label)을 정규화합니다 [출처: PDF Optimizing Defect Detection: A Machine Learning-Ready Data Processing Pipeline].

3. **AI-Driven Analysis (AI 기반 분석):** 딥러닝 알고리즘을 통해 결함을 분류하고, 정상적인 노이즈와 실제 결함을 구분하여 과검(Over-kill)을 방지합니다 [출처: 분석_크레셈CRESSEM20260509001.pdf].

4. **Root Cause Feedback (원인 피드백):** 분석된 결함 데이터를 상위 MES(Manufacturing Execution System) 또는 공정 제어 시스템으로 전송하여, 전공정의 설비 파라미터를 수정하도록 유도합니다.

수율 피드백 및 데이터 통합 아키텍처




그림 3. 수율 피드백 및 데이터 통합 아키텍처

결론/시사점

본 보고서에서 분석한 AOI(Automated Optical Inspection) 결함 검출 알고리즘 파이프라인과 AI 통합 검사 솔루션은 단순한 불량 선별을 넘어, 반도체 제조 공정의 지능화와 수율 최적화를 결정짓는 핵심 요소로 자리 잡았습니다. 차세대 반도체 시장의 급격한 변화에 대응하기 위한 기술적 트렌드 요약 및 크레셈(CRESSEM)의 전략적 대응 방향을 다음과 같이 제언합니다.

1. 차세대 검사 기술 트렌드: Hybrid Bonding 및 초미세화 대응

반도체 패키징 기술이 HBM4 세대로 진입함에 따라, 기존의 Bump 방식에서 구리 직접 접합 방식인 **하이브리드 본딩(Hybrid Bonding, Cu-to-Cu)**으로의 전환이 가속화되고 있습니다. 이는 기존 방식보다 훨씬 높은 수준의 정렬(Alignment) 정밀도와 초미세 간극(Gap) 제어 능력을 요구합니다 [분석HBM4세대전환에따른크레셈CRESSEM의검사장20260509001.pdf]. 따라서 향후 AOI 기술은 단순 표면 검사를 넘어, 초고해상도 3D 프로파일링을 통해 접합부의 미세한 이물질과 간극을 실시간으로 측정할 수 있는 기술로 진화할 것입니다.

2. AI-Driven 검사 솔루션의 고도화

전통적인 Rule-based 방식은 정해진 규칙 외의 변수에 취약하여 과검(Over-kill) 발생률이 높다는 한계가 있습니다. 반면, 딥러닝 기반의 AI 알고리즘은 미세 결함과 정상적인 노이즈를 정교하게 구분함으로써 검사 신뢰도를 극대화합니다 [기업 분석 보고서] (주)크레셈 (CRESSEM): 차세대 반. 향후에는 단순히 불량을 분류하는 단계를 넘어, 검사 데이터를 분석하여 전공정(Fab)의 결함 원인을 역추적(Root Cause Analysis)하는 **데이터 기반 스마트 팩토리 솔루션**이 검사 장비의 핵심 경쟁력이 될 것입니다 [분석_크레셈CRESSEM20260509001.pdf].

3. 크레셈(CRESSEM)의 전략적 대응 방향

크레셈은 현재 보유한 FC-BGA 및 2.5D 기판 검사 기술력을 바탕으로 HBM4의 Base Die 및 Hybrid Bonding 검사 영역으로 기술적 범위를 확장해야 합니다 [분석HBM4세대전환에따른크레셈CRESSEM의검사장20260509001.pdf]. 특히 고객사별로 상이한 공정 프로세스에 유연하게 대응할 수 있는 **고객 맞춤형 모듈화 장비(Customized Inspection System)**를 공급함으로써 고객 락인(Lock-in) 효과를 강화하고, AI 비전 엔진과 고속 광학 엔진을 통합한 독보적인 하드웨어-소프트웨어 결합 솔루션을 통해 글로벌 시장에서의 기술 격차를 유지해 나가야 합니다 [기업 분석 보고서] (주)크레셈 (CRESSEM): 차세대 반.