

딥러닝 기반 웨이퍼 결함 패턴 분류

이성재¹, 용규순², 김민지³, 류병석⁴, 오준석⁵, 김영균⁶¹강원대학교 IT대학 전기전자공학과²강원대학교 문화예술·공과대학 배터리융합공학과³강원대학교 농업생명과학대학 식물자원응용과학전공⁴연세대학교 공과대학 화공생명공학과⁵연세대학교 일반대학원 배터리공학과⁶융합소프트웨어랩sungjae16lee@gmail.com, yks6624@naver.com, applegate44@gmail.com, bsryu@yonsei.ac.kr,
jsoh@yonsei.ac.kr, ygkim-2004@hanmail.net

Deep Learning based Wafer Defect Pattern Classification

Seongjae Lee¹, Gyusun Yong², Minji Kim³, Byungseok Ryu⁴, Junseok Oh⁵
Younggyun Kim⁶¹Dept. of Electrical & Electronics Engineering, Kangwon National University²Dept. of Battery Convergence Engineering, Kangwon National University³Dept. of Applied Plant Sciences, Kangwon National University⁴Dept. of Chemical & Biomolecular Engineering, Yonsei University⁵Dept. of Battery Engineering, Yonsei University⁶Convergence Software Lab

요 약

현대 반도체 공정은 미세화로 인해 수율 확보에 어려움을 겪고 있으며, 웨이퍼 맵의 결함 패턴 분석은 공정 오류를 조기에 발견하고 수율을 개선하는 데 핵심적인 역할을 한다. 그러나 기존의 육안 검사는 많은 시간이 소요되고 인적 오류의 가능성이 존재한다. 본 연구에서는 이러한 한계를 극복하고자 딥러닝 기반 객체 탐지 모델인 YOLOv11n을 활용하여 웨이퍼 맵의 결함 유형과 위치를 자동으로 탐지 및 분류하는 방법을 제안한다. 제안한 방법은 검사 효율성을 높이고 수율 향상에 기여할 것이다.

1. 서론


현대 반도체는 미세 공정을 통해 선폭을 줄임으로써 고집적화, 성능 향상, 소형화 및 저전력화를 실현하고 있다[1][2]. 그러나 공정 미세화에 따라 공정 마진이 감소하고, 특히 리던던시 셀(Redundancy Cell) 구축이 어려운 시스템 반도체의 경우 수율 확보에 어려움이 발생하면서 품질 관리의 중요성이 점차 확대되고 있다[3]. 반도체는 수백 단계의 단위 공정을 거쳐 회로가 형성되며, 패키징 전에는 EDS(Electrical Die Sorting) 웨이퍼 테스트를 통해 전기적 특성을 측정하고 양품 다이(Die)를 선별한다. 이 과정에서 웨이퍼 내 불량 다이의 분포가 특정 패턴을 나타낼 수 있으며, 이는 단위 공정 내 오류의 발생을 시사한다[4]. 예를 들어, 클러스터, 도넛, 엷지, 스크래치와 같은 패턴은 각각 오염, 회전 불균형, 식각 불량, 물리적 손상 등과 관련된다. 이러한 결함 패턴을 분석하면 공정 내 문제점을 조기에 발견할 수 있으며, 이는 수율 향상과 제조 안정성 확보에 기여한다[5]. 기존 산업 현장에서는 웨이

퍼 맵을 육안으로 분류하는 방식에 의존하고 있어 검사 시간이 길고 인적 오류의 가능성이 높다[6]. 이에 따라 딥러닝 기반 자동 판별 기법의 도입은 생산 라인의 자동화와 일관된 판별을 가능하게 하여 검사 효율을 높이고 오류를 줄일 수 있다[7]. 본 연구에서는 실시간 객체 탐지 모델인 YOLOv11n(You Only Look Once version 11 nano) 기반 웨이퍼 결함 패턴 분류 알고리즘을 설계 및 구현하였다. 이를 통해 웨이퍼 맵 내 결함의 위치와 형태를 자동으로 탐지 및 분류하고, 생산 효율과 수율 향상을 위한 방법론을 제안한다.

2. 웨이퍼 결함 패턴 분류 알고리즘

본 알고리즘은 그림 1과 같이 먼저 YOLOv11n 모델을 사용하여 웨이퍼 빈 맵 이미지의 결함 패턴을 검출한다. 그 후, 검출된 결함을 기반으로 결함의 이미지와 결함의 좌표 기반의 공간적 정보를 다중 입력 분류 모델의 입력으로 사용하여, 형태를 나타내는 시각적 특징과 위치를 나타내는 공간적 특징을 추출한다. 이

러한 특징을 융합하여 결함 패턴의 종류를 분석하며 웨이퍼 빈 맵 이미지 상에 바운딩 박스와 분류 결과를 표시한다.



(그림1) 알고리즘 순서도


2.1 데이터 수집

본 연구에서는 반도체 웨이퍼의 불량 패턴 분류를 위해 널리 사용되는 공개 데이터셋인 WM-811K를 활용하였다[8][9]. WM-811K는 실제 산업 공정에서 수집된 총 811,457개의 웨이퍼 맵으로 구성된 대규모 데이터셋이다. 본 연구에서는 8,009개의 데이터를 선별하여 학습 및 평가에 사용하였다. 해당 데이터셋은 정상 패턴(None)을 제외한 8가지 주요 불량 패턴을 포함하고 있다.

2.2. YOLOv11n 모델을 사용한 결함 패턴 검출

YOLOv11n은 객체 검출을 수행하는 최신 모델로, 본 연구에서는 이를 재학습하여 웨이퍼 결함 패턴을 클래스 별로 검출하였다[10][11]. 해당 모델은 웨이퍼 빈 맵 이미지에서 결함의 존재 여부를 판단하고, 이를 바운딩 박스 형태로 제시한다(그림 2). 재학습에 사용된 데이터셋은 Roboflow를 통해 구축되었으며, 총 80,09장의 웨이퍼 빈 맵 이미지가 ‘Center’, ‘Donut’, ‘Edge-Loc’, ‘Edge-Ring’, ‘Loc’, ‘Near-full’, ‘Random’, ‘Scratch’ 등 8개 클래스로 라벨링 되었다. 데이터셋은 Flip과 Rotation을 적용한 3배수 증강 기법을 통해 구성되었으며, 최종적으로 훈련 16,780장, 검증 1,200장, 테스트 1,200장으로 분할되었다. YOLOv11n의 재학습은 Google Colab 환경에서 전체 데이터셋을 대상으


로 100 epoch 동안 수행되었다.



(그림 2) YOLOv11n 검출 이미지

2.2.1 YOLOv11n 모델 재학습 결과


본 연구에서는 YOLOv11n 모델의 결함 패턴 검출 성능을 평가하기 위해 mAP(mean Average Precision) 지표를 활용하였다. mAP는 객체 검출 모델의 성능을 평가하는 대표적인 지표로, 정밀도와 재현율의 관계를 나타내는 PR(Precision-Recall) 곡선 아래 면적을 의미한다. 실험 결과, 제안한 모델은 전체 객체 검출에서 mAP 0.925를 기록하여 높은 정확도를 달성하였다(그림 3).



(그림 3) YOLOv11n의 Precision-Recall Curve

2.3. 결함 패턴 분류

본 연구에서는 전통적인 단일 경로 신경망과 달리 결함의 시각적 특징과 공간적 특징을 효과적으로 학습하기 위해 다중 브랜치(Multi-Branch) 분류 모델을 채택하였다. 여기서 시각적 특징은 결함의 형태를 나타내고 공간적 특징은 웨이퍼 상에서 결함의 위치를 나타낸다. 예를 들어 Center와 Loc 패턴처럼 시각적으로 결함의 형태는 비슷하지만 발생 위치가 다른 경우의 결함을 구별하기 위함이다(그림 4). 따라서 해당 모델은 결함의 시각적 특징과 공간적 특징을 동시에 분석하여 분류 성능을 종합적으로 향상시키고자 제작되었다.



(그림 4) 결합 패턴 예시

2.3.1 다중 브랜치(Multi-Branch) 분류 모델

본 연구에서는 이미지 처리 브랜치와 좌표 처리 브랜치로 구성된 다중 브랜치 분류 모델을 제안한다. ResNet50 기반의 이미지 처리 브랜치가 결합의 시각적 특징을 도출하고 좌표 처리 브랜치가 결합의 좌표를 기반으로 공간적 특징을 도출한다. 최종적으로 두 브랜치에서 추출된 특징들을 융합하여 결합을 분류한다.

2.3.2 ResNet50 기반의 이미지 처리 브랜치

ResNet은 Microsoft Research가 개발한 심층 신경망으로 잔차 학습(Residual Learning)을 도입하여 안정적인 학습과 높은 정확도를 보여주는 딥러닝 모델이다[12]. 잔차 학습은 모델이 변화량(Residual)만을 학습하도록 하는 지름길(Shortcut Connection)을 도입하여, 모델의 구조가 깊어져도 성능 저하 없이 안정적이고 효율적인 학습이 가능하다. 이미지 처리 브랜치는 ResNet50을 활용하여 검출된 결합 이미지로부터 결합의 시각적 특징을 추출한다.

2.3.3 다중 브랜치 구조의 좌표 처리 브랜치


결합의 공간적 정보를 분석하기 위해 다중 브랜치 구조의 좌표 처리 브랜치를 설계하였다. 이 브랜치는 바운딩 박스로 처리된 결합에서 추출된 기하학적 정보와 구역 정보를 입력으로 한다. 기하학적 정보는 바운딩 박스로 처리된 결합의 중심 좌표, 크기, 웨이퍼 중심까지의 거리, 상대적 위치, 종횡비 그리고 가장자리 간 거리를 포함한다. 구역 정보는 웨이퍼 전체를 특정 구간으로 나누어 결합이 어느 구간에 위치하는지를 표시한 정보를 의미한다. 기하학적 정보를 처리하는 부분은 MLP, 잔차 연결, 특징 상호작용을 병렬로 사용하여 기하학적 특징을 추출한다. 그리고 구역 정보를 처리하는 부분은 결합이 속한 구역의 고유한 의미를 학습하기 위해 임베딩과 위치 인코딩 기법을 사용하여 구역 특징을 추출한다. 이러한 다중 브랜치 구조는 단일 구조로 파악하기 힘든 결합의 공간적 특징을 효과적으로 분석하여 웨이퍼 상 위치가 모호한 결합을 정확히 분류하는데 강점이 있다.

2.3.4 어텐션 기반 특징 융합 및 최종 분류

각 브랜치에서 추출된 특징들을 효과적으로 융합하기 위해서 어텐션 기법을 적용했다. 어텐션은 결합을 분류할 때, 추출된 공간적 특징과 연관성이 높은 시각적 특징을 선별하여 가중치를 높이는 방식으로, 모델이 결합의 핵심 특징에 집중하도록 유도하는 기법이다. 본 모델의 특징 융합은 공간적 특징을 기준으로 시각적 특징의 가중치를 선택적으로 제어하여 핵심 특징을 강조하는 게이팅(Gating) 방식으로 구현하였다. 먼저 결합의 기하학적 정보와 구역 정보를 담은 문맥 벡터(Context Vector)를 만든다. 이 문맥 벡터를 기반으로 이미지 특징의 각 요소에 동적인 가중치를 부여한다. 최종적으로 가중치가 적용된 이미지 특징과 문맥 벡터를 결합하여 분류 결과를 출력한다.

2.3.5 결합 분류 결과

분류 모델의 결합별 최종 성능을 평가하기 위해 혼동 행렬(Confusion Matrix) 지표를 활용하였다(그림 5). 혼동 행렬은 실제 데이터와 예측된 데이터를 매칭하여 분류 모델의 성능을 시각화하는 표이다. 행렬의 대각선 성분은 모델이 실제 클래스를 정확하게 예측한 비율을 나타내며, 이 값이 1에 근접할수록 해당 클래스에 대한 성능이 높음을 의미한다. 분류 모델은 8가지의 클래스에 대해 평균 0.946의 정확도를 보였으며, 클래스 별 정확도는 0.78부터 0.99까지 분포하였다. Loc 패턴은 다른 패턴과 형태가 유사한 경우가 많아서 다른 패턴에 비해 정확도가 낮은 경향을 보인다.




(그림 5) 알고리즘의 Confusion Matrix 결과


3. 결과 시각화

웨이퍼 결합 패턴 판별 알고리즘의 분석 결과를 시각화하기 위해 웨이퍼 빈 맵 이미지에서 검출된 결합

을 바운딩 박스로 표시하고 해당 결함의 분류 결과를 표시한 이미지를 제시하였다(그림 6). 전체적으로 바운딩 박스가 결함에 잘 지정되어 있으며 결함을 잘 분류하고 있음을 확인할 수 있다. 하지만 일부 패턴은 다른 특정 패턴으로 오분류되는 경우도 있었다(그림 7).



(그림 6) 결과 시각화



(그림 7) 오분류 사례

4. 결론

본 연구에서는 YOLOv11n과 ResNet50 기반의 분류 모델을 결합하여 웨이퍼 결함 패턴을 자동으로 검출하고 분류하는 알고리즘을 개발하였다. 이러한 접근은 웨이퍼 결함을 신속하게 분석하고 실시간으로 결과를 제공함으로써 수율 향상과 생산성 안정에 기여할 수 있다. 초기 단일 경로 방식의 알고리즘에서 일부 클래스의 경우 낮은 정확도가 나타났으나, 공간적 특징을 세분화하여 분석함으로써 알고리즘의 전체적인 성능을 크게 향상시킬 수 있었다. 하지만 일부 클래스는 공간적 특징을 과하게 적용함으로써 다른 클래스로 오분류되는 경우도 있었다. 향후 연구에서는 이를 보완하기 위해 웨이퍼에서 추출된 두 정보 간의 유기적인 상호작용을 이루는 새로운 융합 기법을 적용하여 오분류되는 사례를 줄이고 다양한 결함 이미지를 추가하여 전체적인 성능을 향상시키고자 한다.

참고문헌

[1] Kawamoto, Y., Kimura, K., Nakazato, J., Nagaoka, M., & Eng, D., The Outlook for Semiconductor Processes and Manufacturing Technologies in the 0.

1- μ m Age, Hitachi Review, 48(6), 335, 1999.

[2] Moore, G.E., Cramming More Components onto Integrated Circuits, Electronics, 38, 114, 1965.

[3] Cheng, K. C.-C., et al., Machine learning-based detection method for wafer test induced defects, IEEE Transactions on Semiconductor Manufacturing, 34(2), 161-167, 2021.

[4] Nakazawa, T., & Kulkarni, D. V., Wafer map defect pattern classification and image retrieval using convolutional neural network, IEEE Transactions on Semiconductor Manufacturing, 31(2), 309-314, 2018.

[5] Hsu, S. C., & Chien, C. F., Hybrid data mining approach for pattern extraction from wafer bin map to improve yield in semiconductor manufacturing, International Journal of Production Economics, 107(1), 88-103, 2007.

[6] Shinde, P. P., Pai, P. P., & Adiga, S. P., Wafer defect localization and classification using deep learning techniques, IEEE Access, 10, 39969-39974, 2022.

[7] Schlosser, T., Friedrich, M., Beuth, F., et al., Improving automated visual fault inspection for semiconductor manufacturing using a hybrid multistage system of deep neural networks, Journal of Intelligent Manufacturing, 33, 1099-1123, 2022.

[8] Wu, M.-J., Jang, J. R., & Chen, J.-L., Wafer map failure pattern recognition and similarity ranking for large-scale data sets, IEEE Transactions on Semiconductor Manufacturing, 28(1), 1-12, 2015.

[9] MIR-WM811K, Dataset for wafer map failure pattern recognition, 2015. Available at: <http://mirlab.org/dataset/public/>

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

[11] Khanam, R., & Hussain, M., YOLOv11: An Overview of the Key Architectural Enhancements, a rXiv preprint, arXiv:2410.17725, 2024.

[12] He, K., Zhang, X., Ren, S., & Sun, J., Deep Residual Learning for Image Recognition, Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas, USA, 2016, pp. 770-778.