

데이터 클래스 불균형을 고려한 전이학습 기반의 반도체 웨이퍼 빈 맵 결함 패턴 분류

박인영, 김지영*
경북대학교 데이터사이언스대학원

Semiconductor Wafer Bin Map Defect Pattern Classification based on Transfer Learning Considering Data Class Imbalance

Inyoung Park, Jeeyoung Kim*
Graduate School of Data Science, Kyungpook National University

요약 웨이퍼(wafer)는 반도체 산업의 핵심 부품 중 하나이며 웨이퍼 검사의 결과물인 웨이퍼 빈 맵(wafer bin map)은 반도체 공정 수율과 직결되는 중요한 도구이다. 웨이퍼 빈 맵에 나타난 결함 패턴을 발견하여 결함의 원인을 파악하고 빠른 조치를 취하면 수율을 향상시킬 수 있다. 그러나, 반도체 공정에서 하루에 생산되는 웨이퍼의 수는 수백에서 수천 장으로 숙련된 기술자가 육안으로 웨이퍼 빈 맵을 확인하고 결함 패턴을 파악하는 데에는 한계가 존재한다. 본 연구에서는 공개 데이터인 WM-811k를 이용하여 정상 패턴을 제외한 8가지의 결함 패턴에 대하여 데이터 증강 없이 전이학습을 기반으로 분류를 진행하였다. 이미지 분류에 사용되는 일반 모델과 더불어 7가지 경량화 모델을 이용한 실험을 진행함으로써 고성능 하드웨어 없이 모바일 기기나 엣지 디바이스를 이용하여 웨이퍼 빈 맵 결함 패턴을 구분하는데 인공지능이 활용될 수 있음을 확인하였다. 또한, 정확도와 F1-score를 비교하여 데이터의 불균형 정도를 판별하고 모델 별로 확인한 패턴 분류 정확도를 이용하여 향후 연구의 방향을 제시한다.

Abstract One of the critical components in the semiconductor industry is the wafer and wafer bin map, a result of wafer inspection, which is a crucial tool linked directly to the overall production yield. Identifying defect patterns on the wafer bin map allows an understanding of the cause of defects and taking prompt action to improve yield. On the other hand, there are limitations for technicians to identify defect patterns for each bin map visually due to the sheer volume of wafers produced everyday. This study classified eight defect patterns, excluding normal patterns of the publicly available and widely used dataset WM-811k, based on transfer learning without data augmentation. Experiments were conducted using conventional image classification models and seven lightweight models. The results confirmed the potential of artificial intelligence to differentiate wafer bin map defect patterns using mobile devices or edge devices. Directions for future research are suggested by comparing the accuracy and F1-score to assess data imbalances and presenting pattern classification accuracies for each model.

Keywords : Semiconductor, Wafer Bin Map, Transfer Learning, Lightweight Models, Defect Classification

본 논문은 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(RS-2023-00242528).

*Corresponding Author : Jeeyoung Kim(Kyungpook National University)

email: jeeyoungkim@knu.ac.kr

Received March 11, 2024

Revised April 19, 2024

Accepted May 3, 2024

Published May 31, 2024

1. 서론

반도체 산업은 우리나라에서 큰 비중을 차지하고 있는 주요 산업 중 하나이다. 반도체는 현대의 기술과 전자 제품의 핵심 부품일 뿐 아니라, 경제적, 기술적, 사회적 측면에서도 국가 발전에 큰 영향을 미치고 있다. Fig. 1은 반도체산업협회, 정보통신산업진흥원에서 제공한 통계 자료로 1997년부터 2022년까지의 반도체 수출 금액을 나타내고 있다. Fig. 1에서 보이는 것과 같이 시간이 지남에 따라 반도체 수출 증가율도 대체로 증가하는 추세를 알 수 있다. 또한, 반도체 산업은 높은 수준의 기술과 전문성을 요구하기 때문에, 국내 반도체 산업이 성장함에 따라 이에 상응하는 인력 수준도 함께 향상된다. 최근 급부상하고 있는 인공지능은 이러한 반도체 산업에서 자동화 및 생산 최적화의 도구로 사용할 수 있다.

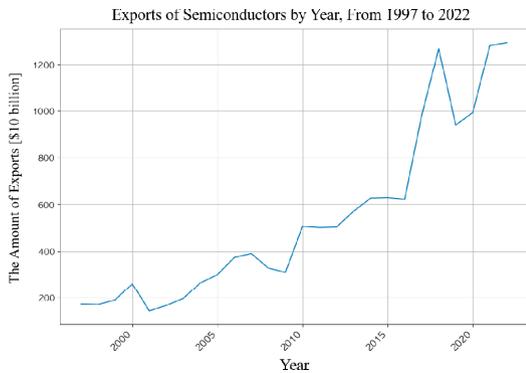


Fig. 1. Korea Semiconductor exports by year (1997-2022).

반도체 공정 중 EDS(Electrical Die Sorting) 검사는 웨이퍼 위의 IC(Integrated Circuit)칩들이 정상적으로 동작하는지를 확인하는 기술이다. EDS의 검사 결과로 웨이퍼 빈 맵이 생성되는데, 이를 통해 각 칩이 어떤 종류의 결함 패턴을 가지고 있는지를 칩의 위치 정보와 함께 알 수 있다. 웨이퍼 빈 맵의 결함 패턴은 생산 과정에서의 결함 원인을 파악할 수 있는 중요한 단서가 된다. 예를 들어, Center 패턴의 결함은 웨이퍼 박막 표면에 발생한 요철이나 굴곡을 화학적 혹은 기계적으로 평탄화하는 CMP(Chemical Mechanical Polishing) 공정에서 문제가 생겼을 때 발생한다[1]. 동일한 결함 패턴을 가지는 웨이퍼는 그 결함의 원인도 대체로 비슷한 것으로 추측할 수 있다. 그러므로, 생산 수율과 직결되는 결함 패턴을 발견하고 결함 발생 원인을 빠르게 파악하여

그것을 해결하는 것이 중요하다.

본 연구에서 중점적으로 다루고자 하는 웨이퍼 검사 과정은 일반적으로 전수 검사로 이루어지며 그 결과인 웨이퍼 빈 맵을 확인하는 과정이 매우 중요하다. 현업에서는 숙련된 기술자가 육안으로 웨이퍼 빈 맵을 파악하여 특정 패턴에 라벨을 붙이거나 추가 분석을 진행한다. 기업의 이윤과도 직결되는 이러한 주요 산업의 경우, 인공지능이 일정 수준의 성능에 도달하였다고 해도 숙련된 기술자를 완벽하게 대체할 수는 없다. 따라서, 인공지능을 숙련된 기술자와 더불어 웨이퍼 빈 맵 결함 패턴을 판단하는 데 도움을 주는 도구로서 이용하는 방법을 모색하여야 한다.

본 연구에서는 이 점에 기인하여 실제 웨이퍼 빈 맵 결함 판단의 과정과 유사한 조건으로 실험하기 위하여 데이터 증강을 하지 않고 실제 데이터만을 이용하였다. 또한, 소규모 데이터 학습에 유용한 전이학습을 이용하여 심층 학습 모델의 성능을 확인하고 웨이퍼 빈 맵 결함을 탐지하는데에 데이터 증강의 필요성 여부에 대해서 살펴본다. 마지막으로, 반도체 산업에서 인공지능을 도구로서 활용하고 정상 데이터와 결함 데이터 간의 클래스 불균형을 고려한 추후 연구 방향을 제안한다.

본 논문의 기여점은 다음과 같다.

- 데이터 증강 없이 전이학습을 기반으로도 일정 수준 이상의 모델을 획득할 수 있음을 실험을 통해 입증함.
- 소수 클래스 데이터의 분류 정확도가 데이터 개수에 비례하지 않음을 실험을 통해 밝혀냄.
- 일부 경량화 모델이 특정 패턴에 대해서 일반적인 모델보다 우수한 성능을 보임을 실험을 통해 확인함.
- 데이터 클래스 불균형을 고려하여 추후 연구 방향을 제안함.

2. 연구 방법

2.1 데이터 개요 및 불균형 문제

본 연구에서 사용한 데이터는 캐글(Kaggle)에 공개된 WM-811k 이다[2]. 이 데이터는 실제 공정 과정에서 수집된 811,457장의 웨이퍼 빈 맵으로 구성되어 있고, 이 중에 라벨이 표기된 웨이퍼 빈 맵은 172,950장이다. 전체 데이터의 구성 비율은 Fig. 2와 같다. 각 데이터 라벨은 결함 패턴이 탐지 되지 않은 None 패턴과 8가지의 결함 패턴인 Center, Edge-Loc, Edge-Ring, Loc, Scratch, Random, Donut, Near-Full로 이루어져 있다. 각 결함 패턴의 예시 이미지는 Fig. 3과 같다.

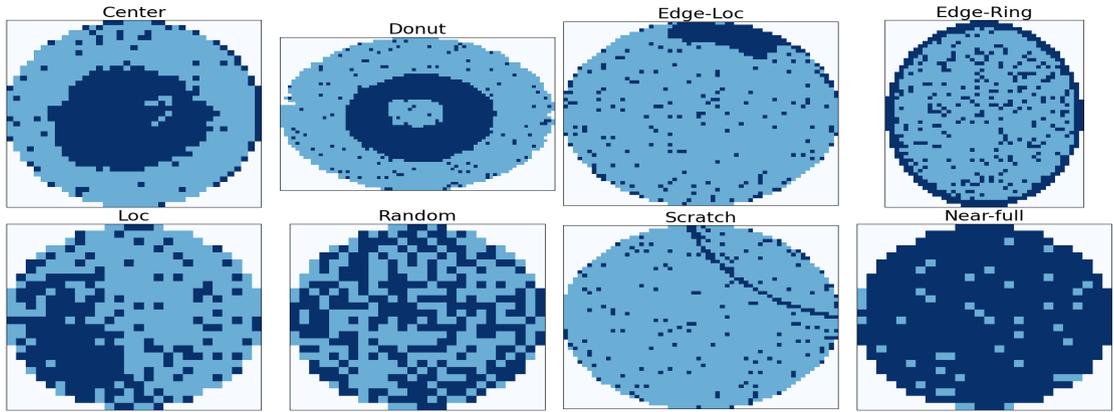


Fig. 3. Example images of 8 defect patterns.

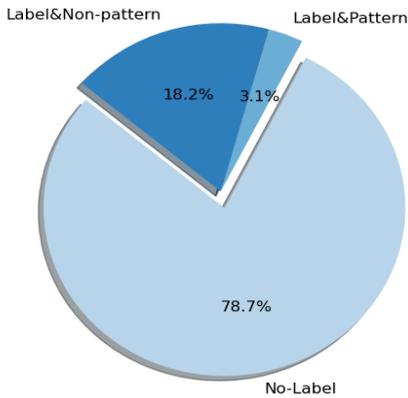


Fig. 2. Composition Percentage of the entire dataset.

이 데이터에는 클래스 간의 불균형이라는 큰 문제점이 존재한다. 라벨이 표기된 172,950장의 웨이퍼 간 클래스 불균형은 Table 1과 같다. 클래스 불균형 문제는 1) 정상 패턴과 결함 패턴 간의 클래스 불균형과 2) 결함 패턴 클래스들 사이의 불균형 문제로 나누어 볼 수 있다. 먼저, 정상 패턴을 의미하는 None 패턴이 라벨링 된 전체 데이터의 85.25%를 차지하며, 결함 패턴으로 구분되는 나머지 8가지 패턴이 나머지인 14.75%를 차지한다. None 패턴의 웨이퍼 빈 맵 개수는 8가지 결함 패턴들의 맵 개수 대비 적게는 15.3배, 많게는 999.47배로 압도적으로 많다.

두 번째 불균형은 결함 패턴 간에도 존재한다. Table 1에서도 볼 수 있듯이, 가장 많은 Edge-Ring 패턴의 경우 9,680장의 데이터가 존재하지만, 가장 적은 Near-Full 패턴은 149장으로 Edge-Ring 패턴의 약 1.54%에 해당한다.

Table 1. Labeled wafer bin map configuration numbers.

Class	Pattern	# of wafer bin map	Ratio to the total [%]
Defect	Center	4,294	2.48
	Donut	555	0.32
	Edge-Loc	5,189	3.00
	Edge-Ring	9,680	5.60
	Loc	3,593	2.08
	Random	866	0.50
	Scratch	1,193	0.69
	Near-Full	149	0.09
Normal	None	147,431	85.25
Total		172,950	

2.2 관련 연구

웨이퍼 결함 패턴을 분류하는 연구는 2015년 본 연구에서 사용한 데이터가 배포된 이후로 활발하게 진행되어 왔다[2-5]. 초기에는 통계적 접근 위주의 연구가 진행되었는데, Wu et al.[2]은 본 연구에서 사용한 데이터인 WM-811k를 배포하고, SVM(Support Vector Machine) 기법을 이용하여 분류 문제를 해결하였다. 최근에는 주로 합성곱 신경망 (Convolutional Neural Network, CNN)을 이용한 연구들이 진행되었다. Lee et al.[3]은 CNN 구조를 활용하여 효과적으로 웨이퍼 결함 패턴 분류를 다루었다. Ji and Lee[4]는 GAN을 이용하여 소수 클래스의 데이터를 증강하여 데이터의 클래스 불균형 문제를 해결하고자 하였고 이를 이용하여 웨이퍼 빈 맵을 분류하였다. Shin and Yoo[5]는 전이 학습을 기반으로 결함 패턴을 분류하는 효율적인 CNN 기반의 경량화 모델을 찾아내는 연구를 하였다. 이들은 데이터의 클래스 불균형 상황을 고려하여 Resize, RandomCrop, RandomRotation, RandomErasing 등의 기법으로 모든 결함 패턴에 대하여 동일하게 10,000장을 증강해주

었다. 그 결과, 모든 모델의 실험 결과에서 정확도가 98% 이상을 도달하며 높은 성능을 보였지만, 정확도에 비하여 F1-score가 평균 0.89로 낮게 출력되었다. 그 이유는 모델 학습 시에 결합 패턴에 대하여 데이터 증강을 해주었음에도 학습 데이터의 None 패턴은 117,945 장이고, 가장 많이 존재하는 결합 패턴인 Edge-Ring은 17,744장으로 None 패턴의 약 15.044%에 해당하기 때문에 클래스 간의 불균형이 존재하기 때문이다.

지도학습을 기반으로 한 연구의 경우에는 과적합(overfitting)을 방지하기 위하여 결합 패턴의 데이터 증강이 필수적으로 고려되어야 한다. 그러나, 데이터 증강을 어떤 방식으로 해주느냐에 따라 모델의 성능뿐만 아니라 데이터 신뢰성의 문제가 제기될 수 있다. 예를 들어, 정상 패턴을 포함하여 모든 데이터를 실험에 사용할 경우, 8가지의 결합 패턴이 여전히 소수 클래스에 해당된다. 이 경우에 8가지 결합 패턴을 모두 동일한 장수로 증강해주었을 경우, 원본 데이터보다 증강 데이터가 더 많아짐에 따라 데이터의 신뢰성이 불확실해짐을 감수해야 한다. 따라서, 본 연구에서는 WM-811k 데이터의 문제점을 파악하고 데이터 증강이 반드시 고려되어야 하는지 여부와 클래스 간의 불균형을 효과적으로 고려하여 결합 패턴을 분류하는 방법을 도출하고자 한다.

2.3 방법론

본 연구는 웨이퍼 빈 맵 결합 패턴 불균형의 문제를 집중적으로 다루기 위해 정상 패턴을 제외한 결합 패턴 8가지에 대해서만 실험을 진행하였다. 전체 데이터의 85.25%를 차지하는 정상 패턴을 포함하여 분류 모델을 설계할 시 정확도(accuracy)와 특이도(specificity)는 높지만 민감도(sensitivity)는 크게 떨어지는 클래스 불균형 문제가 발생한다. 클래스 불균형 문제란 학습 데이터의 클래스 변수가 균일하게 분포 되어있지 않고 하나의 값에 치우쳐서 편향된 모델을 학습하는 문제를 의미한다[6].

또한, 8가지 결합 패턴 간의 데이터 불균형이 존재함에 따라 데이터 증강이 고려되어야 하지만 데이터 증강이 고려되지 않는 상황에서 소수 클래스의 일반적인 성능 비교를 하고자 원본 데이터만을 사용하였다. 라벨이 표기된 모든 웨이퍼 빈 맵의 크기를 모델 훈련 전에 (224, 224, 3)으로 맞춰주고 전체 데이터를 Train:Test=7:3으로 분리하여 사용하였다. Train에 사용한 데이터의 경우에는 4-Fold 교차검증을 이용하여 검증하였다. 실험에 사용한 전체 데이터의 개수는 Table 2와 같다.

Table 2. Number of data used in the experiment.

Pattern	# of Train	# of Test	Total
Center	3,005	1,289	4,294
Donut	388	167	555
Edge-Loc	3,632	1,557	5,189
Edge-Ring	6,776	2,904	9,680
Loc	2,515	1,078	3,593
Random	606	260	866
Scratch	835	358	1,193
Near-Full	104	45	149
Total	17,861	7,658	25,519

본 연구에서는 모델 분류 성능을 비교하기 위하여 전이학습에 자주 이용되는 ResNet50[7]과 DenseNet121[8] 모델을 이용한 실험 1과 MobileNet[9,10], EfficientNet [11], ShuffleNet[12] 기반의 경량화 모델을 이용한 실험 2를 진행하였다. 실험 1을 통하여 데이터 증강 없이 일반적으로 이미지 분류에 널리 사용되는 모델을 이용하여 성능을 확인해보았다. 다음으로, 실험 2를 통하여 데이터 증강 및 고성능 하드웨어 없이 모바일 기기나 엣지 디바이스를 이용한 경량화 모델로 일정 수준 이상의 성능 도출이 가능한지 확인해보았다. 두 실험 모두 기계학습과 심층 학습에서 사용되는 모델 훈련 기법인 전이학습(Transfer Learning)을 기반으로 진행되었다[13]. 본 연구와 같은 소규모의 데이터를 이용하는 경우, 대규모 데이터를 이용하여 사전에 학습된 모델의 지식을 이용하는 전이학습은 데이터 의존성과 과적합의 가능성을 감소시킬 수 있는 장점을 가지고 있다.

3. 실험

3.1 실험 환경

본 연구는 파이썬 3.7.16을 기반으로 전처리를 진행하였고, 파이토치 1.12.0 환경을 기반으로 실험을 진행하였다. 실험 환경은 Table 3과 같다. 모델의 훈련 과정에서 사용한 초매개변수로 손실함수는 Cross-Entropy를, 최적기는 AdamW를 사용하였다. 모델 테스트 시에는 훈련된 모델을 가져온 다음 50번 평가하여 결괏값을 중앙값으로 나타내주었다.

Table 3. Experimental environment.

Server	Ubuntu 18.04.6 LTS
CPU	Intel(R) Xeon(R) CPU E5-2698 v4 @ 2.20GHz
GPU	GV100GL [Tesla V100 DGXS 32GB]

3.2 평가 지표

ResNet50 모델과 DenseNet121 모델을 기반으로 진행한 실험 1의 성능 지표로는 각 패턴의 정확도와 8가지 결함 패턴에 대한 평균 민감도와 평균 특이도를 사용하였다. 민감도는 모델의 성능을 평가하는 지표 중 하나로, 실제 양성인 샘플을 모델이 얼마나 정확하게 양성으로 분류하는지를 측정한다. 특이도 역시 모델의 성능을 평가하는 지표 중 하나로, 실제 음성인 샘플을 모델이 얼마나 정확하게 음성으로 분류하는지를 나타낸다. 본 논문과 같은 다중 클래스 분류 문제에서 민감도와 특이도는 다른 패턴에 비해 특정 패턴을 얼마나 잘 검출할 수 있는지를 판단하기 위하여 사용된다.

MobileNet, EfficientNet, ShuffleNet 기반의 경량화 모델을 이용한 실험 2에서는 실험 1에서 사용한 성능 지표와 더불어 소프트웨어 측면에서의 성능 지표인 모델의 파라미터 개수와 하드웨어 측면의 성능 지표인 FLOPS(Floating point Operations Per Second)를 함께 고려하였다. FLOPS는 하드웨어가 1초당 처리할 수 있는 연산량을 나타낸다.

3.3 실험 결과 및 패턴 분류 정확도

실험 1의 성능 결과는 Table 4와 같다. Table 4를 보면, ResNet50 모델과 DenseNet121 모델이 데이터 증강을 이용하지 않았음에도 일정 수준 이상의 성능에 도달한 것을 확인할 수 있었다. 한편, 기존 연구에 의하면 데이터 클래스 불균형이 심한 경우에는 정확도와 F1-score 간의 차이가 크게 두드러질 수 있다[6]. 본 연구에서는 정확도와 F1-score가 비슷하게 나온 것으로 보아 실험 시 클래스 간의 불균형이 잘 고려되었음을 확인할 수 있다.

경량화 모델로는 MobileNet, EfficientNet, ShuffleNet 기반의 모델을 이용하였는데 각 모델에 대한 파라미터 수와 FLOPs는 Table 5와 같다. 실험 1에서 사용한 DenseNet121 모델의 경우 Dense Block을 이용하여 기존의 ResNet 기반의 모델에 비해서 파라미터 수를 줄인 것이 장점이다. 그러나, 실질적으로 하드웨어 상에서

의 연산량을 결정하는 FLOPS는 실험 2에서 사용한 경량화 모델에 비해서 상당히 많다. ResNet50 모델의 경우, 경량화 모델의 최소 6.96배에서 최대 99배의 연산량을 가진다. DenseNet121 모델의 경우, 경량화 모델의 최소 4.85배, 최대 69배의 연산량을 가진다. 7가지 경량화 모델을 이용한 웨이퍼 빈 맵 분류 결과는 Table 6과 같다. 실험 2의 경우에도 실험 1의 모델과 동일하게 정확도와 F1-score가 비슷한 결과로 나타나 클래스 간의 불균형을 잘 고려되었음을 알 수 있다. 또한, 7가지의 경량화 모델 모두 정확도가 90% 이상 도달하며 일반 모델에 비하여 성능 감소가 지나치게 일어나지는 않음을 확인할 수 있었다. 이로써 웨이퍼 빈 맵 결함 패턴 검출을 위해 현업에서 고성능 하드웨어 없이, 옛지 디바이스에 경량화 모델을 탑재하여 사용할 수 있는 가능성을 확인하였다. 경량화 모델들 간의 효율성을 따져보면 MobileNetV2 모델과 EfficientNet-B0 모델이 가장 성능이 좋았다. Table 5를 기반으로 연산량과 파라미터 수까지 고려하면, MobileNetV2 모델이 EfficientNet-B0 모델보다 FLOPS와 파라미터가 모두 적으므로, 본 연구에서 가장 효율성이 좋은 경량화 모델은 MobileNetV2 모델로 확인되었다.

다음은, 혼동 행렬을 이용하여 각 모델의 패턴별 분류 정확도를 확인해보았다. 실험 1과 실험 2에서 사용한 모델들의 각 패턴에 대한 분류 정확도는 Table 7과 같다. 클래스별로 분류 결과를 0과 1 사이의 값으로 정규화하여 나타내었다. 그 결과, Donut, Loc, Scratch 패턴에 대해서 9가지 모델의 평균 분류 정확도가 90% 이상을 도달하지 못하였다. 이 3가지 패턴에 대하여 특히 ShuffleNet 기반의 모델의 경우 가장 분류 정확도가 낮

Table 4. The Results of the experiment 1.

Model	Accuracy [%]	Mean Sensitivity	Mean Specificity	F1-score
ResNet 50	94.2086	0.9110	0.9220	0.9421
Dense Net121	94.8151	0.9150	0.9348	0.9480

Table 5. Parameters and FLOPS of experiment 2.

Class	Model	MFLOPS	# of Parameters
Light weight	MobileNetV2	312.9234	2,234,120
	MobileNetV3-small	58.6337	1,526,056
	MobileNetV3-large	224.7641	4,212,280
	EfficientNet-B0	400.39	4,017,796
	EfficientNet-B1	590.6491	6,523,432
	ShuffleNet-V2_x0_5	41.5085	349,992
	ShuffleNet-V2_x1_0	147.7926	1,261,804
Reference	ResNet50	4109.481	23,524,424
	DenseNet121	2864.531	6,962,056

Table 6. The accuracy, mean sensitivity, mean specificity and f1-score results of experiment 2.

Model	Accuracy	Mean Sensitivity	Mean Specificity	F1-score
MobileNetV2	94.7760	0.9212	0.9309	0.9478
MobileNetV3-small	92.9172	0.8916	0.8931	0.9284
MobileNetV3-large	94.1500	0.9110	0.9233	0.9417
EfficientNet-B0	94.7760	0.9208	0.9324	0.9478
EfficientNet-B1	94.2673	0.9123	0.9292	0.9425
ShuffleNet-V2_x0_5	91.5868	0.8728	0.8777	0.9156
ShuffleNet-V2_x1_0	91.7042	0.8674	0.8939	0.9168

Table 7. The accuracy of each pattern classification across all models (experiments 1 and 2).

	Center	Donut	Edge-Loc	Edge-Ring	Loc	Random	Scratch	Near-Full
ResNet50	0.974	0.820	0.936	0.979	0.865	0.908	0.871	0.935
DenseNet121	0.974	0.847	0.928	0.989	0.883	0.908	0.887	0.903
MobileNetV2	0.971	0.874	0.933	0.986	0.872	0.931	0.900	0.903
MobileNetV3-small	0.983	0.739	0.936	0.977	0.794	0.920	0.817	0.968
MobileNetV3-large	0.963	0.874	0.920	0.985	0.878	0.891	0.875	0.903
EfficientNet-B0	0.976	0.883	0.919	0.987	0.887	0.920	0.892	0.903
EfficientNet-B1	0.983	0.874	0.929	0.983	0.850	0.885	0.892	0.903
ShuffleNet-V2_x0_5	0.965	0.766	0.888	0.982	0.801	0.902	0.742	0.935
ShuffleNet-V2_x1_0	0.964	0.748	0.874	0.984	0.838	0.908	0.721	0.903
Mean	0.9725	0.825	0.9181	0.9835	0.852	0.9081	0.8441	0.9173

았다. 그러나, EfficientNet 기반 모델의 경우 경량화 모델임에도 불구하고 ResNet50 모델과 DenseNet121 모델보다 이 3가지 패턴을 대부분 잘 분류하였다. 그러므로 EfficientNet 기반 모델의 아키텍처를 이용하면 가볍지만 웨이퍼 빈 맵 결함 패턴 분류에 더 강건한 모델을 설계할 수 있을 것이다.

4. 결론

본 논문에서는 WM-811k 데이터를 활용하여 웨이퍼 빈 맵의 결함 패턴 분류에 대한 연구를 수행하였다. 먼저, 데이터의 클래스 간 불균형 문제를 파악하고, 이를 해결하기 위하여 데이터 증강 없이도 일정 수준 이상의 성능을 달성할 수 있는 모델을 실험을 통해 입증하였다.

또한, 소수 클래스 데이터의 분류 정확도가 데이터 개수에 비례하지 않음을 확인하고, 경량화 모델을 이용하여 효율적인 모델을 제안하였다. 실험 결과를 통해, 데이터 증강 없이도 일반적인 모델을 사용하여 웨이퍼 빈 맵의 결함 패턴을 분류할 수 있음을 확인하였으며, 이는 실제 현업에서 데이터 증강에 대한 의존성을 줄여줄 뿐만 아니라, 데이터 신뢰성의 측면에서도 긍정적인 영향을 미칠 것으로 기대된다.

또한, 클래스 간의 불균형을 고려하여 소수 클래스 데이터에 대한 분류 성능을 개선하는 방법을 모색하였다. 경량화 모델을 이용하여 하드웨어와 소프트웨어 측면에서의 성능을 모두 고려했을 때, 효율적인 모델을 도출할 수 있었다.

본 연구는 반도체 산업에서의 인공지능 활용에 대한 새로운 가능성을 제시하였으며, 향후 연구로는 라벨링

된 데이터가 현저히 부족한 현업의 상황을 반영하여 라벨링이 되어 있는 데이터와 되어 있지 않은 데이터를 함께 고려할 수 있는 반지도 학습을 이용한 웨이퍼 빈 맵의 결함 패턴 분류에 대한 연구를 진행할 예정이다.

References

- [1] C. H. Jin, et al., "A Novel DBSCAN-Based Defect Pattern Detection and Classification Framework for Wafer Bin Map", *IEEE Transactions Semiconductor Manufacturing*, Vol.32, No.3, pp.286-292, 2019. DOI: <https://doi.org/10.1109/TSM.2019.2916835>
- [2] M. Wu, J.-S. R. Jang, and J.-L. Chen, "Wafer Map Failure Pattern Recognition and Similarity Ranking for Large-Scale Data Sets", *IEEE Transactions Semiconductor Manufacturing*, Vol.28, No.1, pp.1-12, 2015. DOI: <https://doi.org/10.1109/TSM.2014.2364237>
- [3] K. B. Lee, S. Chen, and C. O. Kim, "A Convolutional Neural Network for Fault Classification and Diagnosis in Semiconductor Manufacturing Processes", *IEEE Transactions Semiconductor Manufacturing*, Vol.30, No.2, pp.135-142, 2017. DOI: <https://doi.org/10.1109/TSM.2017.2676245>
- [4] Y. S. Ji, and J. Lee, "Using GAN to Improve CNN Performance of Wafer Map Defect Type Classification: Yield Enhancement", *2020 31st Annual SEMI Advanced Semiconductor Manufacturing Conference (ASMC)*, pp.1-6, 2020. DOI: <https://doi.org/10.1109/ASMC49169.2020.9185193>
- [5] E. M. Shin, and C. D. Yoo, "Efficient Convolutional Neural Networks for Semiconductor Wafer Bin Map Classification", *Sensors*, Vol.23, 2023. DOI: <https://doi.org/10.3390/s23041926>
- [6] G. Haixiang, et al., "Learning from Class-Imbalanced Data: Review of Methods and Applications", *Expert Systems with Applications*, Vol.73, pp.220-239, 2017. DOI: <https://doi.org/10.1016/j.eswa.2016.12.035>
- [7] 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*, pp.770-778, 2016. DOI: <https://doi.org/10.48550/arXiv.1512.03385>
- [8] G. Huang, Z. Liu, L. Van Der Maaten and K. Weinberger, "Densely Connected Convolutional Networks", *In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp.4700-4708, 2017. DOI: <https://doi.org/10.48550/arXiv.1608.06993>
- [9] M. Sandler, et al., "MobileNetV2: Inverted Residuals and Linear Bottlenecks", *In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2018. DOI: <https://doi.org/10.48550/arXiv.1801.04381>
- [10] A. Howard, et al., "Searching for MobileNetV3", *In Proceedings of the IEEE/CVF International Conference on Computer Vision*, 2019. DOI: <https://doi.org/10.48550/arXiv.1905.02244>
- [11] M. Tan, and Q. V. Le., "EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks", *International Conference on Machine Learning*, PMLR, 2019. DOI: <https://doi.org/10.48550/arXiv.1905.11946>
- [12] X. Zhang, X. Zhou, M. Lin and J. Sun, "ShuffleNet: An Extremely Efficient Convolutional Neural Network for Mobile Devices", *In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2018. DOI: <https://doi.org/10.48550/arXiv.1707.01083>
- [13] W. Karl, T. M. Khoshgoftaar, and D. Wang., "A Survey of Transfer Learning", *Journal of Big Data*, Vol.3, pp.1-40, 2016. DOI: <https://doi.org/10.1186/s40537-016-0043-6>

박 인 영(Inyoung Park)

[준회원]



- 2022년 2월 : 경북대학교 전자공학부 (심화전자공학사)
- 2022년 3월 ~ 현재 : 경북대학교 데이터사이언스대학원 석사과정

<관심분야>

인공지능, 컴퓨터 비전, 반도체 공학 등

김 지 영(Jeeyoung Kim)

[정회원]



- 2006년 5월 : 미국 펜실베이니아 대학교 컴퓨터공학과 (석사)
- 2013년 8월 : 미국 플로리다대학교 컴퓨터공학과 (박사)
- 2013년 10월 ~ 2018년 7월 : 삼성전자 무선사업부 Senior Professional
- 2018년 8월 ~ 2022년 8월 : 경북대학교 초빙교원
- 2022년 9월 ~ 현재 : 경북대학교 데이터사이언스대학원 조교수

<관심분야>

인간중심의 데이터과학, 기계 학습, 심층 학습 등