



(19) 대한민국특허청(KR)
(12) 공개특허공보(A)

(11) 공개번호 10-2024-0109576
(43) 공개일자 2024년07월11일

- | | |
|---|---|
| <p>(51) 국제특허분류(Int. Cl.)
G06T 7/00 (2017.01) G06F 18/24 (2023.01)
G06V 10/762 (2022.01) G06V 10/764 (2022.01)
H01L 21/66 (2006.01)</p> <p>(52) CPC특허분류
G06T 7/001 (2013.01)
G06F 18/24 (2023.01)</p> <p>(21) 출원번호 10-2023-0170803
(22) 출원일자 2023년11월30일
심사청구일자 2023년11월30일</p> <p>(30) 우선권주장
1020230000910 2023년01월03일 대한민국(KR)</p> | <p>(71) 출원인
고려대학교 산학협력단
서울특별시 성북구 안암로 145, 고려대학교 (안암동5가)</p> <p>(72) 발명자
정주원
경기도 성남시 분당구 수내로 192번길 25
정윤서
서울특별시 강남구 광평로5길 3, B101 (일원동)</p> <p>(74) 대리인
김동용</p> |
|---|---|


전체 청구항 수 : 총 8 항

(54) 발명의 명칭 계층적 군집 분석을 이용한 반도체 웨이퍼의 패턴 탐지 장치 및 방법

(57) 요약

계층적 군집 분석(Hierarchical Clustering, HC)을 이용한 반도체 웨이퍼 패턴 탐지 및 분류 방법이 개시된다. 상기 반도체 웨이퍼 패턴 탐지 및 분류 방법은 적어도 프로세서(Processor)를 포함하는 컴퓨팅 장치에 의해 수행되고, 원시 데이터를 획득하는 단계, 타겟 반도체 웨이퍼의 결함 패턴을 탐지하는 단계, 및 상기 타겟 반도체 웨이퍼의 결함 패턴을 분류하는 단계를 포함하고, 상기 결함 패턴을 탐지하는 단계는, 상기 계층적 군집 분석(HC)을 통해 제1 조율 모수(tuning parameter)를 만족하지 못하는 군집을 제거하는 단계, 및 상기 제1 조율 모수를 만족하는 군집이 존재하지 않는 경우, 상기 타겟 반도체 웨이퍼를 정상으로 판단하는 단계를 포함한다. 패턴 분류하는 단계는 앞서 불량으로 식별된 웨이퍼를 제2 조율 모수를 만족하는 단일 패턴들로 분리하고 특징 추출하여 지도학습을 통해 분류하는 단계를 포함한다.

대표도 - 도2



(52) CPC특허분류

H01L 22/20 (2013.01)

G06T 2207/30148 (2013.01)

이 발명을 지원한 국가연구개발사업

과제고유번호	1711136202
과제번호	2021R1F1A1062347
부처명	과학기술정보통신부
과제관리(전문)기관명	한국연구재단
연구사업명	개인기초연구(과기정통부)(R&D)
연구과제명	이분산성 존재시 분위수 회귀의 모형 선택 방법론
기 여 율	1/1
과제수행기관명	고려대학교
연구기간	2021.06.01 ~ 2022.05.31

명세서

청구범위

청구항 1

적어도 프로세서(Processor)를 포함하는 컴퓨팅 장치에 의해 수행되는, 계층적 군집 분석(Hierarchical Clustering, HC)을 이용한 반도체 웨이퍼 패턴 탐지 및 분류 방법에 있어서,

원시 데이터를 획득하는 단계;

타겟 반도체 웨이퍼의 결함 패턴을 탐지하는 단계; 및

상기 타겟 반도체 웨이퍼의 결함 패턴을 분류하는 단계를 포함하고,

상기 결함 패턴을 탐지하는 단계는,

상기 계층적 군집 분석(HC)을 통해 제1 조율 모수(tuning parameter)를 만족하지 못하는 군집을 제거하는 단계; 및

상기 제1 조율 모수를 만족하는 군집이 존재하지 않는 경우, 상기 타겟 반도체 웨이퍼를 정상으로 판단하는 단계를 포함하는,

반도체 웨이퍼 패턴 탐지 및 분류 방법.

청구항 2

제1항에 있어서

상기 제1 조율 모수는 군집간 제1 최소 허용 거리를 의미하는 제1 높이(height) 및 군집 내 제1 최소 개체수(minPts)를 포함하는,

반도체 웨이퍼 패턴 탐지 및 분류 방법.

청구항 3

제1항에 있어서,

상기 계층적 군집 분석(HC)은 최단 연결법(single linkage) 및 민코우스키(Minkowski) 거리를 이용하는,

반도체 웨이퍼 패턴 탐지 및 분류 방법.

청구항 4

제1항에 있어서,

상기 결함 패턴을 분류하는 단계는,

상기 계층적 군집 분석(HC)을 통해 제2 조율 모수를 만족하지 못하는 군집을 제거하고 상기 제2 조율 모수를 통해 군집이 의미 있는 개별 패턴으로 분리되는 단계;

상기 제2 조율 모수를 만족하는 군집에 대한 특징을 추출하는 단계; 및

상기 특징에 기초하여, 사전 학습된 랜덤 포레스트 모델을 이용하여 상기 결함 패턴을 분류하는 단계를 포함하는,

반도체 웨이퍼 패턴 탐지 및 분류 방법.

청구항 5

제4항에 있어서,

상기 제2 조율 모수는 제2 최소 허용 거리를 의미하는 제2 높이(height) 및 군집 내 제2 최소 개체수(minPts)를

포함하는,

반도체 웨이퍼 패턴 탐지 및 분류 방법.

청구항 6

제2항 또는 제5항에 있어서,

상기 원시 데이터는 동일 크기의 웨이퍼 빈 맵(Wafer Bin Map, WBM)들이고,

상기 제1 조율 모수와 상기 제2 조율 모수는 상기 원시 데이터의 적어도 일부를 이용한 그리드 서치(grid search)를 통해 결정되는,

반도체 웨이퍼 패턴 탐지 및 분류 방법.

청구항 7

제6항에 있어서,

상기 제2 조율 모수는 상기 원시 데이터 중 비정상 데이터의 적어도 일부를 이용하여 결정되는,

반도체 웨이퍼 패턴 탐지 및 분류 방법.

청구항 8

제6항에 있어서,

상기 제1 조율 모수는 F1 스코어(F1 score), 정확도(accuracy), 재현율(recall), 및 정밀도(precision) 순으로 평가 지표를 이용하고,

상기 제2 조율 모수는 패턴 분리, 특징 추출, 분류 분석을 모두 수행한 후의 분류 성능인 F1 macro, Recall macro, Kappa 순으로 평가 지표를 이용하는,

반도체 웨이퍼 패턴 탐지 및 분류 방법.

발명의 설명

기술 분야

[0001] 본 발명은 기계 학습(Machine Learning)을 이용하여 반도체 웨이퍼의 불량률 탐지 및 분류하는 기법에 관한 것으로, 보다 상세하게는 계층적 군집 분석을 이용하여 반도체 웨이퍼에 대한 불량률 탐지 및 분류하기 위한 장치 및 방법에 관한 것이다.

배경 기술

[0002] 반도체 제조 공정은 회로를 구성하기 위해 다수의 화학 공정을 포함하며, 수백에서 수만 개의 반도체 칩을 구성할 수 있는 원형의 웨이퍼 단위로 이루어 진다. 복잡하고 긴 다단계의 화학 공정을 이루는 반도체 제작에서 얼마나 많은 정상 칩을 최종적으로 생산하는 지 여부, 즉 수율이 반도체 제조에 매우 중요한 요소이다. 그러므로, 조기에 결함을 탐지하고 결함의 유형 분류를 통해 원인 파악 및 조치할 수 있다면 공정의 결함으로 인한 수율 저하를 최소화할 수 있다.

[0003] 결함의 탐지와 분류는 반도체 각 공정 단계 처리 직후의 품질 테스트 결과를 활용한다. 결과는 원형의 웨이퍼 상의 각 칩의 위치에 결함과 정상의 형태로 표시되며, 이 결과를 웨이퍼 빈 맵(Wafer Bin Map; WBM)이라 부른다. 공간적인 결함 패턴은 육안으로 확인할 수 있으며, 이를 통해 결함 여부와 유형을 알 수 있어 공정상의 원인을 유추할 수 있다.

[0004] 도 1은 웨이퍼 상의 결함 패턴의 예시이며, 각각 중심 결함(center), 도넛 결함(donut), 지역 결함(local), 주변 지역 결함(edge local), 주변 원형 결함(edge ring), 임의 결함(random), 긁힘 결함(scratch) 등을 나타낸다.

[0005] 기존 연구에서 웨이퍼 결함 탐지를 위해 가장 많이 사용되는 방법은 디노이징(de-noising, 소음 처리)과 같은 공간 필터(spatial filtering)와 공간 임의성 검정(spatial randomness test)이다.

- [0006] 공간 필터는 이미지 처리의 방법으로서 평활화(smoothing)를 통해 노이즈를 제거한다. 2차원 공간상 점 주변에 위치한 결함의 수에 가중합을 주어 계산된 평균(average) 혹은 중위수(median)에 대하여 체계적인 패턴과 그렇지 않은 패턴을 구분하는 임계치(threshold)를 구하여 탐지하는 방식이며, 대개의 경우 좋은 성능을 보인다. 그러나, 얇고 긴 직선 혹은 둥근 선 등 스크래치 형태의 패턴이 노이즈가 많은 웨이퍼 안에 있을 경우, 체계적인 패턴(Systematic Pattern)을 탐지하지 못하는 한계를 가지고 있다. 주로 평균 필터(average filter)와 중앙값 필터(median filter)가 흔히 사용된다.
- [0007] 다른 방법으로는 공간 임의성 검정이 있다. 공간 필터와 유사하게 주변의 점의 수(joint-count statistics)를 세어 그것의 로그 오즈비(Log Odds Ratio) 혹은 카이스퀘어 통계량(Chi-Square Statistic)을 활용하여 가설을 검정하는 방식이다.
- [0008] 일단 웨이퍼에 결함이 있는 것으로 판정되면, 공정의 근본 원인을 찾기 위한 결함 패턴 분류가 필요하다. 지도 학습의 경우 소음 처리(de-noising)에서 분류 분석(classification)까지의 과정에 해당한다. 체계적인 결함이 존재하는 것으로 판정된 것에 대해, (1) 웨이퍼의 체계적인 결함 패턴만을 남기도록 소음을 제거하고, (2) 하나의 웨이퍼에 여러 개의 결함 패턴이 있을 경우 각각을 단일 패턴으로 분리하고, (3) 각 결함 패턴의 특징을 추출하여, (4) 지도 학습을 통해 패턴을 분류 한다. 이렇게 분류된 패턴을 이용하여 제작 공정에서의 결함 원인을 찾을 수 있다.
- [0009] 비지도 학습을 이용한 경우, 소음 제거 후 웨이퍼 내 유사 패턴을 가진 웨이퍼끼리 군집하는 형태로 결함의 유형을 알 수 있다. 지도 학습과 달리 결함 패턴이 알려지지 않은 패턴에 대해서도 유형화할 수 있는 장점이 있다.
- [0010] 본 발명에서는 클러스터 수 계산의 부담이 적은 계층적 군집 분석(Hierarchical Clustering, HC)을 통해, 첫째 웨이퍼의 결함을 탐지하고, 둘째 결함의 분리를 통해 얻은 특징들을 변수 선택이 필요치 않은 분류기인 랜덤 포레스트(Random Forest)와 결합하여 유형 분류를 시도한다. 이를 통해 공정상 문제의 원인을 조기에 식별하고 조치할 수 있다.

선행기술문헌

비특허문헌

- [0011] (비특허문헌 0001) Wu MJ, Jang JSR, and Chen JL (2015). Wafer map failure pattern recognition and similarity ranking for large-scale data sets. IEEE Transactions on Semiconductor Manufacturing, 28(1), 1-12.
- (비특허문헌 0002) Jin C, Na H, Piao M, Pok G, and Ryu K (2019). A novel dbscan-based defect pattern detection and classification framework for wafer bin map. IEEE Transactions on Semiconductor Manufacturing, 32(3), 286-292.
- (비특허문헌 0003) Alawieh M, Wang F, and Li X (2016). Identifying systematic spatial failure patterns through wafer clustering. Volume 2016-July, pages 910-913.
- (비특허문헌 0004) Everitt, B. and Hothorn, T. (2011). An introduction to applied multivariate analysis with R. Springer Science & Business Media.

발명의 내용

해결하려는 과제

- [0012] 본 발명이 이루고자 하는 기술적인 과제는, 계층적 군집 분석(Hierarchical clustering, HC)을 이용한 반도체 웨이퍼 패턴 탐지 및/또는 분류를 위한 장치 및 방법을 제공하는 것이다.

과제의 해결 수단

- [0013] 본 발명의 일 실시예에 따른, 계층적 군집 분석(Hierarchical Clustering, HC)을 이용한 반도체 웨이퍼 패턴 탐지 및 분류 방법은 적어도 프로세서(Processor)를 포함하는 컴퓨팅 장치에 의해 수행되고, 원시 데이터를 획득

하는 단계, 타겟 반도체 웨이퍼의 결함 패턴을 탐지하는 단계, 및 상기 타겟 반도체 웨이퍼의 결함 패턴을 분류하는 단계를 포함하고, 상기 결함 패턴을 탐지하는 단계는, 상기 계층적 군집 분석(HC)을 통해 제1 조율 모수(tuning parameter)를 만족하지 못하는 군집을 제거하는 단계, 및 상기 제1 조율 모수를 만족하는 군집이 존재하지 않는 경우, 상기 타겟 반도체 웨이퍼를 정상으로 판단하는 단계를 포함한다.

발명의 효과

[0014] 본 발명의 실시예에 따른 반도체 웨이퍼 패턴 탐지 및/또는 분류를 위한 장치 및 방법에 의할 경우, 많은 양의 자료를 보다 빠르고 정확하게 탐지 및/또는 분류할 수 있는 효과가 있다.

[0015] 특히, 패턴 탐지의 경우 소수의(예컨대, 패턴별 5 개 이하) 불량 표본만 확보해도 충분한(예컨대, 100여 장 내외) 정상 표본이 있다면 불량 탐지를 자동화할 수 있는 장점이 있으며 신규 패턴이 발생될 때에도 불량 패턴을 탐지할 수 있는 장점이 있다.

도면의 간단한 설명

[0016] 본 발명의 상세한 설명에서 인용되는 도면을 보다 충분히 이해하기 위하여 각 도면의 상세한 설명이 제공된다.

도 1은 웨이퍼 상의 결함 패턴의 예시를 도시하며, 각각 중심 결함(center), 도넛 결함(donut), 지역 결함(local), 주변 지역 결함(edge local), 주변 원형 결함(edge ring), 임의 결함(random), 긁힘 결함(scratch), 및 무결함(none)을 나타낸다.

도 2는 본 발명에서 제시하는 방법에 대한 대략적인 흐름도를 도시한다.

도 3은 본 발명의 일 실시예에 따른, 계층적 군집 분석을 이용한 반도체 웨이퍼의 패턴 탐지 방법을 설명하기 위한 흐름도이다.

발명을 실시하기 위한 구체적인 내용

[0017] 본 명세서에 개시되어 있는 본 발명의 개념에 따른 실시예들에 대해서 특정한 구조적 또는 기능적 설명들은 단지 본 발명의 개념에 따른 실시예들을 설명하기 위한 목적으로 예시된 것으로서, 본 발명의 개념에 따른 실시예들은 다양한 형태들로 실시될 수 있으며 본 명세서에 설명된 실시예들에 한정되지 않는다.

[0018] 본 발명의 개념에 따른 실시예들은 다양한 변경들을 가할 수 있고 여러 가지 형태들을 가질 수 있으므로 실시예들을 도면에 예시하고 본 명세서에서 상세하게 설명하고자 한다. 그러나, 이는 본 발명의 개념에 따른 실시예들을 특정한 개시 형태들에 대해 한정하려는 것이 아니며, 본 발명의 사상 및 기술 범위에 포함되는 모든 변경, 균등물, 또는 대체물을 포함한다.

[0019] 제1 또는 제2 등의 용어는 다양한 구성 요소들을 설명하는데 사용될 수 있지만, 상기 구성 요소들은 상기 용어들에 의해 한정되어서는 안 된다. 상기 용어들은 하나의 구성 요소를 다른 구성 요소로부터 구별하는 목적으로만, 예컨대 본 발명의 개념에 따른 권리 범위로부터 벗어나지 않은 채, 제1 구성 요소는 제2 구성 요소로 명명될 수 있고 유사하게 제2 구성 요소는 제1 구성 요소로도 명명될 수 있다.

[0020] 어떤 구성 요소가 다른 구성 요소에 "연결되어" 있다거나 "접속되어" 있다고 언급된 때에는, 그 다른 구성 요소에 직접적으로 연결되어 있거나 또는 접속되어 있을 수도 있지만, 중간에 다른 구성 요소가 존재할 수도 있다고 이해되어야 할 것이다. 반면에, 어떤 구성 요소가 다른 구성 요소에 "직접 연결되어" 있다거나 "직접 접속되어" 있다고 언급된 때에는 중간에 다른 구성 요소가 존재하지 않는 것으로 이해되어야 할 것이다. 구성 요소들 간의 관계를 설명하는 다른 표현들, 즉 "~사이에"와 "바로 ~사이에" 또는 "~에 이웃하는"과 "~에 직접 이웃하는" 등도 마찬가지로 해석되어야 한다.

[0021] 본 명세서에서 사용한 용어는 단지 특정한 실시예를 설명하기 위해 사용된 것으로서, 본 발명을 한정하려는 의도가 아니다. 단수의 표현은 문맥상 명백하게 다르게 뜻하지 않는 한, 복수의 표현을 포함한다. 본 명세서에서, "포함하다" 또는 "가지다" 등의 용어는 본 명세서에 기재된 특징, 숫자, 단계, 동작, 구성 요소, 부분품 또는 이들을 조합한 것이 존재함을 지정하려는 것이지, 하나 또는 그 이상의 다른 특징들이나 숫자, 단계, 동작, 구성 요소, 부분품 또는 이들을 조합한 것들의 존재 또는 부가 가능성을 미리 배제하지 않는 것으로 이해되어야 한다.

[0022] 다르게 정의되지 않는 한, 기술적이거나 과학적인 용어를 포함해서 여기서 사용되는 모든 용어들은 본 발명이

속하는 기술 분야에서 통상의 지식을 가진 자에 의해 일반적으로 이해되는 것과 동일한 의미를 가진다. 일반적으로 사용되는 사전에 정의되어 있는 것과 같은 용어들은 관련 기술의 문맥상 가지는 의미와 일치하는 의미를 갖는 것으로 해석되어야 하며, 본 명세서에서 명백하게 정의하지 않는 한, 이상적이거나 과도하게 형식적인 의미로 해석되지 않는다.

[0023] 이하, 본 명세서에 첨부된 도면들을 참조하여 본 발명의 실시예들을 상세히 설명한다. 그러나, 특허출원의 범위가 이러한 실시예들에 의해 제한되거나 한정되는 것은 아니다. 각 도면에 제시된 동일한 참조 부호는 동일한 부재를 나타낸다.

[0024] 이하에서는, 본도체 웨이퍼 데이터(WM-811K)에 대해 소개한다.

[0025] 실험에 사용되는 데이터는 대만 반도체 회사에서 공개한 실제 데이터(WM-811K) (Wu MJ, Jang JSR, and Chen JL (2015). Wafer map failure pattern recognition and similarity ranking for large-scale data sets. IEEE Transactions on Semiconductor Manufacturing, 28(1), 1-12.)로서, 총 811,457 개의 웨이퍼 빈 맵(Wafer Bin Map; WBM)이 있으며 이 중 172,950 개의 웨이퍼 빈 맵(WBM)에 정상 여부 혹은 결함 패턴의 이름이 각 웨이퍼 별 하나씩 기입되어 있다. 원형의 웨이퍼 안에는 하나의 반도체 칩이 되는 공간인 다이(die)가 격자로 구분되어 있으며, 웨이퍼 빈 맵(WBM)은 웨이퍼와 다이 사이즈별로 구분할 수 있다. 웨이퍼들의 사이즈는 다양하며 동일 사이즈에는 수백에서 수천 장의 웨이퍼들이 포함되어 있다.

[0026] 하나의 웨이퍼에는 각 다이별로 다수 관측치의 테스트 결과가 이산형으로 표기되어 있다. 관측치의 수는 웨이퍼 당 45 개에서부터 2만 8천여 개로, 평균 2천 개 정도이다. 반도체 제작은 여러 단계의 공정을 거치는데 각 공정을 거칠 때마다 테스트가 이루어 진다. 웨이퍼 상의 지리적 공간에 관측치들의 테스트 결과가 일정한 체계적인 패턴을 나타내면 결함 패턴이라 할 수 있다.

[0027] 데이터에 포함된 웨이퍼의 결함 패턴은, 도 1에서 볼 수 있듯이, 중심 결함(center), 도넛 결함(donut), 지역 결함(local), 주변 지역 결함(edge local), 주변 원형 결함(edge ring), 임의 결함(random), 긁힘 결함(scratch) 등이며, 각 결함 패턴에 따라 원인 공정이 다르다. 예를 들어, 중심부의 원형 패턴인 중심 결함(center)은 화학 기계적 평탄화(Chemical-Mechanical Planarization) 중 발생한 균일성 변화에 의한다. 웨이퍼 가장자리의 둥근 패턴인 주변 원형 결함(edge ring)은 에칭(etching) 문제 혹은 스토리지 노드(storage node) 프로세스에서 층(layer)간 부정합으로 인해 발생하며 결과적으로 더 작아진 콘택트 홀(contact hole)들로 인해 쓰기 리커버리 타임(write recovery time) 실패가 발생하기 때문에 발생한다. 긁힘 결함(scratch)은 부적절한 운반 혹은 응집된 파티클에 의해 발생하며 주로 화학 기계적 평탄화 공정 중 패드가 경화되어 발생한다. 웨이퍼 특정 구역의 결함 패턴인 지역 결함(local)은 균일성 변화 혹은 고르지 않은 세척 작업에 의해 주로 발생한다. 웨이퍼 가장자리의 특정 구역에서의 결함 패턴인 주변 지역 결함(edge local)은 보통 박막 증착 과정에서 발생할 수 있다.

[0028] WM-811K 데이터에는 여러 크기의 웨이퍼와 다이 사이즈가 있으므로 이 중 동일 크기의 웨이퍼와 다이이면서 결함 패턴이 고르게 있고 정상 웨이퍼가 상당량 포함된 다이 크기를 선택할 수 있다. 1376 다이 크기 중 44×41 웨이퍼 크기를 대상으로 하며, 샘플이 적은 패턴(예컨대, 샘플이 1개에 불과한 near full 패턴)은 제외할 수 있다. 선택된 데이터에는 6,133 개의 웨이퍼가 있으며, 이 중 정상은 90.23% 이다. 본 발명에서 분석에 사용한 결함 패턴별 비율은 표 1에 표시되어 있다.

[0029] [표 1]

Failure pattern type	Count (%)
none	5,534 (90.23%)
center	18 (0.29%)
donut	12 (0.2%)
edgeloc	390 (6.36%)
edgering	17 (0.28%)
loc	101 (1.65%)
random	13 (0.21%)
scratch	48 (0.78%)
total	6,133 (100%)

[0030]

- [0031] 이하에서는, 웨이퍼 맵 결함 패턴 탐지 및 분류 방법론을 설명한다.
- [0032] 웨이퍼 결함 패턴 탐지(Failure Pattern Detection) 및 분류(Failure Pattern Classification)의 첫 단계는 체계적인 패턴을 가진 불량 웨이퍼와 그렇지 않은 정상 웨이퍼를 구분하는 것이다. 그 후, 불량 웨이퍼들만을 대상으로 어떤 종류의 결함인가를 파악할 수 있다. 본 발명에서 제시하는 방법에 대한 대략적인 흐름도는 도 2에 도시되어 있다.
- [0033] **1. 결함 패턴 탐지(Failure Pattern Detection)**
- [0034] 본 발명에서는, Jin 등(Jin C, Na H, Piao M, Pok G, and Ryu K (2019). A novel dbscan-based defect pattern detection and classification framework for wafer bin map. IEEE Transactions on Semiconductor Manufacturing, 32(3), 286-292.)의 DBSCAN을 활용한 예에서 군집에 속하지 못하는 개체를 소음(noise) 처리한다는 점에 착안하여, 계층적 군집 분석을 이용한 소음 처리 방법을 제안하고 이를 웨이퍼 결함 탐지에 활용한다.
- [0035] 군집간 거리 계산과 연결법에는 여러 가지 방법이 있다. R의 hclust 함수에서 제공하는 옵션들을 실험적으로 사용해 본 결과, 실험적으로 가장 좋은 성능을 보여주는 민코우스키 거리(Minkowski Distance) $D(\mathbf{X}, \mathbf{Y}) = (\sum_{i=1}^n |x_i - y_i|^p)^{1/p}$ 와 최단 연결법(single linkage)을 사용할 수 있다. 실험에 시도해 보았던 거리 산출 방식은 맨하탄 거리(Manhattan Distance), 유클리드 거리(Euclidean Distance), 민코우스키, 캔버라 거리(Canberra Distance)이며, 시도해 본 연결법은 완전 연결법(complete linkage), 최단 연결법(single linkage), 와드 연결법(Ward's method), 평균 연결법(average linkage)이다. 민코우스키 거리에서 $p = 3$ 을 이용하는데, 이는 성능이 가장 우수하여 이 값을 최종적으로 선택할 수 있다. 다만, 본 발명의 권리범위가 이에 제한되는 것은 아니며, 실시예에 따라, 상이한 거리 계산 방식 및/또는 연결법이 활용될 수 있다.
- [0036] 기술한 방법을 훈련 데이터를 적용하여 계층적 군집 분석 모형에 필요한 조율 모수(tuning parameter)의 값을 선택한다. 이 조율 모수는 군집 분석 후 덴드로그램(dendrogram) 상에서 컷팅하게 되는 높이와 군집으로 인정되기 위한 최소한의 개체수를 의미하고, 이는 도 2에 height와 minPts로 각각 표기되어 있다. 군집 분석은 일반적으로 비지도 학습의 범주에 속한다. 하지만, 본 발명에 사용된 데이터와 같이 정상/불량의 레이블이 있는 경우에는 이 정보를 최적의 조율 모수 선택에 이용하는 지도 학습의 형태를 띠게 된다.
- [0037] 학습 데이터를 이용하여 조율 모수의 선택이 완료되면 테스트하고자 하는 개별 웨이퍼를 조율된 모수 값을 이용하여 계층적 군집 분석을 시행한다. 이 과정에서 일정 개체 수 이상을 포함하지 못하는 군집을 소음으로 간주하여 제거할 수 있다. 만일 형성된 모든 군집에 속한 개체수의 숫자가 기준 값(minPts) 보다 작아서 소음으로 간주된다면, 모든 군집이 제거되어 그 웨이퍼에는 군집이 하나도 없게 된다. 형성된 군집이 하나도 없다는 것은 아무런 패턴도 보이지 못한다는 뜻이며 이는 정상 웨이퍼로 간주된다.
- [0038] 본 발명의 방법은 웨이퍼의 크기가 동일하다는 점과 레이블이 존재한다는 사실에 착안하여, 조율 모수의 값들을 결정할 때 웨이퍼 마다 서로 다른 값들이 아닌 동일한 값을 이용한다. 이러한 방법을 이용하면, 계층적 군집 분석을 활용한 웨이퍼 결함 패턴 탐지에서 군집 수를 계산할 때 소요 시간이 웨이퍼의 수에 비례하는 단점을 해결할 수 있다. 상술한 정상/불량의 학습 과정이 R 함수를 이용한 다음의 알고리즘 1에 요약되어 있다.

[0039] [알고리즘 1]

Algorithm 1 Pattern detection algorithm for wafer bin map

```

1: INPUT : Failure suspected point on single wafer with cartesian coordinate
2: OUTPUT : Cluster assigned for each failure suspected point
3: standard scaling of cartesian coordinates ( $x_i, y_i, i = 1, \dots, n$ ) for each wafer
4: for each grid : height ( $h_j$ ), minPts ( $m_j$ ) do
5:   for each waferk do
6:      $dist \leftarrow dist(data = (x_i, y_i, i = 1, \dots, n), \text{minkowski}, p = 3)$ 
7:      $model \leftarrow hclust(dist, \text{method} = \text{single linkage})$ 
8:      $cls \leftarrow cluster(model, \text{height} = h_j)$ 
9:     for each clusterl do
10:      if(number of obs.  $\leq m_j$ ) then un-assign the cluster (de-noise)
11:    end for
12:    if number of  $cls > 0$  then systematic pattern exists
13:    return points'  $cls$  for each wafer and grid
14:  end for
15: end for
16: Declare whether a wafer is normal or defective.
```

[0040]

[0041]

알고리즘 1에서 3번째 줄에서 i 는 웨이퍼 내에서 i 번째 관측치를 의미하고, 4번째 줄의 j 는 j 번째 조율 모수를 의미한다. h_j 는 height 모수의 j 번째 값을, m_j 는 군집으로 정의되기 위한 최소 개체수인 minPts 중에서 j 번째로 시도되는 값을 의미한다. 5번째 줄의 k 는 k 번째 웨이퍼를 의미하고, 9번째 줄의 l 은 웨이퍼 내에서 탐색된 l 번째 군집을 의미한다. 6번째 줄에서 거리를 정의하고, 이 거리를 이용하여 7번째 줄에서 계층적 군집 분석을 실시한다. 8번째 줄에서 형성된 군집을 저장한 후 10번째 줄에서 minPts보다 적은 개체를 보유한 군집을 소음처리한다. 이 과정을 거쳐 12번째 줄에서 군집이 한 개 이상 존재하게 되면 불량 웨이퍼로 판정하게 된다. 정상으로 분류된 웨이퍼는 추가적인 분석이 필요하지 않다. 반면 불량으로 판정된 웨이퍼는 어떤 형태의 불량인가를 분류하는 과정이 필요하다. 따라서, 이하에서 다루는 결함 패턴의 분류에 대한 내용은 불량으로 판정된 웨이퍼에만 적용되는 방법론을 의미할 수 있다.

[0042]

2. 결함 패턴 분류(Failure Pattern Classification)

[0043]

결함 패턴 탐지 과정에서 결함으로 판정된 웨이퍼들은 그 다음 단계에서 어떠한 패턴의 결함인지 분류하는 작업으로 진행한다. 패턴의 분류를 위해서는, 결함 패턴 탐지에서와 마찬가지로 우선적으로 소음을 제거해야 한다. 이미 결함 패턴의 탐지 과정에서 소음 제거 작업이 이루어졌지만, 이를 이용하지 않고 새롭게 학습을 시도하는데, 그 이유는 정상 웨이퍼들이 제거되어 데이터에 변화가 있기 때문이다. 따라서, 불량 데이터만 이용하여 다시 알고리즘 1을 적용하여 조율 모수들의 최적값을 탐색한다. 이 학습의 과정에서는 여러가지 종류의 불량이 레이블이 된다. 불량과 관련된 레이블의 자세한 내용은 도 1에서 None을 제외한 나머지 범주들에 제시되어 있다.

[0044]

이 두번째 소음 제거 과정은 결함 패턴 탐지의 첫 번째 소음 제거 과정과 다른점이 있다. 우선, 조율 모수를 탐색할 때 적어도 한 군집 이상은 형성이 되도록 학습이 되어야 한다. 군집이 형성되지 않으면 정상 웨이퍼로 간주되므로 당연한 과정이라고 할 수 있다. 다음으로, 두 가지 이상의 혼합된 패턴이 나타나는 경우에는 각각의 패턴에 속한 개체들의 수를 비교하여 가장 많은 개체가 포함된 패턴으로 축약하고 나머지 패턴들은 소음처리한다. 실제로는 두 가지 이상의 혼합된 패턴이 가끔 발생한다. 그러나 두 가지 이상의 레이블을 동시에 갖는 경우를 고려하면 발생 가능한 패턴의 조합의 수가 매우 많아진다. 따라서 본 발명에서는 하나의 웨이퍼에 한가지 불량 패턴만을 가지는 경우로 한정한다. 두 번째의 소음 제거 과정에서도 첫 번째의 경우와 마찬가지로 동일한 조율 모수의 선택이 모든 웨이퍼에 적용된다. 이를 통해, 웨이퍼별로 클러스터의 수를 계산함으로써 발생하는 컴퓨팅 시간을 상당히 단축할 수 있다. 단, 이는 본 발명과 같이 다이 및 웨이퍼의 크기가 동일한 데이터를 분석하는 경우에만 가능한 방법임에 유의할 필요가 있다.

[0045]

두 번째 소음 제거의 과정이 마무리되면 하나의 불량 패턴만 남게 된다. 학습 데이터에는 이 불량 패턴에 대한 레이블이 있으므로, 이를 이용하여 통계적 모형을 구축할 수 있다. 이를 위하여 각 패턴의 특징(feature)을 추출하여 공변량으로 취한다. 이에 관한 구체적인 방법은 다음과 같다.

[0046] 우선 웨이퍼의 패턴은 2차원의 x축과 y축으로 이뤄진 직교 좌표계(orthogonal cartesian coordinate)에 위치한다. 웨이퍼의 중심이 가운데 오도록 중심화(centering) 후 각 다이의 위치를 극좌표(polar coordinates)로 변경하여 그 반지름과 각도를 구한다(Jin 등, 2019). 두 개 좌표계에서 추출할 수 있는 4개의 값들(x축의 좌표, y축의 좌표, 반지름, 각도)로 각각 1차부터 4차까지의 중심 적률(central moment)인 평균, 표준편차, 왜도(skewness), 첨도(kurtosis)를 계산하여 16 개의 공변량을 생성한다. 또한, 4개의 값들의 최소(minimum), 최대(maximum), 중위수(median), 사분위 범위(Inter Quartile Range, IQR)를 이용하여 16 개의 공변량으로 취한다. 여기서, x축의 좌표, y축의 좌표, 반지름, 및 각도 등은 해당하는 다이(보다 구체적으로는 다이의 중심)에 대한 값을 나타낼 수 있다.

[0047] 상술한 공변량들은 탐색적 데이터 분석을 통해 발견한 것으로서 이를 규칙(rule) 기반으로 적용하고 일반화한 것이다. 예를 들면, 중심(center) 결함의 경우 x와 y 좌표의 평균이 0 부근에 위치하여야 하며 반지름의 길이에 대한 평균은 대략 반지름의 절반보다 작다. 그리고 분포된 각 점의 각도는 0 ~ 360° 사이에 있으므로 산포가 커야 한다. 한편, 주변 원형(edge ring) 결함은 중심 결함과 비슷한 모양이나 웨이퍼의 가장자리에 결함이 생기 기 때문에 반지름의 길이가 매우 크다는 특징이 있다. 위에 서술한 32 개의 공변량들은 이러한 결함들의 특징을 어느 정도 반영할 수 있다.

[0048] 다음으로, 선형 긁힘(scratch)의 특징을 설명할 수 있다고 판단되는 주성분의 첫 번째, 두 번째 고유값(eigen value)을 이용할 수 있다. 또한, 곡선형 긁힘의 특징을 파악하기 위하여, 직교 좌표계의 x의 2차항까지 고려한 다중 회귀 모델을 적합하고, 이 모델의 결정 계수(R-squared value)를 공변량으로 활용한다. 반응 변수인 좌표 계의 y값에 대한 결정 계수(R square)가 클수록 곡선형 긁힘(curvilinear scratch)을 잘 반영한다고 할 수 있다. 이 외에도, 일반적으로 결함의 면적이 넓은 랜덤 결함을 위해 패턴이 포함하는 다이의 개수를 추가적인 공변량으로 고려할 수 있다. 일 실시예에 따르면, 총 36개의 특징을 공변량으로 취한 후 결함의 레이블을 반응 변수로 삼아 결함의 패턴을 분류하는 학습 모델을 구축할 수 있다.

[0049] 랜덤 포레스트는 지도 학습 분류기이면서 변수 선택은 불필요한 장점이 있다. 따라서, 선택된 특징들(공변량)과 이에 대응하는 결함 패턴을 포함하는 학습 데이터로 학습된 랜덤 포레스트를 이용하여 결함 패턴을 분류할 수 있다.

[0050] 이하에서는, 본 발명에서 제시하는 방법론과의 비교를 위하여, 앞서 소개한 WM-811K 데이터를 분석한다.

[0051] 1. 웨이퍼 결함 패턴 탐지

[0052] 앞서 제시한 계층적 군집 분석을 실제 데이터에 적용하여 결함 패턴을 탐지한다. 계층적 군집 분석에 필요한 조 율 모수의 선택을 위하여, 최소 거리(height)를 1 부터 2까지 소정의 간격(예컨대, 0.2 간격)으로 또한 군집내 최소 허용 개체수(minPts)를 5 부터 9까지 소정의 간격(예컨대, 2 간격)으로 격자 탐색(grid search)한다. 조율 모수의 탐색을 위해, 먼저 데이터를 훈련용과 검정용으로 분리한다. 훈련 데이터는 표 2의 케이스 1(case 1) 부 터 케이스 6(case 6)까지 총 여섯가지 방법으로 구성할 수 있다. 케이스 1(Case 1) 부터 케이스 5(case 5)까지 의 훈련 데이터는 결함 패턴별 웨이퍼를 각 4 개씩 부여하고 웨이퍼 개수의 합이 각각 40, 70, 100, 300, 500이 되도록 나머지를 정상 웨이퍼로 채운다. 결함 패턴이 7 개이므로 정상 웨이퍼는 케이스(case)별로 최소 12 개부 터 최대 472 개가 된다. 검정 데이터는 3,065 개의 웨이퍼로서 케이스 1(case 1) 부터 6까지 모두 동일하며 원 데이터의 결함 패턴별 비율을 유지하도록 한다. 따라서, 케이스 6(case 6)을 훈련 데이터로 이용하는 경우에는 검정 데이터를 합하였을 때에 표 1에 나타난 전체 데이터가 된다.

[0053] [표 2]

case	none	center	donut	edgeloc	edgering	loc	random	scratch	total
case 1	12	4	4	4	4	4	4	4	40
case 2	42	4	4	4	4	4	4	4	70
case 3	72	4	4	4	4	4	4	4	100
case 4	272	4	4	4	4	4	4	4	300
case 5	472	4	4	4	4	4	4	4	500
case 6	2,767	9	6	195	8	50	6	24	3,065

[0054]

[0055] 제안하는 방법과의 결함 탐지 성능 비교를 위하여, DBSCAN과 전통적으로 흔히 이용되는 평균 또는 중위수를 이 용한 공간 필터링(spatial filtering)을 활용한다. DBSCAN은 R의 dbscan 패키지를 이용하며 조율이 필요한 모수 는 군집 구성시 군집과 개체간 허용되는 최대 반경(epsilon)과 포함할 반경 주변의 허용되는 점의 최소 개수 (minimum point)이다. 공간 필터링의 경우 R의 raster 패키지를 사용하며 공간 필터의 조율 모수는 필터의 차원

(dimension)과 패턴 여부를 결정하는 임계치(threshold)이다.

[0056] 훈련 데이터를 이용하여 각 모형의 조율 모수의 선택이 끝난 후, 이 값을 이용한 각 모형을 검정 데이터로 사용되는 웨이퍼에 적용하여 웨이퍼의 결함 유무를 예측한다. 데이터를 훈련용과 검정용으로 나누는 과정을 10번 반복하여 각 케이스(case)별로 검정 데이터에서 결함 유무를 예측한 결과가 표 3에 요약되어 있다.

[0057] [표 3]

Model	Measure	case 1	case 2	case 3	case 4	case 5	case 6
HC	recall	98.05 (0.54)	96.44 (0.45)	95.87 (0.21)	95.87 (0.21)	95.87 (0.21)	96.31 (0.00)
	F1 score	58.49 (2.87)	67.74 (2.53)	71.40 (0.20)	71.40 (0.20)	71.40 (0.20)	71.30 (0.00)
	accuracy	85.77 (1.50)	90.60 (1.32)	92.53 (0.07)	92.53 (0.07)	92.53 (0.07)	92.46 (0.00)
DBSCAN	recall	95.77 (1.06)	88.69 (2.01)	85.27 (1.91)	68.52 (4.89)	63.39 (4.14)	86.58 (0.89)
	F1 score	53.75 (3.39)	67.23 (2.50)	69.81 (1.68)	69.66 (0.86)	69.46 (0.62)	73.05 (0.12)
	accuracy	82.23 (2.96)	91.11 (1.24)	92.66 (0.78)	94.29 (0.27)	94.65 (0.20)	93.78 (0.10)
SF-Ave	recall	93.52 (1.81)	86.74 (2.54)	78.56 (2.92)	62.65 (1.62)	60.60 (1.40)	77.68 (1.79)
	F1 score	55.44 (3.90)	66.90 (3.12)	72.05 (0.84)	72.46 (0.72)	71.55 (0.78)	76.02 (0.16)
	accuracy	83.37 (2.97)	90.78 (1.64)	94.01 (0.40)	95.39 (0.07)	95.33 (0.09)	95.24 (0.07)
SF-Med	recall	88.05 (4.68)	70.91 (0.46)	70.91 (0.46)	70.91 (0.46)	70.91 (0.46)	71.81 (0.00)
	F1 score	47.87 (7.66)	75.90 (0.39)	75.90 (0.39)	75.90 (0.39)	75.90 (0.39)	76.16 (0.00)
	accuracy	70.00 (6.98)	95.62 (0.07)	95.62 (0.07)	95.62 (0.07)	95.62 (0.07)	95.63 (0.00)

[0058]

[0059] 표 3에서, 평균(average)과 중위수(median)를 이용하는 공간 필터링은 각각 SF-Ave와 SF-Med로 나타내었다. 결과값들은 10 회의 랜덤 분할을 통해 계산되었고, 모든 값들에는 10^2 가 곱해진 상태이다.

[0060] 평가에 사용된 측도는 F1 점수(F1 score), 정확도(accuracy), 및 재현율(recall)이며, 이는 각각 $TP/(TP + (FP + FN)/2)$, $(TP + TN)/(TP + FP + TN + FN)$, 그리고 $TP/(TP + FN)$ 으로 정의된다. 여기서 TP, TN, FP, 및 FN은 각각 true positive, true negative, false positive, 및 false negative에 해당하는 경우의 개수를 의미한다. 세 가지의 측도 중에서 실제 결함 중 탐지된 결함의 비율인 재현율을 가장 중요하게 생각하는데, 그 이유는 결함인 웨이퍼를 결함으로 판명하는 것이 중요하기 때문이다. 공정상의 문제의 원인을 찾아 개선함으로써 결과적으로 수율을 높이기 위한 과정보다 고려하면 당연하다. 따라서 표 3의 결과 중에서도 재현율(recall)이 전반적으로 가장 높은 계층적 군집 분석이 성능이 가장 좋다고 할 수 있다.

[0061] 표 3에서 중위수를 이용한 공간 필터링 방식(SF-Med)도 높은 정확도(accuracy)를 보이나 분석에 이용된 데이터의 약 90% 정도가 정상 웨이퍼인 비대칭을 감안하면 정확도의 결과는 단지 참고용 정도로만 고려한다.

[0062] 훈련과 검정 데이터의 비율이 동일한 케이스 6(case 6)의 경우에 한하여 각 패턴별의 결함 탐지 예측 성능이 표 4의 "with"로 표시된 열에 나타나 있다. 표 4에서 "without"으로 표시된 부분은 데이터의 훈련시 해당 결함 패턴의 표본을 제외한 후 계산한 결함 탐지의 예측 성능이다. 이 경우, 검정 데이터에서는 해당 패턴을 제외하지 않고 예측 성능을 계산한다. 이는 새로운 결함의 패턴이 발생했을 경우에도 기존의 모형이 어느 정도의 성능을 나타낼 수 있는지에 대하여 가늠할 수 있게 해준다. 결과 중에서 주목할 만한 부분은 긁힘 결함(scratch)의 경우이다. 한편, 정상 웨이퍼인 none의 경우에는 항상 훈련에 포함되므로 "without"에 해당하지 않는다. 제안하는 계층적 군집 분석(HC)의 경우 다른 방법들보다 월등히 높은 83.3%를 내며, 그 외의 패턴들에서도 90% 이상의 높은 성능을 보인다. 한편, FP는 7.8% (= 1 - 92.2%)에 그쳐 허용 가능한 수준이라 판단된다. 이에 반해, 다른 모형들은, 특히 긁힘 결함에서, 그 성능이 상당히 저하됨을 발견할 수 있다. 또 다른 주목할 현상은 DBSCAN의 경우 edgeloc와 loc 패턴의 경우 훈련 데이터에 해당 패턴이 있는 경우와 없는 경우의 예측력에 차이가 많이 난다는 것이다. 따라서 기존의 데이터를 이용하여 훈련한 DBSCAN 모형을 이용할 때에 기존에 관측되지 않던 새로운 패턴이 등장한다면 그리고 edgeloc와 loc 같이 그 수량이 많은 편이라면 결함 유무의 판정에 대한 성능이 상당히 저하될 가능성이 있다.

[0063] [표 4]

patterns	HC		DBSCAN		SF-Ave		SF-Med	
	with	without	with	without	with	without	with	without
center	94.4 (1.9)	94.4 (1.9)	91.1 (2.8)	88.9 (2.9)	83.3 (3.0)	83.3 (3.0)	80.0 (4.0)	80.0 (4.0)
donut	100 (0.0)	100 (0.0)	95.0 (2.6)	100 (0.0)	100 (0.0)	100 (0.0)	100 (0.0)	100 (0.0)
edgeloc	99.2 (0.2)	99.2 (0.2)	89.6 (0.5)	75.5 (4.5)	84.6 (0.6)	73.6 (3.6)	74.1 (0.6)	74.1 (0.6)
edgering	100 (0.0)	100 (0.0)	91.3 (1.9)	83.8 (2.7)	73.8 (3.9)	70.0 (2.0)	73.8 (3.9)	70.0 (2.0)
loc	90.0 (1.2)	92.0 (2.0)	85.2 (2.1)	80.2 (4.4)	85.0 (1.1)	83.0 (2.9)	75.6 (1.1)	78.0 (1.3)
random	100 (0.0)	100 (0.0)	100 (0.0)	90.0 (5.1)	100 (0.0)	100 (0.0)	100 (0.0)	100 (0.0)
scratch	83.3 (1.4)	83.3 (1.4)	32.1 (2.0)	20.0 (4.0)	27.1 (1.4)	22.1 (2.4)	16.7 (1.4)	16.7 (1.4)
none	92.0 (0.1)	NA	94.9 (0.2)	NA	96.7 (0.1)	NA	98.3 (0.0)	NA

[0064]

[0065] 2. 웨이퍼 결함 패턴의 분류

[0066]

웨이퍼 결함 패턴 탐지에서 결함으로 판정된 웨이퍼는 그 다음 과정으로 어떤 패턴의 결함인가에 대한 분류를 한다. 이 과정에 대한 자세한 내용은 상술되어 있고 그 내용을 표 1에서 정상 웨이퍼를 제외한 나머지 결함 웨이퍼 데이터에 적용한다. 이를 위해 결함 웨이퍼를 훈련과 검정 데이터로 반반씩 임의로 분할하여 분석을 시행한다. 앞서 언급한 바와 같이, 분류의 단계에서는 두 번째의 소음 제거와 분류의 과정을 거치게 된다.

[0067]

분류 단계에서 본 발명이 제안하는 방법론과 비교하기 위해 두 번째 소음 제거의 단계에서는 DBSCAN과 OPTICS(ordering points to identify the clustering Structure)를 비교하며, 그 후 분류 모형에서는 지지 벡터 기계(support vector machine; SVM)와 랜덤 포레스트 모형을 사용한다. 이 때에 SVM은 선형과 radial basis 커널을 이용한 비선형의 두 가지 경우를 고려한다. OPTICS는 dbscan 패키지, SVM은 e1071 패키지, 랜덤 포레스트는 randomForest 패키지를 각각 이용하여 모형을 적합한다. OPTIC는 DBSCAN과 비슷한 방법론이며 반경(epsilon), 최소 개체수(minPts)와 다밀도 패턴을 분리하기 위한 조율 모수인 ξ ($0 < \xi < 1$)의 3 개의 조율 모수가 있다. 선행 실험을 통하여 반경은 10으로 고정하였고, 최소 개체수는 3 부터 15까지 3 간격으로, ξ 는 0.01 부터 0.5까지 0.03 간격으로 탐색한다. SVM의 경우, 조율 모수는 cost는 2^{-5} 부터 2^{10} 까지, radial basis 커널의 gamma는 0 부터 0.05까지 0.005 간격으로 탐색한다.

[0068]

결함 패턴 분류 분석 평가는 최종 분류 성능을 통해 한다. 분류 성능의 평가는 재현율(recall), 정밀도(precision), F1 점수(F1 score), 및 AUC를 이용한다. 결함의 종류에 따른 표본의 수가 매우 불균형하기 때문에 정확도(accuracy)는 참고 수준으로만 고려한다. 수학적 1과 수학적 2에 성능 측정에 사용된 기준이 주어져 있다. 여기서, TP와 TN은 각각 true positive와 true negative를, FP와 FN은 각각 false positive와 false negative를 나타낸다. 첨자 j는 j번째 타입의 불량율, J는 불량 종류의 전체 개수를 의미한다.

[0069]

[수학적 1]

$$F1 = \frac{1}{J} \sum_{j=1}^J F1_j, \quad \text{where } F1_j = \frac{2\text{precision}_j \cdot \text{recall}_j}{\text{precision}_j + \text{recall}_j} = \frac{TP_j}{TP_j + (FP_j + FN_j)/2}$$

[0070]

[0071]

[수학적 2]

$$AUC = \frac{1}{J} \sum_{j=1}^J AUC_j, \quad \text{where } AUC_j = \frac{1}{2} \left(\frac{TP_j}{TP_j + FN_j} + \frac{TN_j}{TN_j + TP_j} \right)$$

[0072]

[0073]

검정 데이터에서 얻어진 불량 타입에 대한 예측의 결과가 표 5에 요약되어 있다. 우선 HC로 소음을 제거하고 랜덤 포레스트를 이용하여 분류를 한 경우에 가장 높은 예측력을 보이는 것을 알 수 있다. DBSCAN이나 OPTICS 보다는 본 발명에서 제안하는 HC를 이용한 소음 제거의 방법이 여러 평가의 기준에 비취보아 전반적으로 우수한 결과를 나타낸다. OPTICS로 소음을 제거하고 SVM으로 분류를 하는 경우에는 몇몇 데이터 분할(split)의 경우 분류 성능이 떨어져서 정확도(precision)나 F1 스코어(F1 score)를 구하지 못해서 N/A로 표시되어 있다. OPTICS의 성능이 떨어지는 것을 보여주는 또 다른 모습이다.

[0074] [표 5]

Model	accuracy	precision	recall	F1 score	AUC
HC+RF	92.01 (0.44)	88.14 (0.93)	80.82 (1.40)	83.05 (1.16)	98.75 (0.13)
HC+SVM Linear	87.21 (0.74)	79.38 (1.55)	73.69 (1.81)	74.84 (1.67)	96.37 (0.33)
HC+SVM Radial	87.45 (0.61)	81.52 (1.80)	73.42 (2.05)	75.32 (1.83)	96.80 (0.29)
DBSCAN+RF	91.11 (0.52)	88.28 (0.94)	75.89 (1.40)	79.96 (1.22)	98.03 (0.26)
DBSCAN+SVM Linear	86.14 (0.38)	80.86 (1.20)	68.06 (1.28)	70.87 (1.23)	95.62 (0.24)
DBSCAN+SVM Radial	87.21 (0.61)	83.19 (1.58)	68.99 (1.22)	72.82 (1.20)	96.52 (0.28)
OPTICS+RF	87.69 (0.41)	90.72 (0.98)	65.47 (1.20)	73.69 (1.19)	96.44 (0.47)
OPTICS+SVM Linear	78.49 (1.00)	N/A	42.96 (2.95)	N/A	89.06 (0.33)
OPTICS+SVM Radial	79.48 (0.74)	N/A	41.40 (2.10)	N/A	90.70 (0.44)

[0075]

[0076] 표 5에서, 결과는 10 회의 랜덤 분할을 통해 계산되었고, 모든 값들에는 10^2 이 곱해진 상태이다.

[0077] 표 6의 클래스별 분류 성능에서는 RF를 사용한 경우에 HC가 도넛 결함(donut)을 제외하고는 F1 점수가 모두 80 이상이며, AUC는 지역 결함(local)의 97.21%를 제외하고는 모두 98.00% 이상을 보인다. 이와 비교할 때 DBSCAN 역시 우수한 성능을 보이나, F1 점수가 80 미만인 것이 3개로서 HC에 비해 다소 편차가 있는 것을 볼 수 있다. 표 5에서 가장 성능이 우수한 것으로 나타난 HC + RF의 결과를 이용하여 퍼센트로 계산한 혼동 행렬이 표 7에 나타나 있다. 이 결과는 10개의 값을 평균한 것이다.

[0078] 결함의 분류에 쓰인 데이터 중에서 10개 이하의 데이터로 이뤄진 도넛(donut) 결함과 같은 소수의 클래스에서는 분류 성능이 좋지 못함을 알 수 있다.

[0079] [표 6]

Pattern	Method	precision	recall	F1 score	AUC
center	HC	93.53 (1.78)	91.11 (2.77)	92.01 (1.59)	99.15 (0.39)
	DBSCAN	91.36 (2.15)	100 (0.00)	95.37 (1.17)	99.98 (0.01)
	OPTICS	93.39 (2.21)	72.22 (2.48)	81.10 (1.82)	98.72 (0.56)
donut	HC	90.14 (4.26)	65.00 (4.61)	73.72 (2.76)	99.24 (0.15)
	DBSCAN	95.83 (2.85)	55.00 (5.00)	68.42 (3.59)	99.39 (0.22)
	OPTICS	100 (0.00)	52.00 (3.59)	67.82 (2.85)	98.61 (0.22)
loc	HC	84.75 (1.34)	84.00 (1.91)	84.20 (1.13)	97.21 (0.32)
	DBSCAN	82.62 (0.80)	86.80 (1.50)	84.56 (0.70)	97.49 (0.32)
	OPTICS	74.77 (0.78)	80.49 (1.19)	77.50 (0.88)	96.27 (0.36)
edgeloc	HC	94.96 (0.42)	98.05 (0.30)	96.47 (0.22)	98.63 (0.19)
	DBSCAN	95.77 (0.42)	98.21 (0.29)	96.96 (0.21)	98.64 (0.24)
	OPTICS	91.45 (0.38)	97.61 (0.36)	94.43 (0.31)	97.23 (0.32)
edgering	HC	92.56 (3.53)	73.75 (2.92)	81.36 (2.10)	99.30 (0.17)
	DBSCAN	83.71 (4.02)	65.00 (4.49)	72.33 (3.45)	95.72 (1.05)
	OPTICS	91.39 (4.87)	56.25 (5.67)	67.01 (4.51)	96.98 (0.55)
random	HC	76.43 (5.84)	93.33 (3.69)	82.35 (3.69)	99.94 (0.03)
	DBSCAN	71.67 (4.10)	80.00 (4.84)	75.12 (4.05)	99.12 (0.23)
	OPTICS	96.00 (4.00)	48.00 (4.10)	62.62 (4.24)	89.01 (3.02)
scratch	HC	94.99 (1.67)	76.25 (1.87)	84.47 (1.52)	98.43 (0.43)
	DBSCAN	91.75 (1.62)	72.08 (2.24)	80.53 (1.55)	98.72 (0.20)
	OPTICS	85.59 (2.74)	62.08 (2.28)	71.73 (2.03)	96.42 (0.62)

[0080]

[0081] 표 6에서, 결과값은 10 회의 랜덤 분할을 통해 계산되었고, 모든 값들에는 10^2 이 곱해진 상태이다.

[0082] [표 7]

Reference	center	donut	loc	edgeloc	edgering	random	scratch
center	91.11	1.11	4.44	3.33	0	0	0
donut	5.00	65.00	20.00	1.67	0	8.33	0
loc	0.60	0.40	84.00	13.00	0	0.40	1.60
edgeloc	0	0	0.97	98.05	0.31	0.56	0.10
edgering	0	0	0	26.25	73.75	0	0
random	0	5.00	0	1.67	0	93.33	0
scratch	0	0	17.50	4.58	0	1.67	76.25

[0083]


[0084] 표 7에서, 결과값은 10 회의 랜덤 분할을 통해 계산되었다.

- [0085] 이상에서는 반도체 웨이퍼의 결함 패턴 탐지와 분류를 위해 계층적 군집 분석을 제안하였다. 기존 결함 분류에 쓰였던 계층적 군집 분석 방법을 확장하여 결함 탐지에도 이용할 수 있으며, 결함 패턴 탐지의 성능이 경쟁 방법에 비해 우수함을 실제 웨이퍼 빈 맵 데이터를 활용한 실험을 통해 보였다.
- [0086] 도 3은 본 발명의 일 실시예에 따른, 계층적 군집 분석을 이용하여 반도체 웨이퍼 패턴 탐지 및/또는 분류를 수행하는 방법을 설명하기 위한 흐름도이다.
- [0087] 도 3을 참조하면, 제안하는 방법은 적어도 프로세서(Processor) 및/또는 메모리(Memory)를 포함하는 컴퓨팅 장치에 의해 수행될 수 있다. 다시 말하면, 제안하는 방법에 포함되는 단계들 중 적어도 일부는 컴퓨팅 장치에 포함되는 프로세서의 동작으로 이해될 수 있으며, 컴퓨팅 장치는 반도체 웨이퍼 패턴 탐지 및/또는 분류를 수행하는 장치로 명명될 수 있다. 컴퓨팅 장치는 PC(Personal Computer), 서버(server), 랩탑 컴퓨터, 태블릿 PC 등을 포함할 수 있고, 물리적으로 분리된 적어도 하나의 장치로 구현될 수 있다. 이하에서, 제안하는 방법을 설명함에 있어, 앞선 기재와 중복되는 내용에 관하여는 그 구체적인 설명을 생략하기로 한다.
- [0088] 원시 데이터가 획득된다(S110). 원시 데이터는 웨이퍼 빈 맵(WBM)을 포함할 수 있다. 예시적으로, 원시 데이터는 WM-811K 데이터와 같은 웨이퍼 빈 맵(WBM)일 수 있다. 원시 데이터는, 소정의 유무선 통신망을 통하여, 원시 데이터를 제공하는 서버나 외부 장치로부터 수신되거나, USB 메모리 장치와 같은 저장 장치로부터, 소정의 입력력 인터페이스를 통하여, 수신되거나, 컴퓨팅 장치에 미리 저장되어 있을 수 있다. 실시예에 따라, 원시 데이터와 함께, 또는 원시 데이터와는 별도로 타겟 데이터가 더 수신될 수도 있다. 타겟 데이터는 결함 패턴 탐지 및/또는 결함 패턴 분류의 대상이 되는 타겟 웨이퍼에 대한 데이터로써, 웨이퍼 상에 존재하는 결함 유무에 대한 정보를 포함하는 포인트 정보를 포함할 수 있다. 포인트 정보는 웨이퍼 상의 지리적 공간에서의 관측치, 즉 결함 여부에 대한 정보와 포인트의 위치 정보를 포함할 수 있다. 실시예에 따라, 타겟 데이터는 타겟 웨이퍼의 웨이퍼 빈 맵(WBM)을 의미할 수 있다.
- [0089] 결함 패턴이 탐지된다(S120). 이를 통해 타겟 웨이퍼의 결함 여부가 결정될 수 있다. 다시 말하면, 타겟 웨이퍼에 결함 패턴이 존재하는지 여부가 결정될 수 있다.
- [0090] 우선, 계층적 군집 분석(HC)을 위한 제1 조율 모수가 결정되어야 한다. 제1 조율 모수는 최소 허용 거리를 의미하는 높이(height)와 군집 내 최소 개체수(minPts)를 포함할 수 있다. 제1 조율 모수의 결정은 원시 데이터를 이용하여 결정될 수 있다. 구체적으로, 원시 데이터의 적어도 일부를 이용한 그리드 서치(grid search, 격자 탐색)를 통해, 계층적 군집 분석(HC)을 위한 제1 조율 모수의 값이 결정될 수 있다. 이때, 그리드 서치에 이용되는 데이터와 타겟 데이터는 동일한 사이즈를 갖는 웨이퍼에 대한 데이터일 수 있다. 또한, 계층적 군집 분석(HC)을 위한 제1 조율 모수가 미리 결정되어 있다면, 제1 조율 모수를 결정하는 별도의 단계는 생략될 수 있다. 실시예에 따라, 제1 조율 모수의 결정은 S110 단계 이전 또는 S110 단계 이후의 임의의 시점에서 수행되는 것도 가능하다.
- [0091] 결정된 제1 조율 모수를 이용하여 계층적 군집 분석(HC)을 통한 소음 제거 동작이 수행된다. 즉, 계층적 군집 분석(HC)을 수행하여 제1 조율 모수를 만족시키지 못하는 군집은 제거된다.
- [0092] 소음 제거의 결과, 체계적인 패턴(즉, 결함 패턴)이 존재하지 않는다면, 타겟 웨이퍼는 정상 웨이퍼로 결정될 수 있다. 반대로, 체계적인 패턴(즉, 결함 패턴)이 존재한다면, 타겟 웨이퍼는 비정상(불량) 웨이퍼로 결정되고, 이후의 결함 패턴 분류 단계가 수행될 수 있다.
- [0093] 타겟 웨이퍼의 결함 패턴이 분류된다(S130). 즉, 불량 웨이퍼로 결정된(또는 판단된) 웨이퍼에 포함된 결함 패턴이 분류될 수 있다.
- [0094] 우선, 계층적 군집 분석(HC)을 위한 제2 조율 모수가 결정되어야 한다. 제2 조율 모수는 최소 허용 거리를 의미하는 높이(height)와 군집 내 최소 개체수(minPts)를 포함할 수 있다. 제2 조율 모수의 결정은 원시 데이터를 이용하여 결정될 수 있다. 구체적으로, 원시 데이터의 적어도 일부를 이용한 그리드 서치(grid search, 격자 탐색)를 통해, 계층적 군집 분석(HC)을 위한 제2 조율 모수의 값이 결정될 수 있다. 이때, 그리드 서치에 이용되는 데이터와 타겟 데이터는 동일한 사이즈를 갖는 웨이퍼에 대한 데이터일 수 있다. 또한, 계층적 군집 분석(HC)을 위한 제2 조율 모수가 미리 결정되어 있다면, 제2 조율 모수를 결정하는 별도의 단계는 생략될 수 있다. 실시예에 따라, 제2 조율 모수의 결정은 S110 단계 이전 또는 S110 단계 이후의 임의의 시점에서 수행되는 것도 가능하다. 또한, 제2 조율 모수는 원시 데이터 중 비정상 데이터만을 이용하여 결정되기 때문에, 제1 조율 모수와는 상이한 값을 가질 수 있다.

- [0096] 결정된 제2 조율 모수를 이용하여 계층적 군집 분석(HC)을 통한 소음 제거 동작 및/또는 결함 패턴 분리 동작이 수행된다. 즉, 계층적 군집 분석(HC)을 수행하여 제2 조율 모수를 만족시키지 못하는 군집은 제거된다. 또한, 계층적 군집 분석(HC) 과정에서, 타겟 웨이퍼에 복수의 결함 패턴이 존재하는 경우 대표적인 결함 패턴만을 유지하고 나머지 결함 패턴은 제거될 수 있다.
- [0097] 결함 패턴 분류를 위한 특징이 추출되고, 추출된 특징을 이용하여 결함 패턴이 분류될 수 있다. 이러한 동작은 각 결함 패턴별로 수행될 수 있다. 또한, 추출되는 특징은 상술한 공변량을 의미할 수 있고, 결함 패턴의 분류는 사전에 학습된 분류 모델(예컨대, 랜덤 포레스트 모델)을 이용하여 수행될 수 있다.
- [0098] 상술한 바와 같이, 타겟 웨이퍼의 결함 여부에 대한 결정과 결함 패턴에 대한 분류 결과를 이용함으로써, 제조 공정상의 원인 파악 및 조치가 가능하다.
- [0099] 이상에서 설명된 장치는 하드웨어 구성 요소, 소프트웨어 구성 요소, 및/또는 하드웨어 구성 요소 및 소프트웨어 구성 요소의 집합으로 구현될 수 있다. 예를 들어, 실시예들에서 설명된 장치 및 구성 요소는, 예를 들어, 프로세서, 컨트롤러, ALU(Arithmetic Logic Unit), 디지털 신호 프로세서(Digital Signal Processor), 마이크로컴퓨터, FPA(Field Programmable array), PLU(Programmable Logic Unit), 마이크로프로세서, 또는 명령(instruction)을 실행하고 응답할 수 있는 다른 어떠한 장치와 같이, 하나 이상의 범용 컴퓨터 또는 특수 목적 컴퓨터를 이용하여 구현될 수 있다. 처리 장치는 운영 체제(Operation System, OS) 및 상기 운영 체제 상에서 수행되는 하나 이상의 소프트웨어 애플리케이션을 수행할 수 있다. 또한, 처리 장치는 소프트웨어의 실행에 응답하여, 데이터를 접근, 저장, 조작, 처리 및 생성할 수도 있다. 이해의 편의를 위하여, 처리 장치는 하나가 사용되는 것으로 설명된 경우도 있지만, 해당 기술 분야에서 통상의 지식을 가진 자는, 처리 장치가 복수 개의 처리 요소(Processing Element) 및/또는 복수 유형의 처리 요소를 포함할 수 있음을 알 수 있다. 예를 들어, 처리 장치는 복수 개의 프로세서 또는 하나의 프로세서 및 하나의 컨트롤러를 포함할 수 있다. 또한, 병렬 프로세서(Parallel Processor)와 같은, 다른 처리 구성(Processing Configuration)도 가능하다.
- [0100] 소프트웨어는 컴퓨터 프로그램(Computer Program), 코드(Code), 명령(Instruction), 또는 이들 중 하나 이상의 조합을 포함할 수 있으며, 원하는 대로 동작하도록 처리 장치를 구성하거나 독립적으로 또는 결합적으로(Collectively) 처리 장치를 명령할 수 있다. 소프트웨어 및/또는 데이터는, 처리 장치에 의하여 해석되거나 처리 장치에 명령 또는 데이터를 제공하기 위하여, 어떤 유형의 기계, 구성 요소(Component), 물리적 장치, 가상 장치(Virtual Equipment), 컴퓨터 저장 매체 또는 장치, 또는 전송되는 신호 파(Signal Wave)에 영구적으로, 또는 일시적으로 구체화(Embody)될 수 있다. 소프트웨어는 네트워크로 연결된 컴퓨터 시스템 상에 분산되어서, 분산된 방법으로 저장되거나 실행될 수도 있다. 소프트웨어 및 데이터는 하나 이상의 컴퓨터 판독 가능 기록 매체에 저장될 수 있다.
- [0101] 실시예에 따른 방법은 다양한 컴퓨터 수단을 통하여 수행될 수 있는 프로그램 명령 형태로 구현되어 컴퓨터 판독 가능 매체에 기록될 수 있다. 상기 컴퓨터 판독 가능 매체는 프로그램 명령, 데이터 파일, 데이터 구조 등을 단독으로 또는 조합하여 포함할 수 있다. 상기 매체에 기록되는 프로그램 명령은 실시예를 위하여 특별히 설계되고 구성된 것들이거나 컴퓨터 소프트웨어 당업자에게 공지되어 사용 가능한 것일 수도 있다. 컴퓨터 판독 가능 기록 매체의 예에는 하드 디스크, 플로피 디스크 및 자기 테이프와 같은 자기 매체(Magnetic Media), CD-ROM, DVD와 같은 광기록 매체(Optical Media), 플롭티컬 디스크(Floptical Disk)와 같은 자기-광 매체(Magneto-optical Media), 롬(ROM), 램(RAM), 플래시 메모리 등과 같은 프로그램 명령을 저장하고 수행하도록 특별히 구성된 하드웨어 장치가 포함된다. 프로그램 명령의 예에는 컴파일러에 의해 만들어지는 것과 같은 기계어 코드뿐만 아니라 인터프리터 등을 사용해서 컴퓨터에 의해서 실행될 수 있는 고급 언어 코드를 포함한다. 상기된 하드웨어 장치는 실시예의 동작을 수행하기 위해 하나 이상의 소프트웨어 모듈로서 작동하도록 구성될 수 있으며, 그 역도 마찬가지이다.
- [0102] 본 발명은 도면에 도시된 실시예를 참고로 설명되었으나 이는 예시적인 것에 불과하며, 본 기술 분야의 통상의 지식을 가진 자라면 이로부터 다양한 변형 및 균등한 타 실시예가 가능하다는 점을 이해할 것이다. 예를 들어, 설명된 기술들이 설명된 방법과 다른 순서로 수행되거나, 및/또는 설명된 시스템, 구조, 장치, 회로 등의 구성 요소들이 설명된 방법과 다른 형태로 결합 또는 조합되거나, 다른 구성 요소 또는 균등물에 의하여 대치되거나 치환되더라도 적절한 결과가 달성될 수 있다. 따라서, 본 발명의 진정한 기술적 보호 범위는 첨부된 등록청구범위의 기술적 사상에 의해 정해져야 할 것이다.


도면

도면1




도면2

Failure Pattern Detection



Failure Pattern Classification



도면3

