

Wafer bin map failure pattern recognition using hierarchical clustering

Joowon Jeong^a, Yoonsuh Jung^{1,a}

^aDepartment of Statistics, Korea University

Abstract

The semiconductor fabrication process is complex and time-consuming. There are sometimes errors in the process, which results in defective die on the wafer bin map (WBM). We can detect the faulty WBM by finding some patterns caused by dies. When one manually seeks the failure on WBM, it takes a long time due to the enormous number of WBMs. We suggest a two-step approach to discover the probable pattern on the WBMs in this paper. The first step is to separate the normal WBMs from the defective WBMs. We adapt a hierarchical clustering for de-noising, which nicely performs this work by wisely tuning the number of minimum points and the cutting height. Once declared as a faulty WBM, then it moves to the next step. In the second step, we classify the patterns among the defective WBMs. For this purpose, we extract features from the WBM. Then machine learning algorithm classifies the pattern. We use a real WBM data set (WM-811K) released by Taiwan semiconductor manufacturing company.

Keywords: failure pattern classification, failure pattern detection, hierarchical clustering, wafer bin map

1. Introduction

반도체 제조는 회로를 구성하기 위해 다수의 화학 공정을 거치며 수백에서 수만개의 반도체 칩을 구성할 수 있는 원형의 웨이퍼 단위로 이루어진다. 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 (Jin 등, 2019; Kim 등, 2018).

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 (Kim 등, 2018). 공간적인 결함 패턴은 육안으로 확인할 수 있으며 (Hsu와 Chien, 2007) 이를 통해 결함 여부와 유형을 알 수 있어 공정상의 원인을 유추할 수 있다. Figure 1은 웨이퍼 상의 결함 패턴의 예시이며 각각 중심결함(center), 도넛결함(donut), 지역결함(local), 주변 지역결함(edge local), 주변 원형결함(edge ring), 임의결함(random), 긁힘결함(scratch) 등을 나타낸다.

기존 연구에서 웨이퍼 결함 탐지를 위해 가장 많이 사용되는 방법은 de-noising과 같은 공간 필터 (Wang 등, 2006b; Chang 등, 2012; Wang, 2008; Yu와 Lu, 2016; Wang 등, 2006a; Yuan 등, 2010)와 공간 임의성 검정 (Wang, 2009; Li와 Huang, 2009; Kim 등, 2016; Hsu와 Chien, 2007; Chien 등, 2013; Jeong 등, 2008)이다.

Jung's work has been partially supported by National Research Foundation of Korea (NRF) grants funded by the Korean government (MIST) 2021R1F1A1062347 and Korea University research fund K2122591.

¹ Corresponding author: Associate Professor, Department of Statistics, Korea University, 145 Anam-ro Seongbuk-Gu, Seoul 02841, Korea, Republic of. E-mail: yoons77@korea.ac.kr

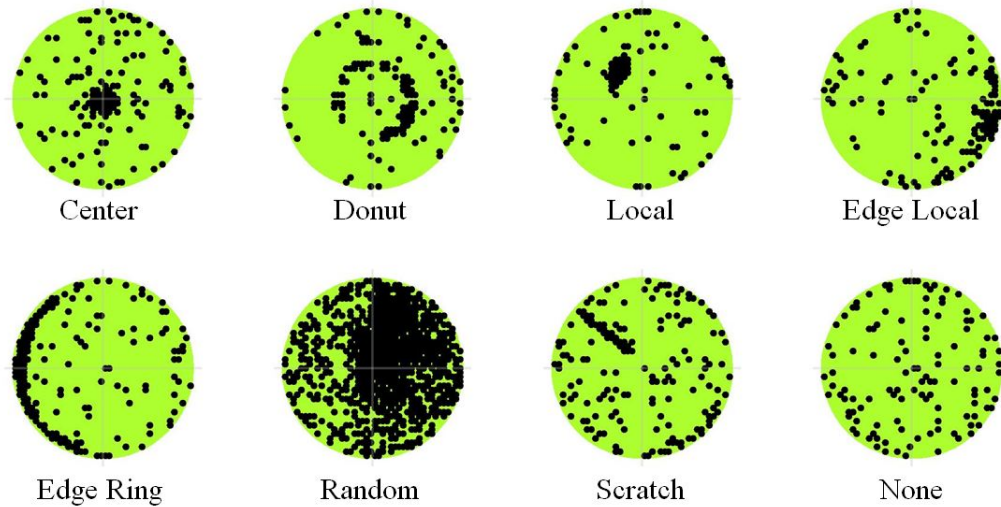


Figure 1: Various type of defective wafer patterns. 'None' corresponds to a normal wafer.

공간 필터는 이미지 처리의 방법으로서 평활화(smoothing)를 통해 노이즈를 제거한다 (Wang, 2009; Wang 등, 2006a). 2차원 공간상 점 주변에 위치한 결함의 수에 가중합을 주어 계산된 평균 혹은 중위수에 대하여 체계적인 패턴과 그렇지 않은 패턴을 구분하는 임계치(threshold)를 구하여 탐지하는 방식이며 대개의 경우 좋은 성능을 보인다. 그러나 얇고 긴 직선 혹은 등근 선 등 스크래치 형태의 패턴이 노이즈가 많은 웨이퍼 안에 있을 경우 체계적인 패턴을 탐지하지 못하는 한계를 가지고 있다 (Kim 등, 2018; Jin 등, 2019). 주로 평균 필터(average filter)와 중앙값 필터(median filter)가 흔히 사용된다. 다른 방법으로는 공간 임의성 검정 (spatial randomness test)이 있다. 공간 필터와 유사하게 주변의 점의 수(joint-count statistics)를 세어 그것의 로그 오즈비 혹은 카이스퀘어 통계량을 활용하여 가설 검정하는 방식이다.

웨이퍼가 일단 결함으로 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.

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. 본 논문에서는 클러스터 수 계산의 부담이 적은 계층적 군집 분석(hierarchical clustering)을 통해 첫째 웨이퍼의 결함을 탐지하고 둘째 결함의 분리를 통해 얻은 특징들을 변수 선택이 필요치 않은 분류기인 랜덤 포레스트와 결합하여 유형 분류를 시도한다. 이를 통해 공정상 문제의 원인을 조기에 식별하고 조치할 수 있는 방법을 모색하고 기존의 방법론들과 비교하고자 한다.

본 논문의 나머지는 다음과 같이 구성된다. 2절에서 실험에 사용될 글로벌 반도체 제조사의 실제 데이터를 설명한다. 3절에서는 웨이퍼 맵 결함의 탐지와 분류를 위해 제안된 방법을 논의한다. 특히 3.1절에서는 결함 패턴 탐지와 분리에 사용될 개선된 계층적 군집 분석 방법을 제시한다. 그리고 3.2절에서는 결함 패턴의 특징 추출을 위해 극좌표의 중심 적률을 사용한 방법과 특히 굵힘 결함(scratch)에 대한 특징 추출 방법을 제시한다. 이렇게 추출된 특징들은 기계 학습 방법론의 공변량으로 이용된다. 4절에서는 글로벌 반도체 제조사의 실제

Table 1: Type of failure patterns and its count in WM-811K data set when considering die size 1376

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%)

데이터를 활용하여 제시한 방법론과 기존의 방법들을 비교한다. 결론과 향후 연구 계획은 5절에 기술되어 있다.

2. 반도체 웨이퍼 데이터 (WM-811K) 소개

실험에 사용되는 데이터는 대만 반도체 회사에서 공개한 실제 데이터(WM-811K) (Wu 등, 2015)로서 총 811,457개의 웨이퍼 빈 맵(wafer bin map; WBM)이 있으며 이 중 172,950개의 웨이퍼 빈 맵에 정상 여부 혹은 결함 패턴의 이름이 각 웨이퍼 별 하나씩 기입되어 있다. 원형의 웨이퍼 안에는 하나의 반도체 칩이 되는 공간인 다이(die)가 격자로 구분돼 있으며 앞서 언급된 웨이퍼 빈 맵은 웨이퍼와 다이 사이즈별로 구분할 수 있다. 웨이퍼들의 사이즈는 다양하며 동일 사이즈에는 수백에서 수 천장의 웨이퍼들이 포함돼 있다.

하나의 웨이퍼에는 각 다이 별로 다수 관측치의 테스트 결과가 이산형으로 표기되어 있다. 관측치의 수는 작게는 웨이퍼 당 45개에서부터 많게는 2만 8천여개로, 평균 2천개 정도이다. 반도체 제작은 여러 단계의 공정을 거치는데 각 공정을 거칠 때마다 테스트가 이뤄진다. 웨이퍼 상의 지리적 공간에 관측치들의 테스트 결과가 일정한 체계적인 패턴을 나타내면 결함 패턴이라 할 수 있다. 본 논문의 데이터에 포함된 웨이퍼의 결함 패턴은 Figure 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 의한 것이다. 웨이퍼 가장자리의 둥근 패턴인 주변 원형결함(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 (Kim 등, 2018).

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 선택한다. 1376 다이 크기 중 44×41 웨이퍼 크기를 대상으로 하며 샘플이 1개에 불과한 near full 패턴은 제외한다. 선택된 데이터에는 6,133 개의 웨이퍼가 있으며 이 중 정상은 90.23% 이다. 본 논문에서 분석에 사용한 결함 패턴별 비율은 Table 1에 표시돼 있다.

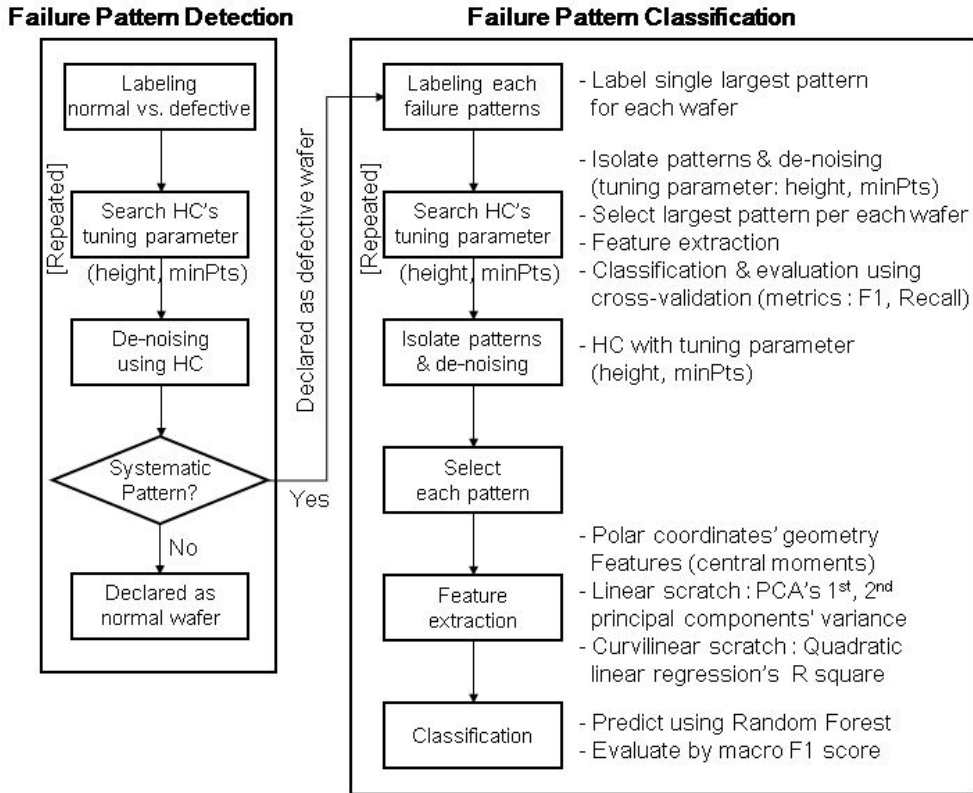


Figure 2: Flowchart for the process of wafer map failure pattern detection and classification. 'height' and 'minPts' are tuning parameters in the hierarchical clustering (HC).

3. 웨이퍼 맵 결함 패턴 탐지 및 분류 방법론

웨이퍼 결함 패턴 탐지 및 분류의 첫 단계는 체계적인 패턴을 가진 불량 웨이퍼와 그렇지 않은 정상 웨이퍼를 구분하는 것이다. 그 후 불량 웨이퍼들만을 대상으로 어떤 종류의 결함인가를 파악한다. 본 논문에서 제시하는 방법에 대한 대략의 흐름도가 Figure 2에 나타나 있다.

3.1. 결함 패턴 탐지

본 논문에서는 Jin 등 (2019)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. 군집간 거리 계산과 연결법에는 여러 가지 방법이 있다. R의 `hclust` 함수에서 제공하는 옵션들을 실험적으로 사용해 본 결과 경험적으로 가장 좋은 성능을 보여주는 민코우스키 거리 $D(\mathbf{X}, \mathbf{Y}) = (\sum_{i=1}^n |x_i - y_i|^p)^{1/p}$ 와 최단 연결법(single linkage)을 사용한다. 실험에 시도해 보았던 거리 산출 방식은 맨하탄, 유클리드, 민코우스키, 캔버라 거리이며, 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 직관적으로 잘 이해되지 않는 부분이나 성능이 가장 우수하여 이 값을 최종적으로 선택한다. 기술한 방법을 훈련 데이터를 적용하여 계층적 군집 분석 모형에 필요한 조율 모수의 값을 선택한다. 이 조율 모수는 군집

분석 후 덴드로그램 상에서 컷팅하게 되는 높이와 군집으로 인정되기 위한 최소한의 개체수인데, 이는 Figure 2에 height와 minPts로 각각 표기되어 있다. 군집 분석은 일반적으로 비지도 학습의 범주에 속한다. 하지만 본 논문에 사용한 데이터와 같이 정상/불량의 레이블이 있는 경우에는 이 정보를 최적의 조율 모수 선택에 이용하는 지도 학습의 형태를 띠게 된다.

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 제거한다. 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.

본 논문의 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 Alawieh 등 (2016)의 계층적 군집 분석을 활용한 웨이퍼 결함 패턴 탐지에서 군집 수를 계산할 때 소요 시간이 웨이퍼의 수에 비례하는 단점을 해결할 수 있다. 위에서 기술한 정상/불량의 학습 과정이 R 함수를 이용한 다음의 알고리즘 1에 요약되어 있다. 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 군집분석을 실시한다. 8번째 줄에서 형성된 군집을 저장한 후 10번째 줄에서 minPts보다 적은 개체를 보유한 군집을 소음처리한다. 이 과정을 거쳐 12번째 줄에서 군집이 한개 이상 존재하게 되면 불량 웨이퍼로 판정하게 된다. 정상으로 분류된 웨이퍼는 추가적인 분석이 필요하지 않다. 반면 불량으로 판정된

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 wafer $k$  do
6:      $dist \leftarrow \text{dist}(\text{data} = (x_i, y_i, i = 1, \dots, n), \text{minkowski}, p = 3)$ 
7:      $model \leftarrow \text{hclust}(dist, \text{method} = \text{single linkage})$ 
8:      $cls \leftarrow \text{cluster}(model, \text{height} = h_j)$ 
9:     for each cluster $l$  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.
  
```

웨이퍼는 어떤 형태의 불량인가를 분류하는 과정이 필요하다. 따라서 다음 절에서 다루는 결함 패턴의 분류에 대한 내용은 본 절에서 불량으로 판정된 웨이퍼에만 적용되는 방법론이다.

3.2. 결함 패턴 분류

3.1절에서 결함으로 판정된 웨이퍼들은 그 다음 단계에서 어떠한 패턴의 결함인지 분류하는 작업으로 진행된다. 패턴의 분류를 위해서는 3.1절에서와 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 조울 모수들의 최적값을 탐색한다. 이 학습의 과정에서는 여러가지 종류의 불량이 레이블이 된다. 불량과 관련된 레이블의 자세한 내용은 Figure 1에서 None을 제외한 나머지 범주들에 제시되어 있다. 이 두 번째 소음 제거 과정은 결함 패턴 탐지의 첫 번째 소음 제거 과정과 다른점이 있다. 우선, 조울 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 논문에서는 하나의 웨이퍼에 한 가지 불량 패턴만을 가지는 경우로 한정한다. 두 번째의 소음 제거 과정에서도 첫 번째의 경우와 마찬가지로 동일한 조울 모수의 선택이 모든 웨이퍼에 적용된다. 이러한 이유로 비슷한 방법인 Huang (2002, 2007)의 방법에서 웨이퍼 별로 클러스터의 수를 계산하여 발생하는 컴퓨팅 시간을 상당히 단축할 수 있다. 단, 이는 본 논문과 같이 다이 및 웨이퍼의 크기가 동일한 데이터를 분석하는 경우에만 가능한 방법임에 유의해야 한다. 만일 서로 크기가 다른 웨이퍼들도 함께 고려한다면 본 논문에서 제시하는 방법이 확장되어야 한다. 조울모수들의 값이 웨이퍼의 반지름이나 면적의 크기에 대한 함수로 설정하는 등의 방법을 생각해볼 수 있겠으나 이는 향후과제로 미루도록 한다.

두 번째 소음 제거의 과정이 마무리되면 하나의 불량 패턴만 남게 된다. 학습 데이터에는 이 불량 패턴에 대한 레이블이 있으므로 이를 이용하여 통계적 모형을 구축한다. 이를 위하여 각 패턴의 특징(feature)을 추출하여 공변량으로 취한다. 그 구체적인 방법은 다음과 같다. 우선 웨이퍼의 패턴은 2차원의 x 축과 y 축으로 이뤄진 직교 좌표계(orthogonal cartesian coordinate)에 위치한다. 웨이퍼의 중심이 가운데 오도록 중심화 후 각 다이의 위치를 극좌표로 변경하여 그 반지름과 각도를 구한다 (Jin 등, 2019). 두 개 좌표계에서 추출할 수 있는 4개의 값들 (x 축의 좌표, y 축의 좌표, 반지름, 각도)로 각각 1차부터 4차까지의 중심 적률인 평균, 표준편차, 왜도, 첨도를 계산하여 16개의 공변량을 만들어 낸다. 또한 4개의 값들의 최소, 최대, 중위수, 사분위 범위수를 이용하여 16개의 공변량으로 취한다. 기술한 공변량들은 탐색적 데이터 분석을 통해 발견한 것으로서 이를 규칙(rule) 기반으로 적용하고 일반화한 것이다. 예를 들면, 중심(center) 결함의 경우 x 와 y 좌표의 평균이 0 부근에 위치해야 하며 반지름의 길이에 대한 평균은 대략 반지름의 절반보다 작다. 그리고 분포된 각 점의 각도는 $0 \sim 360^\circ$ 사이에 있으므로 산포가 커야 한다. 한편, 주변 원형(edge ring) 결함은 중심 결함과 비슷한 모양이나 웨이퍼의 가장자리에 결함이 생기기 때문에 반지름의 길이가 매우 크다는 특징이 있다. 위에 서술한 32개의 공변량들은 이러한 결함들의 특징을 어느 정도 반영한다.

다음으로 선형 글림의 특징을 설명할 수 있다고 생각되는 주성분의 첫 번째, 두 번째 고유값을 이용한다. 또한, 곡선형 글림의 특징을 파악하기 위하여 직교 좌표계의 x 의 2차항까지 고려한 다중 회귀 모형을 적합하고, 이 모형의 결정 계수(R-squared value)를 공변량으로 활용한다. 반응 변수인 좌표계의 y 값에 대한 결정 계수가 클수록 곡선형 글림을 잘 반영한다고 할 수 있다. 이 외에도 일반적으로 결함의 면적이 넓은 랜덤 결함을 위해 패턴이 포함하는 다이의 개수를 마지막 공변량으로 고려한다. 이와 같이 특징 추출에 대한 기존의 방법론들을 참고 및 수정하여 총 36개의 특징을 공변량으로 취한 후 결함의 레이블을 반응 변수로 삼아 결함의 패턴을 분류하는 학습 모형을 구축한다. 본 논문에서 새롭게 추가한 방법은 곡선형 글림의 특징을 추출하기 위하여 2차항의 선형 회귀 모형에서 계산한 결정 계수이다. 다음 절에서는 본 논문에서 제시하는 방법론과의

Table 2: Various cases for the training data. Case 6 is about half of the whole data set we consider as given in Table 1

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

비교를 위하여 2절에서 소개한 WM-811K 데이터를 분석한다.

4. 실제 데이터 분석

4.1. 웨이퍼 결함 패턴 탐지

본 절에서는 3.1절에서 제시한 계층적 군집분석을 실제 데이터에 적용하여 결함 패턴을 탐지한다. 계층적 군집분석에 필요한 조율 모수의 선택을 위하여 최소 거리(height)를 1부터 2까지 0.2 간격으로 또한 군집내 최소 허용 개체수(minPts)를 5부터 9까지 2간격으로 격자 탐색한다. 조율 모수의 탐색을 위해 먼저 데이터를 훈련용과 검정용으로 분리한다. 훈련 데이터는 Table 2의 case 1부터 case 6까지 총 여섯가지 방법으로 구성한다. Case 1부터 case 5까지의 훈련 데이터는 결함 패턴 별 웨이퍼를 각 4개씩 부여하고 웨이퍼 개수의 합이 각각 40, 70, 100, 300, 500이 되도록 나머지를 정상 웨이퍼로 채운다. 결함 패턴이 7개이므로 정상 웨이퍼는 case 별로 최소 12개부터 최대 472개가 된다. 검정 데이터는 3,065개의 웨이퍼로서 case 1부터 6까지 모두 동일하며 원 데이터의 결함 패턴별 비율을 유지하도록 한다. 따라서 case 6을 훈련 데이터로 이용하는 경우에는 검정 데이터를 합하였을 때에 Table 1에 나타난 전체 데이터가 된다.

제안하는 방법과의 결함 탐지 성능 비교를 위하여 DBSCAN과 전통적으로 흔히 이용되는 평균 또는 중위수를 이용한 공간 필터링(spatial filtering)을 활용한다 (Wang, 2008). DBSCAN은 R의 `dbscan` 패키지를 이용하며 조율이 필요한 모수는 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 (Hijmans, 2021) 사용하며 공간 필터의 조율 모수는 필터의 차원(dimension)과 패턴 여부를 결정하는 임계치(threshold)이다.

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 case별로 검정 데이터에서 결함 유무를 예측한 결과가 Table 3에 요약되어 있다.

평가에 사용된 측도는 F1 점수(F1 score), 정확도(accuracy), 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, FN은 각각 true positive, true negative, false positive, 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 과정임을 고려하면 당연하다. 따라서 Table 3의 결과 중에서도 재현율(recall)이 전반적으로 가장 높은 계층적 군집분석이 성능이 가장 좋다고 할 수 있다.

Table 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.

Table 3: Mean rate (and its standard error in the parenthesis) of detecting the defective wafer when evaluated in the test data set using three measures. Spatial filtering using average and median is expressed as SF-Ave and SF-Med, respectively. The results are calculated over ten random splits. All values are multiplied by 10^2 .

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)

Table 4: Mean rate (and its standard error in the parenthesis) of recall when evaluated in the test data set. All values are multiplied by 10^2 .

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

훈련과 검정 데이터의 비율이 동일한 case 6의 경우에 한하여 각 패턴별의 결함 탐지 예측 성능이 Table 4의 ‘with’로 표시된 열에 나타나 있다. Table 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 가능할 수 있게 해준다. 결과 중에서 주목할 만한 부분은 굽힘 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%)로 그쳐 허용 가능한 수준이라 판단된다. 이에 반해, 다른 모형들은 특히 굽힘 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.

Table 5: Mean wafer map failure pattern classification rate (and its standard error) for various models. HC stands for hierarchical clustering and RF for random forest. The combined method is composed of de-noising process and for classification. The results are from 10 random splits and all values are multiplied by 10^2 .

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)

4.2. 웨이퍼 결함 패턴의 분류

4.1절에서 결함으로 판정된 웨이퍼는 그 다음 과정으로 어떤 패턴의 결함인가에 대한 분류를 한다. 이 과정에 대한 자세한 내용은 3.2절에 기술되어 있고 그 내용을 Table 1에서 정상 웨이퍼를 제외한 나머지 결함 웨이퍼 데이터에 적용한다. 이를 위해 결함 웨이퍼를 훈련과 검정 데이터로 반반씩 임의로 분할하여 분석을 시행한다. 3.2절에서 언급한 바와 같이 분류의 단계에서는 두 번째의 소음 제거와 분류의 과정을 거치게 된다.

분류 단계에서 본 논문이 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(ϵ), 최소 개체수(\minPts)와 다밀도 패턴을 분리하기 위한 조율 모수인 ξ ($0 < \xi < 1$)의 3개의 조율 모수가 있다. 선형 실험을 통하여 반경은 10으로 고정하였고, 최소 개체수는 3부터 15까지 3 간격으로, ξ 는 0.01부터 0.5까지 0.03 간격으로 탐색한다. SVM의 경우, 조율 모수는 cost 는 2^{-5} 부터 2^{10} 까지, radial basis 커널의 γ 는 0부터 0.05까지 0.005 간격으로 탐색한다.

결함 패턴 분류 분석 평가는 최종 분류 성능을 통해 한다. 분류 성능의 평가는 재현율(recall), 정밀도(precision), F1 점수(F1 score) AUC를 이용한다. 결함의 종류에 따른 표본의 수가 매우 불균형하기 때문에 정확도(accuracy)는 참고 수준으로만 고려한다. 식 (4.1)과 식 (4.2)에 성능 측정에 사용된 기준이 주어졌다. 여기서 TP와 TN은 각각 true positive와 true negative를, FP와 FN은 각각 false positive와 false negative를 나타낸다. 첨자 j 는 j 번째 타입의 불량율, J 는 불량 종류의 전체 개수를 의미한다.

$$F1 = \frac{1}{J} \sum_{j=1}^J F1_j, \quad \text{where } F1_j = \frac{2\text{precision}_j \cdot \text{recall}_j}{\text{precision}_j + \text{recall}_j} = \frac{TP_j}{TP_j + (FP_j + FN_j)/2}, \quad (4.1)$$

$$AUC = \frac{1}{J} \sum_{j=1}^J AUC_j, \quad \text{where } AUC_j = \frac{1}{2} \left(\frac{TP_j}{TP_j + FN_j} + \frac{TN_j}{TN_j + TP_j} \right). \quad (4.2)$$

검정 데이터에서 얻어진 불량 타입에 대한 예측의 결과가 Table 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 논문에서 제안하는 HC를 이용한 소음 제거의 방법이 여러 평가의 기준에 비추어

Table 6: Mean wafer map failure pattern classification rate (and its standard error) for random forest. HC, DBSCAN, and OPTICS are used for the de-noising. The results are from 10 random splits and all values are multiplied by 10^2

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)

Table 7: Confusion matrix (in percent) for wafer map failure pattern classification for HC + RF. The values are averaged over 10 random splits.

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

전반적으로 우수한 결과를 나타낸다. OPTICS로 소음을 제거하고 SVM으로 분류를 하는 경우에는 몇몇 데이터 split의 경우 분류 성능이 떨어져서 precision이나 F1 score를 구하지 못해서 N/A로 표시되어 있다. OPTICS의 성능이 떨어지는 것을 보여주는 또 다른 모습이다.

Table 6의 클래스 별 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 보이거나 F1 점수가 80 미만인 것이 3개로서 HC에 비해 다소 편차가 있는 것을 볼 수 있다. Table 5에서 가장 성능이 우수한 것으로 나타난 HC + RF의 결과를 이용하여 퍼센트로 계산한 혼동 행렬이 Table 7에 나타나 있다. 이 결과는 10개의 값을 평균한 것이다.

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

5. 결론

본 논문은 반도체 웨이퍼의 결함 패턴 탐지와 분류를 위해 계층적 군집 분석을 제안한다. 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. 본 논문에서 제안하는 방안을 여러가지 웨이퍼 사이즈의 데이터에 확장하여 적용할 수 있는 연구를 추후 진행할 계획이다.

References

- Alawieh M, Wang F, and Li X (2016). Identifying systematic spatial failure patterns through wafer clustering. *Volume 2016-July*, pages 910–913.
- Chang CW, Chao TM, Horng JT, Lu CF, and Yeh RH (2012). Development pattern recognition model for the classification of circuit probe wafer maps on semiconductors. *IEEE Transactions on Components, Packaging and Manufacturing Technology*, **2(12)**, 2089–2097.
- Chien CF, Hsu SC, and Chen YJ (2013). A system for online detection and classification of wafer bin map defect patterns for manufacturing intelligence. *International Journal of Production Research*, **51(8)**, 2324–2338.
- Hijmans RJ (2021). Raster: geographic data analysis and modeling. R package version 3.5-11.
- Hsu SC and Chien CF (2007). 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.
- Huang CJ (2002). Application of neural networks and filtered back projection to wafer defect cluster identification. *Proceedings of the 4th International Symposium on Electronic Materials and Packaging*, pages 99–105.
- Huang CJ (2007). Clustered defect detection of high quality chips using self-supervised multilayer perceptron. *Expert Systems with Applications*, **33(4)**, 996–1003.
- Huang CJ, Wang CC, and Wu CF (2002). Image processing techniques for wafer defect cluster identification. *IEEE Design and Test of Computers*, **19(2)**, 44–48.
- Jeong YS, Kim SJ, and Jeong M (2008). Automatic identification of defect patterns in semiconductor wafer maps using spatial correlogram and dynamic time warping. *IEEE Transactions on Semiconductor Manufacturing*, **21(4)**, 625–637.
- 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.
- Kim B, Jeong YS, Tong S, Chang IK, and Jeong MK (2016). Stepdown spatial randomness test for detecting abnormalities in dram wafers 40 with multiple spatial maps. *IEEE Transactions on Semiconductor Manufacturing*, **29(1)**, 57–65.
- Kim J, Lee Y, and Kim H (2018). Detection and clustering of mixed-type defect patterns in wafer bin maps. *IIEE Transactions*, **50(2)**, 99–111.
- Li TS and Huang CL (2009). Defect spatial pattern recognition using a hybrid som-svm approach in semiconductor manufacturing. *Expert Systems with Applications*, **36(1)**, 374–385.
- Wang CH (2008). Recognition of semiconductor defect patterns using spatial filtering and spectral clustering.

- Expert Systems with Applications*, **34(3)**, 1914–1923.
- Wang CH (2009). Separation of composite defect patterns on wafer bin 42 map using support vector clustering. *Expert Systems with Applications*, **36(2 PART 1)**, 2554–2561.
- Wang CH, Kuo W, and Bensmail H (2006a). Detection and classification of defect patterns on semiconductor wafers. *IIE Transactions (Institute of Industrial Engineers)*, **38(12)**, 1059–1068.
- Wang CH, Wang SJ, and Lee WD (2006b). Automatic identification of spatial defect patterns for semiconductor manufacturing. *International Journal of Production Research*, **44(23)**, 5169–5185.
- 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.
- Yu J and Lu X (2016). Wafer map defect detection and recognition using joint local and nonlocal linear discriminant analysis. *IEEE Transactions on Semiconductor Manufacturing*, **29(1)**, 33–43.
- Yuan T, Bae S, and Park, J. (2010). Bayesian spatial defect pattern recognition in semiconductor fabrication using support vector clustering. *International Journal of Advanced Manufacturing Technology*, **51(5-8)**, 671–683.

Received February 22, 2022; Revised March 18, 2022; Accepted March 20, 2022

계층적 군집분석을 이용한 반도체 웨이퍼의 불량 및 불량 패턴 탐지

정주원^a, 정윤서^{1,a}

^a고려대학교 데이터 통계학과

요 약

반도체는 제조 공정이 복잡하고 길어 결함이 발생될 때 빠른 탐지와 조치가 이뤄져야 결함으로 인한 손실을 최소화할 수 있다. 테스트 공정을 거쳐 구성된 웨이퍼 빈 맵(WBM)의 체계적인 패턴을 탐지하고 분류함으로써 문제의 원인을 유추할 수 있다. 이 작업은 수작업으로 이뤄지기 때문에 대량의 웨이퍼를 단 시간에 처리하는 데 한계가 있다. 본 논문은 웨이퍼 빈 맵의 정상 여부를 구분하기 위해 계층적 군집 분석을 활용한 새로운 결함 패턴 탐지 방법을 제시한다. 제시하는 방법은 여러 장점이 있다. 군집의 수를 알 필요가 없으며 군집분석의 조율 모수가 적고 직관적이다. 동일한 크기의 웨이퍼와 다이(die)에서는 동일한 조율 모수를 가지므로 대량의 웨이퍼도 빠르게 결함을 탐지할 수 있다. 소량의 결함 데이터만 있어도 그리고 데이터의 결함 비율을 가정하지 않더라도 기계학습 모형을 훈련할 수 있다. 제조 특성상 결함 데이터는 구하기 어렵고 결함의 비율이 수시로 바뀔 수 있기 때문에 필요하다. 또한 신규 패턴 발생시에도 안정적으로 탐지한다. 대만 반도체 기업에서 공개한 실제 웨이퍼 빈 맵 데이터(WM-811K)로 실험하였다. 계층적 군집 분석을 이용한 결함 패턴 탐지는 불량률의 재현율이 96.31%로 기존의 공간 필터(spatial filter)보다 우수함을 보여준다. 결함 분류는 혼합 유형에 장점이 있는 계층적 군집 분석을 그대로 사용한다. 직선형과 곡선형의 긁힘(scratch) 결함의 특징에 각각 주성분 분석의 고유값과 2차 다항식의 결정계수를 이용하고 랜덤 포레스트 분류기를 이용한다.

주요용어: 웨이퍼 빈 맵, 계층적 군집 분석, 결함 패턴 탐지, 결함 패턴 분류

이 논문은 2021년도 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임 (2021R1F1A1062347). 또한 고려대학교의 지원을 받아 수행된 연구임 (K2122591).

¹교신저자: (02841), 서울특별시 성북구 안암로 145, 고려대학교 통계학과, E-mail: yoons77@korea.ac.kr