



(19) 대한민국특허청(KR)  
(12) 등록특허공보(B1)

(45) 공고일자 2017년06월09일  
(11) 등록번호 10-1744194  
(24) 등록일자 2017년05월31일

(51) 국제특허분류(Int. Cl.)  
H01L 21/66 (2006.01) G01N 21/88 (2006.01)  
G01N 21/95 (2006.01)  
(52) CPC특허분류  
H01L 22/30 (2013.01)  
G01N 21/88 (2013.01)  
(21) 출원번호 10-2016-0105665  
(22) 출원일자 2016년08월19일  
심사청구일자 2016년08월19일  
(56) 선행기술조사문헌  
US20160148850 A1\*  
JP5715873 B2\*  
JP5719760 B2  
\*는 심사관에 의하여 인용된 문헌

(73) 특허권자  
인하대학교 산학협력단  
인천광역시 남구 인하로 100, 인하대학교 (용현동)  
(72) 발명자  
한영신  
인천광역시 남동구 백범로124번길 43, 201동 606호 (만수동, 주공아파트)  
김재권  
인천광역시 계양구 효서로 115, 1동 502호(효성동, 미도아파트)  
(74) 대리인  
양성보

전체 청구항 수 : 총 3 항

심사관 : 홍종선


(54) 발명의 명칭 반도체 FAB 제조공정에서 유클리드 거리를 활용한 웨이퍼 자동 불량 검사 분류 예측 장치 및 방법

(57) 요약

반도체 FAB 제조공정에서 유클리드 거리를 활용한 웨이퍼 자동 불량 검사 분류 예측 장치 및 방법이 제시된다. 본 발명에서 제안하는 웨이퍼 자동 불량 검사 분류 예측 장치는 반도체 FAB 제조공정에서의 센서로부터 획득된 데이터를 분석하는 데이터 전처리부, 상기 데이터 전처리부로부터 데이터를 분석을 통해 선택된 특징들을 입력

(뒷면에 계속)

대표도 - 도1



받아 상기 특징들에 대해 학습 데이터를 준비하고, 상기 학습 데이터를 학습하여 자동 불량 분류 예측모델을 생성하는 분류 예측부를 포함하고, 상기 데이터 전처리부는 상기 센서로부터 획득된 데이터에서 불필요한 데이터를 제거하는 데이터 클리닝부, 상기 데이터 클리닝부로부터 전송 받은 데이터에 관해 반도체의 양품 클래스 및 불량 클래스의 균형을 맞추기 위해 오버 샘플링을 수행하는 데이터 오버 샘플링부, 상기 반도체의 양품 클래스 및 불량 클래스에 대한 평균값 및 상기 반도체의 양품 클래스 및 불량 클래스 각각의 열에 대한 표준편차값을 계산하고, 상기 평균값 및 상기 표준편차값을 이용하여 유클리드 거리를 계산하고, 계산된 유클리드 거리에 기반하여 분류 예측에 필요한 데이터를 선택하는 유클리드 거리 기반 특징 선택부를 포함한다.

(52) CPC특허분류

*G01N 21/9501* (2013.01)

*H01L 22/12* (2013.01)

*H01L 22/20* (2013.01)

## 명세서

### 청구범위

#### 청구항 1

웨이퍼 자동 불량 검사 분류 예측 장치에 있어서,

반도체 FAB 제조공정에서의 센서로부터 획득된 데이터를 분석하는 데이터 전처리부; 및

상기 데이터 전처리부로부터 데이터를 분석을 통해 선택된 특징들을 입력 받아 상기 특징들에 대해 학습 데이터를 준비하고, 뉴럴 네트워크 기반의 분류 알고리즘을 적용하여 상기 학습 데이터를 학습하여 자동 불량 분류 예측모델을 생성하는 분류 예측부

를 포함하고,

상기 데이터 전처리부는,

상기 센서로부터 획득된 데이터에서 불필요한 데이터를 제거하는 데이터 클리닝부;

상기 데이터 클리닝부로부터 전송 받은 데이터에 관해 반도체의 양품 클래스 및 불량 클래스의 균형을 맞추기 위해 오버 샘플링을 수행하는 데이터 오버 샘플링부; 및

상기 반도체의 양품 클래스 및 불량 클래스에 대한 평균값 및 상기 반도체의 양품 클래스 및 불량 클래스 각각의 열에 대한 표준편차값을 계산하고, 상기 평균값 및 상기 표준편차값을 이용하여 유클리드 거리를 계산하고, 계산된 유클리드 거리에 기반하여 양품 클래스 및 불량 클래스 분류 예측에 필요한 데이터를 선택하는 유클리드 거리 기반 특징 선택부

를 포함하고,

상기 유클리드 거리 기반 특징 선택부는,

상기 반도체의 양품 클래스 및 불량 클래스에 대한 평균값을 계산하고, 상기 계산된 평균값에 대한 소속도 값을 계산하고, 불량 검사 대상 웨이퍼의 양품 클래스 및 불량 클래스 분류를 위한 평균 임계값을 정하고,

상기 반도체의 양품 클래스 및 불량 클래스 각각의 열에 대한 표준편차값을 계산하고, 불량 검사 대상 웨이퍼의 양품 클래스 및 불량 클래스 분류를 위한 표준편차 임계값을 정하고,

상기 평균 임계값 및 표준편차 임계값을 이용하여 유클리드 거리를 계산하는

웨이퍼 자동 불량 검사 분류 예측 장치.

#### 청구항 2

삭제

#### 청구항 3

데이터 전처리부 및 분류 예측부를 포함하는 웨이퍼 자동 불량 검사 분류 예측 장치의 분류 예측 방법에 있어서,

상기 데이터 전처리부가 반도체 FAB 제조공정에서의 센서로부터 획득된 데이터를 분석하는 단계; 및

상기 분류 예측부가 상기 데이터 전처리부로부터 데이터를 분석을 통해 선택된 특징들을 입력 받아 상기 특징들에 대해 학습 데이터를 준비하고, 뉴럴 네트워크 기반의 분류 알고리즘을 적용하여 상기 학습 데이터를 학습하여 예측모델을 생성하는 단계

를 포함하고,

데이터 클리닝부, 데이터 오버 샘플링부 및 유클리드 거리 기반 특징 선택부를 포함하는 상기 데이터 전처리부가 반도체 FAB 제조공정에서의 센서로부터 획득된 데이터를 분석하는 단계는,

상기 데이터 클리닝부가 상기 센서로부터 획득된 데이터로부터 불필요한 데이터를 제거하는 단계;

상기 데이터 오버 샘플링부가 상기 데이터 클리닝부로부터 전송 받은 데이터에 관해 반도체의 양품 클래스 및 불량 클래스의 균형을 맞추기 위해 오버 샘플링을 수행하는 단계; 및

상기 유클리드 거리 기반 특징 선택부가 상기 반도체의 양품 클래스 및 불량 클래스에 대한 평균값 및 상기 반도체의 양품 클래스 및 불량 클래스 각각의 열에 대한 표준편차값을 계산하고, 상기 평균값 및 상기 표준편차값을 이용하여 유클리드 거리를 계산하고, 계산된 유클리드 거리에 기반하여 양품 클래스 및 불량 클래스 분류 예측에 필요한 데이터를 선택하는 단계

를 포함하고,

상기 유클리드 거리에 기반하여 분류 예측에 필요한 데이터를 선택하는 단계는,

상기 반도체의 양품 클래스 및 불량 클래스에 대한 평균값을 계산하는 단계;

상기 계산된 평균값에 대한 소속도 값을 계산하고, 불량 검사 대상 웨이퍼의 양품 클래스 및 불량 클래스 분류를 위한 평균 임계값을 정하는 단계;

상기 반도체의 양품 클래스 및 불량 클래스 각각의 열에 대한 표준편차값을 계산하고, 불량 검사 대상 웨이퍼의 양품 클래스 및 불량 클래스 분류를 위한 표준편차 임계값을 정하는 단계; 및

상기 평균 임계값 및 표준편차 임계값을 이용하여 유클리드 거리를 계산하는 단계

를 포함하는 웨이퍼 자동 불량 검사 분류 예측 방법.

#### 청구항 4

삭제

#### 청구항 5

제3항에 있어서,

상기 학습 데이터를 학습하여 예측모델을 생성하는 단계는,

상기 데이터 전처리부로부터 데이터를 분석을 통해 유클리드 거리를 기반으로 선택된 특징들을 입력 받아 상기 특징들에 대해 학습 데이터를 준비하는 단계;

상기 학습 데이터를 학습하여 예측모델을 생성하기 위해 뉴럴 네트워크 기반의 분류 알고리즘을 적용하여 학습하는 단계; 및

새로운 데이터를 입력 받을 경우, 상기 학습을 통해 불량 검사 대상 웨이퍼의 양품 클래스 및 불량 클래스에 대한 자동 불량 분류 예측모델을 생성하는 단계

를 포함하는 웨이퍼 자동 불량 검사 분류 예측 방법.

### 발명의 설명

#### 기술 분야

[0001] 본 발명은 반도체 FAB 제조공정에서 유클리드 거리를 활용한 웨이퍼 자동 불량 검사 분류 예측 장치 및 방법에 관한 것이다.

#### 배경 기술

[0002] 반도체는 다양한 전자제품에 필수적인 요소이기 때문에 반도체의 생산성 향상을 위해서는 설비진단, 공정관리, 수율 안정화 등을 향상시키고 첨단 공정기술을 개발하기 위한 노력이 필요하며, 그 중에서 제조 공정은 매우 복잡한 공정을 거쳐야 하며, 반도체 산업 중에서도 가장 중요하다. 복잡한 반도체의 웨이퍼 FAB 제조 공정은 일부 결함이 발생할 수 있으며, 불량 유형에 따라 최종 제품 생산에 실패를 할 수 있다.

[0003] 이러한 문제점으로 인해 반도체 FAB 제조공정에서의 웨이퍼 오류검출 및 분류 기법이 필요하며, 제품의 최종 생산되기 이전의 자동 불량 검출 방법을 통해 반도체의 품질과 신뢰성을 향상시킬 수 있다. 기존의 자동 불량 검

출 방법들은 입력된 반도체의 데이터를 바탕으로 웨이퍼의 불량 유무를 분류 예측할 수 있는 방법으로서 반도체 FAB 제조공정에서 많이 활용되고 있다.

[0004] 그러나 이러한 분류 모델을 생성하기 위해서는 입력 데이터를 구성하기 위한 특징 추출이 매우 중요하다. 특징 추출 방법에 따라 잘못 선택할 경우, 불량 검사의 오류율이 높아지고 불필요한 비용이 소모된다. 이러한 특징 추출은 데이터의 특성을 분석하여 불필요한 특징들을 제거하고, 필요한 특징들을 선택하여 분류 예측의 정확도를 높일 수 있다.

[0005] 이와 같이 반도체 FAB 제조공정에 있어서 웨이퍼 자동 불량 검사 분류 예측방법에서의 특징 선택 방법은 매우 중요하지만, 효율적인 특징 선택방법이 어렵다. 기존의 방법은 사람이 직접 웨이퍼를 검사하는 방법과 통계적인 방법으로 사용했지만, 자동 불량 분류 예측을 위해서는 특징 선택에 따른 정확도를 높이고 분류의 오류율을 최대한 개선하여 비용을 줄일 수 있는 방안을 필요로 한다.

[0006] 그 중에서 특히, 반도체 FAB 제조공정의 웨이퍼 결함 장치 센서로부터 획득된 데이터는 분석이 매우 어렵기 때문에 제대로 분석하지 못할 경우 많은 비용이 소모된다. 또한, 특징 선택에 따르는 분류 예측 성능에 대해서도 비용이 소모되기 때문에 반도체 FAB 제조공정의 웨이퍼 결함 장치 센서로부터 획득된 데이터를 활용한 효율적인 자동 불량 검사 분류 예측 방법을 고려해야 하는 문제점이 있다.

## 발명의 내용

### 해결하려는 과제

[0007] 본 발명이 이루고자 하는 기술적 과제는 반도체 FAB 제조 공정에서 유클리드 거리를 활용하여 웨이퍼 자동 불량 검사 분류에 활용하고 자동적인 불량 검사 장치 및 그 분류 방법을 제공함으로써, 저비용으로 FAB 제조 공정에서 불량 검사의 분류 성능을 높이기 위한 방법 및 장치를 제공하는데 있다.

### 과제의 해결 수단

[0008] 일 측면에 있어서, 본 발명에서 제안하는 웨이퍼 자동 불량 검사 분류 예측 장치는 반도체 FAB 제조공정에서의 센서로부터 획득된 데이터를 분석하는 데이터 전처리부, 상기 데이터 전처리부로부터 데이터를 분석을 통해 선택된 특징들을 입력 받아 상기 특징들에 대해 학습 데이터를 준비하고, 상기 학습 데이터를 학습하여 자동 불량 분류 예측모델을 생성하는 분류 예측부를 포함한다.

[0009] 상기 데이터 전처리부는 상기 센서로부터 획득된 데이터에서 불필요한 데이터를 제거하는 데이터 클리닝부, 상기 데이터 클리닝부로부터 전송 받은 데이터에 관해 반도체의 양품 클래스 및 불량 클래스의 균형을 맞추기 위해 오버 샘플링을 수행하는 데이터 오버 샘플링부, 상기 반도체의 양품 클래스 및 불량 클래스에 대한 평균값 및 상기 반도체의 양품 클래스 및 불량 클래스 각각의 열에 대한 표준편차값을 계산하고, 상기 평균값 및 상기 표준편차값을 이용하여 유클리드 거리를 계산하고, 계산된 유클리드 거리에 기반하여 분류 예측에 필요한 데이터를 선택하는 유클리드 거리 기반 특징 선택부를 포함한다.

[0010] 상기 유클리드 거리 기반 특징 선택부는 상기 반도체의 양품 클래스 및 불량 클래스에 대한 평균값을 계산하고, 상기 계산된 평균값에 대한 소속도 값을 계산하고, 불량 검사 대상 웨이퍼의 양품 클래스 및 불량 클래스 분류를 위한 평균 임계값을 정하고, 상기 반도체의 양품 클래스 및 불량 클래스 각각의 열에 대한 표준편차값을 계산하고, 불량 검사 대상 웨이퍼의 양품 클래스 및 불량 클래스 분류를 위한 표준편차 임계값을 정하고, 상기 평균 임계값 및 표준편차 임계값을 이용하여 유클리드 거리를 계산한다.

[0011] 또 다른 일 측면에 있어서, 본 발명에서 제안하는 웨이퍼 자동 불량 검사 분류 예측 방법은 데이터 전처리부가 반도체 FAB 제조공정에서의 센서로부터 획득된 데이터를 분석하는 단계, 분류 예측부가 상기 데이터 전처리부로부터 데이터를 분석을 통해 선택된 특징들을 입력 받아 상기 특징들에 대해 학습 데이터를 준비하고, 상기 학습 데이터를 학습하여 예측모델을 생성하는 단계를 포함한다.

[0012] 상기 데이터 전처리부가 반도체 FAB 제조공정에서의 센서로부터 획득된 데이터를 분석하는 단계는 데이터 클리닝부가 상기 센서로부터 획득된 데이터로부터 불필요한 데이터를 제거하는 단계, 데이터 오버 샘플링부가 상기 데이터 클리닝부로부터 전송 받은 데이터에 관해 반도체의 양품 클래스 및 불량 클래스의 균형을 맞추기 위해 오버 샘플링을 수행하는 단계, 유클리드 거리 기반 특징 선택부가 상기 반도체의 양품 클래스 및 불량 클래스에 대한 평균값 및 상기 반도체의 양품 클래스 및 불량 클래스 각각의 열에 대한 표준편차값을 계산하고, 상기 평균값 및 상기 표준편차값을 이용하여 유클리드 거리를 계산하고, 계산된 유클리드 거리에 기반하여 분류 예측에

필요한 데이터를 선택하는 단계를 포함한다.

[0013] 상기 유클리드 거리에 기반하여 분류 예측에 필요한 데이터를 선택하는 단계는 상기 반도체의 양품 클래스 및 불량 클래스에 대한 평균값을 계산하는 단계, 상기 계산된 평균값에 대한 소속도 값을 계산하고, 불량 검사 대상 웨이퍼의 양품 클래스 및 불량 클래스 분류를 위한 평균 임계값을 정하는 단계, 상기 반도체의 양품 클래스 및 불량 클래스 각각의 열에 대한 표준편차값을 계산하고, 불량 검사 대상 웨이퍼의 양품 클래스 및 불량 클래스 분류를 위한 표준편차 임계값을 정하는 단계, 상기 평균 임계값 및 표준편차 임계값을 이용하여 유클리드 거리를 계산하는 단계를 포함한다.

[0014] 상기 학습 데이터를 학습하여 예측모델을 생성하는 단계는 상기 데이터 전처리부로부터 데이터를 분석을 통해 유클리드 거리를 기반으로 선택된 특징들을 입력 받아 상기 특징들에 대해 학습 데이터를 준비하는 단계, 상기 학습 데이터를 학습하여 예측모델을 생성하기 위해 뉴럴 네트워크 기반의 분류 알고리즘을 적용하여 학습하는 단계, 새로운 데이터를 입력 받을 경우, 상기 학습을 통해 불량 검사 대상 웨이퍼의 양품 클래스 및 불량 클래스에 대한 자동 불량 분류 예측모델을 생성하는 단계를 포함한다.

### 발명의 효과

[0015] 본 발명의 실시예들에 따르면 웨이퍼 결함 장치센서로부터 획득된 데이터를 유클리드 거리(Euclidean Distance)를 이용하여 특징들을 선택하고 자동분류가 가능하여 반도체 웨이퍼의 자동 검출 성능을 높이고 비용을 감소시킬 수 있는 웨이퍼 결함 장치 센서로부터 데이터를 획득할 수 있다. 반도체 FAB 제조공정에서 웨이퍼 결함 장치 센서에서 획득된 데이터를 활용한 자동 불량 검사 분류 예측 방법과 그 분류 예측을 하는데 있어서, 불필요한 데이터를 제외하고 필요한 데이터를 선택하게 해주는 유클리드 거리기반의 특징 선택 방법은 분류 예측의 성능을 높일 수 있기 때문에 비용이익의 장점을 충분히 살릴 수가 있고 불량 웨이퍼 처리 비용에 따르는 수익성도 우수하다. 또한, 반도체 FAB 제조공정에서 자동 분류 예측을 통해서 웨이퍼의 불량 수율에 대해 정확하게 예측을 할 수 있기 때문에 컴퓨팅의 신뢰도를 높일 수 있다.

### 도면의 간단한 설명

[0016] 도 1은 본 발명의 일 실시예에 따른 반도체 FAB 제조공정에서 유클리드 거리를 활용한 웨이퍼 자동 불량 검사 분류 예측 장치의 구성을 나타내는 도면이다.

도 2는 본 발명의 일 실시예에 따른 데이터 전처리부의 구성을 나타내는 도면이다.

도 3은 본 발명의 일 실시예에 따른 반도체 FAB 제조공정에서 유클리드 거리를 활용한 웨이퍼 자동 불량 검사 분류 예측 방법을 설명하기 위한 흐름도이다.

도 4는 본 발명의 일 실시예에 따른 유클리드 거리에 기반하여 분류 예측에 필요한 데이터를 선택하는 과정을 설명하기 위한 흐름도이다.

도 5는 본 발명의 일 실시예에 따른 학습 데이터를 학습하여 자동 불량 분류 예측모델을 생성하는 과정을 설명하기 위한 흐름도이다.

도 6은 본 발명의 일 실시예에 따른 일반적인 뉴럴 네트워크 흐름도이다.

### 발명을 실시하기 위한 구체적인 내용

[0017] 이하, 본 발명의 실시 예를 첨부된 도면을 참조하여 상세하게 설명한다.

[0018] 도 1은 본 발명의 일 실시예에 따른 반도체 FAB 제조공정에서 유클리드 거리를 활용한 웨이퍼 자동 불량 검사 분류 예측 장치의 구성을 나타내는 도면이다.

[0019] 제안하는 반도체 FAB 제조공정에서 유클리드 거리를 활용한 웨이퍼 자동 불량 검사 분류 예측 장치(100)는 데이터 전처리부(110), 분류 예측부(120)를 포함한다.

[0020] 자동 불량 검사 분류 예측 장치(100)는 데이터 전처리부(110)를 통해 FAB 제조공정에서의 반도체 센싱 데이터(200)를 입력 받아 반도체와 관련된 데이터를 분석한다.

[0021] 데이터 전처리부(110)는 데이터 클리닝부, 데이터 오버 샘플링부, 유클리드 거리 기반 특징 선택부를 포함한다.

- [0022] 데이터 클리닝부는 반도체 데이터로부터 불필요한 데이터를 제거하고, 데이터 오버 샘플링부는 데이터 클리닝부로부터 전송 받은 데이터에 대해 균형을 맞추기 위한 데이터 오버 샘플링을 수행하고, 거리 기반 특징 선택부는 분류 예측에 필요한 데이터를 선택할 수 있는 유클리드 거리에 기반하여 특징들을 선택한다.
- [0023] 여기서, 유클리드 거리 기반 특징 선택 부는 각 클래스에 대해 평균값을 계산하고, 계산된 평균값에 대해 소속도 값을 계산한 이후에, 표준 편차값을 계산한다. 그리고, 평균값과 표준편차값을 이용하여 유클리드 거리를 계산한 후, 기술통계를 이용하여 신뢰도 수준에 준하는 평균보다 높은 특징들을 선택한다. 도 2를 참조하여 데이터 전처리부(110)에 대해 더욱 상세히 설명한다.
- [0024] 분류 예측부(120)는 상기 분석된 데이터에 대해 분류 예측 모델을 생성한다.
- [0025] 분류 예측부(120)는 데이터 전처리부(110)로부터 데이터를 분석을 통해 선택된 특징들을 입력 받아 상기 특징들에 대해 학습 데이터를 준비하고, 상기 학습 데이터를 학습하여 자동 불량 분류 예측모델을 생성한다.
- [0026] 분류 예측부(120)는 선택된 특징들에 관한 데이터에 대해 학습 데이터를 준비한 후, 뉴럴 네트워크 기반의 분류알고리즘을 적용하여 자동 불량 분류 예측 모델을 생성한다.
- [0027] 도 2는 본 발명의 일 실시예에 따른 데이터 전처리부의 구성을 나타내는 도면이다.
- [0028] 데이터 전처리부(110)는 데이터 클리닝부(111), 데이터 오버 샘플링부(112), 유클리드 거리 기반 특징 선택부(113)를 포함한다.
- [0029] 데이터 클리닝부(111)는 센서로부터 획득된 데이터에서 불필요한 데이터를 제거하고, 입력 받은 반도체 센싱 데이터 중에서 잘못 입력된 값을 제거한다. 그리고, 누락된 데이터에 대해 삭제처리를 하고, 해당되는 데이터의 행과 열을 모두 삭제한다.
- [0030] 데이터 오버 샘플링부(112)는 데이터 클리닝부로부터 전송 받은 데이터에 관해 반도체의 양품 클래스 및 불량 클래스의 균형을 맞추기 위해 오버 샘플링을 수행한다. 반도체의 양품 및 불량 결과 클래스의 불균형을 해결하기 위한 데이터 오버 샘플링부(112)는 데이터 클리닝부(111)로부터 데이터를 전송 받아 반도체 센싱 데이터 중에서 양품 및 불량 클래스에서 불균형이 존재하기 때문에, 예측모델의 성능을 높이기 위해 불균형을 해소한다.
- [0031] 예를 들어, 오버 샘플링은 양품 및 불량을 포함하는 모든 클래스 중에서, 상대적으로 적은 불량 클래스, 다시 말해 낮은 클래스의 행의 개수를 높은 클래스의 행의 개수로 맞추기 위한 방법이며, 적은 클래스의 행들 중에서 임의로 추출하여 클래스가 많은 양품 클래스, 다시 말해 높은 클래스의 행의 개수가 될 때까지 오버 샘플링 하여 반도체 센싱 데이터를 생성한다.
- [0032] 유클리드 거리 기반 특징 선택부(113)는 반도체의 양품 클래스 및 불량 클래스에 대한 평균값 및 상기 반도체의 양품 클래스 및 불량 클래스 각각의 열에 대한 표준편차값을 계산한다. 그리고, 상기 평균값 및 상기 표준편차값을 이용하여 유클리드 거리를 계산하고, 계산된 유클리드 거리에 기반하여 분류 예측에 필요한 데이터를 선택한다.
- [0033] 다시 말해, 유클리드 거리 기반 특징 선택부(113)는 반도체의 양품 클래스 및 불량 클래스에 대한 평균값을 계산하고, 상기 계산된 평균값에 대한 소속도 값을 계산하여 불량 검사 대상 웨이퍼의 양품 클래스 및 불량 클래스 분류를 위한 평균 임계값을 정한다.
- [0034] 이후, 반도체의 양품 클래스 및 불량 클래스 각각의 열에 대한 표준편차값을 계산하고, 불량 검사 대상 웨이퍼의 양품 클래스 및 불량 클래스 분류를 위한 표준편차 임계값을 정한다.
- [0035] 그리고, 평균 임계값 및 표준편차 임계값을 이용하여 유클리드 거리를 계산한다. 도 3 내지 도 4의 흐름도를 참조하여 유클리드 거리를 활용한 웨이퍼 자동 불량 검사 분류 예측 방법에 대해 더욱 상세히 설명한다.
- [0036] 도 3은 본 발명의 일 실시예에 따른 반도체 FAB 제조공정에서 유클리드 거리를 활용한 웨이퍼 자동 불량 검사 분류 예측 방법을 설명하기 위한 흐름도이다.
- [0037] 제안하는 유클리드 거리를 활용한 웨이퍼 자동 불량 검사 분류 예측 방법은 데이터 전처리부가 반도체 FAB 제조 공정에서의 센서로부터 획득된 데이터를 분석하는 단계(310), 분류 예측부가 상기 데이터 전처리부로부터 데이

터를 분석을 통해 선택된 특징들을 입력 받아 상기 특징들에 대해 학습 데이터를 준비하고, 상기 학습 데이터를 학습하여 예측모델을 생성하는 단계(320)를 포함한다.

[0038] 상기 데이터 전처리부가 반도체 FAB 제조공정에서의 센서로부터 획득된 데이터를 분석하는 단계(310)는 데이터 클리닝부가 상기 센서로부터 획득된 데이터로부터 불필요한 데이터를 제거하는 단계(311), 데이터 오버 샘플링부가 상기 데이터 클리닝부로부터 전송 받은 데이터에 관해 반도체의 양품 클래스 및 불량 클래스의 균형을 맞추기 위해 오버 샘플링을 수행하는 단계(312), 유클리드 거리 기반 특징 선택부가 상기 반도체의 양품 클래스 및 불량 클래스에 대한 평균값 및 상기 반도체의 양품 클래스 및 불량 클래스 각각의 열에 대한 표준편차값을 계산하고, 상기 평균값 및 상기 표준편차값을 이용하여 유클리드 거리를 계산하고, 계산된 유클리드 거리에 기반하여 분류 예측에 필요한 데이터를 선택하는 단계(313)를 포함한다. 도 4를 참조하여 유클리드 거리에 기반하여 분류 예측에 필요한 데이터를 선택하는 과정을 더욱 상세히 설명한다.

[0039] 도 4는 본 발명의 일 실시예에 따른 유클리드 거리에 기반하여 분류 예측에 필요한 데이터를 선택하는 과정을 설명하기 위한 흐름도이다.

[0040] 유클리드 거리에 기반하여 분류 예측에 필요한 데이터를 선택하는 과정은 상기 반도체의 양품 클래스 및 불량 클래스에 대한 평균값을 계산하는 단계(410), 상기 계산된 평균값에 대한 소속도 값을 계산하고, 불량 검사 대상 웨이퍼의 양품 클래스 및 불량 클래스 분류를 위한 평균 임계값을 정하는 단계(420), 상기 반도체의 양품 클래스 및 불량 클래스 각각의 열에 대한 표준편차값을 계산하고, 불량 검사 대상 웨이퍼의 양품 클래스 및 불량 클래스 분류를 위한 표준편차 임계값을 정하는 단계(430), 상기 평균 임계값 및 표준편차 임계값을 이용하여 유클리드 거리를 계산하는 단계(440)를 포함한다.

[0041] 단계(410)에서, 유클리드 거리 기반 특징선택부(113)는 데이터 오버 샘플링부(112)로부터 반도체 센싱 데이터의 오버샘플링이 완료된 데이터를 전송 받아 반도체 센싱 데이터 중에서 특징들을 선택하여 데이터 열을 결정한다.

[0042] 여기서, 데이터 열을 결정하기 위해 각각의 클래스(양품 및 불량)에 대하여 데이터의 각 열마다의 평균값, 다시 말해 MAV(Mean Absolute Value)를 계산한다. MAV를 계산하는 방법은 수학적 식 1과 같다.

$$MAV_{feature(N)} = \frac{1}{n} \sum_{k=1}^n |x_k| \quad \text{수학적 식 (1)}$$

[0044] 여기서, feature(N)은 해당되는 열, n은 데이터에서 행의 개수, x는 센싱 데이터를 나타낸다.

[0045] 단계(420)에서, 계산된 MAV에 대해 소속도 값을 계산한다. 소속도 값을 계산하는 방법은 수학적 식 2와 같다.

$$\begin{aligned} A &= 1 / (\max(feature(N)) + (-\min(feature(N)))) \\ B &= 1 + (-(\max(feature(N)) * A)) \\ MAVp(n) &= A * MAV_{feature(N)} + B \end{aligned} \quad \text{수학적 식 (2)}$$

[0047] 여기서, max(feature(N))은 해당되는 열에서의 최대값, min(feature(N))은 최소값이다. 여기서 MAVp(n)은 양품 클래스 및 불량 클래스의 소속값을 의미하며 A, B는 소속값을 계산하기 위한 함수이다. 최종적으로 MAVp(n)을 계산하며, MAVp는 각 양품 클래스의 MAV값의 결과인 MAVpass 와 불량 클래스의 MAV값의 결과인 MAVfail로 구분된다.

[0048] 단계(430)에서, 각각의 클래스(양품 및 불량)에 대하여 데이터의 각 열마다의 표준편차값, 다시 말해 SD (Standard Deviation)를 계산한다. SD를 계산하는 방법은 수학적 식 3과 같다.

$$SD_{feature(N)} = \sigma = \sqrt{\frac{\sum_{k=1}^n (x_k - m)^2}{n}} = \sqrt{\frac{\sum_{k=1}^n x_k^2}{n} - m^2} \quad \text{수학적 식 (3)}$$

[0050] 여기서, n은 feature(N)에 해당되는 행의 개수, 최종적으로 SDfeature(n)은 양품 클래스의 SD값인 SDpass 와 불량 클래스의 SD값인 SDpail로 구분된다.

[0051] 단계(440)에서, 계산된 SD 및 MAV값을 이용하여 유클리드 거리를 계산한다. 유클리드 거리를 계산하는 방법은 수학적 식 4와 같다.

$$EuclideanDistance = \sqrt{(MAV_{Pass} - MAV_{Fail})^2 + (SD_{Pass} - SD_{Fail})^2} \text{ 수학식 (4)}$$

여기서, 각 특징들(feature)의 계산이 완료된다. 또한, 계산된 유클리드 거리 값 중에서 기술통계를 이용하여 신뢰수준이 95%에 준하는 평균보다 높은 특징들을 선택하는 단계(450)를 더 포함할 수 있다.

본 발명의 일 실시예에 따른 유클리드 거리에 기반하여 분류 예측에 필요한 데이터를 선택하는 방법은 센서로부터 모든 시점의 데이터를 수집하고, 상기 모든 시점의 데이터 중에서 양품 클래스를 포함하는 데이터들을 MAV 및 SD로 계산한 이후에 제1 지점을 정한다. 그리고, 불량 클래스를 포함하는 데이터들을 MAV 및 SD로 계산한 이후에 제2 지점을 정하고, 제1 지점 및 제2 지점 사이의 거리를 유클리드 거리를 이용하여 측정하는 방법이다. 다시 말해 본 발명의 일 실시예에 따른 유클리드 거리에 기반하여 분류 예측에 필요한 데이터를 선택하는 방법은 양품 클래스 및 불량 클래스의 시점에 따라 유클리드 거리를 적용한다.

도 5는 본 발명의 일 실시예에 따른 학습 데이터를 학습하여 자동 불량 분류 예측모델을 생성하는 과정을 설명하기 위한 흐름도이다.

학습 데이터를 학습하여 예측모델을 생성하는 단계(320)는 데이터 전처리부로부터 데이터를 분석을 통해 유클리드 거리를 기반으로 선택된 특징들을 입력 받아 상기 특징들에 대해 학습 데이터를 준비하는 단계(510), 상기 학습 데이터를 학습하여 예측모델을 생성하기 위해 뉴럴 네트워크 기반의 분류 알고리즘을 적용하여 학습하는 단계(520), 새로운 데이터를 입력 받을 경우, 상기 학습을 통해 불량 검사 대상 웨이퍼의 양품 클래스 및 불량 클래스에 대한 자동 불량 분류 예측모델을 생성하는 단계(530)를 포함한다.

단계(510)에서, 분류 예측부(120)를 통해 분류 예측 모델을 생성하기 위해, 데이터 전처리부(110)로부터 특징들을 할당 받은 후, 선택된 특징들의 데이터에 대해서 학습 데이터를 준비한다. 여기서, 전체의 학습 데이터들 중에서 전체 중에서 70%의 데이터를 이용하여 단계(520)으로 전송하여 예측모델을 생성하며 나머지 30%의 데이터를 이용하여 단계(530)으로 전송하여 검증으로 이용한다.

반도체 데이터는 측정 장비에 포함되는 센서에 따라 다르지만, 본 발명의 실시예에 따른 웨이퍼 자동 불량 검사 분류 예측 장치에서 사용되는 센서는 590개의 특징을 추출할 수 있다. 이 중에서 양품 클래스 및 불량 클래스에 대한 판별을 위한 특징을 추출하기 위해 기술통계, 다시 말해 유클리드 거리를 사용한다. 그리고, 추출된 특징들을 바탕으로 뉴럴네트워크 기반 분류알고리즘을 적용한다.

본 발명의 실시예에 따른 뉴럴네트워크 기반 분류알고리즘은 종래기술에서 육안으로 직접 구분하는 방법보다 데이터 획득 시 보다 빠르게 판별할 수 있다. 센서를 통해 추출된 특징들의 데이터는 복잡하고 비선형적인 구조를 가지고 있기 때문에 복잡한 구조를 학습하기 위해 뉴럴네트워크를 사용한다.

따라서 뉴럴네트워크 기반 분류알고리즘은 센서로부터 획득되는 복잡하고 비선형적인 데이터에 대해 학습이 용이하며, 종래기술의 웨이퍼 이미지를 육안으로 검증하는 것에 비해 빠르게 검증할 수 있다. 또한, 뉴럴네트워크만을 이용했던 종래기술에서는 양품 클래스 및 불량 클래스의 분류예측에 있어서 불필요한 특징을 사용했기 때문에 정확도가 떨어질 수 있다. 하지만, 본 발명에서 제안하는 방법은 뉴럴네트워크를 학습하기 이전에 특징들을 선택하고, 그 특징들을 바탕으로 뉴럴네트워크로 학습함으로써 정확도를 향상시킬 수 있다.

도 6는 본 발명의 일 실시예에 따른 뉴럴 네트워크를 도시한 것이다.

도 6를 참조하면, 뉴럴 네트워크(621)는 입력 노드(621a), 숨겨진 노드(621b) 및 출력 노드(621c)를 포함한다.

입력 노드(621a)는  $n(n=1)$ 개의 입력 데이터 값을 포함한다. 숨겨진 노드(621b)는 하나 이상일 수 있다. 출력 노드(621c)는 분류할 클래스(양품, 불량 클래스) 별로 하나의 출력 노드를 포함하며, 입력된 데이터에 대하여 각 클래스(양품, 불량) 별로 출력 값을 출력한다.

이때, 뉴럴 네트워크(621)의 구조는 화살표로 도시된 노드간의 연결 정보와 도시 되지는 않았지만 각 연결에서 사용되는 가중치로 나타낼 수 있다. 이때, 입력 노드(621a), 숨겨진 노드(621b), 출력 노드(621c) 내의 각각의 노드들 간에는 연결이 되지 않고, 입력 노드(621a), 숨겨진 노드(621b), 출력 노드(621c)간에는 완전하게 혹은 부분적으로 연결된다.

도 6를 참조하여 도 5의 단계(520)와 단계(530)의 일 실시 내용을 상세하게 설명한다.

[0066] 단계(520)에서, 학습 데이터를 학습하여 예측모델을 생성하기 위해 뉴럴 네트워크(621)으로 학습한다.

[0067] 여기서, 뉴럴 네트워크 기반으로 학습하기 위해 단계(510)으로부터 준비된 학습 데이터를 이용한다. 단계(510)으로부터 선택된 특징들의 데이터를 입력 노드(621a)으로 지정하며, 각 특징들에 따른 결과값인 양품 및 불량 클래스를 출력 노드(621c)으로 지정한다.

[0068] 각 노드는 화살표로 연결된 이전 노드의 출력을 입력받아 계산하고, 계산 결과를 화살표로 연결된 이후 노드에 출력으로 내보낸다. 이때, 각 노드는 입력된 값을 비선형 함수에 적용하여 출력할 값을 계산한다.

[0069] 단계(530)에서, 학습모델이 생성된 후 새로운 데이터를 입력 받으면, 양품 및 불량을 분류 할 수 있는 자동 불량 분류 예측 모델을 생성한다.

[0070] 여기서, 도 6의 뉴럴 네트워크(621)의 입력 및 출력은 수학적 식 (5)와 같이 정의될 수 있다.

$$\begin{aligned} \mathbf{x} &= (x_1, x_2, \dots, x_k) \\ y_j &= P(y = j | \mathbf{x}), j = 1, \dots, C \\ h^{l+1}_i &= f\left(\sum_{j=1}^{n_l} h^l_j \cdot w_{ji} + b_i\right), i = 1, \dots, n_{l+1}, l = 0, \dots, L-1 \end{aligned}$$

[0071] 수학적 식 5

[0072] 여기서,  $\mathbf{x}$ 는 유클리드 거리 기반 특징선택부(113)로부터 선택된 특징들로 구성되며, 입력 데이터를 의미한다. 또한  $y_j$ 는 입력데이터  $\mathbf{x}$ 가  $j$ 번째 클래스에 속할 확률,  $C$ 는 클래스의 개수를 의미한다. 여기서  $C$ 는 양품 및 불량 클래스인 1(양품)과 -1(불량)로 구성되기 때문에 2이다.  $h^{l+1}_i$ 는  $l$ 번째 숨겨진 노드에서  $j$ 노드번째 노드의 출력 값,  $n_l$ 은  $l$ 번째 숨겨진 노드 레이어의 노드 숫자,  $b_i$ 는  $i$ 번째 노드의 바이어스(bias)값,  $w_{ji}$ 는 이전 레이어  $j$ 번째 노드와 다음 레이어의  $i$ 번째 노드를 연결하는 가중치를 의미하고, 함수  $f$ 는 시그모이드 (sigmoid) 함수를 의미한다.

[0073] 이상에서 설명된 장치는 하드웨어 구성요소, 소프트웨어 구성요소, 및/또는 하드웨어 구성요소 및 소프트웨어 구성요소의 조합으로 구현될 수 있다. 예를 들어, 실시예들에서 설명된 장치 및 구성요소는, 예를 들어, 프로세서, 콘트롤러, 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(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 기술분야에서 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 콘트롤러를 포함할 수 있다. 또한, 병렬 프로세서(parallel processor)와 같은, 다른 처리 구성(processing configuration)도 가능하다.

[0074] 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, 구성요소(component), 물리적 장치, 가상장치(virtual equipment), 컴퓨터 저장 매체 또는 장치에 영구적으로, 또는 일시적으로 구체화(embodiment)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.

[0075] 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 판


독 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), 및 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.

[0076] 이상과 같이 실시예들이 비록 한정된 실시예와 도면에 의해 설명되었으나, 해당 기술분야에서 통상의 지식을 가진 자라면 상기의 기재로부터 다양한 수정 및 변형이 가능하다. 예를 들어, 설명된 기술들이 설명된 방법과 다른 순서로 수행되거나, 및/또는 설명된 시스템, 구조, 장치, 회로 등의 구성요소들이 설명된 방법과 다른 형태로 결합 또는 조합되거나, 다른 구성요소 또는 균등물에 의하여 대치되거나 치환되더라도 적절한 결과가 달성될 수 있다.


[0077] 그러므로, 다른 구현들, 다른 실시예들 및 특허청구범위와 균등한 것들도 후술하는 특허청구범위의 범위에 속한다.

## 도면


### 도면1




### 도면2




도면3



도면4



도면5



도면6

