



공개특허 10-2021-0017651



(19) 대한민국특허청(KR)
(12) 공개특허공보(A)

(11) 공개번호 10-2021-0017651
(43) 공개일자 2021년02월17일

(51) 국제특허분류(Int. Cl.)
G05B 23/02 (2006.01) *H01L 21/66* (2006.01)
H01L 21/67 (2006.01)
(52) CPC특허분류
G05B 23/0281 (2013.01)
G05B 23/0221 (2013.01)
(21) 출원번호 10-2019-0097255
(22) 출원일자 2019년08월09일
심사청구일자 2019년08월09일

(71) 출원인
연세대학교 산학협력단
서울특별시 서대문구 연세로 50 (신촌동, 연세대학교)
(72) 별명자
김창옥
서울특별시 서대문구 연세로 50 연세대학교 제4공학관 1012호
장재연
서울특별시 서대문구 연세로 50 연세대학교 제4공학관 1012호
(74) 대리인
특허법인우인

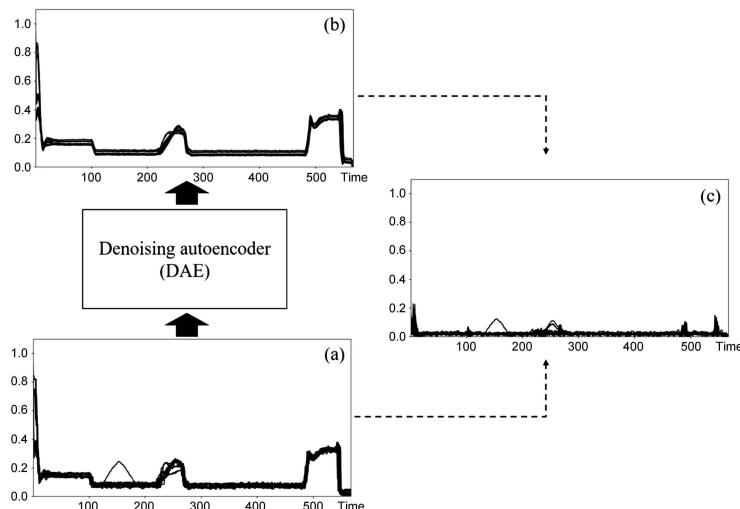
전체 청구항 수 : 총 16 항

(54) 발명의 명칭 반도체 제조 공정에서 고장 검출 및 불량 원인 진단을 위한 방법

(57) 요약

본 실시예들은 수집한 시계열 데이터에서 복원 모델을 통해 복원한 데이터를 제거하여 잔차 데이터를 생성하고, 잔차 데이터에서 센서 노이즈를 제거하여 디노이즈 잔차 데이터를 생성하고, 디노이즈 잔차 데이터를 분석하여 고장을 분류함으로써, 제품 제작 공정에서 불량의 원인이 되는 이상 패턴의 발생 시점 및 이상 패턴의 형태를 시각화할 수 있는 고장 검출 및 분류 장치를 제공한다.

대 표 도



(52) CPC특허분류

G05B 23/0254 (2013.01)*H01L 21/67242* (2013.01)*H01L 22/20* (2013.01)

이 발명을 지원한 국가연구개발사업

과제고유번호 NRF-2016R1A2B4008337

부처명 과학기술정보통신부

과제관리(전문)기관명 한국연구재단

연구사업명 이공분야기초연구사업-중견연구자지원사업

연구과제명 Smart Thinking Factory: 제조 데이터 사이언스를 활용한 지능형 생산관리 기술

기여율 1/1

과제수행기관명 연세대학교 산학협력단

연구기간 2016.06.01 ~ 2019.05.31

명세서

청구범위

청구항 1

고장 검출 및 분류 장치에 의한 고장 검출 및 분류 방법에 있어서,
 제조 공정에서 공정 파라미터 별로 제품을 센싱한 시계열 데이터를 수집하는 단계;
 상기 수집한 시계열 데이터에서 복원 모델을 통해 복원한 데이터를 제거하여 잔차 데이터를 생성하는 단계;
 상기 잔차 데이터에서 센서 노이즈를 제거하여 디노이즈 잔차 데이터를 생성하는 단계; 및
 상기 디노이즈 잔차 데이터를 분석하여 고장을 분류하는 단계
 를 포함하는 고장 검출 및 분류 방법.

청구항 2

제1항에 있어서,

상기 복원 모델은 복수의 레이어가 연결된 네트워크이며, 입력 레이어에 노이즈(noise)를 추가하고, 은닉 레이어의 뉴런 수를 상기 입력 레이어보다 작게 설정해서 차원을 축소하고, 상기 차원이 축소된 은닉 레이어가 상기 입력 레이어와 동일 차원의 출력 레이어에 맵핑되어, 원본 입력을 복원하도록 네트워크를 학습시키는 오토인코더인 것을 특징으로 하는 고장 검출 및 분류 방법.

청구항 3

제1항에 있어서,

상기 잔차 데이터를 생성하는 단계는

제품 간의 변동 및 센서 노이즈를 포함하는 정상 제품에 대한 시계열 데이터 집합을 상기 복원 모델을 통해 학습하고, 상기 복원 모델은 상기 센서 노이즈가 제거된 시계열 데이터를 복원하고, 상기 정상 제품에 대한 시계열 데이터에서 상기 복원한 시계열 데이터를 차감하여, 상기 제품 간의 변동이 제거된 센서 노이즈와 이상 패턴을 갖는 시계열 데이터를 추출하는 것을 특징으로 하는 고장 검출 및 분류 방법.

청구항 4

제1항에 있어서,

상기 디노이즈 잔차 데이터를 생성하는 단계는,

상기 잔차 데이터의 크기를 기준으로 제1 노이즈 임계치를 설정하고, 상기 제1 노이즈 임계치를 이용하여 센서 노이즈를 제거하는 것을 특징으로 하는 고장 검출 및 분류 방법.

청구항 5

제4항에 있어서,

상기 제1 노이즈 임계치는 상기 잔차 데이터에서 시점 별로 산출된 통계적 대표값 및 교차 검증을 통해 상기 통계적 대표값을 변경하는 조정 파라미터로 표현되며, 상기 조정 파라미터는 상기 제1 노이즈 임계치를 초과한 누적 횟수의 비율을 제1 유의수준과 비교한 결과에 따라 설정되는 것을 특징으로 하는 고장 검출 및 분류 방법.

청구항 6

제4항에 있어서,

상기 디노이즈 잔차 데이터를 생성하는 단계는,

상기 잔차 데이터의 지속 시간을 기준으로 제2 노이즈 임계치를 설정하고, 상기 제2 노이즈 임계치를 이용하여

이상 패턴을 검출하는 것을 특징으로 하는 고장 검출 및 분류 방법.

청구항 7

제6항에 있어서,

상기 제2 노이즈 임계치는 상기 잔차 데이터에서 상기 제1 노이즈 임계치를 하나 이상 연속적으로 넘어가는 구간을 검색하고, 상기 넘어가는 구간의 길이를 산출하고 히스토그램으로 변환한 후 제2 유의수준에 대응하는 값으로 설정되는 것을 특징으로 하는 고장 검출 및 분류 방법.

청구항 8

제6항에 있어서,

상기 디노이즈 잔차 데이터를 생성하는 단계는,

상기 제2 노이즈 임계치보다 작은 값을 갖는 상기 잔차 데이터를 제로로 설정하는 것을 특징으로 하는 고장 검출 및 분류 방법.

청구항 9

제1항에 있어서,

상기 디노이즈 잔차 데이터를 분석하여 고장을 분류하는 단계는,

상기 디노이즈 잔차 데이터 간의 거리 기반의 분류 모델을 통해 고장을 분류하며, 상기 디노이즈 잔차 데이터를 상기 분류 모델에 입력하고 상기 분류 모델은 점수를 출력하고, 제3 유의수준에 따라 상기 출력된 점수를 분류 하며,

상기 제3 유의수준은 제품 간의 변동 및 센서 노이즈를 포함하는 정상 제품에 대한 시계열 데이터 집합을 이용하여 설정하는 것을 특징으로 하는 고장 검출 및 분류 방법.

청구항 10

제1항에 있어서,

상기 디노이즈 잔차 데이터를 분석하여 고장을 분류하는 단계 이후에, 상기 디노이즈 잔차 데이터를 분석하여 상기 고장의 원인을 진단하는 단계를 포함하며,

상기 공정 파라미터 별로 상기 디노이즈 잔차 데이터가 0보다 큰 구간을 검색하고, 상기 디노이즈 잔차 데이터의 크기 및 패턴을 기반으로 상기 센싱한 시계열 데이터와 시간적으로 비교하여 이상 패턴의 발생 여부를 판단하고, 상기 이상 패턴의 발생 시점을 출력하는 것을 특징으로 하는 고장 검출 및 분류 방법.

청구항 11

제10항에 있어서,

상기 고장의 원인을 진단하는 단계는,

상기 고장에 대해서 상기 디노이즈 잔차 데이터를 분석하여 고장의 원인이 되는 공정 파라미터, 상기 이상 패턴의 발생 시점, 및 상기 이상 패턴의 형태를 출력하는 것을 특징으로 하는 고장 검출 및 분류 방법.

청구항 12

하나 이상의 프로세서 및 상기 하나 이상의 프로세서에 의해 실행되는 하나 이상의 프로그램을 저장하는 메모리를 포함하는 고장 검출 및 분류 장치에 있어서,

상기 프로세서는 제조 공정에서 공정 파라미터 별로 제품을 센싱한 시계열 데이터를 수집하고,

상기 프로세서는 상기 수집한 시계열 데이터에서 복원 모델을 통해 복원한 데이터를 제거하여 잔차 데이터를 생성하고,

상기 프로세서는 상기 잔차 데이터에서 센서 노이즈를 제거하여 디노이즈 잔차 데이터를 생성하고,

상기 프로세서는 상기 디노이즈 잔차 데이터를 분석하여 고장을 분류하는 것을 특징으로 하는 고장 검출 및 분류 장치.

청구항 13

제12항에 있어서,

상기 프로세서는,

제품 간의 변동 및 센서 노이즈를 포함하는 정상 제품에 대한 시계열 데이터 집합을 상기 복원 모델을 통해 학습하고, 상기 복원 모델은 상기 센서 노이즈가 제거된 시계열 데이터를 복원하고, 상기 정상 제품에 대한 시계열 데이터에서 상기 복원한 시계열 데이터를 차감하여, 상기 제품 간의 변동이 제거된 센서 노이즈와 이상 패턴을 갖는 시계열 데이터를 추출하는 것을 특징으로 하는 고장 검출 및 분류 장치.

청구항 14

제12항에 있어서,

상기 프로세서는,

상기 잔차 데이터의 크기를 기준으로 제1 노이즈 임계치를 설정하고, 상기 제1 노이즈 임계치를 이용하여 센서 노이즈를 제거하고,

상기 잔차 데이터의 지속 시간을 기준으로 제2 노이즈 임계치를 설정하고, 상기 제2 노이즈 임계치를 이용하여 이상 패턴을 검출하는 것을 특징으로 하는 고장 검출 및 분류 장치.

청구항 15

제12항에 있어서,

상기 프로세서는,

상기 디노이즈 잔차 데이터 간의 거리 기반의 분류 모델을 통해 고장을 분류하며, 상기 디노이즈 잔차 데이터를 상기 분류 모델에 입력하고 상기 분류 모델은 점수를 출력하고, 제3 유의수준에 따라 상기 출력된 점수를 분류 하며,

상기 제3 유의수준은 제품 간의 변동 및 센서 노이즈를 포함하는 정상 제품에 대한 시계열 데이터 집합을 이용하여 설정하는 것을 특징으로 하는 고장 검출 및 분류 장치.

청구항 16

제12항에 있어서,

상기 프로세서는,

상기 공정 파라미터 별로 상기 디노이즈 잔차 데이터가 0보다 큰 구간을 검색하고, 상기 디노이즈 잔차 데이터의 크기 및 패턴을 기반으로 상기 센싱한 시계열 데이터와 시간적으로 비교하여 이상 패턴의 발생 여부를 판단하고, 상기 이상 패턴의 발생 시점을 출력하는 것을 특징으로 하는 고장 검출 및 분류 장치.

발명의 설명

기술 분야

[0001] 본 발명이 속하는 기술 분야는 고장 검출 및 분류 방법에 관한 것이다.

배경 기술

[0002] 이 부분에 기술된 내용은 단순히 본 실시예에 대한 배경 정보를 제공할 뿐 종래기술을 구성하는 것은 아니다.

[0003] 반도체 공정에서 고장 검출 및 분류(Fault Detection and Classification, FDC)는 기계학습이나 데이터 마이닝 기법을 이용해 각 웨이퍼의 공정 상황을 반영하는 센서 데이터 스트림을 기반으로 공정 결과를 판단하는 모델을 수립한다.

- [0004] 정확한 고장 검출 및 분류 모델을 수립하는 것은 웨이퍼(Wafer) 제조 공정 중 발생하는 고장을 조기에 발견하여 불량 제품이 후속 공정으로 유출되는 것을 방지하고, 공정에 대한 지속적인 모니터링을 통해 수율 향상에 기여 할 수 있다.
- [0005] 기존의 고장 검출 및 분류 모델은 트레이스 데이터에서 소수의 특징들을 추출하여 분류에 사용함으로써 패턴 정보가 손실되거나, 특징 추출 과정에서 반도체 공정의 특성을 고려하지 않아 정상 트레이스 데이터와 이상 트레이스 데이터의 특징이 유사하게 형성되는 오류가 있다.
- [0006] 이상적인 반도체 공정 설비 상태에서는 웨이퍼마다 트레이스 패턴이 거의 동일하다. 설비의 노후화 및 챔버의 오염이 진행되면 트레이스는 웨이퍼 간의 변동이 발생하여 정상 웨이퍼가 비정상 웨이퍼로 인식될 수 있다.

선행기술문헌

특허문헌

- [0007] (특허문헌 0001) 한국등록특허공보 제10-0679721호 (2007.01.31.)
 (특허문헌 0002) 한국등록특허공보 제10-1744194호 (2017.05.31.)

발명의 내용

해결하려는 과제

- [0008] 본 발명의 실시예들은 공정 드리프트(Drift)와 쉬프트(Shift)로 인한 웨이퍼 간의 변동 및 센서 측정 과정에서 발생한 센서 노이즈를 고려하여 트레이스 데이터를 처리함으로써, 반도체 공정에서 불량의 원인이 되는 이상 패턴의 발생 시점 및 이상 패턴의 형태를 시각화하는 데 주된 목적이 있다.
- [0009] 본 발명의 명시되지 않은 또 다른 목적들은 하기의 상세한 설명 및 그 효과로부터 용이하게 추론할 수 있는 범위 내에서 추가적으로 고려될 수 있다.

과제의 해결 수단

- [0010] 본 실시예의 일 측면에 의하면, 고장 검출 및 분류 장치에 의한 고장 검출 및 분류 방법에 있어서, 제조 공정에서 공정 파라미터 별로 제품을 센싱한 시계열 데이터를 수집하는 단계, 상기 수집한 시계열 데이터에서 복원 모델을 통해 복원한 데이터를 제거하여 잔차 데이터를 생성하는 단계, 상기 잔차 데이터에서 센서 노이즈를 제거하여 디노이즈 잔차 데이터를 생성하는 단계, 및 상기 디노이즈 잔차 데이터를 분석하여 고장을 분류하는 단계를 포함하는 고장 검출 및 분류 방법을 제공한다.
- [0011] 본 실시예의 다른 측면에 의하면, 하나 이상의 프로세서 및 상기 하나 이상의 프로세서에 의해 실행되는 하나 이상의 프로그램을 저장하는 메모리를 포함하는 고장 검출 및 분류 장치에 있어서, 상기 프로세서는 제조 공정에서 공정 파라미터 별로 제품을 센싱한 시계열 데이터를 수집하고, 상기 프로세서는 상기 수집한 시계열 데이터에서 복원 모델을 통해 복원한 데이터를 제거하여 잔차 데이터를 생성하고, 상기 프로세서는 상기 잔차 데이터에서 센서 노이즈를 제거하여 디노이즈 잔차 데이터를 생성하고, 상기 프로세서는 상기 디노이즈 잔차 데이터를 분석하여 고장을 분류하는 것을 특징으로 하는 고장 검출 및 분류 장치를 제공한다.

발명의 효과

- [0012] 이상에서 설명한 바와 같이 본 발명의 실시예들에 의하면, 수집한 시계열 데이터에서 복원 모델을 통해 복원한 데이터를 제거하여 잔차 데이터를 생성하고, 잔차 데이터에서 센서 노이즈를 제거하여 디노이즈 잔차 데이터를 생성하고, 디노이즈 잔차 데이터를 분석하여 고장을 분류함으로써, 제품 제작 공정에서 불량의 원인이 되는 이상 패턴의 발생 시점 및 이상 패턴의 형태를 시각화할 수 있는 효과가 있다.
- [0013] 여기에서 명시적으로 언급되지 않은 효과라 하더라도, 본 발명의 기술적 특징에 의해 기대되는 이하의 명세서에서 기재된 효과 및 그 잠정적인 효과는 본 발명의 명세서에 기재된 것과 같이 취급된다.

도면의 간단한 설명

[0014]

도 1은 본 발명의 일 실시예에 따른 고장 검출 및 분류 장치를 예시한 블록도이다.

도 2는 본 발명의 일 실시예에 따른 고장 검출 및 분류 장치의 복원 모델을 예시한 도면이다.

도 3 및 도 4는 본 발명의 일 실시예에 따른 고장 검출 및 분류 장치가 생성한 잔차 데이터를 예시한 도면이다.

도 5는 본 발명의 일 실시예에 따른 고장 검출 및 분류 장치가 잔차 데이터에서 임계치를 설정하는 동작을 예시한 도면이다.

도 6은 본 발명의 다른 실시예에 따른 고장 검출 및 분류 방법을 예시한 흐름도이다.

도 7 및 도 8는 본 발명의 실시예들에 따라 수행된 모의실험 결과를 도시한 것이다.

발명을 실시하기 위한 구체적인 내용

[0015]

이하, 본 발명을 설명함에 있어서 관련된 공지기능에 대하여 이 분야의 기술자에게 자명한 사항으로서 본 발명의 요지를 불필요하게 흐릴 수 있다고 판단되는 경우에는 그 상세한 설명을 생략하고, 본 발명의 일부 실시예들을 예시적인 도면을 통해 상세하게 설명한다.

[0016]

웨이퍼 가공을 위해 챔버 내로 투입되는 공정 파라미터를 실시간으로 모니터링하는 센서가 설치되어 있어, 웨이퍼 가공이 완료되면 공정 파라미터 별로 트레이스 데이터가 생성된다. 고장 검출 및 분류 장치는 트레이스 데이터를 분석하여 고장을 검출한다.

[0017]

기존 방식은 트레이스 데이터에 웨이퍼 간 변동 및 센서 노이즈가 혼재된 상황을 고려하지 않는 반면에, 본 실시예에 따른 고장 검출 및 분류 장치는 웨이퍼 간 변동을 고려하여 고장을 정확하게 진단할 수 있다.

[0018]

도 1은 본 발명의 일 실시예에 따른 고장 검출 및 분류 장치를 예시한 블록도이다.

[0019]

고장 검출 및 분류 장치(110)는 적어도 하나의 프로세서(120), 컴퓨터 판독 가능한 저장매체(130) 및 통신 버스(170)를 포함한다.

[0020]

프로세서(120)는 고장 검출 및 분류 장치(110)로 동작하도록 제어할 수 있다. 예컨대, 프로세서(120)는 컴퓨터 판독 가능한 저장 매체(130)에 저장된 하나 이상의 프로그램들을 실행할 수 있다. 하나 이상의 프로그램들은 하나 이상의 컴퓨터 실행 가능 명령어를 포함할 수 있으며, 컴퓨터 실행 가능 명령어는 프로세서(120)에 의해 실행되는 경우 고장 검출 및 분류 장치(110)로 하여금 예시적인 실시예에 따른 동작들을 수행하도록 구성될 수 있다.

[0021]

컴퓨터 판독 가능한 저장 매체(130)는 컴퓨터 실행 가능 명령어 내지 프로그램 코드, 프로그램 데이터 및/또는 다른 적합한 형태의 정보를 저장하도록 구성된다. 컴퓨터 판독 가능한 저장 매체(130)에 저장된 프로그램(140)은 프로세서(120)에 의해 실행 가능한 명령어의 집합을 포함한다. 일 실시예에서, 컴퓨터 판독 가능한 저장 매체(130)는 메모리(랜덤 액세스 메모리와 같은 휘발성 메모리, 비휘발성 메모리, 또는 이들의 적절한 조합), 하나 이상의 자기 디스크 저장 디바이스들, 광학 디스크 저장 디바이스들, 플래시 메모리 디바이스들, 그 밖에 고장 검출 및 분류 장치(110)에 의해 액세스되고 원하는 정보를 저장할 수 있는 다른 형태의 저장 매체, 또는 이들의 적합한 조합일 수 있다.

[0022]

통신 버스(170)는 프로세서(120), 컴퓨터 판독 가능한 저장 매체(140)를 포함하여 고장 검출 및 분류 장치(110)의 다른 다양한 컴포넌트들을 상호 연결한다.

[0023]

고장 검출 및 분류 장치(110)는 또한 하나 이상의 입출력 장치(미도시)를 위한 인터페이스를 제공하는 하나 이상의 입출력 인터페이스(150) 및 하나 이상의 통신 인터페이스(160)를 포함할 수 있다. 입출력 인터페이스(150) 및 통신 인터페이스(160)는 통신 버스(170)에 연결된다. 입출력 장치(미도시)는 입출력 인터페이스(150)를 통해 고장 검출 및 분류 장치(110)의 다른 컴포넌트들에 연결될 수 있다.

[0024]

고장 검출 및 분류 장치(110)는 공정 드리프트(Drift)와 쉬프트(Shift)로 인한 웨이퍼 간의 변동 및 센서 측정 과정에서 발생한 센서 노이즈를 고려하여 트레이스 데이터를 처리한다. 고장 검출 및 분류 장치(110)는 시계열 데이터에서 복원 모델을 통해 복원한 데이터를 제거하여 잔차 데이터를 생성하고, 잔차 데이터에서 센서 노이즈를 제거하여 디노이즈 잔차 데이터를 생성하고, 디노이즈 잔차 데이터를 분석하여 고장을 분류함으로써, 제품 제작 공정에서 불량의 원인이 되는 이상 패턴의 발생 시점 및 이상 패턴의 형태를 시각화할 수 있다.

[0025]

프로세서(120)는 제조 공정에서 공정 파라미터 별로 제품을 센싱한 시계열 데이터를 수집한다. 프로세서(120)는

수집한 시계열 데이터에서 복원 모델을 통해 복원한 데이터를 제거하여 잔차 데이터를 생성한다. 프로세서(120)는 잔차 데이터에서 센서 노이즈를 제거하여 디노이즈 잔차 데이터를 생성한다. 프로세서(120)는 디노이즈 잔차 데이터를 분석하여 고장을 분류한다.

[0026] 도 2는 본 발명의 일 실시예에 따른 고장 검출 및 분류 장치의 복원 모델을 예시한 도면이다.

[0027] 복원 모델은 복수의 레이어가 연결된 인공 신경망(Artificial Neural Network)이며, 입력 레이어에 노이즈 (Noise)를 추가하고, 은닉 레이어의 뉴런 수를 입력 레이어보다 작게 설정해서 차원을 축소하고, 은닉 레이어의 정보가 출력 레이어에 맵핑될 때 입력 레이어와 동일 차원으로 복원된다.

[0028] 복원 모델은 인코더와 디코더로 구성된 디노이징 오토인코더(Denoising Auto Encoder, DAE)로, 노이즈가 추가된 입력 레이어가 은닉 레이어에 맵핑되어, 원본 입력을 복원하도록 네트워크를 학습시킨다. 은닉 레이어에 맵핑된 후 출력 레이어에 맵핑되면서 입력을 복원한다. 오토인코더는 입력 레이어와 출력 레이어 사이에 비선형 특징 추출을 위한 하나 이상의 은닉 레이어로 구성된 피드 포워드 신경 회로망(Feed Forward Neural Network)으로 입력 데이터를 출력에서 복원하기 위한 특징을 원본 입력 차원보다 감소된 차원에서 학습한다.

[0029] 입력 데이터 X 가 확률적(stochastic) 맵핑 $q(\tilde{X}|X)$ 에 의해 부분적으로 노이즈가 첨가된 \tilde{X} 로 변형된다. 도 2를 참조하면 x_3 과 x_5 에 노이즈가 첨가되었다.

[0030] 노이즈가 첨가된 입력이 은닉 표현 $\mathbf{Y} = h(\mathbf{W}\tilde{\mathbf{X}} + \mathbf{b})$ 로 맵핑된다. \mathbf{W} 는 입력 레이어와 은닉 레이어 간의 가중치 매트릭스이고, \mathbf{b} 는 대응하는 바이어스 벡터이고, h 는 설정된 활성화 함수이다.

[0031] 은닉 표현 \mathbf{Y} 가 복원 데이터 $\hat{\mathbf{X}} = h(\mathbf{W}'\mathbf{Y} + \mathbf{b}')$ 로 맵핑된다. \mathbf{W}' 는 입력과 은닉 간의 가중치 매트릭스이고, \mathbf{b}' 는 대응하는 바이어스 벡터이다.

[0032] 입력 데이터 \mathbf{X}_i ($i = 1, \dots, n$)에 대한 손실함수 $L(\mathbf{X}_i, \hat{\mathbf{X}}_i) = \|\mathbf{X}_i - \hat{\mathbf{X}}_i\|^2$ 를 계산하고, 전체 훈련 데이터 세트의 평균 손실이 최소가 되도록 확률적 경사 하강(Stochastic gradient descent, SGD)을 통해 학습 파라미터 세트 $\theta^* = \{\mathbf{W}^*, \mathbf{b}^*, \mathbf{W}'^*, \mathbf{b}'^*\}$ 를 학습하여 최적의 학습 파라미터 세트를 산출한다. 학습 파라미터 세트를 산출하는 공식은 수학식 1과 같이 표현된다.

수학식 1

$$\theta^* = \underset{\theta}{\operatorname{argmin}} \frac{1}{n} \sum_{i=1}^n L(\mathbf{X}_i, \hat{\mathbf{X}}_i)$$

[0033] 이하에서는 도 3 및 도 4를 참조하여 고장 검출 및 분류 장치가 잔차 데이터를 생성하는 동작을 설명하기로 한다.

[0034] 도 3 및 도 4는 본 발명의 일 실시예에 따른 고장 검출 및 분류 장치가 생성한 잔차 데이터를 예시한 도면이다.

[0035] 고장 검출 및 분류 장치가 잔차 데이터를 생성하는 단계는 제품 간의 변동 및 센서 노이즈를 포함하는 정상 제품에 대한 시계열 데이터 집합을 복원 모델을 통해 학습한다. 복원 모델은 센서 노이즈가 제거된 시계열 데이터를 복원한다.

[0036] 고장 검출 및 분류 장치가 정상 제품에 대한 시계열 데이터에서 복원한 시계열 데이터를 차감하여, 제품 간의 변동이 제거된 센서 노이즈와 이상 패턴을 갖는 시계열 데이터를 추출한다.

[0037] 제품 제작 공정에서 1번쩨 웨이퍼의 가공 중에 센서가 측정한 M 공정 파라미터의 다변량분포(Multivariate) 가공 전 트레이스 데이터(Raw Trace Data)를 $\mathbf{X}_{\ell} = [\mathbf{X}_{\ell 1}, \dots, \mathbf{X}_{\ell M}]^T$ 라고 하고, 공정 파라미터

m ($m = 1, \dots, M$) 의 트레이스는 $\mathbf{X}_{\ell m} = [x_{\ell m1}, \dots, x_{\ell mT}]$ 이고, T는 공정 주기이다.

[0039] 공정 파라미터 m 과 1번째 제품에 대한 시계열 데이터 집합은 수학식 2와 같이 표현된다. 제품을 웨이퍼로 가정한다. 제품 간의 변동은 웨이퍼 간의 변동(Wafer-to-Wafer, W2W)일 수 있다.

수학식 2

$$\mathbf{X}_{\ell m} = \mathbf{I}_{\ell m} + \mathbf{V}_{\ell m} + \mathbf{N}_{\ell m} + \mathbf{P}_{\ell m}$$

[0041] 이상적인 트레이스 $\mathbf{I}_{\ell m} = [i_{\ell m1}, \dots, i_{\ell mT}]$, 제품 간의 변동 $\mathbf{V}_{\ell m} = [v_{\ell m1}, \dots, v_{\ell mT}]$, 센서 노이즈 $\mathbf{N}_{\ell m} = [n_{\ell m1}, \dots, n_{\ell mT}]$, 이상 패턴 $\mathbf{P}_{\ell m} = [p_{\ell m1}, \dots, p_{\ell mT}]$ 으로 구성된다. 웨이퍼 1이 정상이면 이상 패턴이 발생하지 않기 때문에 P_{1m} 은 제로 벡터이다.

[0042] 본 실시예에 따른 고장 검출 및 분류 장치는 이상적인 시계열 데이터와 제품 간의 변동 정보가 제거된 잔차 데이터를 생성한다.

[0043] 정상 제품의 시계열 데이터로 구성된 DAE 훈련 데이터 세트를 이용해 각 공정 파라미터 m 마다 개별적으로 복원 모델을 학습한다. DAE 훈련 데이터 세트는 제품 간의 변동과 센서 노이즈가 포함된 정상 데이터를 포함한다.

[0044] 복원된 시계열 데이터는 $\widehat{\mathbf{X}}_{\ell m} = \mathbf{I}_{\ell m} + \mathbf{V}_{\ell m}$ 으로 정의될 수 있다. 잔차 데이터는 $\mathbf{RT}_{\ell m} = |\widehat{\mathbf{X}}_{\ell m} - \mathbf{X}_{\ell m}| = |\mathbf{N}_{\ell m} + \mathbf{P}_{\ell m}|$ 로 정의될 수 있다.

[0045] 도 3의 (a)는 가공전 시계열 데이터이고, 도 3의 (b)는 복원된 시계열 데이터이고, 도 3의 (c)는 잔차 데이터이다.

[0046] 도 3의 (b)의 복원된 시계열 데이터를 참조하면, 복원 모델을 통해 센서 노이즈와 이상 패턴이 제거되고 이상적인 시계열 데이터와 제품 간의 변동은 복원할 수 있다. 도 3의 (c)의 잔차 데이터는 센서 노이즈와 이상 패턴을 보여준다.

[0047] 도 4의 (a)는 실제 CVD(Chemical Vapor Deposition) 공정의 파라미터별 가공전 데이터이고, 도 4의 (b)는 복원된 데이터이다. 약 150 번째 센싱에서 발생한 갑작스런 변화와 250 번째 센싱에서 발생한 미소교란이 잔차 데이터에 포함되어 있음을 알 수 있다. 즉, 복원 모델이 제품 간의 변동과 이상적인 시계열 데이터만을 복원하여, 잔차 데이터에 센서 노이즈와 이상 패턴만 남는다.

[0048] 이하에서는 도 5를 참조하여 고장 검출 및 분류 장치가 디노이즈 잔차 데이터를 생성하는 동작을 설명하기로 한다.

[0049] 고장 검출 및 분류 장치가 디노이즈 잔차 데이터를 생성하는 단계는, 잔차 데이터의 크기를 기준으로 제1 노이즈 임계치를 설정하고, 제1 노이즈 임계치를 이용하여 센서 노이즈를 제거한다.

[0050] 제1 노이즈 임계치는 잔차 데이터에서 시점 별로 산출된 통계적 대표값 및 교차 검증을 통해 통계적 대표값을 변경하는 조정 파라미터로 표현되며, 조정 파라미터는 제1 노이즈 임계치를 초과한 누적 횟수의 비율을 제1 유의수준과 비교한 결과에 따라 설정된다.

[0051] 고장 검출 및 분류 장치가 디노이즈 잔차 데이터를 생성하는 단계는, 잔차 데이터의 지속 시간을 기준으로 제2 노이즈 임계치를 설정하고, 제2 노이즈 임계치를 이용하여 이상 패턴을 검출한다.

[0052] 제2 노이즈 임계치는 잔차 데이터에서 제1 노이즈 임계치를 하나 이상 연속적으로 넘어가는 구간을 검색하고,

넘어가는 구간의 길이를 산출하고 히스토그램으로 변환한 후 제2 유의수준에 대응하는 값으로 설정된다.

[0053] 고장 검출 및 분류 장치가 디노이즈 잔차 데이터를 생성하는 단계는, 제2 노이즈 임계치보다 작은 값을 갖는 잔차 데이터를 제로로 설정한다.

[0054] 도 5는 본 발명의 일 실시예에 따른 고장 검출 및 분류 장치가 잔차 데이터에서 임계치를 설정하는 동작을 예시한 도면이다.

[0055] 고장 검출 및 분류 장치는 우선 잔차 데이터에서 시점 별로 제1 노이즈 임계치를 설정하며, 잔차 데이터의 크기가 제1 노이즈 임계치보다 작으면 센서 노이즈로 간주한다. 이상 패턴의 최소 유지기간 기준인 제2 노이즈 임계치를 설정하여 잔차 데이터의 크기가 제1 노이즈 임계치를 넘더라도 제2 노이즈 임계치 이상의 기간 동안 지속되지 못하면 노이즈로 간주한다. 그렇지 않으면 이상 패턴이 발생한 것으로 판단한다.

[0056] 잔차 데이터로부터 각 시점 t 별로 표본평균 $\hat{\mu}_t$ 과 표준편차 $\hat{\sigma}_t$ 를 구하고 제1 노이즈 임계치

$NCL_t = \hat{\mu}_t + \kappa \hat{\sigma}_t$ 를 설정한다. k 는 제1 노이즈 임계치의 크기를 조절하는 조정 파라미터이고, 교차검증을 이용하여 결정된다.

[0057] 교차검증(Cross Validation)은 데이터 세트를 h 개의 서로소 서브세트로 분할한 후 ($h-1$) 서브세트를 모델 훈련에 사용하고 나머지 1개의 서브세트를 모델 검증에 사용한다. 실험을 h 번 반복한 후 제1 노이즈 임계치를 누적 횟수의 비율을 구한 후 제1 유의수준 ε 과 비교한다. 비율이 ε 과 같거나 초과할 때까지 k 를 조금씩 증가시켜 교차검증을 수행한다. 제1 노이즈 임계치를 초과한 잔차 데이터 횟수 비율이 ε 을 초과하는 최소의 k 를 선택한다.

[0058] 제1 유의수준 ε 는 노이즈가 진실임에도 노이즈가 아니라고 잘못 판단하는 비율로 가설 검정에서의 유형 I 에러에 해당한다. 제1 유의수준이 0.01이라면 1% 정도의 크기가 큰 노이즈는 피크와 같은 이상 패턴으로 오인하는 것을 허용하다는 의미이다.

[0059] 본 실시예에 따른 고장 검출 및 분류 장치는 제1 유의수준을 이용하여 통계적으로 노이즈를 제거하더라도 노이즈가 맞지만 노이즈가 아니라고 잘못 판단하는 위험요소가 존재하는 문제를 해결하기 위해서, 잔차 데이터에서 노이즈가 아니라고 판단된 잔차 데이터의 지속 시간(Run Length)을 계산하여 다시 한번 더 노이즈를 판단한다.

[0060] 정상 웨이퍼에 비해 고장 웨이퍼의 발생 비율이 극히 적은 반도체 공정의 특성상 임계치 훈련 데이터 세트는 대부분 정상 웨이퍼 데이터로부터 생성된다. 임계치 훈련 세트의 잔차 데이터에서 일부 이상 패턴일 가능성이 있는 잔차 데이터를 제외하고, 제1 노이즈 임계치보다 큰 잔차 데이터의 지속 시간은 확률적으로 매우 작을 것이므로 이러한 잔차 데이터를 모두 제거할 필요가 있다.

[0061] 고장 검출 및 분류 장치는 잔차 데이터마다 제1 노이즈 임계치를 하나 이상 연속적으로 넘어가는 잔차 데이터 구간을 모두 찾고 구간의 길이에 해당하는 지속 시간을 계산한다. 모든 잔차 데이터에서 찾은 지속 시간에 대한 히스토그램을 작성한 뒤 제2 유의 수준 δ 에 대응되는 제2 노이즈 임계치를 찾는다. 그 후 잔차 데이터에서 제2 노이즈 임계치보다 작은 지속 시간을 갖는 구간의 잔차 데이터를 모두 노이즈로 간주하여 제로(zero)로 변경한다.

[0062] 제1 노이즈 임계치(Noise Control Limit, NCL)와 제2 노이즈 임계치(Run Length Limit, RLL)를 이용해서 새로운 웨이퍼 1의 디노이즈 잔차 데이터(DRT)를 생성하는 과정을 설명하면 다음과 같다.

[0063] 먼저 공정 파라미터 m ($m=1, \dots, M$)별로 수집된 시계열 데이터 X_{lm} 을 학습된 복원 모델(DAE)에 입력하여 복원된

시계열 데이터를 출력하고, 잔차 데이터 $RT_{\ell m} = |X_{\ell m} - \hat{X}_{\ell m}|$ 를 생성한다.

[0064] 잔차 데이터가 제1 노이즈 임계치 NCL_m 을 초과하는 모든 구간을 찾고, 이 구간들의 지속 시간 집합 LS_{lm} 과 시점 집합 IS_{lm} 을 생성한다.

수학식 3

$$[0065] LS_{\ell m} = \{RL_{\ell m \tau} | \tau \in \{1, 2, \dots, NA_{\ell m}\} \}$$

수학식 4

$$[0066] IS_{\ell m} = \{TI_{\ell m \tau} | \tau \in \{1, 2, \dots, NA_{\ell m}\} \}$$

[0067] $RL_{1m\tau}$ 은 τ 번째 구간의 지속 시간, $TI_{1m\tau}$ 은 τ 번째 구간의 시점 집합 그리고 NA_{1m} 은 RT_{1m} 이 NCL_m 을 초과하는 총 구간의 수이다. 도 5의 RT_{19} 의 첫 번째 구간의 시점 $TI_{191}=\{106, 107, \dots, 137\}$ 그리고 $RL_{191}=32$ 이다.

[0068] RT_{1m} 이 NCL_m 이 하인 모든 지점과, RT_{1m} 이 NCL_m 을 초과하는 구간들 중 지속 시간 $RL_{1m\tau}$ 가 제2 노이즈 임계치 RLL_m 미만인 구간의 $TI_{1m\tau}$ 에 대해서는 잔차 데이터를 모두 zero로 치환하여 디노이즈 잔차 데이터 DRT_{1m} 을 생성한다.

[0069] 고장 검출 및 분류 장치는 디노이즈 잔차 데이터를 분석하여 고장을 분류한다.

[0070] 고장 검출 및 분류 장치가 디노이즈 잔차 데이터를 분석하여 고장을 분류하는 단계는, 정상 제품의 데이터 간의 거리보다 이상 제품의 데이터 및 정상 제품의 데이터 간의 거리가 큰 것을 전제로 하는 거리 기반의 분류 모델을 통해 고장을 분류한다. 분류 모델은 디노이즈 잔차 데이터 간의 거리를 이용하여 고장을 분류한다.

[0071] 고장 검출 및 분류 장치는 디노이즈 잔차 데이터를 분류 모델에 입력하고 상기 분류 모델은 점수를 출력하고, 제3 유의수준에 따라 상기 출력된 점수를 분류한다. 제3 유의수준은 제품 간의 변동 및 센서 노이즈를 포함하는 정상 제품에 대한 시계열 데이터 집합을 이용하여 설정한다.

[0072] 단일 클래스 kNN(k-Nearest Neighbor) 알고리즘을 이용해 DRT 정보를 고장 검출 및 분류 인덱스(FDC-Index)로 요약하여 제작된 웨이퍼의 불량 여부를 판단한다. 단일 클래스 kNN 알고리즘은 이상 감지를 위한 거리 기반 분류 방법으로, 고장 웨이퍼 데이터와 정상 웨이퍼 데이터 사이의 거리는 정상 웨이퍼 데이터 간의 거리에 비해 훨씬 클 것이라는 가정을 기반으로 한다. kNN 알고리즘의 입력으로 M개의 공정 파라미터의 디노이즈 잔차 데이터를 연결한 데이터를 사용한다. 웨이퍼 1의 결합한 디노이즈 잔차 데이터 DRT를 $DRT_1=[DRT_{111}, \dots, DRT_{11T}, \dots, DRT_{1M1}, \dots, DRT_{1MT}]$ 라고 정의하면, 웨이퍼 1의 고장 검출 및 분류 인덱스는 수학식 5와 같이 표현된다.

수학식 5

$$[0073] FDC-Index_{\ell} = \sum_{\ell=1}^k \sum_{m=1}^M \sum_{t=1}^T (DRT_{\ell mt} - DRT_{n(\ell,j)mt})^2$$

[0074] k 는 이웃의 개수이고, $n(1, j)$ 는 웨이퍼 1에서 j 번째 가장 가까운 이웃을 의미한다. $FDC-Index_1$ 은 DAE 훈련 데이터 세트에 있는 정상 웨이퍼 데이터 중에서 웨이퍼 1과 가장 가까운 k 개 이웃들과의 유clidean 거리 차승의 합이다. 웨이퍼 1의 $FDC-Index_1$ 점수가 클수록 정상 데이터의 디노이즈 잔차 데이터(DRT)와 차이가 있으므로, 해당 웨이퍼는 불량일 가능성성이 높아진다.

[0075] 웨이퍼 1의 불량 여부를 결정하기 위한 $FDC-Index$ 의 상한은 DAE 훈련 데이터 세트를 가지고 설정한다. DAE 훈련 데이터 세트의 웨이퍼마다 $FDC-Index$ 값을 계산하고, 계산한 결과를 근거로 제3 유의수준 a 를 만족하는 인덱스 임계치 $FDC-Index_a$ 를 설정한다. 웨이퍼 1의 가공전 시계열 데이터를 수집하면, 공정 파라미터 별로 디노이즈 잔차 데이터(DRT)를 생성하고 DRT_1 를 kNN 알고리즘에 입력하여 $FDC-Index$ 점수를 구한다. 만약 $FDC-Index_1 \leq FDC-Index_a$ 이면 웨이퍼 1은 정상으로, 그렇지 않다면 고장으로 분류한다.

- [0076] FDC-Index를 통해 분류한 결과 웨이퍼 1이 고장이라고 판정된 경우, DRT 정보를 이용하여 고장 원인 진단을 진행한다. 디노이즈 잔차 데이터는 이상 패턴으로 구성된다. 디노이즈 잔차 데이터는 일부 제거되지 않은 노이즈를 포함할 수 있다. 디노이즈 잔차 데이터가 0보다 큰 구간은 이상 패턴이 발생한 구간일 가능성이 높다.
- [0077] 각 공정 파라미터 별로 디노이즈 잔차 데이터를 확인하여 디노이즈 잔차 데이터가 0보다 큰 모든 구간을 찾아낸 후 디노이즈 잔차 데이터의 크기와 패턴을 확인한다. 확인 결과 디노이즈 잔차 데이터의 크기가 크고 오래 지속되는 구간들은 이상 패턴이 발생한 것으로 판단하고, 디노이즈 잔차 데이터가 작고 짧은 기간 동안만 유지된 구간들에 대해서는 웨이퍼 1의 가공전 시계열 데이터와 DAE 훈련 데이터 세트의 가공전 시계열 데이터를 시간적으로 비교하여 패턴에 차이가 있는지 확인한다. 만일 가공전 시계열 데이터 패턴에서 차이를 발견되면 해당 구간은 이상 패턴이 발생한 것으로 판단한다.
- [0078] 이상 패턴이 확정된 구간의 디노이즈 잔차 데이터는 공정 파라미터의 이상 발생 시점 및 이상 패턴의 형태를 알려줄 수 있다.
- [0079] 도 6은 본 발명의 다른 실시예에 따른 고장 검출 및 분류 방법을 예시한 흐름도이다. 고장 검출 및 분류 방법은 고장 검출 및 분류 장치에 의하여 수행될 수 있다.
- [0080] 단계 S210에서 프로세서는 제조 공정에서 공정 파라미터 별로 제품을 센싱한 시계열 데이터를 수집한다.
- [0081] 단계 S220에서 프로세서는 수집한 시계열 데이터에서 복원 모델을 통해 복원한 데이터를 제거하여 잔차 데이터를 생성한다. 복원 모델은 복수의 레이어가 연결된 네트워크이며, 입력 레이어에 노이즈(noise)를 추가하고, 은닉 레이어의 뉴런 수를 상기 입력 레이어보다 작게 설정해서 차원을 축소하고, 차원이 축소된 은닉 레이어가 입력 레이어와 동일 차원의 출력 레이어에 맵핑되어 원본 입력이 복원된다. 복원 모델은 원본 입력을 복원하도록 네트워크를 학습시키는 디노이징 오토인코더일 수 있다.
- [0082] 잔차 데이터를 생성하는 단계(S220)는 제품 간의 변동 및 센서 노이즈를 포함하는 정상 제품에 대한 시계열 데이터 집합을 상기 복원 모델을 통해 학습하고, 복원 모델은 센서 노이즈가 제거된 시계열 데이터를 복원하고, 정상 제품에 대한 시계열 데이터에서 복원한 시계열 데이터를 차감하여, 제품 간의 변동이 제거된 센서 노이즈와 이상 패턴을 갖는 시계열 데이터를 추출한다.
- [0083] 단계 S230에서 프로세서는 잔차 데이터에서 센서 노이즈를 제거하여 디노이즈 잔차 데이터를 생성한다.
- [0084] 디노이즈 잔차 데이터를 생성하는 단계(S230)는 잔차 데이터의 크기를 기준으로 제1 노이즈 임계치를 설정하고, 제1 노이즈 임계치를 이용하여 센서 노이즈를 제거한다. 제1 노이즈 임계치는 잔차 데이터에서 시점 별로 산출된 통계적 대표값 및 교차 검증을 통해 통계적 대표값을 변경하는 조정 파라미터로 표현되며, 조정 파라미터는 제1 노이즈 임계치를 초과한 누적 횟수의 비율을 제1 유의수준과 비교한 결과에 따라 설정된다.
- [0085] 디노이즈 잔차 데이터를 생성하는 단계(S230)는 잔차 데이터의 지속 시간을 기준으로 제2 노이즈 임계치를 설정하고, 제2 노이즈 임계치를 이용하여 이상 패턴을 검출한다. 제2 노이즈 임계치는 잔차 데이터에서 제1 노이즈 임계치를 하나 이상 연속적으로 넘어가는 구간을 검색하고, 넘어가는 구간의 길이를 산출하고 히스토그램으로 변환한 후 제2 유의수준에 대응하는 값으로 설정된다.
- [0086] 디노이즈 잔차 데이터를 생성하는 단계(S230)는 제2 노이즈 임계치보다 작은 값을 갖는 잔차 데이터를 제로로 설정한다.
- [0087] 단계 S240에서 프로세서는 디노이즈 잔차 데이터를 분석하여 고장을 분류한다.
- [0088] 디노이즈 잔차 데이터를 분석하여 고장을 분류하는 단계(S240)는 정상 제품의 데이터 간의 거리보다 이상 제품의 데이터 및 정상 제품의 데이터 간의 거리가 큰 것을 전제로 하는 거리 기반의 분류 모델을 통해 고장을 분류한다. 분류 모델은 디노이즈 잔차 데이터 간의 거리를 이용하여 고장을 분류한다. 디노이즈 잔차 데이터를 분류 모델에 입력하고 분류 모델은 점수를 출력하고, 제3 유의수준에 따라 상기 출력된 점수를 분류한다. 제3 유의수준은 제품 간의 변동 및 센서 노이즈를 포함하는 정상 제품에 대한 시계열 데이터 집합을 이용하여 설정된다.
- [0089] 단계 S250에서 프로세서는 디노이즈 잔차 데이터를 분석하여 고장을 분류하는 단계 이후에, 디노이즈 잔차 데이터를 분석하여 고장의 원인을 진단한다.
- [0090] 고장의 원인을 진단하는 단계(S250)는 공정 파라미터 별로 상기 디노이즈 잔차 데이터가 0보다 큰 구간을 검색하고, 디노이즈 잔차 데이터의 크기 및 패턴을 기반으로 센싱한 시계열 데이터와 시간적으로 비교하여 이상 패

턴의 발생 여부를 판단하고, 이상 패턴의 발생 시점을 출력한다.

[0091] 고장의 원인을 진단하는 단계(S250)는 고장에 대해서 디노이즈 잔차 데이터를 분석하여 고장의 원인이 되는 공정 파라미터, 이상 패턴의 발생 시점, 및 이상 패턴의 형태를 출력한다.

[0092] 도 7 및 도 8는 본 발명의 실시예들에 따라 수행된 모의실험 결과를 도시한 것이다. 도 7은 각각 공정의 데이터에 대한 진단 결과이다.

[0093] 도 7의 (a)는 공정 파라미터 중에서 $BCI_3 flow$ 에 대한 디노이즈 잔차 데이터이고, 도 7의 (b)는 공정 파라미터 중에서 $BCI_3 flow$ 에 대한 가공전 시계열 데이터이다.

[0094] 고장 웨이퍼 12의 총 웨이퍼 가공시간 동안 디노이즈 잔차 데이터가 크게 형성되어 있다. 디노이즈 잔차 데이터를 통해 가공전 시계열 데이터에 뚜렷하고 지속적인 이상 패턴이 발생했음을 진단할 수 있다.

[0095] 도 7의 (c)는 공정 파라미터 중에서 압력에 대한 디노이즈 잔차 데이터이고, 도 7의 (d)는 공정 파라미터 중에서 압력에 대한 가공전 시계열 데이터이다.

[0096] 0초~6초, 53초 ~ 55초 기간에 고장 웨이퍼 4, 7, 13 및 18의 디노이즈 잔차 데이터가 크게 증가했다가 감소한다. 두 기간에 높은 압력 변동이 발생했음을 진단할 수 있다.

[0097] 도 7의 (e)는 공정 파라미터 중에서 RF 파워에 대한 디노이즈 잔차 데이터이고, 도 7의 (f)는 공정 파라미터 중에서 RF 파워에 대한 가공전 시계열 데이터이다.

[0098] 고장 웨이퍼 4, 13 및 17 가공 중에 이상 변동이 발생했을 것으로 진단 결과가 나왔다. 고장 웨이퍼 4 및 13은 49초 ~ 54초 기간에 갑작스럽게 떨어졌다가 올라가는 피크 형태의 이상 변동이 발생했음을 확인할 수 있다.

[0099] 고장 웨이퍼 17은 22초 ~ 24초, 62초 ~ 66초 기간에 피크가 발생했을 것으로 추정된다. 도 7의 (f)의 두 원은 고장 웨이퍼 17 가공 중에 이상 변동이 발생했을 것으로 추정된 기간의 가공전 시계열 데이터를 보여주는데, 첫 번째 기간에는 고장 웨이퍼 17의 시계열 데이터와 정상 시계열 데이터가 큰 차이를 보이지 않아 잘못된 경고인 것으로 판단되고, 두 번째 기간에는 아래 방향으로 피크가 발생했음을 파악할 수 있다.

[0100] 도 8은 CVD 공정의 데이터에 대한 진단 결과이다.

[0101] 도 8의 (a)는 이상 패턴이 발생한 고장 웨이퍼 3 및 7의 디노이즈 잔차 데이터이다. 고장 웨이퍼 3은 226초 ~ 264초 구간에서, 고장 웨이퍼 7은 246초 ~ 264초 구간에서 디노이즈 잔차 데이터가 0을 초과한 것으로 나타난다. 도 8의 (b)의 가공전 시계열 데이터를 DAE 훈련 웨이퍼의 가공전 시계열 데이터와 비교한 결과 고장 웨이퍼 3 가공 중에는 작은 변화가 발생했고, 고장 웨이퍼 7 가공 중에는 파라미터 값이 일정하게 유지되어야 하는 구간에서 갑작스런 변화가 발생했음을 파악할 수 있다. 센서의 파라미터 관측 주기가 0.2초인 것을 고려하면 고장 웨이퍼 3과 7의 가공이 시작된지 각각 45.2초와 49.2초 후에 이상 패턴이 발생했음을 파악할 수 있다.

[0102] 도 8의 (c)는 이상 패턴이 발생한 정상 웨이퍼 29 및 고장 웨이퍼 2의 디노이즈 잔차 데이터이다. 도 8의 (d)의 가공전 시계열 데이터를 분석한 결과, 정상 웨이퍼 29의 디노이즈 잔차 데이터가 0을 초과한 구간에서 정상 웨이퍼 29의 가공전 시계열 데이터와 DAE 훈련 웨이퍼의 가공전 시계열 데이터와 패턴 차이는 볼 수 없고, 고장 웨이퍼 2는 346초 ~ 396초 구간에 해당하는 69.2초 ~ 79.2초까지 심각한 진동이 발생했음을 파악할 수 있다. 디노이즈 잔차 데이터의 출력이 오분류되더라도 가공전 시계열 데이터를 추가로 비교하여 분류 결과를 정정할 수 있다.

[0103] 도 8의 (e)는 이상 패턴이 발생한 고장 웨이퍼 3, 4, 5, 및 6의 디노이즈 잔차 데이터이다. 도 8의 (f)의 가공전 시계열 데이터를 분석한 결과, 45.2초 ~ 52.8초 구간에서 피크 형태의 이상 패턴이 발생한 것을 확인할 수 있다.

[0104] 고장 검출 및 분류 장치는 하드웨어, 펌웨어, 소프트웨어 또는 이들의 조합에 의해 로직회로 내에서 구현될 수 있고, 범용 또는 특정 목적 컴퓨터를 이용하여 구현될 수도 있다. 장치는 고정배선형(Hardwired) 기기, 필드 프로그램 가능한 게이트 어레이(Field Programmable Gate Array, FPGA), 주문형 반도체(Application Specific Integrated Circuit, ASIC) 등을 이용하여 구현될 수 있다. 또한, 장치는 하나 이상의 프로세서 및 컨트롤러를 포함한 시스템온칩(System on Chip, SoC)으로 구현될 수 있다.

[0105] 고장 검출 및 분류 장치는 하드웨어적 요소가 마련된 컴퓨팅 디바이스 또는 서버에 소프트웨어, 하드웨어, 또는 이들의 조합하는 형태로 탑재될 수 있다. 컴퓨팅 디바이스 또는 서버는 각종 기기 또는 유무선 통신망과 통신을

수행하기 위한 통신 모뎀 등의 통신장치, 프로그램을 실행하기 위한 데이터를 저장하는 메모리, 프로그램을 실행하여 연산 및 명령하기 위한 마이크로프로세서 등을 전부 또는 일부 포함한 다양한 장치를 의미할 수 있다.

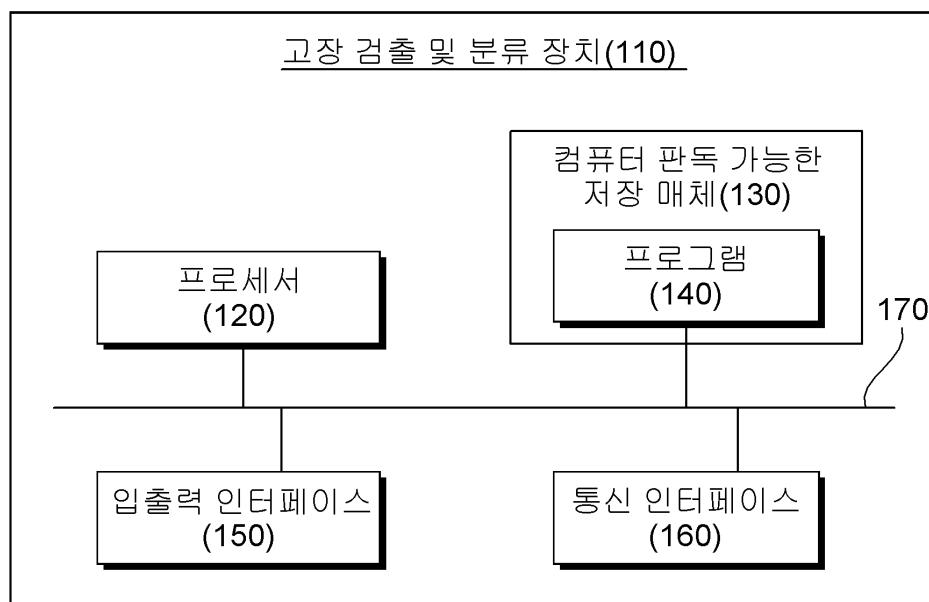
[0106] 도 6에서는 각각의 과정을 순차적으로 실행하는 것으로 기재하고 있으나 이는 예시적으로 설명한 것에 불과하고, 이 분야의 기술자라면 본 발명의 실시예의 본질적인 특성에서 벗어나지 않는 범위에서 도 6에 기재된 순서를 변경하여 실행하거나 또는 하나 이상의 과정을 병렬적으로 실행하거나 다른 과정을 추가하는 것으로 다양하게 수정 및 변형하여 적용 가능할 것이다.

[0107] 본 실시예들에 따른 동작은 다양한 컴퓨터 수단을 통하여 수행될 수 있는 프로그램 명령 형태로 구현되어 컴퓨터 판독 가능한 매체에 기록될 수 있다. 컴퓨터 판독 가능한 매체는 실행을 위해 프로세서에 명령어를 제공하는데 참여한 임의의 매체를 나타낸다. 컴퓨터 판독 가능한 매체는 프로그램 명령, 데이터 파일, 데이터 구조 또는 이들의 조합을 포함할 수 있다. 예를 들면, 자기 매체, 광기록 매체, 메모리 등이 있을 수 있다. 컴퓨터 프로그램은 네트워크로 연결된 컴퓨터 시스템 상에 분산되어 분산 방식으로 컴퓨터가 읽을 수 있는 코드가 저장되고 실행될 수도 있다. 본 실시예를 구현하기 위한 기능적인(Functional) 프로그램, 코드, 및 코드 세그먼트들은 본 실시예가 속하는 기술분야의 프로그래머들에 의해 용이하게 추론될 수 있을 것이다.

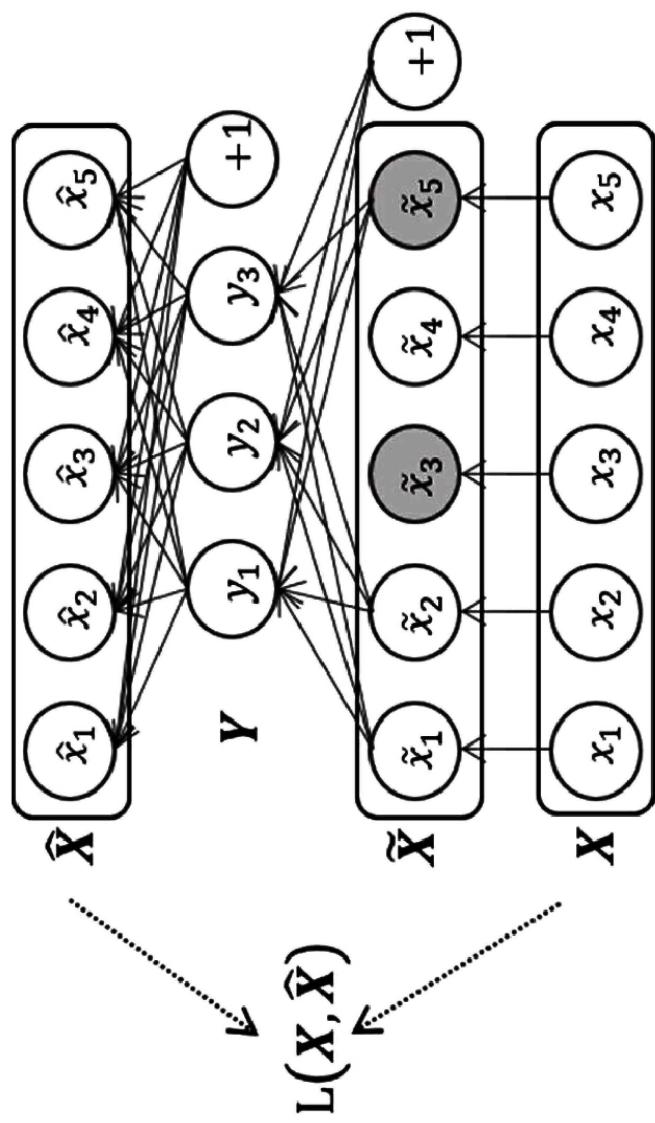
[0108] 본 실시예들은 본 실시예의 기술 사상을 설명하기 위한 것이고, 이러한 실시예에 의하여 본 실시예의 기술 사상의 범위가 한정되는 것은 아니다. 본 실시예의 보호 범위는 아래의 청구범위에 의하여 해석되어야 하며, 그와 동등한 범위 내에 있는 모든 기술 사상은 본 실시예의 권리범위에 포함되는 것으로 해석되어야 할 것이다.

도면

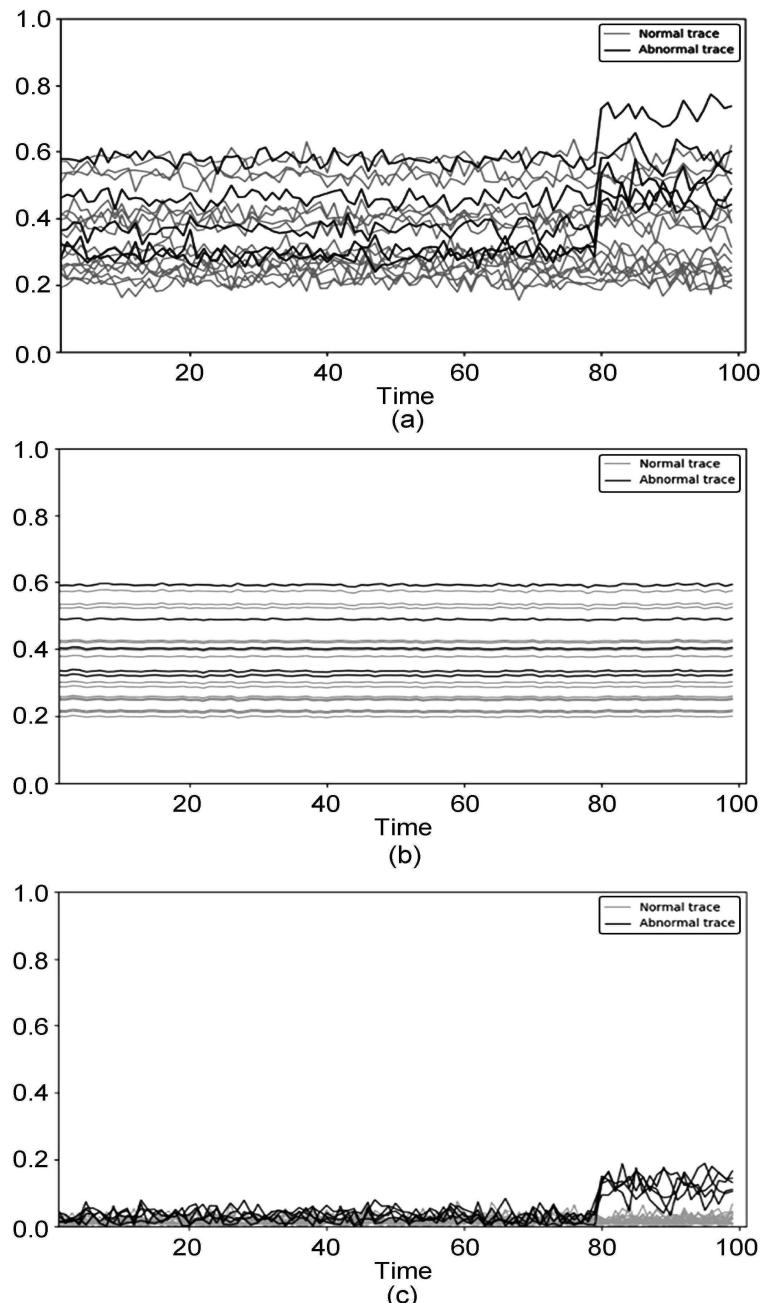
도면1



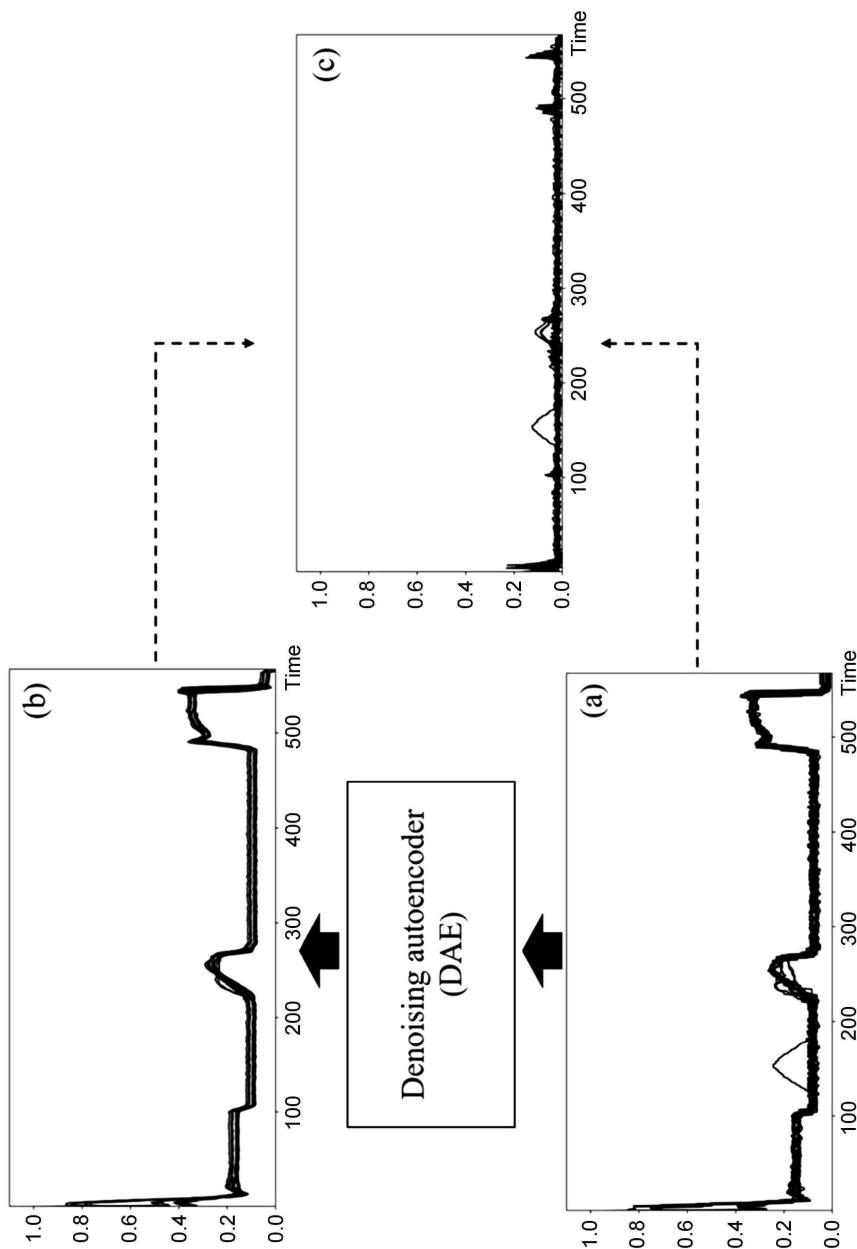
도면2



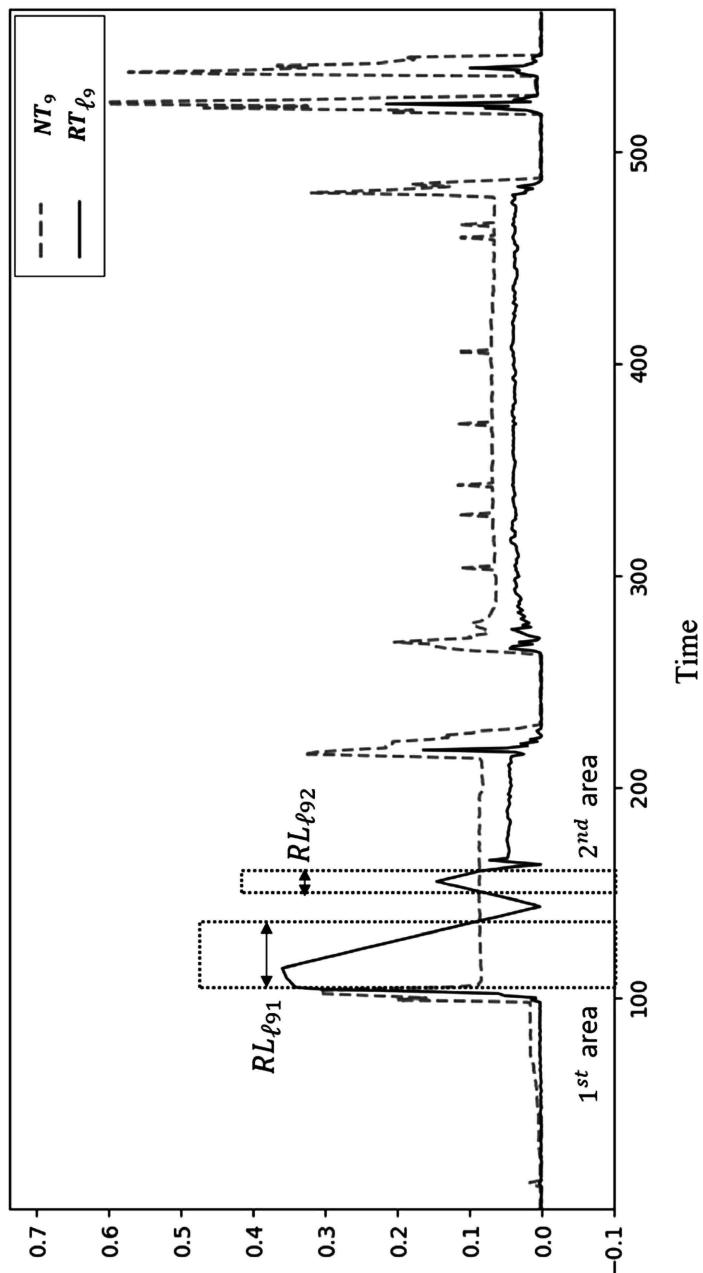
도면3



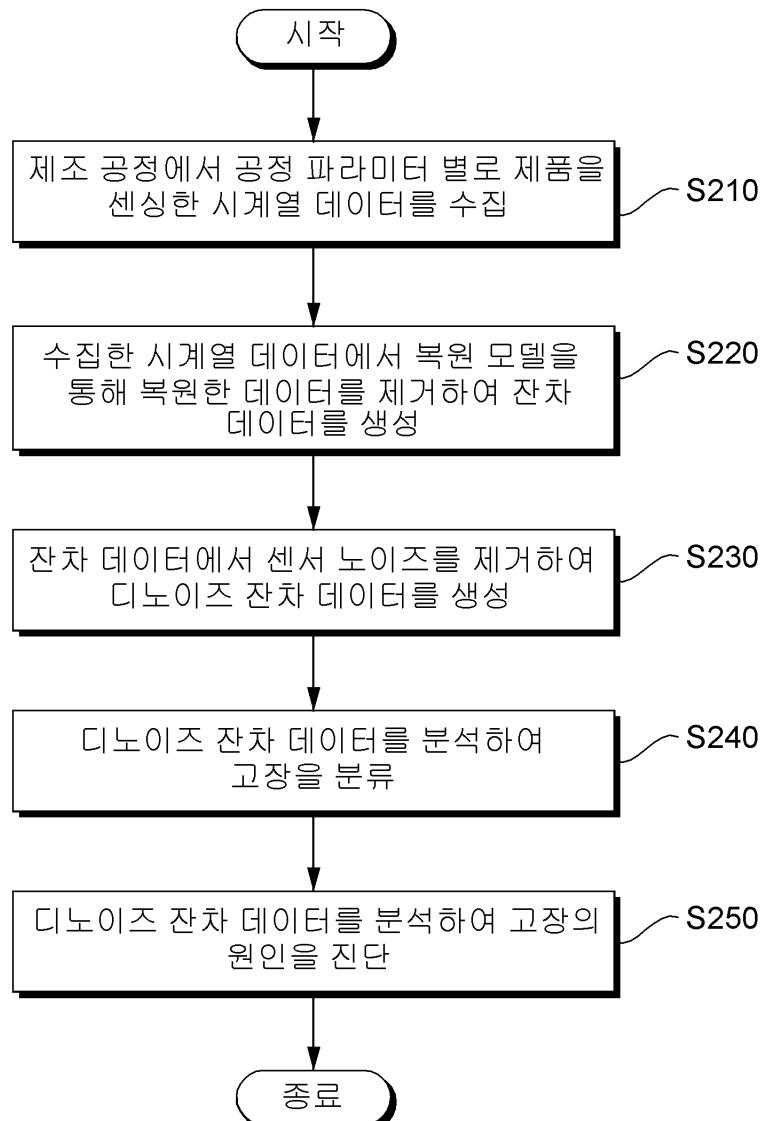
도면4



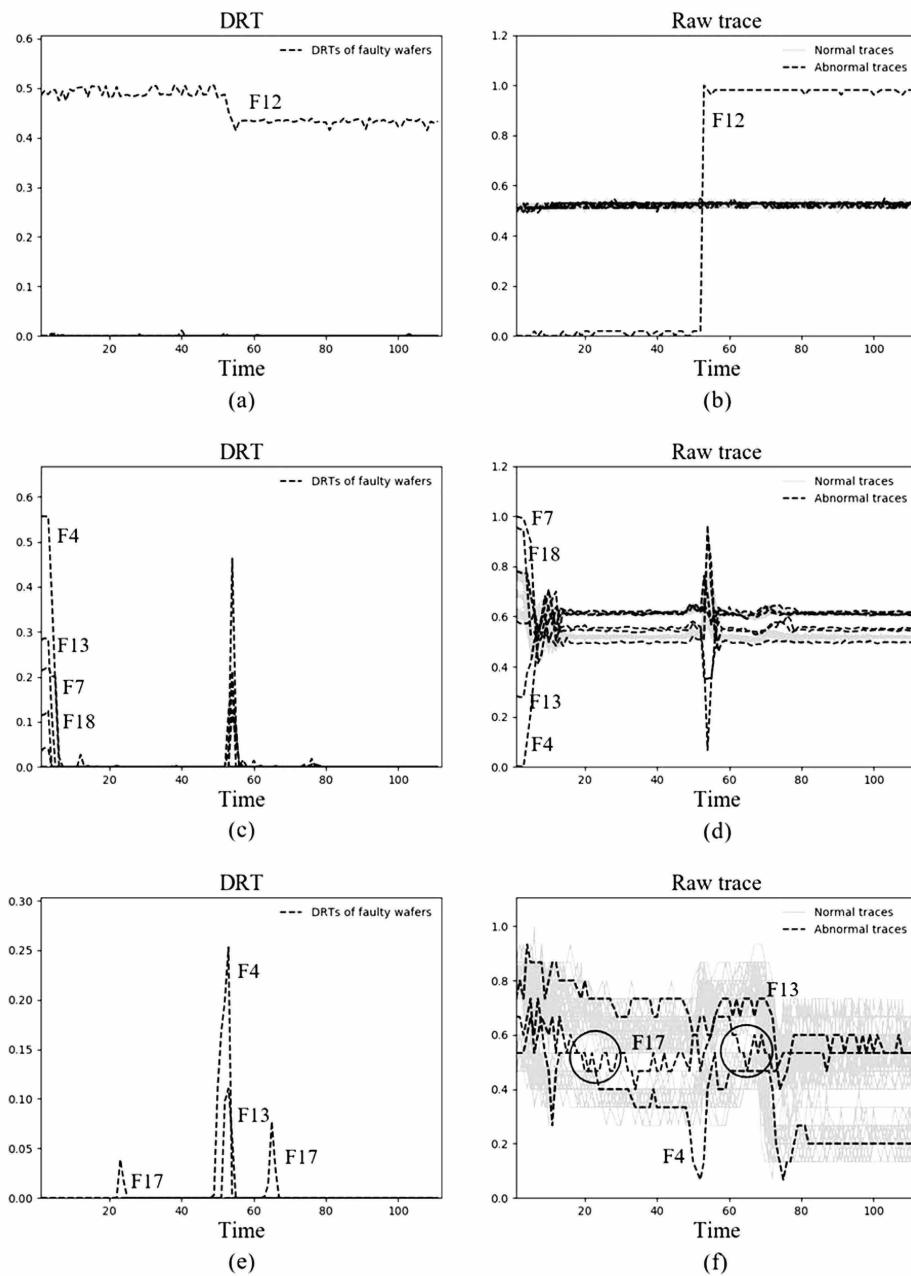
도면5



도면6



도면7



도면8

