



(19) 대한민국특허청(KR)
(12) 등록특허공보(B1)

(45) 공고일자 2024년12월23일
(11) 등록번호 10-2745059
(24) 등록일자 2024년12월17일

(51) 국제특허분류(Int. Cl.)
G06N 3/08 (2023.01) G01N 21/95 (2006.01)
G06N 3/04 (2023.01)
(52) CPC특허분류
G06N 3/08 (2023.01)
G01N 21/8851 (2013.01)
(21) 출원번호 10-2021-0061755
(22) 출원일자 2021년05월13일
심사청구일자 2024년05월13일
(65) 공개번호 10-2022-0014805
(43) 공개일자 2022년02월07일
(30) 우선권주장
16/942,677 2020년07월29일 미국(US)
(56) 선행기술조사문헌
US20170357895 A1

(73) 특허권자
어플라이드 머티리얼즈 이스라엘 리미티드
이스라엘 레호보트 파크 래빈 오픈하이머 스트리트 9 (우: 76705)
(72) 발명자
스테이만, 마탄
이스라엘 6356410 텔 아비브 그네신 스트리트 3
엘카얌, 샬롬
이스라엘 7230164 람라 에후드 매너 스트리트 9
(74) 대리인
양영준, 백만기

전체 청구항 수 : 총 20 항


심사관 : 송근배

(54) 발명의 명칭 반도체 시편의 검사에 사용가능한 훈련 데이터의 생성

(57) 요약

반도체 시편의 검사에 사용가능한 심층 신경망을 훈련시키기 위한 훈련 데이터를 생성하는 시스템 및 방법이 제공된다. 방법은: 제1 훈련 이미지 및 각각의 세그먼트에서 선택된 픽셀들의 군과 각각 연관된 제1 라벨들을 획득하는 단계, 제1 훈련 이미지를 특징화하는 특징들의 세트를 추출하는 단계, 제1 라벨들, 픽셀들의 군의 값들, 및 픽셀들의 군에 대응하는 특징들의 세트 각각의 특징 값들을 사용하여 기계 학습(ML) 모델을 훈련시키는 단계, 제1 세그먼트화 지도를 획득하기 위해, 훈련된 ML 모델을 사용하여 제1 훈련 이미지를 처리하는 단계, 및 기준이 충족될 때 제1 훈련 이미지 및 제1 세그먼트화 지도를 DNN 훈련 데이터에 포함시키고, 기준이 충족되지 않을 때 제2 특징들의 추출, 훈련 및 처리를 반복하는 것을 결정하는 단계를 포함한다.

대표도



(52) CPC특허분류

G01N 21/9501 (2013.01)

G06N 20/00 (2021.08)

G06N 3/045 (2023.01)

G06N 5/022 (2023.01)

명세서

청구범위

청구항 1

반도체 시편의 검사에 사용가능한 심층 신경망을 훈련시키기 위한 훈련 데이터(DNN 훈련 데이터)를 생성하는 컴퓨터화된 시스템으로서,

상기 시스템은 프로세서 및 메모리 회로(PMC)를 포함하고, 상기 PMC는:

상기 반도체 시편의 제1 훈련 이미지, 및 상기 제1 훈련 이미지로부터 사용자에게 의해 식별된 하나 이상의 세그먼트 각각에서 선택된 픽셀들의 군과 각각 연관된 제1 라벨들을 획득하고 - 상기 제1 라벨들은 상기 제1 훈련 이미지의 부분 라벨 데이터로서 제공됨 -;

상기 제1 훈련 이미지를 특징화하는 특징들의 세트를 추출하고 - 각각의 특징은 상기 제1 훈련 이미지의 픽셀들에 대응하는 특징 값들을 갖고, 상기 특징들의 세트는 상기 제1 훈련 이미지의 맥락 정보를 나타내는 제1 특징들, 및 각각의 세그먼트의 상기 픽셀들의 군의 통계적 척도에 관한 상기 제1 훈련 이미지에서의 픽셀 분포에 대한 정보를 제공하는 제2 특징들을 포함함 -;

상기 제1 라벨들, 각각의 세그먼트에서 선택된 상기 픽셀들의 군의 값들, 및 각각의 세그먼트의 상기 픽셀들의 군에 대응하는 상기 특징들의 세트의 각각의 특징의 상기 특징 값들을 사용하여 이미지 세그먼트화를 위한 기계학습(ML) 모델을 훈련시키고;

상기 제1 훈련 이미지의 각각의 픽셀들과 연관된 예측된 라벨들에 대한 정보를 제공하는 제1 세그먼트화 지도를 획득하기 위해 상기 훈련된 ML 모델을 사용하여 상기 제1 훈련 이미지를 처리하고 - 각각의 예측된 라벨은 각각의 픽셀이 속하는 세그먼트를 나타냄 -;

기준이 충족될 때, 상기 제1 훈련 이미지 및 상기 제1 세그먼트화 지도를 포함하는 제1 훈련 샘플을 상기 DNN 훈련 데이터에 포함시키는 것을 결정하도록 구성되는 - 상기 제1 세그먼트화 지도는 상기 제1 훈련 이미지의 전체 라벨 데이터로서 사용됨 -, 컴퓨터화된 시스템.

청구항 2

제1항에 있어서,

상기 훈련 데이터는, 자동화된 세그먼트화, 자동화된 계측, 자동화된 결함 검출, 자동화된 결함 검토, 및 런타임 이미지들에 기초한 자동화된 결함 분류를 포함하는 군으로부터 선택된 적어도 하나의 검사 프로세스를 위해 심층 신경망(DNN)을 훈련시키는 데 사용가능한, 컴퓨터화된 시스템.

청구항 3

제1항에 있어서,

상기 제1 특징들은 상기 제1 훈련 이미지의 하나 이상의 요소들의 맥락 및 상기 하나 이상의 요소들 사이의 맥락 관계들을 나타내는, 컴퓨터화된 시스템.

청구항 4

제1항에 있어서,

상기 기준은 상기 제1 세그먼트화 지도에 대한 사용자 피드백에 기초하고, 상기 PMC는, 상기 제1 세그먼트화 지도에 대해 부정적인 사용자 피드백을 수신할 때, 세그먼트들 중 적어도 하나의 세그먼트의 픽셀들의 추가적인 군과 연관된 추가적인 제1 라벨들을 획득하고 - 상기 제1 라벨들 및 상기 추가적인 제1 라벨들은 집계된 라벨 데이터를 구성함 -, 긍정적인 사용자 피드백을 수신할 때까지, 상기 집계된 라벨 데이터에 기초하여, 상기 제2 특징들의 상기 추출, 상기 훈련 및 상기 처리를 반복하도록 구성되는, 컴퓨터화된 시스템.

청구항 5

제4항에 있어서,

상기 PMC는, 상기 제1 세그먼트화 지도에 대해 긍정적인 사용자 피드백을 수신할 때, 상기 제1 훈련 샘플을 상기 훈련 데이터 내에 포함시키도록 구성되는, 컴퓨터화된 시스템.

청구항 6

제5항에 있어서,

상기 PMC는, 제2 훈련 이미지 및 상기 제2 훈련 이미지로부터 사용자에게 의해 식별된 하나 이상의 세그먼트 각각에서 선택된 픽셀들의 군과 각각 연관된 제2 라벨들을 획득하고 - 상기 제2 라벨들은 상기 집계된 라벨 데이터에 추가된 -, 상기 제2 훈련 이미지를 특징화하고 상기 제1 특징들 및 상기 제2 특징들을 포함하는 특징들의 세트를 추출하고, 상기 집계된 라벨 데이터, 상기 집계된 라벨 데이터와 연관된 픽셀들의 값들, 및 상기 집계된 라벨 데이터와 연관된 상기 픽셀들에 대응하는 상기 특징들의 세트의 각각의 특징의 상기 특징 값들을 사용하여 상기 ML 모델을 훈련시키고, 상기 제2 훈련 이미지에 기초하여 상기 처리 및 결정을 수행하도록 더 구성되는, 컴퓨터화된 시스템.

청구항 7

제1항에 있어서,

상기 하나 이상의 세그먼트 중 적어도 하나는 상기 제1 훈련 이미지에 제시된 하나 이상의 구조적 요소에 대응하는, 컴퓨터화된 시스템.

청구항 8

제1항에 있어서,

상기 제1 특징들은:

상기 제1 훈련 이미지를 필터들의 세트로 처리하고, 특징 응답들의 세트를 생성하는 것 - 각각의 특징 응답은, 상기 필터들의 세트 중 하나의 필터에 대응하고 상기 제1 훈련 이미지의 각각의 픽셀들에 대응하는 특징 응답 값들을 포함하며, 상기 제1 훈련 이미지의 각각의 픽셀은 그의 특징 응답 값들의 세트를 포함하는 특징 벡터에 대응함 -;

상기 제1 훈련 이미지의 상기 픽셀들에 대응하는 상기 특징 벡터들을 복수의 클러스터들로 클러스터화하는 것;

각각의 픽셀에 대해, 그의 상기 특징 벡터가 속하는 상기 클러스터에 따라 특징 값을 할당하고, 상기 제1 훈련 이미지의 픽셀들에 대응하는 특징 값들을 포함하는 특징 지도를 생성하는 것 - 상기 특징 지도는 각각의 특징 값들에 대응하는 복수의 채널들로 분리가능함 -; 및

샘플링 필터를 사용하여 상기 특징 지도의 각각의 채널을 샘플링하고, 복수의 샘플링된 채널들을 갖는 특징 지도를 생성하는 것

에 의해 추출된 질감 특징들을 포함하는, 컴퓨터화된 시스템.

청구항 9

제8항에 있어서,

상기 제1 특징들은, 상기 제1 훈련 이미지의 픽셀 값들을 복수의 클러스터들로 클러스터화하는 것, 각각의 픽셀에 대해, 상기 픽셀 값이 속하는 상기 클러스터에 따라 특징 값을 할당하고, 각각의 특징 값들에 대응하는 복수의 채널들로 분리가능한 특징 지도를 생성하는 것, 및 샘플링 필터를 사용하여 상기 특징 지도의 각각의 채널을 샘플링하고, 복수의 샘플링된 채널들을 갖는 특징 지도를 생성하는 것에 의해 추출되는 강도 특징들을 더 포함하는, 컴퓨터화된 시스템.

청구항 10

제8항에 있어서,

상기 필터들의 세트는 미분 필터들, 가버 필터들, 및 라플라시안 필터들 중 하나 이상을 포함하는, 컴퓨터화된

시스템.

청구항 11

제1항에 있어서,

상기 제2 특징들은, 각각의 세그먼트의 상기 픽셀들의 군에 대한 통계적 척도를 계산하는 것, 및, 상기 제1 훈련 이미지의 각각의 픽셀에 대해, 대응하는 특징 값을 상기 픽셀의 값과 각각의 세그먼트의 상기 통계적 척도 사이의 거리로서 계산하고, 각각이, 픽셀 값들과 각각의 세그먼트의 상기 통계적 척도 사이의 거리들에 대응하는 특징 값들을 포함하는 하나 이상의 특징 지도를 생성하는 것에 의해 추출되는, 컴퓨터화된 시스템.

청구항 12

제1항에 있어서,

상기 PMC는 상기 DNN을 훈련시키기 위해 상기 DNN 훈련 데이터를 사용하고, 이미지들의 검증 세트를 사용하여 상기 훈련된 DNN을 검증하도록 더 구성되는, 컴퓨터화된 시스템.

청구항 13

반도체 시편의 검사에 사용가능한 심층 신경망을 훈련시키기 위한 훈련 데이터(DNN 훈련 데이터)를 생성하기 위한 컴퓨터화된 방법으로서,

상기 방법은 프로세서 및 메모리 회로(PMC)에 의해 수행되고, 상기 방법은:

상기 반도체 시편의 제1 훈련 이미지, 및 상기 제1 훈련 이미지로부터 사용자에게 의해 식별된 하나 이상의 세그먼트 각각에서 선택된 픽셀들의 군과 각각 연관된 제1 라벨들을 획득하는 단계 - 상기 제1 라벨들은 상기 제1 훈련 이미지의 부분 라벨 데이터로서 제공됨 -;

상기 제1 훈련 이미지를 특징화하는 특징들의 세트를 추출하는 단계 - 각각의 특징은 상기 제1 훈련 이미지의 픽셀들에 대응하는 특징 값들을 갖고, 상기 특징들의 세트는 상기 제1 훈련 이미지의 맥락 정보를 나타내는 제1 특징들, 및 각각의 세그먼트의 상기 픽셀들의 군의 통계적 척도에 관한 상기 제1 훈련 이미지에서의 픽셀 분포에 대한 정보를 제공하는 제2 특징들을 포함함 -;

상기 제1 라벨들, 각각의 세그먼트에서 선택된 상기 픽셀들의 군의 값들, 및 각각의 세그먼트의 상기 픽셀들의 군에 대응하는 상기 특징들의 세트의 각각의 특징의 상기 특징 값들을 사용하여 이미지 세그먼트화를 위한 기계 학습(ML) 모델을 훈련시키는 단계;

상기 제1 훈련 이미지의 각각의 픽셀들과 연관된 예측된 라벨들에 대한 정보를 제공하는 제1 세그먼트화 지도를 획득하기 위해 상기 훈련된 ML 모델을 사용하여 상기 제1 훈련 이미지를 처리하는 단계 - 각각의 예측된 라벨은 각각의 픽셀이 속하는 세그먼트를 나타냄 -; 및

기준이 충족될 때, 상기 제1 훈련 이미지 및 상기 제1 세그먼트화 지도를 포함하는 제1 훈련 샘플을 상기 DNN 훈련 데이터에 포함시키는 것을 결정하는 단계 - 상기 제1 세그먼트화 지도는 상기 제1 훈련 이미지의 전체 라벨 데이터로서 사용됨 -를 포함하는, 컴퓨터화된 방법.

청구항 14

제13항에 있어서,

상기 기준은 상기 제1 세그먼트화 지도에 대한 사용자 피드백에 기초하고, 상기 방법은: 상기 제1 세그먼트화 지도에 대해 부정적인 사용자 피드백을 수신할 때, 세그먼트들 중 적어도 하나의 픽셀들의 추가적인 군과 연관된 추가적인 제1 라벨들을 획득하고 - 상기 제1 라벨들 및 상기 추가적인 제1 라벨들은 집계된 라벨 데이터를 구성함 -, 긍정적인 사용자 피드백을 수신할 때까지, 상기 집계된 라벨 데이터에 기초하여, 상기 제2 특징들의 상기 추출, 상기 훈련 및 상기 처리를 반복하는 단계를 더 포함하는, 컴퓨터화된 방법.

청구항 15

제14항에 있어서,

상기 제1 세그먼트화 지도에 대해 긍정적인 사용자 피드백을 수신할 때, 상기 제1 훈련 샘플을 상기 훈련 데이

터 내에 포함시키는 단계를 더 포함하는, 컴퓨터화된 방법.

청구항 16

제13항에 있어서,

상기 제1 특징들은:

상기 제1 훈련 이미지를 필터들의 세트로 처리하고, 특징 응답들의 세트를 생성하는 단계 - 각각의 특징 응답은, 상기 필터들의 세트 중 하나의 필터에 대응하고 상기 제1 훈련 이미지의 각각의 픽셀들에 대응하는 특징 응답 값들을 포함하며, 상기 제1 훈련 이미지의 각각의 픽셀은 그의 특징 응답 값들의 세트를 포함하는 특징 벡터에 대응함 -;

상기 제1 훈련 이미지의 상기 픽셀들에 대응하는 상기 특징 벡터들을 복수의 클러스터들로 클러스터화하는 단계;

각각의 픽셀에 대해, 그의 상기 특징 벡터가 속하는 상기 클러스터에 따라 특징 값을 할당하고, 상기 제1 훈련 이미지의 픽셀들에 대응하는 특징 값들을 포함하는 특징 지도를 생성하는 단계 - 상기 특징 지도는 각각의 특징 값들에 대응하는 복수의 채널들로 분리가능함 -; 및

샘플링 필터를 사용하여 상기 특징 지도의 각각의 채널을 샘플링하고, 복수의 샘플링된 채널들을 갖는 특징 지도를 생성하는 단계

에 의해 추출된 질감 특징들을 포함하는, 컴퓨터화된 방법.

청구항 17

제16항에 있어서,

상기 제1 특징들은, 상기 제1 훈련 이미지의 픽셀 값들을 복수의 클러스터들로 클러스터화하는 단계, 각각의 픽셀에 대해, 상기 픽셀 값이 속하는 상기 클러스터에 따라 특징 값을 할당하고, 각각의 특징 값들에 대응하는 복수의 채널들로 분리가능한 특징 지도를 생성하는 단계, 및 샘플링 필터를 사용하여 상기 특징 지도의 각각의 채널을 샘플링하고, 복수의 샘플링된 채널들을 갖는 특징 지도를 생성하는 단계에 의해 추출되는 강도 특징들을 더 포함하는, 컴퓨터화된 방법.

청구항 18

제13항에 있어서,

상기 제2 특징들은, 각각의 세그먼트의 상기 픽셀들의 군에 대한 통계적 척도를 계산하는 단계, 및, 상기 제1 훈련 이미지의 각각의 픽셀에 대해, 대응하는 특징 값을 상기 픽셀의 값과 각각의 세그먼트의 상기 통계적 척도 사이의 거리로서 계산하고, 각각이, 픽셀 값들과 각각의 세그먼트의 상기 통계적 척도 사이의 거리들에 대응하는 특징 값들을 포함하는 하나 이상의 특징 지도를 생성하는 단계에 의해 추출되는, 컴퓨터화된 방법.

청구항 19

제13항에 있어서,

상기 DNN을 훈련시키기 위해 상기 DNN 훈련 데이터를 사용하는 단계, 및 이미지들의 검증 세트를 사용하여 상기 훈련된 DNN을 검증하는 단계를 더 포함하는, 컴퓨터화된 방법.

청구항 20

컴퓨터에 의해 실행될 때, 상기 컴퓨터로 하여금, 반도체 시편의 검사에 사용가능한 심층 신경망을 훈련시키기 위한 훈련 데이터(DNN 훈련 데이터)를 생성하는 방법을 수행하게 하는 명령어들의 프로그램을 유형적으로 구현하는 비일시적 컴퓨터 판독가능 저장 매체로서,

상기 방법은:

상기 반도체 시편의 제1 훈련 이미지, 및 상기 제1 훈련 이미지로부터 사용자에게 의해 식별된 하나 이상의 세그먼트 각각에서 선택된 픽셀들의 군과 각각 연관된 제1 라벨들을 획득하는 단계 - 상기 제1 라벨들은 상기 제1

훈련 이미지의 부분 라벨 데이터로서 제공됨 -;

상기 제1 훈련 이미지를 특징화하는 특징들의 세트를 추출하는 단계 - 각각의 특징은 상기 제1 훈련 이미지의 픽셀들에 대응하는 특징 값들을 갖고, 상기 특징들의 세트는 상기 제1 훈련 이미지의 맥락 정보를 나타내는 제1 특징들, 및 각각의 세그먼트의 상기 픽셀들의 군의 통계적 척도에 관한 상기 제1 훈련 이미지에서의 픽셀 분포에 대한 정보를 제공하는 제2 특징들을 포함함 -;

상기 제1 라벨들, 각각의 세그먼트에서 선택된 상기 픽셀들의 군의 값들, 및 각각의 세그먼트의 상기 픽셀들의 군에 대응하는 상기 특징들의 세트의 각각의 특징의 상기 특징 값들을 사용하여 이미지 세그먼트화를 위한 기계 학습(ML) 모델을 훈련시키는 단계;

상기 제1 훈련 이미지의 각각의 픽셀들과 연관된 예측된 라벨들에 대한 정보를 제공하는 제1 세그먼트화 지도를 획득하기 위해 상기 훈련된 ML 모델을 사용하여 상기 제1 훈련 이미지를 처리하는 단계 - 각각의 예측된 라벨은 각각의 픽셀이 속하는 세그먼트를 나타냄 -; 및

기준이 충족될 때, 상기 제1 훈련 이미지 및 상기 제1 세그먼트화 지도를 포함하는 제1 훈련 샘플을 상기 DNN 훈련 데이터에 포함시키는 것을 결정하는 단계 - 상기 제1 세그먼트화 지도는 상기 제1 훈련 이미지의 전체 라벨 데이터로서 사용됨 - 를 포함하는, 비밀시적 컴퓨터 판독가능 저장 매체.

발명의 설명

기술 분야

[0001] 본 개시된 주제는, 일반적으로, 반도체 시편 검사 분야에 관한 것이며, 더 구체적으로, 시편의 검사에 사용가능한 훈련 데이터 생성에 관한 것이다.

배경 기술

[0002] 제조되는 디바이스들의 극초대규모 집적 회로와 연관된, 높은 밀도 및 성능에 대한 현재의 요구들은 미크론미만 피쳐들, 증가된 트랜지스터 및 회로 속도들, 및 개선된 신뢰성을 필요로 한다. 반도체 프로세스들이 진행됨에 따라, 패턴 치수들, 예컨대, 라인 폭, 및 다른 유형들의 임계 치수들이 연속적으로 축소된다. 그러한 요구들은 높은 정밀도 및 균일성으로 디바이스 피쳐들을 형성하는 것을 필요로 하는데, 이는 차례로, 디바이스들이 여전히 반도체 웨이퍼들의 형태로 되어 있는 동안 디바이스들의 자동화된 검사를 포함하는, 제조 프로세스의 주의 깊은 모니터링을 요한다.

[0003] 비제한적인 예로서, 런타임 검사는 2단계 절차, 예를 들어, 시편의 검사 및 이어서, 잠재적 결함들의 샘플링된 위치들의 검토를 채용할 수 있다. 검사는 일반적으로, 광 또는 전자들을 웨이퍼쪽으로 지향시키고 웨이퍼로부터의 광 또는 전자들을 검출함으로써 시편에 대한 특정 출력(예를 들어, 이미지들, 신호들 등)을 생성하는 것을 수반한다. 제1 단계 동안, 시편의 표면은 고속 및 비교적 저해상도로 검사된다. 결함 검출은 전형적으로, 결함 검출 알고리즘을 검사 출력에 적용함으로써 수행된다. 결함의 높은 확률을 갖는, 시편 상의 의심되는 위치들을 보여주기 위해 결함 지도가 생성된다. 가장 흔하게, 검사의 목적은 웨이퍼 상의 방해 및 잡음의 검출을 억제하면서, 관심 있는 결함들을 검출하기 위해 높은 감도를 제공하는 것이다. 제2 단계 동안, 의심되는 위치들 중 적어도 일부가, 비교적 높은 해상도로 더 철저하게 분석된다. 일부 경우들에서, 양쪽 단계들 모두, 동일한 검사 툴에 의해 구현될 수 있고, 일부 다른 경우들에서는, 이러한 2개의 단계들은 상이한 검사 툴들에 의해 구현된다.

[0004] 검사 프로세스들은 복수의 검사 단계들을 포함할 수 있다. 제조 프로세스 동안, 검사 단계들은 여러 번, 예를 들어, 특정 층들의 제조 또는 처리 후에 등에 수행될 수 있다. 추가적으로 또는 대안적으로, 각각의 검사 단계는, 예를 들어, 상이한 웨이퍼 위치들에 대해 또는 상이한 검사 설정들로 동일한 웨이퍼 위치들에 대해 다수 회 반복될 수 있다.

[0005] 검사 프로세스들은, 시편들 상의 결함들을 검출하고 분류할 뿐만 아니라 계측 관련 작동들을 수행하기 위해, 반도체 제조 동안 다양한 단계들에 사용된다. 검사의 유효성은, 예를 들어, 결함 검출, 자동 결함 분류(ADC), 자동 결함 검토(ADR), 이미지 세그먼트화, 자동화된 계측 관련 작동들 등과 같은 프로세스(들)의 자동화에 의해 증가될 수 있다.

발명의 내용

- [0006] 본 개시된 주제의 특정 양상들에 따르면, 반도체 시편의 검사에 사용가능한 심층 신경망을 훈련시키기 위한 훈련 데이터(DNN 훈련 데이터)를 생성하는 컴퓨터화된 시스템이 제공되며, 시스템은 프로세서 및 메모리 회로(PMC)를 포함하고, 프로세서 및 메모리 회로는: 반도체 시편의 적어도 일부를 나타내는 제1 훈련 이미지, 및 제1 훈련 이미지로부터 사용자에게 의해 식별되는 하나 이상의 세그먼트 각각에서 선택된 픽셀들의 군과 각각 연관된 제1 라벨들을 획득하고; 제1 훈련 이미지를 특징화하는 특징들의 세트를 추출하고 - 각각의 특징은 제1 훈련 이미지의 픽셀들에 대응하는 특징 값들을 가지며, 특징들의 세트는 제1 훈련 이미지의 하나 이상의 세그먼트 사이의 맥락 관계들에 대한 정보를 제공하는 제1 특징들, 및 각각의 세그먼트의 픽셀들의 군의 통계적 척도에 관한 제1 훈련 이미지에서의 픽셀 분포에 대한 정보를 제공하는 제2 특징들을 포함함 -; 제1 라벨들, 제1 라벨들과 연관된 각각의 세그먼트에서 선택된 픽셀들의 군의 값들, 및 각각의 세그먼트의 픽셀들의 군에 대응하는 특징들의 세트의 각각의 특징의 특징 값들을 사용하여 기계 학습(ML) 모델을 훈련시키고 - ML 모델은 이미지 세그먼트화를 위해 훈련됨 -; 제1 훈련 이미지의 각각의 픽셀들과 연관된 예측된 라벨들에 대한 정보를 제공하는 제1 세그먼트화 지도를 획득하기 위해, 훈련된 ML 모델을 사용하여 제1 훈련 이미지를 처리하고 - 각각의 예측된 라벨은 각각의 픽셀이 속하는 세그먼트를 나타냄 -; 기준이 충족될 때, 제1 훈련 이미지 및 제1 세그먼트화 지도를 포함하는 제1 훈련 샘플을 DNN 훈련 데이터 내에 포함시키고, 기준이 충족되지 않을 때 제2 특징들의 추출, 훈련 및 처리를 반복하는 것을 결정하도록 구성된다.
- [0007] 상기 특징들 외에도, 본 개시된 주제의 이 양상에 따른 시스템은 아래에 열거된 특징들 (i) 내지 (xi) 중 하나 이상을, 기술적으로 가능한 임의의 원하는 조합 또는 순열로 포함할 수 있다.
- [0008] (i). 훈련 데이터는, 자동화된 세그먼트화, 자동화된 계측, 자동화된 결함 검출, 자동화된 결함 검토, 및 런타임 이미지들에 기초한 자동화된 결함 분류를 포함하는 군으로부터 선택된 적어도 하나의 검사 프로세스를 위해 심층 신경망(DNN)을 훈련시키는 데 사용가능할 수 있다.
- [0009] (ii). 기준은 제1 세그먼트화 지도에 대한 사용자 피드백에 기초하고, PMC는, 제1 세그먼트화 지도에 대해 부정적인 사용자 피드백을 수신할 때, 세그먼트들 중 적어도 하나의 세그먼트의 픽셀들의 추가적인 군과 연관된 추가적인 제1 라벨들을 획득하고 - 제1 라벨들 및 추가적인 제1 라벨들은 집계된 라벨 데이터를 구성함 -, 긍정적인 사용자 피드백을 수신할 때까지, 집계된 라벨 데이터에 기초하여, 제2 특징들의 추출, 훈련 및 처리를 반복하도록 구성된다.
- [0010] (iii). PMC는, 제1 세그먼트화 지도에 대해 긍정적인 사용자 피드백을 수신할 때, 제1 훈련 샘플을 훈련 데이터 내에 포함시키도록 구성된다.
- [0011] (iv). PMC는, 제2 훈련 이미지 및 제2 훈련 이미지로부터 사용자에게 의해 식별된 하나 이상의 세그먼트 각각에서 선택된 픽셀들의 군과 각각 연관된 제2 라벨들을 획득하고 - 제2 라벨들은 집계된 라벨 데이터에 추가됨 -, 제2 훈련 이미지를 특징화하고 제1 특징들 및 제2 특징들을 포함하는 특징들의 세트를 추출하고, 집계된 라벨 데이터, 집계된 라벨 데이터와 연관된 픽셀들의 값들, 및 집계된 라벨 데이터와 연관된 픽셀들에 대응하는 특징들의 세트의 각각의 특징의 특징 값들을 사용하여 ML 모델을 훈련시키고, 제2 훈련 이미지에 기초하여 처리 및 결정을 수행하도록 더 구성된다.
- [0012] (v). 하나 이상의 세그먼트 중 적어도 하나는 제1 훈련 이미지에 제시된 하나 이상의 구조적 요소에 대응한다.
- [0013] (vi). 제1 특징들은, 제1 훈련 이미지를 필터들의 세트로 처리하고, 각각이, 제1 훈련 이미지의 각각의 픽셀들에 대응하는 특징 응답 값들을 포함하는 특징 응답들의 세트를 생성하는 단계 - 각각의 픽셀은 그의 특징 응답 값들의 세트를 포함하는 특징 벡터에 대응함 -; 제1 훈련 이미지의 픽셀들에 대응하는 특징 벡터들을 복수의 클러스터들로 클러스터화하는 단계; 각각의 픽셀에 대해, 그의 특징 벡터가 속하는 클러스터에 따라 특징 값을 할당하고, 제1 훈련 이미지의 픽셀들에 대응하는 특징 값들을 포함하는 특징 지도를 생성하는 단계 - 특징 지도는 각각의 특징 값들에 대응하는 복수의 채널들로 분리가능함 -; 및 샘플링 필터를 사용하여 특징 지도의 각각의 채널을 샘플링하고, 복수의 샘플링된 채널들을 갖는 특징 지도를 생성하는 단계에 의해 추출되는 질감 특징들을 포함한다.
- [0014] (vii). 제1 특징들은, 제1 훈련 이미지의 픽셀 값들을 복수의 클러스터들로 클러스터화하는 단계, 각각의 픽셀에 대해, 픽셀 값이 속하는 클러스터에 따라 특징 값을 할당하고, 각각의 특징 값들에 대응하는 복수의 채널들로 분리가능한 특징 지도를 생성하는 단계, 및 샘플링 필터를 사용하여 특징 지도의 각각의 채널을 샘플링하고, 복수의 샘플링된 채널들을 갖는 특징 지도를 생성하는 단계에 의해 추출되는 강도 특징들을 더 포함한다.
- [0015] (viii). 필터들의 세트는 다음 필터들: 미분 필터들, 가버 필터들 및 라플라시안 필터들 중 하나 이상을 포함한

다.

- [0016] (ix). 제2 특징들은, 각각의 세그먼트의 픽셀들의 군에 대한 통계적 척도를 계산하는 단계, 및, 제1 훈련 이미지의 각각의 픽셀에 대해, 대응하는 특징 값을 픽셀의 값과 각각의 세그먼트의 통계적 척도 사이의 거리로서 계산하고, 각각이, 픽셀 값들과 각각의 세그먼트의 통계적 척도 사이의 거리들에 대응하는 특징 값들을 포함하는 하나 이상의 특징 지도를 생성하는 단계에 의해 추출된다.
- [0017] (x). 훈련 이미지는 상이한 관점들로부터 캡처된 다수의 채널들을 포함하고, 특징들의 세트는 다수의 채널들로부터 추출된다.
- [0018] (xi). PMC는 DNN을 훈련시키기 위해 DNN 훈련 데이터를 사용하고, 이미지들의 검증 세트를 사용하여, 훈련된 DNN을 검증하도록 더 구성된다.
- [0019] 본 개시된 주제의 다른 양상들에 따르면, 시편의 검사에 사용가능한 심층 신경망을 훈련시키기 위한 훈련 데이터(DNN 훈련 데이터)를 생성하기 위한 방법이 제공되며, 방법은 프로세서 및 메모리 회로(PMC)에 의해 수행되고, 반도체 시편의 적어도 일부를 나타내는 제1 훈련 이미지, 및 제1 훈련 이미지로부터 사용자에게 의해 식별되는 하나 이상의 세그먼트 각각에서 선택된 픽셀들의 군과 각각 연관된 제1 라벨들을 획득하는 단계; 제1 훈련 이미지를 특징화하는 특징들의 세트를 추출하는 단계 - 각각의 특징은 제1 훈련 이미지의 픽셀들에 대응하는 특징 값들을 가지며, 특징들의 세트는 제1 훈련 이미지의 하나 이상의 세그먼트 사이의 맥락 관계들에 대한 정보를 제공하는 제1 특징들, 및 각각의 세그먼트의 픽셀들의 군의 통계적 척도에 관한 제1 훈련 이미지에서의 픽셀 분포에 대한 정보를 제공하는 제2 특징들을 포함함 -; 제1 라벨들, 제1 라벨들과 연관된 각각의 세그먼트에서 선택된 픽셀들의 군의 값들, 및 각각의 세그먼트의 픽셀들의 군에 대응하는 특징들의 세트의 각각의 특징의 특징 값들을 사용하여 기계 학습(ML) 모델을 훈련시키는 단계 - ML 모델은 이미지 세그먼트화를 위해 훈련됨 -; 제1 훈련 이미지의 각각의 픽셀들과 연관된 예측된 라벨들에 대한 정보를 제공하는 제1 세그먼트화 지도를 획득하기 위해, 훈련된 ML 모델을 사용하여 제1 훈련 이미지를 처리하는 단계 - 각각의 예측된 라벨은 각각의 픽셀이 속하는 세그먼트를 나타냄 -; 및, 기준이 충족될 때, 제1 훈련 이미지 및 제1 세그먼트화 지도를 포함하는 제1 훈련 샘플을 DNN 훈련 데이터 내에 포함시키고, 기준이 충족되지 않을 때 제2 특징들의 추출, 훈련 및 처리를 반복하는 것을 결정하는 단계를 포함한다.
- [0020] 개시된 주제의 이 양상은 시스템과 관련하여 위에서 열거된 특징들 (i) 내지 (xi) 중 하나 이상을, 준용하여, 기술적으로 가능한 임의의 원하는 조합 또는 순열로 포함할 수 있다.
- [0021] 본 개시된 주제의 다른 양상들에 따르면, 컴퓨터에 의해 실행될 때, 컴퓨터로 하여금, 시편의 검사에 사용가능한 심층 신경망을 훈련시키기 위한 훈련 데이터(DNN 훈련 데이터)를 생성하기 위한 방법을 수행하게 하는 명령어들을 포함하는 비일시적 컴퓨터 판독가능 매체가 제공되며, 방법은: 반도체 시편의 적어도 일부를 나타내는 제1 훈련 이미지, 및 제1 훈련 이미지로부터 사용자에게 의해 식별되는 하나 이상의 세그먼트 각각에서 선택된 픽셀들의 군과 각각 연관된 제1 라벨들을 획득하는 단계; 제1 훈련 이미지를 특징화하는 특징들의 세트를 추출하는 단계 - 각각의 특징은 제1 훈련 이미지의 픽셀들에 대응하는 특징 값들을 가지며, 특징들의 세트는 제1 훈련 이미지의 하나 이상의 세그먼트 사이의 맥락 관계들에 대한 정보를 제공하는 제1 특징들, 및 각각의 세그먼트의 픽셀들의 군의 통계적 척도에 관한 제1 훈련 이미지에서의 픽셀 분포에 대한 정보를 제공하는 제2 특징들을 포함함 -; 제1 라벨들, 제1 라벨들과 연관된 각각의 세그먼트에서 선택된 픽셀들의 군의 값들, 및 각각의 세그먼트의 픽셀들의 군에 대응하는 특징들의 세트의 각각의 특징의 특징 값들을 사용하여 기계 학습(ML) 모델을 훈련시키는 단계 - ML 모델은 이미지 세그먼트화를 위해 훈련됨 -; 제1 훈련 이미지의 각각의 픽셀들과 연관된 예측된 라벨들에 대한 정보를 제공하는 제1 세그먼트화 지도를 획득하기 위해, 훈련된 ML 모델을 사용하여 제1 훈련 이미지를 처리하는 단계 - 각각의 예측된 라벨은 각각의 픽셀이 속하는 세그먼트를 나타냄 -; 및, 기준이 충족될 때, 제1 훈련 이미지 및 제1 세그먼트화 지도를 포함하는 제1 훈련 샘플을 DNN 훈련 데이터 내에 포함시키고, 기준이 충족되지 않을 때 제2 특징들의 추출, 훈련 및 처리를 반복하는 것을 결정하는 단계를 포함한다.
- [0022] 개시된 주제의 이 양상은 방법과 관련하여 위에서 열거된 특징들 (i) 내지 (xi) 중 하나 이상을, 준용하여, 기술적으로 가능한 임의의 원하는 조합 또는 순열로 포함할 수 있다.

도면의 간단한 설명

- [0023] 본 개시내용을 이해하고 본 개시내용이 어떻게 실제로 수행될 수 있는지를 알기 위해, 이제, 첨부 도면을 참조

하여 단지 비제한적인 예로서 실시예들이 설명될 것이고, 도면들에서:

도 1은 본 개시된 주제의 특정 실시예들에 따른 검사 시스템의 일반화된 블록도를 예시한다.

도 2a는 본 개시된 주제의 특정 실시예들에 따라 반도체 시편의 검사에 사용가능한 DNN을 훈련시키기 위한 훈련 데이터를 생성하는 일반화된 흐름도를 예시한다.

도 2b는 본 개시된 주제의 특정 실시예들에 따라 제1 세그먼트화 지도에 대해 부정적인 사용자 피드백을 수신할 때 DNN 훈련 데이터 생성의 계속된 프로세스의 일반화된 흐름도를 예시한다.

도 3a는 본 개시된 주제의 특정 실시예들에 따라 제1 훈련 이미지로부터 질감 특징들을 추출하는 일반화된 흐름도를 예시한다.

도 3b는 본 개시된 주제의 특정 실시예들에 따라 제1 훈련 이미지로부터 통계적 특징들을 추출하는 일반화된 흐름도를 예시한다.

도 4는 본 개시된 주제의 특정 실시예들에 따라 DNN을 훈련시키기 위한 생성된 DNN 훈련 데이터를 사용하는 일반화된 흐름도를 예시한다.

도 5는 본 개시된 주제의 특정 실시예들에 따른 훈련 이미지의 예를 예시한다.

도 6은 본 개시된 주제의 특정 실시예들에 따른 훈련 이미지에 대한 부분적인 사용자 주석의 예를 예시한다.

도 7은 본 개시된 주제의 특정 실시예들에 따른 질감 특징의 예 및 강도 특징의 예를 예시한다.

도 8은 본 개시된 주제의 특정 실시예들에 따른 부정적인 사용자 피드백을 갖는 세그먼트화 지도의 예를 예시한다.

도 9a는 본 개시된 주제의 특정 실시예들에 따라 사용자에게 의해 제공되는 추가적인 제1 라벨들의 예를 예시한다.

도 9b는 본 개시된 주제의 특정 실시예들에 따른 긍정적인 사용자 피드백을 갖는 업데이트된 세그먼트화 지도의 예를 예시한다.

발명을 실시하기 위한 구체적인 내용

[0024] 이하의 상세한 설명에서, 본 개시내용의 완전한 이해를 제공하기 위해 다수의 특정한 세부 사항들이 열거된다. 그러나, 본 개시된 주제가 이러한 구체적인 세부 사항들 없이 실시될 수 있다는 점을 관련 기술분야의 통상의 기술자는 이해할 것이다. 다른 경우들에서, 잘 알려진 방법들, 절차들, 구성요소들 및 회로들은 본 개시된 주제를 모호하게 하지 않기 위해 상세히 설명되지 않았다.

[0025] 이하의 논의들로부터 명백한 바와 같이, 구체적으로 달리 언급되지 않는 한, 본 명세서 전반에 걸쳐 "생성", "훈련", "획득", "추출", "처리", "결정", "반복", "포함", "수신", "클러스터화", "할당", "샘플링", "계산", "사용", "검증" 등과 같은 용어들을 활용하는 논의들이, 데이터 - 상기 데이터는 물리적으로, 예컨대, 전자, 양들로 표현되고/거나 상기 데이터는 물리적 대상들을 표현함 - 를 다른 데이터로 조작하고/거나 변환하는, 컴퓨터의 작동(들) 및/또는 프로세스(들)를 지칭한다는 것을 이해한다. "컴퓨터"라는 용어는, 비제한적인 예로서, 본 출원에 개시된 검사 시스템, 훈련 데이터 생성 시스템 및 그의 각각의 부분들을 포함하는, 데이터 처리 능력들을 갖는 임의의 종류의 하드웨어 기반 전자 디바이스를 포함하는 것으로 광범위하게 이해되어야 한다.

[0026] 본 명세서에서 사용되는 "검사"라는 용어는 임의의 종류의 계측 관련 작동들뿐만 아니라 시편의 제조 동안 시편의 결함들의 검출 및/또는 분류와 관련된 작동들도 포함하는 것으로 광범위하게 이해되어야 한다. 검사는 검사될 시편의 제조 동안 또는 제조 이후에 비파괴적 검사 툴들을 사용함으로써 제공된다. 비제한적인 예로서, 검사 프로세스는, 동일하거나 상이한 검사 툴들을 사용하는, 시편 또는 그의 부분들에 관하여 제공되는 (단일 또는 다수 횟수의 스캔들의) 런타임 스캐닝, 샘플링, 검토, 측정, 분류 및/또는 다른 작동들을 포함할 수 있다. 마찬가지로, 검사는 검사될 시편의 제조 이전에 제공될 수 있고, 예를 들어, 검사 레시피(들)를 생성하는 것 및/또는 다른 설정 작동들을 포함할 수 있다. 구체적으로 달리 언급되지 않는 한, 본 명세서에서 사용되는 "검사"라는 용어 또는 그의 파생어들은 검사 영역의 크기 또는 해상도에 관하여 제한되지 않는다는 점을 주목한다. 다양한 비파괴적 검사 툴들은, 비제한적인 예로서, 주사 전자 현미경들, 원자간력 현미경들, 광학 검사 툴들 등을 포함한다.

- [0027] 본원에서 사용되는 "비일시적 메모리" 및 "비일시적 저장 매체"라는 용어들은 본 개시된 주제에 적합한 임의의 휘발성 또는 비휘발성 컴퓨터 메모리를 포함하는 것으로 광범위하게 이해되어야 한다.
- [0028] 본 명세서에서 사용되는 "시편"이라는 용어는 반도체 집적 회로들, 자기 헤드들, 평판 디스플레이들, 및 다른 반도체 제조 물품들을 제조하기 위해 사용되는 임의의 종류의 웨이퍼, 마스크들, 및 다른 구조들, 이들의 조합들 및/또는 부분들을 포함하는 것으로 광범위하게 이해되어야 한다.
- [0029] 본 명세서에서 사용되는 "결함"이라는 용어는 시편 상에 또는 시편 내에 형성된 임의의 종류의 이상 또는 바람직하지 않은 피처를 포함하는 것으로 광범위하게 이해되어야 한다.
- [0030] 본 명세서에서 사용되는 "설계 데이터"라는 용어는 시편의 계층적 물리적 설계(레이아웃)를 나타내는 임의의 데이터를 포함하는 것으로 광범위하게 이해되어야 한다. 설계 데이터는 각각의 설계자에 의해 제공될 수 있고/거나 물리적 설계로부터(예를 들어, 복잡한 모의, 간단한 기하학적 및 부울 연산 등을 통해) 유도될 수 있다. 설계 데이터는, 비제한적인 예들로서, GDSII 포맷, OASIS 포맷 등과 같은 상이한 포맷들로 제공될 수 있다. 설계 데이터는 벡터 포맷, 그레이스케일 강도 이미지 포맷 또는 다른 방식으로 제시될 수 있다.
- [0031] 구체적으로 달리 언급되지 않는 한, 개별 실시예들의 맥락으로 설명되는 본 개시된 주제의 특정한 특징들이 또한, 조합하여 단일 실시예에 제공될 수 있다는 것이 이해된다. 반대로, 단일 실시예의 맥락으로 설명되는 본 개시된 주제의 다양한 특징들이 또한, 개별적으로 또는 임의의 적합한 하위조합으로 제공될 수 있다. 이하의 상세한 설명에서, 방법들 및 장치의 완전한 이해를 제공하기 위해 다수의 특정한 세부 사항들이 열거된다.
- [0032] 이를 염두에 두고, 본 개시된 주제의 특정 실시예들에 따른 검사 시스템의 기능 블록도를 예시하는 도 1에 주목한다.
- [0033] 도 1에 예시된 검사 시스템(100)은 시편 제조 프로세스의 부분으로서 반도체 시편(예를 들어, 웨이퍼 및/또는 그의 부분들)의 검사를 위해 사용될 수 있다. 예시된 검사 시스템(100)은 시편 제조 동안 획득된 이미지들(이하에서 제조 프로세스(FP) 이미지들로 지칭됨)을 사용하여 계측 관련 정보 및/또는 결함 관련 정보를 자동적으로 결정할 수 있는 컴퓨터 기반 시스템(101)을 포함한다. 본 개시된 주제의 특정 실시예들에 따르면, 시스템(101)은 반도체 시편의 검사에 사용가능한 심층 신경망(DNN)을 훈련시키기 위한 훈련 데이터를 생성하도록 구성될 수 있다. 따라서, 시스템(101)은 또한, 본 개시내용에서 훈련 시스템 또는 훈련 데이터 생성 시스템으로 지칭된다. 시스템(101)은 하나 이상의 검사 툴(120)에 작동가능하게 연결될 수 있다. 검사 툴들(120)은 FP 이미지들을 캡처하고/거나 캡처된 FP 이미지(들)를 검토하고/거나 캡처된 이미지(들)에 관련된 측정들을 가능하게 하거나 그러한 측정들을 제공하도록 구성된다.
- [0034] 예를 들어, FP 이미지들은, 제조 프로세스 동안 캡처된, 시편(예를 들어, 웨이퍼 또는 그의 부분들)의 이미지들, 다양한 전처리 단계들에 의해 획득된, 캡처된 이미지들의 파생물들(예를 들어, 주사 전자 현미경(SEM) 또는 광학 검사 시스템에 의해 캡처된, 포토마스크 또는 웨이퍼의 부분의 이미지들, ADC에 의해 분류된 결함을 대략 중심으로 하는 SEM 이미지들, ADR에 의해 결함이 국부화된 더 큰 영역들의 SEM 이미지들, 동일한 마스크 위치에 대응하는, 상이한 검사 양식들의 정합된 이미지들, 세그먼트화된 이미지들, 높이 지도 이미지들 등) 및 컴퓨터로 생성된 설계 데이터 기반 이미지들로부터 선택될 수 있다. 일부 경우들에서, 이미지들이 이미지 데이터(예를 들어, 캡처된 이미지들, 처리된 이미지들 등) 및 연관된 수치 데이터(예를 들어, 메타데이터, 수작업 속성들 등)를 포함할 수 있다는 것을 주목해야 한다. 이미지 데이터는 시편의 관심 있는 층 및/또는 하나 이상의 다른 층에 관련된 데이터를 포함할 수 있다는 점을 더 주목한다.
- [0035] 본원에서 사용되는 "검사 툴(들)"이라는 용어는, 비제한적인 예로서, 시편 또는 그의 부분들과 관련하여 제공되는, 이미지화, (단일 또는 다수 횡수의 스캔들의) 스캐닝, 샘플링, 검토, 측정, 분류 및/또는 다른 프로세스들을 포함하는 검사 관련 프로세스들에서 사용될 수 있는 임의의 툴들을 포함하는 것으로 광범위하게 이해되어야 한다. 하나 이상의 검사 툴(120)은 하나 이상의 검사 툴 및/또는 하나 이상의 검토 툴을 포함할 수 있다. 일부 경우들에서, 검사 툴들(120) 중 적어도 하나는 잠재적 결함들의 검출을 위해 (전형적으로, 비교적 고속 및/또는 저해상도로) 검사 이미지들을 캡처하기 위해서 시편(예를 들어, 전체 웨이퍼, 전체 다이 또는 그의 부분들)을 스캐닝하도록 구성된 검사 툴일 수 있다. 일부 경우들에서, 검사 툴들(120) 중 적어도 하나는 검토 툴일 수 있고, 이는, 잠재적 결함이 실제로 결함인지를 확인하기 위해, 검사 툴들에 의해 검출된 결함들 중 적어도 일부의 검토 이미지들을 캡처하도록 구성된다. 그러한 검토 툴은 일반적으로, 한 번에 하나씩(전형적으로, 비교적 저속 및/또는 고해상도로) 다이의 단편들을 검사하도록 구성된다. 검사 툴 및 검토 툴은 동일하거나 상이한 위치들에 위치한 상이한 툴들, 또는 2개의 상이한 모드들로 작동되는 단일 툴일 수 있

다. 일부 경우들에서, 적어도 하나의 검사 톨이 계층 능력들을 가질 수 있고, FP 이미지들에 대해 계층 측정들을 수행하도록 구성될 수 있다.

[0036] 어떠한 방식으로든 본 개시내용의 범위를 제한하지 않고, 검사 톨들(120)은 다양한 유형들의 검사 기계들, 예컨대, 광학 이미지화 기계들, 전자 빔 검사 기계들 등으로서 구현될 수 있다는 점을 또한 주목해야 한다. 일부 경우들에서, 동일한 검사 톨이, 저해상도 이미지 데이터 및 고해상도 이미지 데이터를 제공할 수 있다.

[0037] 시스템(101)은 하드웨어 기반 I/O 인터페이스(126)에 작동가능하게 연결된 프로세서 및 메모리 회로(PMC)(102)를 포함한다. PMC(102)는 도 2a 및 2b를 참조하여 더 상세히 설명되는 바와 같이 시스템을 작동시키기 위해 필요한 처리를 제공하도록 구성되고, 프로세서(개별적으로 도시되지 않음) 및 메모리(개별적으로 도시되지 않음)를 포함한다. PMC(102)의 프로세서는 PMC에 포함된 비일시적 컴퓨터 판독가능 메모리 상에 구현된 컴퓨터 판독가능 명령어들에 따라 몇몇 기능 모듈들을 실행하도록 구성될 수 있다. 그러한 기능 모듈들은 이하에서 PMC에 포함되는 것으로 지칭된다.

[0038] 특정 실시예들에 따르면, PMC(102)에 포함된 기능 모듈들은 특징 추출기(104), 훈련 모듈(106), 및 기계 학습 모델(108)을 포함할 수 있다. PMC(102)는, I/O 인터페이스(126)를 통해, 반도체 시편의 적어도 일부를 나타내는 제1 훈련 이미지, 및 제1 훈련 이미지로부터 사용자에게 의해 식별된 하나 이상의 세그먼트 각각에서 선택된 픽셀들의 군과 각각 연관된 제1 라벨들을 획득하도록 구성될 수 있다. 특징 추출기(104)는 제1 훈련 이미지를 특징화하는 특징들의 세트를 추출하도록 구성될 수 있다. 세트의 각각의 특징은 제1 훈련 이미지의 픽셀들에 대응하는 특징 값들을 갖는다. 특징들의 세트는 제1 훈련 이미지의 하나 이상의 세그먼트 사이의 맥락 관계들에 대한 정보를 제공하는 제1 특징들, 및 각각의 세그먼트의 픽셀들의 군의 통계적 척도에 관한 제1 훈련 이미지에서의 픽셀 분포에 대한 정보를 제공하는 제2 특징들을 포함한다. 훈련 모듈(106)은, 제1 라벨들, 제1 라벨들과 연관된 각각의 세그먼트에서 선택된 픽셀들의 군의 값들, 및 각각의 세그먼트에서 선택된 픽셀들의 군에 대응하는 특징들의 세트의 각각의 특징의 특징 값들을 사용하여 기계 학습 모델(108)을 훈련시키도록 구성될 수 있다. 훈련된 기계 학습 모델(108)은 제1 훈련 이미지의 각각의 픽셀들과 연관된 예측된 라벨들에 대한 정보를 제공하는 제1 세그먼트화 지도를 획득하기 위해 제1 훈련 이미지를 처리하는 데 사용될 수 있고, 각각의 예측된 라벨은 각각의 픽셀이 속하는 세그먼트를 나타낸다. 훈련 모듈(106)은, 기준이 충족될 때, 제1 훈련 이미지 및 제1 세그먼트화 지도를 포함하는 제1 훈련 샘플을 훈련 데이터(즉, 본원에서 DNN 훈련 데이터로 또한 지칭되는, 심층 신경망(DNN)을 훈련시키기 위한 훈련 데이터)에 포함시키고, 기준이 충족되지 않을 때, 제2 특징들의 추출, 훈련 및 처리를 반복하는 것을 결정하도록 더 구성될 수 있다. 훈련 데이터 생성 프로세스의 세부 사항들은 도 2a 및 2b를 참조하여 아래에 설명된다.

[0039] 특정 실시예들에서, 훈련 시스템(101)에 의해 생성된 바와 같은 DNN 훈련 데이터는 반도체 시편을 검사하는 데 사용가능한 DNN(110)을 훈련시키는 데 사용될 수 있다. 일부 경우들에서, DNN은 시스템(101)의 PMC(102)에 포함될 수 있거나, 대안적으로, 도 1에 예시된 바와 같이, 시스템(101)에 작동가능하게 연결될 수 있다. DNN(110)은 제조 입력 데이터에 기초하여 응용 관련 데이터를 출력하기 위해 심층 신경망(들)을 사용하는 데이터 처리를 가능하게 하도록 구성될 수 있다. 일 실시예에서, 특정 응용은 이미지 세그먼트화일 수 있고, 응용 관련 출력은 입력 FP 이미지들에 대응하는 세그먼트화 지도들일 수 있다. 시스템(101), PMC(102) 및 그의 기능 모듈들의 작동은 도 2a 및 2b를 참조하여 더 상세히 설명될 것이다.

[0040] DNN(110)은 각각의 DNN 아키텍처에 따라 조직화된 계층들을 포함하는 감독된 또는 감독되지 않은 DNN 모델을 포함할 수 있다. 비제한적인 예로서, DNN의 계층들은 콘볼루션 신경망(CNN) 아키텍처, 순환 신경망 아키텍처, 재귀 신경망들 아키텍처, 생성적 대립 신경망(GAN) 아키텍처 또는 다른 방식에 따라 조직화될 수 있다. 선택적으로, 계층들 중 적어도 일부는 복수의 DNN 부분망들로 조직화될 수 있다. DNN의 각각의 계층은 관련 기술분야에서 차원들, 뉴런들, 또는 노드들로서 전형적으로 지칭되는 다수의 기본 계산 요소들(CE)을 포함할 수 있다.

[0041] 일반적으로, 주어진 계층의 계산 요소들은 선행 계층 및/또는 후속 계층의 CE들과 연결될 수 있다. 선행 계층의 CE와 후속 계층의 CE 사이의 각각의 연결은 가중 값과 연관된다. 주어진 CE는 각각의 연결들을 통해 이전 계층의 CE들로부터 입력들을 수신할 수 있고, 각각의 주어진 연결은 주어진 연결의 입력에 적용될 수 있는 가중 값과 연관된다. 가중 값들은 연결들의 상대적 강도 및 그에 따른 주어진 CE의 출력에 대한 각각의 입력들의 상대적 영향을 결정할 수 있다. 주어진 CE는 활성화 값(예를 들어, 입력들의 가중 합)을 계산하고, 계산된 활성화에 활성화 함수를 적용함으로써 출력을 더 유도하도록 구성될 수 있다. 활성화 함수는, 예를 들어, 항등 함수, 결정 함수(예를 들어, 선형, 시그모이드, 임계 등), 확률적 함수, 또는 다른 적합한 함수일 수 있다. 주어진 CE로부터의 출력은 각각의 연결들을 통해 후속 계층의 CE들로 송신될 수 있다. 마찬가지로, 상기와 같이,

CE의 출력에서의 각각의 연결은, 후속 계층의 CE의 입력으로서 수신되기 전에 CE의 출력에 적용될 수 있는 가중 값과 연관될 수 있다. 가중 값들에 추가로, 연결들 및 CE들과 연관된 임계 값들(극한 함수들을 포함함)이 존재할 수 있다.

- [0042] 심층 신경망의 가중 및/또는 임계 값들은 훈련 전에 초기에 선택될 수 있고, 훈련된 DNN에서 가중 및/또는 임계 값들의 최적 세트를 달성하기 위해, 훈련 동안 더 반복적으로 조정 또는 수정될 수 있다. 각각의 반복 후에, 데이터의 각각의 훈련 세트와 연관된 목표 출력과 DNN 모듈에 의해 생성된 실제 출력 사이의 차이가 결정될 수 있다. 차이는 오류 값으로 지칭될 수 있다. 훈련은, 오류 값을 나타내는 손실/비용 함수가, 미리 결정된 값 미만일 때 또는 반복들 사이의 성능에서의 제한된 변화가 달성될 때 완료되는 것으로 결정될 수 있다.
- [0043] 심층 신경망의 가중치들/임계치들을 조정하기 위해 사용되는 DNN 입력 데이터의 세트는 이하에서 DNN 훈련 데이터로서 지칭된다. 전술된 바와 같이, 시스템(101)은 DNN을 훈련시키기 위해 사용가능한 그러한 DNN 훈련 데이터를 생성하도록 구성된다.
- [0044] 본 개시된 주제의 교시들은 위에서 설명된 바와 같은 DNN의 특정 아키텍처에 의해 제한되지 않는다는 점을 주목한다.
- [0045] 일부 실시예들에서, DNN은 FP 이미지들에 대해 이미지 세그먼트화를 수행하도록 구성되는 세그먼트화 DNN일 수 있다. 일부 경우들에서, DNN(110)에 대해 추가적으로, 검사 시스템(100)은 하나 이상의 검사 모듈, 예컨대, 예를 들어, 결합 검출 모듈 및/또는 자동 결합 검토 모듈(ADR) 및/또는 자동 결합 분류 모듈(ADC) 및/또는 계측 관련 모듈 및/또는 반도체 시편의 검사에 사용가능한 다른 검사 모듈들을 포함할 수 있다. 하나 이상의 검사 모듈은 독립형 컴퓨터들로서 구현될 수 있거나, 그들의 기능들(또는 그의 적어도 일부)이 검사 툴(120)과 통합될 수 있다. 일부 경우들에서, DNN(110)은 하나 이상의 검사 모듈에 포함될 수 있다. 선택적으로, DNN(110)은 검사 모듈들 간에 공유될 수 있거나, 대안적으로, 하나 이상의 검사 모듈 각각이 그 자신의 DNN(110)을 포함할 수 있다.
- [0046] 특정 실시예들에 따르면, 시스템(101)은 저장 유닛(122)을 포함할 수 있다. 저장 유닛(122)은 운영 시스템(101)에 필요한 임의의 데이터, 예를 들어, 시스템(101)의 입력 및 출력에 관련된 데이터뿐만 아니라, 시스템(101)에 의해 생성된 중간 처리 결과들을 저장하도록 구성될 수 있다. 예로서, 저장 유닛(122)은 검사 툴(120)에 의해 생성된 이미지들 및/또는 그의 파생물들을 저장하도록 구성될 수 있다. 이에 따라, 하나 이상의 이미지는 저장 유닛(122)으로부터 검색되어 추가의 처리를 위해 PMC(102)에 제공될 수 있다.
- [0047] 일부 실시예들에서, 시스템(101)은 시스템(101)과 관련된 사용자 특정 입력들을 가능하게 하도록 구성된 컴퓨터 기반 그래픽 사용자 인터페이스(GUI)(124)를 선택적으로 포함할 수 있다. 예를 들어, 사용자는, 시편의 이미지 데이터를 포함하는, 시편의 시각적 표현을 (예를 들어, GUI(124)의 일부를 형성하는 디스플레이에 의해) 제시받을 수 있다. 사용자는 특정 작동 파라미터들을 정의하는 옵션들을 GUI를 통해 제공받을 수 있다. 예를 들어, 사용자는 이미지 상에 수동으로 주석을 다는 것에 의해 라벨 데이터를 제공할 수 있다. 사용자는 또한, GUI 상에서 작동 결과들, 예컨대, 예를 들어, 세그먼트화 지도들을 볼 수 있다.
- [0048] 도 2a 및 2b를 참조하여 더 상세히 설명된 바와 같이, 시스템(101)은 I/O 인터페이스(126)를 통해 FP 입력 데이터를 수신하도록 구성된다. FP 입력 데이터는, 검사 툴들(120)에 의해 생성된 데이터(및/또는 그의 파생물들 및/또는 그와 연관된 메타데이터) 및/또는 하나 이상의 데이터 저장소에 저장된 데이터를 포함할 수 있다. 일부 경우들에서, FP 입력 데이터는 이미지 데이터(예를 들어, 캡처된 이미지들, 캡처된 이미지들로부터 유도된 이미지들, 모의된 이미지들, 합성 이미지들 등) 및 연관된 수치 데이터(예를 들어, 메타데이터, 수작업 속성들 등)를 포함할 수 있다는 점을 주목한다. 이미지 데이터는 시편의 관심 있는 층 및/또는 하나 이상의 다른 층에 관련된 데이터를 포함할 수 있다는 점을 더 주목한다. 본 개시내용의 일부 실시예들에서, 훈련 목적들을 위해, FP 입력 데이터는 DNN을 훈련시키기 위해 사용가능한 훈련 데이터를 생성하는 목적을 위해 하나 이상의 훈련 이미지를 포함할 수 있다.
- [0049] 시스템(101)은 수신된 FP 입력 데이터를 처리하고, I/O 인터페이스(126)를 통해, 결과들(또는 그의 일부)을 저장 유닛(122), 및/또는 DNN(110), 및/또는 (결과들을 렌더링하기 위한) GUI(124)에 전송하도록 더 구성된다.
- [0050] 관련 기술분야의 통상의 기술자는, 본 개시된 주제의 교시들이, 도 1에 예시된 시스템에 의해 제한되지 않고; 동등하고/거나 수정된 기능이, 다른 방식으로 통합되거나 분할될 수 있으며 하드웨어 및/또는 펌웨어와 소프트웨어의 임의의 적절한 조합으로 구현될 수 있다는 것을 용이하게 이해할 것이다.
- [0051] 도 1에 예시된 검사 시스템은, 도 1에 도시된 전술한 기능 모듈들이 몇몇 로컬 및/또는 원격 디바이스들에 분산

될 수 있고 통신망을 통해 연결될 수 있는 분산 컴퓨팅 환경으로 구현될 수 있다는 점을 주목한다. 다른 실시예들에서, 검사 툴들(120), 저장 유닛(122) 및/또는 GUI(124) 중 적어도 일부는 검사 시스템(100)의 외부에 있을 수 있고 I/O 인터페이스(126)를 통해 시스템(101)과 데이터 통신하여 작동할 수 있다는 점을 더 주목한다. 시스템(101)은 검사 툴들과 함께 사용될 독립형 컴퓨터(들)로서 구현될 수 있다. 대안적으로, 시스템(101)의 각각의 기능들은, 적어도 부분적으로, 하나 이상의 검사 툴(120)과 통합될 수 있고, 이로써, 검사 관련 프로세스들에서 검사 툴들(120)의 기능들을 용이하게 하고 향상시킨다.

- [0052] 단지 예시의 목적을 위해, 다음의 설명은 반도체 시편의 검사에 사용가능한 DNN을 훈련시키기 위한 DNN 훈련 데이터를 생성하기 위해 제공된다. 관련 기술분야의 통상의 기술자는, 본 개시된 주제의 교시들이, 다양한 유형들의 기계 학습 모델들에, 그리고, 다양한 검사들, 예컨대, 예를 들어, 세그먼트화, 결함 검출, ADR, ADC, 자동화된 내비게이션 모듈, 계측 관련 모듈 등에 적용가능하다는 것을 용이하게 이해할 것이다.
- [0053] 도 2a를 참조하면, 본 개시된 주제의 특정 실시예들에 따라 반도체 시편의 검사에 사용가능한 DNN을 훈련시키기 위한 훈련 데이터를 생성하는 일반화된 흐름도가 예시된다.
- [0054] 특정 실시예들에 따르면, DNN을 훈련시키기 위해 사용되는 훈련 데이터(또한, DNN 훈련 데이터로 지칭됨)는 복수의 훈련 샘플들을 포함할 수 있고, 훈련 샘플들 각각은 각각의 훈련 이미지 및 그와 연관된 대응하는 실측 정보 데이터를 포함한다. 실측 정보 데이터는 응용 특정 정보를 나타내는 라벨 데이터를 포함할 수 있다. 예를 들어, 이미지 세그먼트화의 응용의 경우, 각각의 훈련 샘플은 반도체 시편의 훈련 이미지 및 훈련 이미지의 하나 이상의 세그먼트를 나타내는 라벨 데이터를 포함할 수 있다.
- [0055] 훈련 이미지는 제조 프로세스에서 획득된 반도체 시편의 "실제" 이미지(예를 들어, 위에서 설명된 바와 같은 FP 이미지)일 수 있다. 비제한적인 예로서, 이미지는 잠재적 결함들의 검출을 위해 (전형적으로, 비교적 고속 및/또는 비교적 저해상도로) 하나 이상의 검사 툴을 사용하여 시편을 검사함으로써 획득된 검사 이미지일 수 있다. 그러한 검사 툴들은, 예를 들어, 광학 검사 시스템, 저해상도 SEM 등일 수 있다. 대안적으로, 이미지는, 검사 툴들에 의해 검출된 잠재적 결함이 실제로 결함인지를 확인하기 위해, (전형적으로, 비교적 저속 및/또는 비교적 고해상도로) 하나 이상의 검토투를 사용하여 잠재적 결함 위치들의 하위세트에서 시편을 검사함으로써 획득된 검토투 이미지일 수 있다. 그러한 검토투 툴들은, 예를 들어, 주사 전자 현미경(SEM) 등일 수 있다.
- [0056] 실측 정보 데이터는 다양한 방식으로 획득될 수 있다. 예로서, 실측 정보 데이터는 인간 주석에 의해 생성되거나, 합성적으로 생성되거나(예를 들어, CAD 기반 이미지들), 기계 학습 주석에 의해 생성되거나(예를 들어, 특징 추출 및 분석에 기초한 라벨들), 이들의 조합 등일 수 있다.
- [0057] 특정 실시예들에 따르면, DNN은 반도체 시편 이미지들(예를 들어, FP 이미지들)에 대한 이미지 세그먼트화의 특정 응용을 위해 훈련된다. 본원에서 사용되는 "세그먼트화"라는 용어는, 이미지를 의미하는 부분들/세그먼트들(예를 들어, 배경 및 전경, 잡음이 있는 및 잡음이 없는 영역들, 구조적 요소들, 결함 및 비결함 등)로 분할하는 한편, 그러한 세그먼트들을 나타내는 픽셀별 또는 영역별 값들을 제공하는 임의의 프로세스를 지칭할 수 있다. 본 개시된 주제에 따라 생성된 바와 같은 DNN 훈련 데이터는 FP 이미지들의 세그먼트화에 사용가능한 DNN을 훈련시키는 데 사용된다.
- [0058] 예로서, 훈련 이미지는 SEM 이미지 또는 그의 파생물들일 수 있고, 라벨 데이터는 SEM 이미지에 대응하는 세그먼트화 지도(또한, 세그먼트화 마스크로 칭해짐)일 수 있다. 세그먼트화 지도는 훈련 이미지의 대응하는 픽셀들과 연관된 예측된 라벨들에 대한 정보를 제공한다. 각각의 예측된 라벨은 각각의 픽셀이 속한 이미지의 세그먼트를 나타낸다.
- [0059] 세그먼트화 지도는 통상적으로, 전체 훈련 이미지에 대해 수동으로 주석을 다는 사용자에게 의해 생성된다. 수동 주석 프로세스는 이미지의 크기 및 해상도를 고려하여 매우 시간 소모적이고, 주석이 달린 결과는 때때로 부정확하고 오류가 발생하기 쉽다. 이는 사용자가 원치 않는데, 라벨 데이터의 품질이 훈련 프로세스 및 훈련된 DNN의 성능에 직접적으로 영향을 미치기 때문이다. 이에 따라, 본 개시내용은 도 2a 및 2b를 참조하여 아래에서 설명하는 바와 같이, DNN을 훈련시키기 위해 사용가능한 정확한 라벨 데이터를 자동으로 생성하는 더 효율적인 방법을 제안한다.
- [0060] 특정 실시예들에 따르면, 반도체 시편의 적어도 일부를 나타내는 제1 훈련 이미지는, 제1 훈련 이미지로부터 사용자에게 의해 식별된 하나 이상의 세그먼트 각각에서 선택된 픽셀들의 군과 각각 연관된 제1 라벨들과 함께 (예를 들어, I/O 인터페이스(126)를 통해 PMC(102)에 의해) 획득될 수 있다(202). 일부 경우들에서, 하나 이상의 세그먼트 중 적어도 하나는 제1 훈련 이미지에 제시된 하나 이상의 구조적 요소에 대응한다.

- [0061] 이제 도 5를 참조하면, 본 개시된 주제의 특정 실시예들에 따른 훈련 이미지의 예가 예시된다. 훈련 이미지(502)는 SEM 검토 툴에 의해 캡처되고 웨이퍼의 다이의 일부를 표현하는 SEM 이미지로서 예시된다. 도시된 바와 같이, 이미지에 제시된 복수의 구조적 요소들(504)(웨이퍼 상의 접촉의 요소들을 나타내는 다각형들로서 예시됨)이 존재한다. 본원에서 사용되는 구조적 요소는, 일부 경우들에서 다른 객체(들)와 결합되는, 윤곽이 있는 기하학적 형상 또는 기하학적 구조를 갖는 이미지 데이터 상의 임의의 원래 객체를 지칭할 수 있다. 구조적 요소는, 예를 들어, 다각형 형태로 제시될 수 있다.
- [0062] 일부 실시예들에서, 훈련 이미지는 상이한 관점들로부터 캡처된 다수의 채널들을 포함할 수 있다. 예를 들어, 도 5의 예에서, 502는 검사 툴의 최상부 검출기에 의해 수직 관점으로부터 취해진 이미지의 하나의 채널을 나타낼 수 있고, 506은 검사 툴의 측부 검출기에 의해 측면 관점으로부터 취해진 이미지의 다른 채널을 나타낼 수 있다. 일부 경우들에서, 상이한 각도들로부터 하나 초과와 측부 검출기가 존재할 수 있고, 이에 따라, 훈련 이미지는 다수의 측 채널 이미지들(506)을 포함할 수 있다. 일부 경우들에서, 다수의 측 채널 이미지들은 하나의 조합된 측 채널 이미지로 조합될 수 있다.
- [0063] 전체 이미지의 전체 주석에 대한 사용자의 노력을 절약하기 위해, 훈련 이미지와 연관된 부분적인 라벨 데이터가 사용자에게 의해 제공될 수 있다. 예로서, 사용자는 사용자가 세그먼트화 지도에서 식별할 것으로 예측하는 하나 이상의 세그먼트를 결정하고, 세그먼트들 각각으로부터 픽셀들의 군을 선택하고, 픽셀들의 군에, 그들이 속하는 세그먼트를 나타내도록 주석을 달 수 있다. 도 6은 본 개시된 주제의 특정 실시예들에 따른 훈련 이미지에 대한 부분적인 사용자 주석의 예를 예시한다.
- [0064] 훈련 이미지(602)가 도 6에 예시된다. 훈련 이미지(602)는 도 5의 훈련 이미지들(502 및 506)과 동일한 웨이퍼 부위를 캡처하고, 동일한 설계 패턴을 공유하는 복수의 구조적 요소들을 포함한다. 그러한 구조적 요소들은 또한, 동등한 구조적 요소들로 지칭된다. 예로서, 사용자는 구조적 요소들이 하나의 세그먼트에 속할 수 있고, 배경은 다른 세그먼트에 속하는 것을 결정할 수 있다. 따라서, 사용자는 어느 한 세그먼트로부터 몇 개의 픽셀들을 선택하고 그들에 각각의 세그먼트를 나타내도록 마킹할 수 있다. 예로서, 도 6의 원형 영역(604)에 도시된 바와 같이(604의 확대도가 우측에 예시됨), 구조적 요소 내의 픽셀들의 군(606)은, 그들이, 구조적 요소들을 나타내는 하나의 세그먼트에 속한다는 것을 나타내는 특정 그레이 레벨 값으로 사용자에게 의해 마킹되고, 배경의 픽셀들의 다른 군(608)은, 그들이, 배경 영역을 나타내는 다른 세그먼트에 속한다는 것을 나타내는 다른 그레이 레벨 값으로 사용자에게 의해 마킹된다. 블록(206)과 관련하여 아래에서 설명되는 바와 같이, 각각의 세그먼트의 선택된 픽셀들에 대한 사용자 주석은 기계 학습 모델을 훈련시키기 위한 부분적인 라벨 데이터로서 사용될 수 있다.
- [0065] 사용자가 세그먼트화 지도 내에 포함되기를 원하는 훈련 이미지의 상이한 유형들의 세그먼트화를 사용자가 결정할 수 있다는 점을 주목해야 한다. 예로서, 일부 경우들에서, 훈련 이미지는 하나 초과와 계열의 동등한 구조적 요소들을 포함할 수 있다. 사용자는 동등한 구조적 요소들의 각각의 계열이 각각의 세그먼트에 속하는 것을 결정할 수 있거나, 대안적으로, 사용자는, 배경이, 상이한 세그먼트에 속하는 동안, 모든 구조적 요소들이 하나의 세그먼트에 속하는 것을 결정할 수 있다. 다른 예로서, 사용자는 이미지에서의 그레이 레벨 변동에 따라 세그먼트들을 결정할 수 있다. 예를 들어, 특정 구조 프로파일로 인해 하나의 구조적 요소 내에 그레이 레벨 콘트라스트가 존재할 수 있고, 사용자는 그레이 레벨 분리에 대응하도록 각각의 구조적 요소 내에 2개의 세그먼트들을 갖는 것으로 결정할 수 있다. 본 개시내용은 세그먼트화의 특정 방식 및 훈련 이미지 상의 세그먼트들의 개수에 의해 제한되지 않는다.
- [0066] 도 2a의 설명을 계속하면, 제1 훈련 이미지를 특징화하는 특징들의 세트가 (예를 들어, 특징 추출기(104)에 의해) 추출될 수 있다(204). 각각의 특징은 제1 훈련 이미지의 픽셀들에 대응하는 특징 값들을 갖는다. 특징들의 세트는 제1 훈련 이미지의 맥락 정보 또는 표현을 나타내는 제1 특징들을 포함할 수 있다. 예를 들어, 제1 특징들은 제1 훈련 이미지의 하나 이상의 세그먼트들 사이의 맥락 관계들/관련성들에 대한 정보를 제공할 수 있다. 특징들의 세트는 각각의 세그먼트의 픽셀들의 군의 통계적 척도에 관한 제1 훈련 이미지에서의 픽셀 분포에 대한 정보를 제공하는 제2 특징들을 더 포함할 수 있다.
- [0067] 제1 특징들은 또한, 본원에서 맥락 특징들로 지칭된다. 맥락 특징들이라는 용어는 이미지의 특정 아이템/요소, 예컨대, 예를 들어, 픽셀들, 구조적 요소들 또는 세그먼트들 등의 맥락(예를 들어, 아마도 상이한 범위들의 주변 영역), 및/또는 이미지의 그러한 요소들 또는 세그먼트들 간의 전역적인 맥락 관계를 나타내는 것으로 광범위하게 이해되어야 한다. 맥락 관계들은 요소들 또는 세그먼트들 사이의 상대적 질감, 공간 레이아웃, 강도 등의 관점에서 반영될 수 있다. 예를 들어, 구조적 요소 내의 픽셀들은 그들의 주변 픽셀들(둘러싸지만 여전히

구조적 요소 내에 있음)과 유사한 질감을 공유하는 반면, 구조적 요소 외부의 픽셀들의 질감은 구조적 요소 내의 픽셀들과 상당히 상이하며, 이는, 구조적 요소 내의 픽셀들 및 구조적 요소 외부의 픽셀들이, 상이한 세그먼트들에 속할 수 있음을 나타낸다. 일부 실시예들에서, 제1 특징들은 질감 특징들을 포함할 수 있다. 일부 경우들에서, 제1 특징들은 강도 특징들을 더 포함할 수 있다.

[0068] 질감 특징들은 이미지의 인지되는 질감을 나타내는 데 사용될 수 있다. 예를 들어, 그러한 특징들은 이미지의 상이한 요소들 또는 세그먼트들을 특징화하는 구조들 또는 패턴들의 공간 배열을 나타낼 수 있다. 이제 도 3a를 참조하면, 본 개시된 주제의 특정 실시예들에 따라 제1 훈련 이미지로부터 질감 특징들을 추출하는 일반화된 흐름도가 예시된다.

[0069] 제1 훈련 이미지는 필터들의 세트(또한 필터 뱅크로 칭해짐)로 처리될 수 있고(302), 필터들의 세트에 대응하는 특징 응답들의 세트를 생성할 수 있다. 각각의 특징 응답은 제1 훈련 이미지의 각각의 픽셀들에 대응하는 특징 응답 값들을 포함한다. 각각의 픽셀은 특징 응답 값들의 세트를 포함하는 특징 벡터에 대응한다. 이미지의 픽셀들에 대응하는 특징 벡터들은 복수의 클러스터들로 클러스터화될 수 있다(304). 각각의 픽셀에 대해, 픽셀의 특징 벡터가 속하는 클러스터에 따라 특징 값이 할당될 수 있고(306), 제1 훈련 이미지의 픽셀들에 대응하는 특징 값들을 포함하는 특징 지도를 생성할 수 있다. 특징 지도는 각각의 특징 값들에 대응하는 복수의 채널들로 분리가능하다. 특징 지도의 각각의 채널은 샘플링 필터를 사용하여 샘플링될 수 있고(308), 복수의 샘플링된 채널들을 갖는 특징 지도를 생성할 수 있다.

[0070] 일부 실시예들에서, 질감 특징들은 텍스톤 특징들로서 구현될 수 있다. 텍스톤이라는 용어는 일반적으로, 이미지들의 기본적인 마이크로 구조들을 지칭한다. 텍스톤들은 객체/요소의 상이한 외관들의 범위에 대한 간결한 표현을 제공할 수 있고, 질감들뿐만 아니라 일반 객체 부류들도 범주화하는 데 효과적일 수 있다.

[0071] 예로서, 제1 훈련 이미지는 필터들의 세트, 예를 들어, 다차원 필터 뱅크와 콘볼빙될 수 있고, 훈련 이미지의 모든 픽셀들에 대한 다차원 특징 응답들을 생성할 수 있다. 필터들의 세트는 반도체 이미지를 나타내는 특징들을 추출하도록 선택될 수 있다. 예를 들어, 필터들의 세트는 다양한 계열들의 필터들, 예컨대, 예를 들어, 미분 필터들, 가버 필터들 및 라플라시안 필터들을 포함할 수 있다. 미분 필터들은 이미지에 제시된 픽셀 휘도 정보의 변화율에 대한 정량적 측정을 제공할 수 있다. 이미지와의 콘볼루션을 통해, 미분 필터들은, 커널들의 선택에 따라, 상이한 방향들 및 스케일들로 도함수들을 생성할 수 있다. 휘도 변화율들에 관한 결과적인 정보는 콘트라스트를 향상시키고, 에지들 및 경계들을 검출하고, 특징 배향을 측정하는 데 사용될 수 있다. 가버 필터는, 관심 지점 또는 영역 주위의 국소화된 영역에서 특정 방향으로 이미지에 임의의 특정 주파수 콘텐츠가 존재하는지를 분석하는 선형 필터이다. 가버 필터들의 주파수 및 배향 표현들은 인간 시각계의 것들과 유사하다. 질감을 나타내는 특징들을 제1 훈련 이미지로부터 추출하기 위해, 상이한 주파수들 및 배향들을 갖는 가버 필터들의 세트가 사용될 수 있다. 라플라시안 필터는 또한, 가우시안의 라플라시안(LoG) 필터로 칭해진다. 이는 이미지의 제2 공간 도함수의 척도이다. 이미지의 라플라시안은 빠른 강도 변화의 영역들을 강조하고 에지 검출을 위해 사용될 수 있다. 예를 들어, 이미지가, 일정한 강도를 갖는(즉, 강도 구배가 0인) 영역들에서, LoG 응답은 0일 것이다. 그러나, 강도의 변화의 부근에서, LoG 응답은 더 어두운 측에 대해서는 긍정적인 것이고, 더 밝은 측에 대해서는 부정적인 것이다.

[0072] 본 개시내용의 일부 실시예들에서, 3개의 계열들의 필터들이 조합되어 사용될 수 있으며, 조합된 필터 세트가, 열악한 신호 대 잡음비(SNR) 및 콘트라스트 대 잡음비(CNR)를 갖는 정상적으로 잡음이 많은 반도체 이미지들에서의 구조들의 질감 및 레이아웃을 나타내는 특징들을 추출하는 데 있어서 더 신뢰성있다는 것이 본 개시내용에 의해 증명된다. 그러나, 이는 결코 본 개시내용을 어떠한 방식으로든 제한하는 것이 아니다. 다른 계열들/유형들의 필터들 또는 유사한 기능들을 갖는 필터들이 상기 내용에 추가적으로 또는 상기 내용 대신에 사용될 수 있다. 특히, 위에서 설명된 바와 같은 각각의 계열의 특정 필터들은 예시의 목적들로 예시된다는 점을 주목해야 한다. 계열 내의 다른 적합한 필터들이 상기 내용에 추가적으로 또는 상기 내용 대신에 사용될 수 있다. 본 개시내용은 특정 유형들의 필터들 및 각각의 계열에 사용되는 필터들의 개수에 의해 제한되지 않는다.

[0073] 예로서, 훈련 이미지가 $M \times N$ 의 차원에 있고 필터들의 세트가 F 개의 필터들, 즉, F 차원 필터 뱅크를 포함한다고 가정하면, 다차원 특징 응답들은, 예를 들어, $M \times N \times F$ 의 차원을 갖는 특징 행렬의 형태로 생성될 것이다. 즉, 훈련 이미지의 각각의 픽셀에 대해, 픽셀에 대응하는 특징 벡터를 형성하는 F 개의 특징 응답들이 존재한다. 다차원 특징 응답들, 즉, $M \times N \times F$ 의 특징 행렬은 $M \times N$ 개의 픽셀들에 대응하는 $M \times N$ 개의 특징 벡터들을 포함하는 것으로 간주될 수 있다.

[0074] 일단, 훈련 이미지의 모든 픽셀들에 대한 다차원 특징 응답들이 획득되면, 클러스터화(예를 들어, 감독되지 않

은 클러스터화)가 다차원 특징 응답들에 대해 수행될 수 있다. 예로서, $M \times N$ 개의 특징 벡터들에 대해 유클리드 거리 K -평균 클러스터화 알고리즘이 수행될 수 있고, 특징 벡터들의 복수의 클러스터들(예를 들어, K 개의 클러스터들)을 생성할 수 있다. 훈련 이미지의 각각의 픽셀은 K 개의 클러스터들 중 하나로 클러스터화되고 클러스터 번호에 대응하는 특징 값이 할당되며, 제1 훈련 이미지의 픽셀들에 대응하는 특징 값들을 포함하는 특징 지도(예를 들어, 텍스톤 지도)를 생성한다. 텍스톤 지도(T)는, 각각의 픽셀(i)에 대해, 대응하는 특징 값(T_i)이 $T_i \in \{1, \dots, K\}$ 인 특징 값들을 포함한다. 특징 지도(예를 들어, 텍스톤 지도)는 각각의 특징 값들에 대응하는 K 개의 채널들로(예를 들어, 각각의 텍스톤에 대해 하나씩) 분리될 수 있고, 각각의 채널에 대해, 각각의 텍스톤에 대해 하나의 빈(bin)을 갖는 히스토그램과 유사하게, 개별 채널 지도(예를 들어, 적분 지도)가 유도될 수 있다. 분리된 채널 지도들은 $M \times N \times K$ 의 차원에 있다.

[0075] 샘플링은, 예를 들어, 샘플링 필터를 사용함으로써, 각각의 채널에 대해 수행될 수 있다. 예를 들어, K 개의 채널 지도들은 샘플링 필터와 각각 컨볼빙될 수 있고, 샘플링된 채널 지도들을 생성할 수 있다. 예로서, 샘플링 필터는 평균화, 가우시안, 또는 다른 종류들의 샘플링 방법들을 사용하여 구현될 수 있다. 채널 지도와 컨볼빙될 때, 이는 샘플링된 채널 지도들에서의 결과적인 컨볼빙된 값 내의 각각의 픽셀의 맥락 상황(예를 들어, 각각의 픽셀의 주변 영역)을 효과적으로 반영할 수 있고, 그에 의해, 샘플링된 지도들에 감도를 추가한다. K 개의 샘플링된 채널 지도들(예를 들어, $M \times N \times K$ 의 차원의 특징 행렬의 형태)은 제1 훈련 이미지에 대응하는 질감 특징들로서 사용될 수 있다.

[0076] 특정 실시예들에 따르면, 제1 특징들은, 질감 특징들에 추가적으로, 강도 특징들을 더 포함할 수 있다. 강도 특징들은 이미지의 상이한 요소들 또는 세그먼트들을 특징화하는 픽셀 강도들의 공간 배열을 나타낼 수 있다. 일부 실시예들에서, 강도 특징들은 또한, 텍스톤 특징들로서 구현될 수 있다. 예로서, 위에서 설명된 바와 같은 클러스터화는 제1 훈련 이미지의 픽셀 값들에 대해 수행될 수 있다. 유사하게, 훈련 이미지의 각각의 픽셀은 복수의 클러스터들 중 하나로 클러스터화되고, 픽셀 값이 속하는 클러스터에 대응하는 특징 값을 할당받을 수 있으며, 복수의 채널들로 분리될 수 있는 특징 지도를 생성할 수 있다. 샘플링은, 예를 들어, 샘플링 필터를 사용함으로써 각각의 채널에 대해 수행될 수 있고, 샘플링된 채널 지도들은 제1 훈련 이미지에 대응하는 강도 특징들로서 사용될 수 있다.

[0077] 이제 도 7을 참조하면, 본 개시된 주제의 특정 실시예들에 따른 질감 특징의 예 및 강도 특징의 예가 예시된다. 도시된 바와 같이, 특징 지도(702)는 제1 훈련 이미지(502)로부터 추출된 질감 특징이고, 특징 지도(704)는 동일한 이미지로부터 추출된 강도 특징이다.

[0078] 제1 특징들에 추가적으로, 특징들의 세트는 각각의 세그먼트의 픽셀들의 군의 통계적 척도에 관한 제1 훈련 이미지에서의 픽셀 분포에 대한 정보를 제공하는 제2 특징들을 더 포함할 수 있다. 제2 특징들은 또한, 통계적 특징들로 지칭된다. 본원에서 언급된 통계적 특징들은 픽셀들의 통계적 의미에 따른 정량적 척도를 나타낼 수 있으며, 정량적 척도는 특정 세그먼트들에 속하는 픽셀들의 가능성을 나타낸다. 도 3b를 참조하면, 본 개시된 주제의 특정 실시예들에 따라 제1 훈련 이미지로부터 통계적 특징들을 추출하는 일반화된 흐름도가 예시된다.

[0079] 각각의 세그먼트에서 선택된 픽셀들의 군에 대해 통계적 척도가 계산될 수 있다(312). 예로서, 통계적 척도는 각각의 세그먼트의 픽셀들의 군의 값들에 기초하여 계산된 평균값일 수 있다. 다른 예로서, 통계적 척도는 평균값 및 평균값에 대한 픽셀들의 군의 값들의 변동 또는 분산의 양을 측정하는 표준 편차(STD)에 기초하여 계산될 수 있다. 제1 훈련 이미지의 각각의 픽셀에 대해, 대응하는 특징 값은 픽셀의 값과 각각의 세그먼트의 통계적 척도 사이의 거리로서 계산될 수 있고(314), 각각이, 픽셀 값들과 각각의 세그먼트의 통계적 척도 사이의 거리들에 대응하는 특징 값들을 포함하는 하나 이상의 특징 지도를 생성할 수 있다. 예를 들어, 도 6의 예에서, 통계적 척도는, 구조적 요소들을 나타내는 세그먼트의 픽셀들의 군(606) 및 배경 영역을 나타내는 다른 세그먼트의 픽셀들의 군(608)에 대해 각각 계산될 수 있다. 2개의 특징 지도들이 제1 훈련 이미지에 대해 생성될 수 있고, 제1 특징 지도는 이미지(602)의 각각의 픽셀 값과 606에 대해 계산된 통계적 척도 사이의 거리 값들을 포함하고, 제2 특징 지도는 이미지(602)의 각각의 픽셀 값과 608에 대해 계산된 통계적 척도 사이의 거리 값들을 포함한다. 그러므로, 그러한 방식으로 생성된 특징 지도들은 (사용자에 의해 마킹된 픽셀들의 군에 기초하여) 각각의 세그먼트에 대해 계산된 통계적 척도에 관한 바와 같이 이미지에서의 픽셀 값 분포/분산을 나타내며, 이는 픽셀들이 특정 세그먼트들에 속할 가능성이 얼마나 있는지를 나타낸다.

[0080] 도 2a의 설명을 계속하면, 블록(202)을 참조하여 설명된 바와 같이 제1 훈련 이미지 및 제1 라벨들을 획득하고, 블록(204)을 참조하여 설명된 바와 같이 특징들의 세트를 획득할 때, 기계 학습(ML) 모델은 제1 라벨들, 제1 라벨들과 연관된 각각의 세그먼트에서 선택된 픽셀들의 군의 값들, 및 각각의 세그먼트의 픽셀들의 군에 대응하는

특징들의 세트의 각각의 특징의 특징 값들을 사용하여 (예를 들어, 훈련 모듈(106)에 의해) 훈련될 수 있다 (206). ML 모델은 이미지 세그먼트화를 위해 훈련된다.

[0081] 일부 실시예들에서, ML 모델은 분류기로서 구현될 수 있다. 본원에서 언급되는 "분류기", "분류기 모델" 또는 "분류 모델"이라는 용어는, 데이터의 훈련 세트를 기준으로 하여, 새로운 인스턴스가 범주들/부류들의 세트 중 어느 것에 속하는지를 식별할 수 있는 임의의 학습 모델을 포함하는 것으로 폭넓게 해석되어야 한다. 예로서, 본 개시내용에서, 분류기는 픽셀 후보들을 사용자에게 의해 정의된 바와 같은 세그먼트 부류들의 세트로 분류하도록 훈련될 수 있다. 예를 들어, 도 6의 예에서, 분류기는 훈련 세트에 기초하여 훈련되고, 훈련 세트는: 2개의 세그먼트들을 나타내는 제1 라벨들(예를 들어, 하나의 세그먼트를 나타내는 픽셀들의 군(606) 상의 사용자 주석 및 다른 세그먼트를 나타내는 픽셀들의 군(608) 상의 사용자 주석), 제1 훈련 이미지의 픽셀들의 군(606) 및 픽셀들의 군(608)의 픽셀 값들, 및 픽셀들의 군(606) 및 픽셀들의 군(608)에 대응하는 (특징들의 세트의 각각의 특징의) 특징 값들을 포함한다. 예를 들어, 특징들의 세트가 702에 예시된 바와 같은 질감 특징, 704에 예시된 바와 같은 강도 특징, 및 도 3b를 참조하여 위에서 설명된 바와 같은 통계적 특징을 포함한다고 가정하면, 픽셀들의 선택된 군들(606 및 608)에 대응하는 (특징 지도들 또는 특징 행렬들의 형태의) 3개의 특징들 각각에서의 특징 값들은 훈련 세트의 일부로서 사용된다.

[0082] 훈련된 분류기는 이미지 세그먼트화를 위해, 즉, 이미지가 속하는 세그먼트를 나타내는, 이미지의 각각의 픽셀에 대한 예측된 라벨을 제공하기 위해 사용될 수 있다. 분류기는 다양한 유형들의 기계 학습 모델들, 예컨대, 예를 들어, 선형 분류기들, 서포트 벡터 머신들(SVM), 신경망들, 결정 트리 등으로서 구현될 수 있고, 본 개시내용은 구현된 특정 모델에 의해 제한되지 않는다는 점을 주목해야 한다.

[0083] 제1 훈련 이미지는, 제1 훈련 이미지의 각각의 픽셀들과 연관된 예측된 라벨들에 대한 정보를 제공하는 제1 세그먼트화 지도를 획득하기 위해, 훈련된 ML 모델을 사용하여 처리될 수 있다(208). 각각의 예측된 라벨은 각각의 픽셀이 속하는 세그먼트를 나타낸다. 특정 실시예들에 따르면, 훈련된 ML 모델(예를 들어, 분류기)은 (예를 들어, 각각의 세그먼트에서 선택되고 분류기의 훈련을 위해 사용되는 픽셀들의 군을 제외한) 제1 훈련 이미지의 적어도 나머지 픽셀들을 처리하는 데 사용될 수 있다. 분류기의 출력은, 훈련 이미지와 동일한 크기이고 이미지의 대응하는 픽셀들에 대한 예측된 라벨들을 포함하는 세그먼트화 지도(또한, 세그먼트화 마스크로 칭해짐)이다.

[0084] 기준이 충족될 때, 제1 훈련 이미지 및 제1 세그먼트화 지도를 포함하는 제1 훈련 샘플을 DNN 훈련 데이터에 포함시키고, 기준이 충족되지 않을 때, 제2 특징들의 추출, 훈련 및 처리를 반복하는 것이 (예를 들어, 훈련 모듈(106)에 의해) 결정된다(210). 다시 말해서, 위에서 설명된 바와 같이, 기준에 기초하여, DNN 훈련 데이터에 제1 훈련 샘플을 포함시킬지, 또는 프로세스를 반복할지가 결정될 수 있다. 일부 실시예들에서, 기준은, 예를 들어, 사용자에게 의한, 제1 세그먼트화 지도에 대한 피드백과 관련될 수 있다. 예로서, 기준은 사용자 피드백에 기초할 수 있다. 예를 들어, 기준은 제1 세그먼트화 지도에 대한 긍정적인 사용자 피드백일 수 있는데, 예를 들어, 제1 세그먼트화 지도는 만족스러운 품질을 갖는다. 따라서, 제1 세그먼트화 지도에 대한 긍정적인 사용자 피드백을 수신할 때, 제1 훈련 샘플은 DNN 훈련 데이터에 포함될 수 있다.

[0085] 반면에, 제1 세그먼트화 지도에 대한 부정적인 사용자 피드백을 수신할 때, 예를 들어, 제1 세그먼트화 지도의 품질이 만족스럽지 않을 때, 이는, 현재 훈련된 바와 같은 ML 모델이, 사용자가 예측한만큼 제1 훈련 이미지를 세그먼트화하도록 학습되지 않았음을 의미하고, 따라서, 도 2a를 참조하여 위에서 설명된 작동들 중 적어도 일부가 반복될 필요가 있다. 도 8은 본 개시된 주제의 특정 실시예들에 따른 부정적인 사용자 피드백을 갖는 세그먼트화 지도의 예를 예시한다.

[0086] 세그먼트화 지도(800)는 도 5 및 6에 예시된 바와 같은 훈련 이미지들에 대응하여 생성된다. 본 예에서, 세그먼트화 지도는 2개의 세그먼트들을 나타내는 이진 지도로서 예시되고, 제1 세그먼트는 이미지의 구조적 요소들(접촉 요소들을 나타내는 흰색 원들로 예시됨)에 대응하고, 제2 세그먼트는 배경 영역(검은색 영역으로 예시됨)에 대응한다. 도시된 바와 같이, 이미지의 경계를 따른 변연부 배경 영역인 영역(802)의 경우, 검은색으로 마킹되었어야 하지만, 영역(802)은 실수로 흰색으로 마킹되었다. 따라서, 영역(802)은 구조적 요소들의 제1 세그먼트에 속하는 것으로 잘못 예측되었다. 영역(804)의 경우, 2개의 구조적 요소들 사이의 배경 영역이 제1 세그먼트에 속하는 것으로 잘못 예측된 유사한 오류가 발생한다(도면에서 2개의 요소들이 서로 연결된 것으로 도시되고, 따라서 그 사이의 배경 영역이 없어짐). 그러한 세그먼트화 지도는, 사용자의 검토에 따르면, 잘못 세그먼트화된 영역들로 인해 만족스럽지 않다. 이에 따라, 분류기는 만족스러운 품질을 갖는 세그먼트화 지도 출력을 생성할 때까지 재훈련될 필요가 있다. 일부 경우들에서, 세그먼트화 지도의 만족스러운 품질은 품질 조건

에 따라 결정될 수 있다는 점을 주목해야 한다. 예를 들어, 품질 조건은 정확히 세그먼트화된 픽셀들의 백분율의 범위 또는 임계치일 수 있다.

[0087] 이제 도 2b를 참조하면, 본 개시된 주제의 특정 실시예들에 따라 제1 세그먼트화 지도에 대해 부정적인 사용자 피드백을 수신할 때 DNN 훈련 데이터 생성의 계속된 프로세스의 일반화된 흐름도가 예시된다.

[0088] 구체적으로, 세그먼트들 중 적어도 하나의 세그먼트의 픽셀들의 추가적인 군과 연관된 추가적인 제1 라벨들이 사용자로부터 획득될 수 있다(212). 그러한 경우들에서, 추가적인 제1 라벨들은 사용자에게 의해 이전에 제공된 바와 같은 제1 라벨들과 함께, 라벨 데이터의 일부로서 추가될 수 있다. 제1 라벨들 및 추가적인 제1 라벨들은 집계된 라벨 데이터를 구성한다. 도 9a를 참조하면, 본 개시된 주제의 특정 실시예들에 따라 사용자에게 의해 제공되는 추가적인 제1 라벨들의 예가 예시된다.

[0089] 도 9a의 제1 훈련 이미지(602)에 도시된 바와 같이, (원형 영역(604)에 도시된 바와 같은) 원래의 제1 라벨들에 추가적으로, (원형 영역들(902 및 904)에 도시된) 픽셀들의 추가적인 군이 이러한 픽셀들이 속하는 예측된 세그먼트들을 나타내는 라벨들로 사용자에게 의해 마킹된다. 예를 들어, 사용자는, 특히, 제1 세그먼트화 지도에(예를 들어, 영역들(802 및 804)에) 잘못된 세그먼트화가 있었던 영역들을 마킹할 수 있다. 사용자는 하나의 세그먼트에서, 또는 양쪽 세그먼트들 모두에서 추가적인 픽셀들을 마킹하도록 선택할 수 있다. 예를 들어, 902에서, 사용자는 구조적 요소 및 배경 양쪽 모두의 픽셀들을 마킹했고, 반면에 904에서, 사용자는 배경의 픽셀들만을 마킹했다. 그러므로, 추가적인 마킹 후에, 집계된 라벨 데이터는 영역들(604, 902 및 904)의 픽셀들의 군들에 대해 마킹된 라벨들을 포함한다.

[0090] 집계된 라벨 데이터를 획득할 때, 제2 특징들의 추출, 훈련 및 처리는 기준이 충족될 때까지, 예를 들어, 긍정적인 사용자 피드백을 수신할 때까지, 집계된 라벨 데이터에 기초하여 반복될 수 있다. 구체적으로, 라벨 데이터가 업데이트되었기 때문에, 라벨들과 연관된 각각의 세그먼트의 픽셀들의 군에 기초하여 계산되는 제2 특징들, 즉, 통계적 특징들이 또한, 집계된 라벨 데이터에 기초하여 업데이트되어야 한다(214). 예를 들어, 제2 특징들은 픽셀들의 군 및 픽셀들의 추가적인 군의 픽셀 값들에 기초하여 계산된 통계적 척도를 사용하여 재추출될 수 있다.

[0091] 분류기는 집계된 라벨들, 집계된 라벨 데이터와 연관된 픽셀들의 값들, 및 집계된 라벨 데이터와 연관된 픽셀들에 대응하는 특징들의 세트의 각각의 특징의 특징 값들을 사용하여 재훈련될 수 있다(216). 제1 훈련 이미지는, 업데이트된 제1 세그먼트화 지도를 획득하기 위해, 재훈련된 분류기를 사용하여 다시 처리될 수 있다(218). 그 다음, 업데이트된 제1 세그먼트화 지도에 대한 사용자 피드백에 기초하여, 상기 프로세스(블록들(212-218)을 참조하는 작동들)를 반복할지, 또는 업데이트된 제1 세그먼트화 지도 및 제1 훈련 이미지를 DNN 훈련 데이터의 제1 훈련 샘플로서 포함시킬지 여부가 결정될 수 있다(220).

[0092] 도 9b를 참조하면, 본 개시된 주제의 특정 실시예들에 따른 긍정적인 사용자 피드백을 갖는 업데이트된 세그먼트화 지도의 예가 예시된다.

[0093] 세그먼트화 지도(900)는, 도 9a에 예시된 바와 같은 추가적인 제1 라벨들을 획득할 때, 도 2b를 참조하여 설명된 작동들에 따라 생성된다. 이는, 도 8에 예시된 바와 같은 제1 세그먼트화 지도(800)의 업데이트된 세그먼트화 지도이다. 도시된 바와 같이, 업데이트된 세그먼트화 지도(900)는 세그먼트화 지도(800)와 반대로, 2개의 세그먼트들의 만족스러운 세그먼트화 결과들을 제공한다. 이전의 잘못 세그먼트화된 영역들(802 및 804)에서의 세그먼트화는 사용자에게 의해 제공된 추가적인 제1 라벨들 및 분류기의 재훈련에 의해 고쳐진다. 업데이트된 세그먼트화 지도는, 대응하는 훈련 이미지와 함께, DNN 훈련 데이터에 훈련 샘플로서 포함된다.

[0094] 특정 실시예들에 따르면, 도 2a 및 2b에 예시된 바와 같은 프로세스는, 훈련 이미지들과 함께 DNN 훈련 데이터에 포함될 수 있는 하나 이상의 세그먼트화 지도를 생성하기 위해, 하나 이상의 훈련 이미지에 대해 반복될 수 있다. 예로서, 제2 훈련 이미지가, 제2 훈련 이미지로부터 사용자에게 의해 식별된 하나 이상의 세그먼트 각각에서 선택된 픽셀들의 군과 각각 연관된 제2 라벨들과 함께 획득될 수 있다. 제2 라벨들은 집계된 라벨 데이터에 추가된다. 제1 특징들 및 제2 특징들을 포함하는, 제2 훈련 이미지를 특징화하는 특징들의 세트가 추출될 수 있다. 기계 학습 모델은 집계된 라벨 데이터, 집계된 라벨 데이터와 연관된 픽셀들의 값들, 및 집계된 라벨 데이터와 연관된 픽셀들에 대응하는 특징들의 세트의 각각의 특징의 특징 값들을 사용하여 훈련될 수 있다. 블록들(208 및 210)을 참조하여 위에서 설명된 바와 같은 처리 및 결정은 제2 훈련 이미지에 기초하여 수행될 수 있다.

[0095] 이제 도 4를 참조하면, 본 개시된 주제의 특정 실시예들에 따라, DNN을 훈련시키기 위한 생성된 DNN 훈련 데이

터를 사용하는 일반화된 흐름도가 예시된다.


- [0096] 특정 실시예들에 따르면, DNN은 반도체 시편 이미지들(예를 들어, FP 이미지들)에 대한 이미지 세그먼트화의 특정 응용을 위해 훈련된다. 예로서, 그러한 세그먼트화는 시편에 대해 측정들을 수행하기 위한 계측 툴들에 의해 사용될 수 있다. 다른 예로서, 세그먼트화는 또한, 속성들을 구성할 때(예를 들어, 결합이 주 패턴 상에 있는지, 배경 상에 있는지, 또는 양쪽 모두에 있는지를 정의하기 위해) ADC에, 각각의 세그먼트에 대해 세그먼트 특정 검출 임계치들을 적용하기 위해 ADR에 등에 사용될 수 있다.
- [0097] 프로세스는 DNN의 세그먼트화 특정 훈련의 설정 단계(410), 및 이미지 세그먼트화를 위해, 훈련된 DNN을 사용하는 런타임 단계(420)를 포함한다.
- [0098] 설정(410) 동안, 도 2a 및 2b의 설명에 따라 생성된 바와 같은 DNN 훈련 데이터가 획득될 수 있다(412). DNN 훈련 데이터는 각각이 훈련 이미지 및 대응하는 세그먼트화 지도를 포함하는 하나 이상의 훈련 샘플을 포함한다. DNN 훈련 데이터는 DNN을 훈련시키는(414) 데 사용될 수 있고, 그에 의해, 세그먼트화 관련 훈련 파라미터들에 의해 특징화되는 훈련된 DNN을 획득한다. 일부 실시예들에서, 훈련 프로세스는 주기적일 수 있고, DNN이 충분히 훈련될 때까지 여러 번 반복될 수 있다. 예로서, DNN은 세그먼트화 정확도에 관련된 비용 함수(예를 들어, 정확한 세그먼트화 라벨 지도 대 예측된 라벨 지도)를 사용하여 훈련될 수 있다. 훈련된 DNN은 이미지들의 검증 세트를 사용하여 검증될 수 있다(416). 이미지들의 검증 세트는 훈련 이미지 세트와 상이한 이미지 세트일 수 있고, 검증 목적들을 위해 선택된 FP 이미지들을 포함할 수 있다. 사용자는 검증 동안 DNN에 의해 도달된 결과들에 대한 피드백을 제공할 수 있다.
- [0099] 런타임(420) 동안, PMC는 각각의 이미지에 대한 세그먼트화 지도를 제공(424) 하기 위해, 세그먼트화될 하나 이상의 캡처된 FP 이미지를 포함하는 하나 이상의 런타임 이미지를 처리(422)하기 위해서, 훈련된 DNN을 사용한다. 하나 이상의 FP 이미지는 동일하거나 상이한 검사 양상들에 의해 획득될 수 있다. 획득된 세그먼트화 지도는 이미지 상의 상이한 세그먼트들을 표시하는 픽셀별 또는 영역별 세그먼트화 라벨들에 대한 정보를 제공할 수 있다. 예로서, 하나의 층 상의 다각형들은 하나의 세그먼트화 라벨을 가질 수 있고, 다른 층 상의 다각형들은 상이한 세그먼트화 라벨을 가질 수 있는 반면, 배경은 별개의 세그먼트화 라벨을 가질 수 있다.
- [0100] 본원에 설명된 바와 같은 훈련 데이터 생성 프로세스의 특정 실시예들의 장점들 중에는, 시간 소모적이고 오류가 발생하기 쉬운, 전체 훈련 이미지에 대한 종래의 수동 주석과 비교하여, DNN을 훈련시키는데 사용가능한 정확한 실측 정보 데이터를 생성하는 자동 수단이 제공된다는 것이 있다. 그러한 프로세스의 자동화는, 적어도, 세그먼트화에 적합한 의미있는 특징들을 추출하는 것, 및 사용자의 부분적인 주석 및 피드백에 기초한, ML 모델의 상호작용 훈련에 의해 가능해진다.
- [0101] 본원에 설명된 바와 같은 훈련 데이터 생성 프로세스의 특정 실시예들의 추가의 장점들 중에는, 훈련 이미지를 특징화하는 맥락 특징들 및 통계적 특징들 양쪽 모두를 추출하고 사용함으로써, 본 개시내용이 질감, 레이아웃, 맥락, 및 통계적 의미 등의 관점에서 반도체 이미지의 신뢰성있는 표현을 제공하도록 관리하며, 따라서 대표적인 특징들을 사용하여 ML 모델을 훈련시키고 효율적인 방식으로 세그먼트화 지도를 생성할 수 있으며 만족스러운 결과를 갖는다는 것이 있다.
- [0102] 예시된 예들은 예시의 목적들을 위하여 본원에서 설명되고, 어떤 식으로든 본 개시내용을 제한하는 것으로 간주되어서는 안 된다는 것을 주목해야 한다. 다른 적합한 예들이 상기 내용에 추가적으로 또는 상기 내용 대신에 사용될 수 있다.
- [0103] 본 개시내용은 본 출원에서 본원에 포함된 설명에 열거되거나 도면들에 예시된 세부 사항들로 제한되지 않는다는 것을 이해해야 한다.
- [0104] 또한, 본 개시내용에 따른 시스템은, 적어도 부분적으로, 적절히 프로그래밍된 컴퓨터 상에 구현될 수 있다는 것을 이해할 것이다. 마찬가지로, 본 개시내용은, 본 개시내용의 방법을 실행하기 위해, 컴퓨터에 의해 판독가능한 컴퓨터 프로그램을 고려한다. 본 개시내용은, 본 개시내용의 방법을 실행하기 위해 컴퓨터에 의해 실행가능한 명령어들의 프로그램을 유형적으로 구현하는 비일시적 컴퓨터 판독가능 메모리를 더 고려한다.
- [0105] 본 개시내용은 다른 실시예들이 가능하고, 다양한 방식으로 실시되거나 수행될 수 있다. 그러므로, 본원에서 채용되는 어법 및 용어는 설명의 목적을 위한 것이며 제한으로서 간주되어서는 안 된다는 점을 이해해야 한다. 이로써, 관련 기술분야의 통상의 기술자는, 본 개시내용이 기초로 하는 개념이, 본 개시된 주제의 몇몇 목적을 수행하기 위한 다른 구조들, 방법들 및 시스템들을 설계하기 위한 기초로서 용이하게 활용될 수 있음을 이해할

것이다.


[0106] 관련 기술분야의 통상의 기술자는, 다양한 수정들 및 변경들이, 본 개시내용의 범위로부터 벗어나지 않고 앞서 설명되고 첨부된 청구항들에서 그리고 청구항들에 의해 정의된 바와 같이 본 개시내용의 실시예들에 적용될 수 있다는 것을 용이하게 이해할 것이다.

도면


도면1




도면2a




도면2b




도면3a




도면3b




도면4




도면5




도면6




도면7



도면8



도면9a



도면9b

