



등록특허 10-2203694



(19) 대한민국특허청(KR)
(12) 등록특허공보(B1)

(45) 공고일자 2021년01월15일
(11) 등록번호 10-2203694
(24) 등록일자 2021년01월11일

(51) 국제특허분류(Int. Cl.)
G06T 7/00 (2017.01) *G06N 3/08* (2006.01)

G06T 1/20 (2018.01)

(52) CPC특허분류

G06T 7/00 (2013.01)*G06N 3/08* (2013.01)

(21) 출원번호 10-2017-0126009

(22) 출원일자 2017년09월28일

심사청구일자 2020년04월17일

(65) 공개번호 10-2018-0037593

(43) 공개일자 2018년04월12일

(30) 우선권주장

16192142.4 2016년10월04일
유럽특허청(EPO)(EP)

(56) 선행기술조사문헌

Saliency detection by multi-context deep learning, IEEE, 2015.

Finding action tubes, IEEE, 2015.

Deep learning for saliency prediction in natural video, 2016.

Predicting eye fixations using convolutional neural networks, IEEE, 2015

(73) 특허권자
엑시스 에이비
스웨덴왕국 룬트 에스-223 69, 엠달라베겐 14

(72) 발명자
다니엘손 니클라스
스웨덴 룬트 223 69 엠달라베겐 14 엑시스 커뮤니케이션스 에이비 씨/오
판 쟁 다니엘손
스웨덴 룬트 223 69 엠달라베겐 14 엑시스 커뮤니케이션스 에이비 씨/오

(74) 대리인
박장원

전체 청구항 수 : 총 10 항

심사관 : 신재철


(54) 발명의 명칭 뉴럴 네트워크들에 트레이닝 데이터를 제공하기 위한 이미지 분석 알고리즘들을 사용하는 장치 및 방법

(57) 요 약

본 발명은, 일반적으로, 복수의 입력 디지털 이미지를 수신하고 그리고 각 특정 입력 디지털 이미지에 대해, 특정 입력 디지털 이미지에서 픽셀들의 그룹들에 대한 관련성 레벨을 결정하기 위한 데이터를 출력하는 뉴럴 네트워크를 트레이닝하기 위한 방법, 컴퓨터 프로그램, 컴퓨터 및 시스템에 관한 것이다.

대 표 도 - 도2

200



(52) CPC특허분류

G06T 1/20 (2013.01)
G06T 2207/10016 (2013.01)
G06T 2207/20081 (2013.01)
G06T 2207/20084 (2013.01)

명세서

청구범위

청구항 1

인코딩 프로세스 동안 이미지상에 비트 레이트 예산(bit rate budget)을 분배할 때 비디오 카메라에 의해 사용될 뉴럴 네트워크(neural network)를 트레이닝(training)하는 방법으로서,

상기 뉴럴 네트워크는, 복수의 입력 디지털 이미지들을 수신하고 그리고 각 특정 입력 디지털 이미지에 대해, 상기 특정 입력 디지털 이미지에서 매크로 블록들에 대한 관련성 레벨(relevance level)을 결정하기 위한 데이터를 출력하며,

상기 방법은:

제1 복수의 디지털 트레이닝 이미지들에 대하여, 매크로 블록의 이미지 특성들에 기초하여 상기 매크로 블록을 관련성 레벨로 자동적으로 라벨(label)링하도록 구성된 제1 이미지 분석 알고리즘을 사용하여 상기 제1 복수의 디지털 트레이닝 이미지들의 각 특정 디지털 트레이닝 이미지에서 매크로 블록들에 대한 관련성 레벨을 결정(S402)하고,

사용자 특정된 상황을 나타내는 제2 복수의 디지털 트레이닝 이미지들에 대하여, 매크로 블록의 이미지 특성들에 기초하여 상기 매크로 블록을 관련성 레벨로 자동적으로 라벨링하도록 구성된 제2 이미지 분석 알고리즘을 사용하여 상기 제2 복수의 디지털 트레이닝 이미지들의 각 특정 디지털 트레이닝 이미지에서 매크로 블록들에 대한 관련성 레벨을 결정(S404)함으로써, 트레이닝 데이터 세트를 결정하는 단계 -

상기 제2 이미지 분석 알고리즘은 상기 사용자 특정된 상황을 나타내는 이미지들을 분석하도록 특별히 구성된다는 점에서 상기 제1 이미지 분석 알고리즘과 상이하며,

매크로 블록의 관련성 레벨이 높을수록, 관련성 레벨이 낮은 매크로 블록에 비해 상기 인코딩 프로세스 동안 매크로 블록에 대한 비트레이트 예산의 더 많은 부분을 소비하도록 지시하고 - 와;

상기 제1 및 제2 복수의 디지털 트레이닝 이미지들 및 상기 관련성 레벨들을 상기 트레이닝 데이터 세트로서 포함하는 단계와; 그리고

상기 뉴럴 네트워크의 트레이닝(S408)을 위해 상기 트레이닝 데이터 세트를 사용하는 단계를 포함하고,

상기 제1 복수의 디지털 트레이닝 이미지들 및 상기 관련성 레벨들은 상기 뉴럴 네트워크를 초기에 트레이닝하는데 사용되며, 그리고 상기 제2 복수의 디지털 트레이닝 이미지들 및 상기 관련성 레벨들은 상기 사용자 특정된 상황에 맞게 상기 뉴럴 네트워크의 트레이닝을 미세조정하기 위해 후속으로 사용되는 것을 특징으로 하는

뉴럴 네트워크를 트레이닝하는 방법.

청구항 2

제1항에 있어서,

상기 제1 이미지 분석 알고리즘은,

매크로 블록에 대한 공간 통계적 측정치를 계산하고,

상기 제1 복수의 디지털 트레이닝 이미지들의 이미지들의 시퀀스에 대해 시간 필터링을 적용함으로써 매크로 블록에 대한 시간 통계적 측정치를 계산하고, 상기 이미지들의 시퀀스는 상기 특정 디지털 트레이닝 이미지를 포함하며, 그리고

매크로 블록에 대한 상기 시간 통계적 측정치 및 상기 공간 통계적 측정치를 가중함으로써 가중된 통계적 측정치를 계산하고 그리고 상기 가중된 통계적 측정치에 기초한 관련성 레벨로 매크로 블록을 라벨링함으로써,

매크로 블록을 관련성 레벨로 자동적으로 라벨링하는 것을 특징으로 하는

뉴럴 네트워크를 트레이닝하는 방법.

청구항 3

제2항에 있어서,

상기 제2 복수의 디지털 트레이닝 이미지들은 상기 제1 복수의 디지털 트레이닝 이미지들의 일부인 적어도 하나의 디지털 트레이닝 이미지를 포함하는 것을 특징으로 하는

뉴럴 네트워크를 트레이닝하는 방법.

청구항 4

제2항에 있어서,

상기 제2 복수의 디지털 트레이닝 이미지들은 상기 제1 복수의 디지털 트레이닝 이미지들의 일부가 아닌 적어도 하나의 디지털 트레이닝 이미지를 포함하는 것을 특징으로 하는

뉴렐 네트워크를 트레이닝하는 방법.

청구항 5

제1항에 있어서,

상기 트레이닝 데이터 세트는, 관련성 레벨을 갖는 상기 제1 복수의 디지털 트레이닝 이미지를 중에서 적어도 하나의 디지털 트레이닝 이미지의 매크로 블록들을 수동으로 라벨링(S406)함으로써 또한 결정되는 것을 특징으로 하는

뉴렐 네트워크를 트레이닝하는 방법.

청구항 6

제2항에 있어서,

상기 트레이닝 데이터 세트는, 관련성 레벨을 갖는 상기 제2 복수의 디지털 트레이닝 이미지를 중에서 적어도 하나의 디지털 트레이닝 이미지의 매크로 블록들을 수동으로 라벨링함으로써 또한 결정되는 것을 특징으로 하는

뉴렐 네트워크를 트레이닝하는 방법.

청구항 7

프로세싱 능력을 갖는 디바이스에 의해 실행될 때 제1항의 방법을 수행하도록하는 명령어들을 구비한 컴퓨터가 관독 가능한 기록매체.

청구항 8

인코딩 프로세스 동안 이미지상에 비트 레이트 예산을 분배할 때 비디오 카메라에 의해 사용될 뉴렐 네트워크를 트레이닝하도록 구성된 프로세서를 포함하는 컴퓨터로서,

상기 뉴렐 네트워크는, 복수의 입력 디지털 이미지들을 수신하고 그리고 각 특정 입력 디지털 이미지에 대해, 상기 특정 입력 디지털 이미지에서 매크로 블록들에 대한 관련성 레벨을 결정하기 위한 데이터를 출력하며,

상기 뉴렐 네트워크를 트레이닝하는 것은,

제1 복수의 디지털 트레이닝 이미지들에 대하여, 매크로 블록의 이미지 특성들에 기초하여 상기 매크로 블록을 관련성 레벨로 자동적으로 라벨링하도록 구성된 제1 이미지 분석 알고리즘을 사용하여 상기 제1 복수의 디지털 트레이닝 이미지들의 각 특정 디지털 트레이닝 이미지에서 매크로 블록들에 대한 관련성 레벨을 결정(S402)하고,

사용자 특정된 상황을 나타내는 제2 복수의 디지털 트레이닝 이미지들에 대하여, 매크로 블록의 이미지 특성들에 기초하여 상기 매크로 블록을 관련성 레벨로 자동적으로 라벨링하도록 구성된 제2 이미지 분석 알고리즘을 사용하여 상기 제2 복수의 디지털 트레이닝 이미지들의 각 특정 디지털 트레이닝 이미지에서 매크로 블록들에 대한 관련성 레벨을 결정(S404)함으로써, 트레이닝 데이터 세트를 결정하는 것 -

상기 제2 이미지 분석 알고리즘은 상기 사용자 특정된 상황을 나타내는 이미지들을 분석하도록 특별히 구성

된다는 점에서 상기 제1 이미지 분석 알고리즘과 상이하며,

매크로 블록의 관련성 레벨이 높을수록, 관련성 레벨이 낮은 매크로 블록에 비해 상기 인코딩 프로세스 동안 매크로 블록에 대한 비트레이트 예산의 더 많은 부분을 소비하도록 지시하고 - 과;

상기 제1 및 제2 복수의 디지털 트레이닝 이미지를 및 상기 관련성 레벨들을 상기 트레이닝 데이터 세트로서 포함하는 것과; 그리고

상기 뉴럴 네트워크의 트레이닝(S408)을 위해 상기 트레이닝 데이터 세트를 사용하는 것을 포함하고,

상기 제1 복수의 디지털 트레이닝 이미지를 및 상기 관련성 레벨들은 상기 뉴럴 네트워크를 초기에 트레이닝하는데 사용되며, 그리고 상기 제2 복수의 디지털 트레이닝 이미지를 및 상기 관련성 레벨들은 상기 사용자 특정된 상황에 맞게 상기 뉴럴 네트워크의 트레이닝을 미세조정하기 위해 후속으로 사용되는 것을 특징으로 하는 컴퓨터.

청구항 9

비디오 카메라 및 제8항에 따른 컴퓨터를 포함하는 시스템으로서,

상기 프로세서는 결과적으로 트레이닝된 뉴럴 네트워크를 상기 카메라에 제공(S410)하도록 추가로 구성되고,

상기 카메라는:

상기 트레이닝된 뉴럴 네트워크를 수신하고,

복수의 디지털 이미지를 캡쳐하고, 상기 복수의 디지털 이미지들의 이미지 데이터를 상기 트레이닝된 뉴럴 네트워크에 제공하며, 그리고 상기 복수의 디지털 이미지들의 각각의 특정 디지털 이미지에 대해, 상기 특정 디지털 이미지의 매크로 블록에 각각 대응하는 복수의 관련성 레벨들을 획득하도록 구성되는 것을 특징으로 하는 시스템.

청구항 10

제9항에 있어서,

상기 카메라는,

상기 획득된 관련성 레벨들에 따라 상기 특정 디지털 이미지의 압축 정도를 제어함으로써 상기 특정 디지털 이미지를 인코딩하도록 또한 구성되는 것을 특징으로 하는

시스템.

청구항 11

삭제

발명의 설명

기술 분야

[0001] 본 발명은, 일반적으로, 복수의 입력 디지털 이미지를 수신하고 그리고 각 특정 입력 디지털 이미지에 대해, 특정 입력 디지털 이미지에서 픽셀들의 그룹들에 대한 관련성 레벨을 결정하기 위한 데이터를 출력하는 뉴럴 네트워크를 트레이닝하기 위한 방법, 컴퓨터 프로그램, 컴퓨터 및 시스템에 관한 것이다.

배경 기술

[0002] 이미지 프로세싱에서 많은 애플리케이션들은 상이한 이미지 영역들에 대해 리소스들의 유동적인 할당을 요구한다. 예를 들어, 압축 파라미터들이 이미지의 특정 특성들에 기초하여 선택될 수 있거나, 또는 이미지 영역들은 전송 신뢰도와 효율성 사이에서 최적의 트레이드-오프를 달성하기 위해 유동적인 여러 정정의 대상이 될 수 있다. 특정 이미지 영역에 할당되어야 하는 리소스들의 양을 결정하기 위해 이미지 영역들의 관련 레벨들을 자동으로 식별하는 것은 중요하고 그리고 그러한 알고리즘을 실행하는 것은 또한 가치 있는 CPU 시간을 요구할 수 있다. 이는, 예를 들어, 많은 프로그램들이 모니터링 카메라와 같은 임베딩된 플랫폼에서 제한된 리소스들을 위

해 경쟁하는 경우 문제들을 야기할 수 있다.

[0003] 따라서 이러한 맥락에서 개선이 필요하다.

발명의 내용

해결하려는 과제

[0004] 상기의 관점에서, 본 발명의 목적은 상기에서 서술된 단점들 중 하나 이상을 해결하거나 적어도 감소시키는 것이다. 일반적으로, 상기 목적은 첨부된 독립 특허 청구항들에 의해 달성된다.

과제의 해결 수단

[0005] 제1 양상에 따라, 본 발명은, 복수의 입력 디지털 이미지들을 수신하고 그리고 각 특정 입력 디지털 이미지에 대해, 상기 특정 입력 디지털 이미지에서 픽셀들의 그룹들에 대한 관련성 레벨(relevance level)을 결정하기 위한 데이터를 출력하는 뉴럴 네트워크(neural network)를 트레이닝(training)하는 방법에 의해 실현된다. 상기 방법은, 제1 복수의 디지털 트레이닝 이미지들에 대해, 상기 픽셀들의 그룹을 관련성 레벨로 자동적으로 라벨(label)링하는 제1 이미지 분석 알고리즘을 사용하여 상기 제1 복수의 디지털 트레이닝 이미지들의 각 특정 디지털 트레이닝 이미지에서 픽셀들의 그룹들에 대한 관련성 레벨을 결정함으로써 트레이닝 데이터 세트를 결정하는 단계와, 상기 제1 복수의 디지털 트레이닝 이미지들 및 상기 라벨들을 상기 트레이닝 데이터 세트로서 포함하는 단계와; 그리고 상기 뉴럴 네트워크의 트레이닝을 위해 상기 트레이닝 데이터 세트를 사용하는 단계를 포함한다.

[0006] "뉴럴 네트워크(neural network)"라는 용어는, 본 명세서의 문맥에서, 뇌의 방대한 뉴런들의 네트워크와 유사한, 노드들의 상호 연결된 그룹으로 이해되어야 한다. 뉴럴 네트워크는 또한 "인공 뉴럴 네트워크(artificial neural network)"(ANN)로 명명될 수 있다. 이 문맥에서 사용될 수 있는 특정 유형의 뉴럴 네트워크는 컨벌루션 뉴럴 네트워크(convolutional neural network: CNN)이다. "딥 러닝(Deep learning)"이라는 용어도 일반적으로 사용된다.

[0007] "관련성 레벨(relevance level)"이라는 용어는, 본 명세서의 문맥에서, 이미지 내의 대응하는 영역의 이미지 콘텐트의(예를 들어, 사용자에 대한) 관심의 등급 부여로 이해되어야 한다. 즉, 관련성 레벨은 이미지의 영역(픽셀들의 그룹)에 대응하고 그리고 상기 관련성 레벨은 상기 영역의 이미지 콘텐트에 대해 상기 이미지의 뷰어가 얼마나 관심이 있는지를 정의한다. 이는 유리하게도 이미지에 비트 전송률 예산을 분배하는 데 사용될 수 있다. 예를 들어, 관련성 레벨은, 압축 레벨을 설정하거나 인코더가 해당 영역에 대해 코딩을 스킁해야하는 정도를 결정하는 등을 통해 대응하는 영역의 압축 정도를 제어하는데 사용될 수 있다. 관련성 레벨은, 예를 들어, 인코딩된 이미지를 전송할 때 여러 정정의 정도들을 결정하기 위해, 여러 코딩 목적들을 위해 추가로 사용될 수 있다. 이미지의 특정 영역에 대해 관련성 레벨이 상대적으로 높다는 것은, 관련성 레벨이 낮은 다른 이미지 영역에 비해 특정 영역에 비트 전송률 예산의 많은 부분이 사용될 수 있음을 의미한다.

[0008] 선행 기술에서 관련성 레벨 대신에 사용될 수 있는 다른 용어는 "관심 영역(region of interest)" 또는 "ROI"를 포함한다.

[0009] "픽셀들의 그룹을 관련성 레벨로 자동적으로 라벨(label)하는 이미지 분석 알고리즘"이라는 용어는, 본 명세서의 문맥에서, 그 부분의 이미지 특성들(즉, 이미지 분석)에 기초하여 이미지 내의 대응하는 영역(예를 들어, 매크로 블록들)의 이미지 내용의 (예를 들어, 사용자에 대한) 관심을 자동적으로(예를 들어, 사람의 도움이 없이 컴퓨터에 의해) 등급화하는데 사용될 수 있는 임의의 적합한 알고리즘으로 이해될 수 있다. 이미지 특성들은, 공간, 예를 들어, 디지털 이미지의 일부에 존재하는 에지들, 노이즈의 존재, 반복적으로 텍스처링된 부분들, 얼굴 인식, 객체 검출 등일 수 있다. 이미지 특성은 또한 일시적, 예를 들어, 모션 검출일 수 있다. 적합한 이미지 분석 알고리즘의 예는 엑시스 커뮤니케이션(Axis Communication)에 의해 이 제공하는 집스트림(Zipstream) 알고리즘이다. 이 알고리즘의 일부들은 예를 들어 EP3021583 호의 유럽 특허 출원에 기재되어있다.

[0010] 본 발명자들은, 상기에서 서술된 것처럼 기준의 이미지 분석 알고리즘을 사용하여 트레이닝된 뉴럴 네트워크를 사용하는 것이 몇 가지 이점들을 갖는다는 것을 깨달았다. 예를 들어, 뉴럴 네트워크의 설계는 매우 단순하며, 그리고 뉴럴 네트워크는 거대한 양의 매우 반복적이지만 매우 단순한 계산들에 의해 기능하기에 하드웨어 구현에 적합하다. 또한, 모델 압축 분야에서 진행중인 작업이 진행됨에 따라, 모니터링 카메라와 같은 임베디드 플랫폼을 설치하는데 뉴럴 네트워크들의 사용이 점차 더 유용하게 되었다. 이와 같이, 예를 들어, 모니터링 카메

라와 같은 임베딩된 플랫폼에서의 뉴럴 네트워크의 사용은, 카메라에서 실제 이미지 분석 알고리즘을 실행하는 것보다 유리할 수 있다.

[0011] 일부 실시예들에 따라, 상기 제1 이미지 분석 알고리즘은, 상기 핵심들의 그룹에 대한 공간 통계적 측정치를 계산하고, 상기 복수의 디지털 트레이닝 이미지들의 이미지들의 시퀀스에 대해 시간 필터링을 적용함으로써 상기 핵심들의 그룹에 대한 시간 통계적 측정치를 계산하고, 상기 이미지들의 시퀀스는 상기 특정 디지털 트레이닝 이미지를 포함함으로써 상기 핵심들의 그룹을 관련성 레벨로 자동적으로 라벨링하도록 구성된다.

[0012] 그 다음, 2개의 통계적 측정치들은 시간 통계적 측정치 및 핵심들의 그룹에 대한 공간 통계적 측정치를 가중함으로써 가중된 통계적 측정치를 계산하고, 그리고 상기 가중된 통계적 측정치에 기초하여 핵심들의 그룹을 관련성 레벨로 라벨링하는데 사용할 수 있다. 사용된 가중치는 정적 가중치, 예를 들어, 0.5, 0.3, 0.7 등일 수 있거나, 또는 관련 이미지 영역들의 이미지 특성에 따라 달라질 수 있다.

[0013] 일부 실시예들에 따라, 상기 트레이닝 데이터 세트를 결정하는 단계는: 제2 복수의 디지털 트레이닝 이미지들에 대하여, 상기 핵심들의 그룹을 관련성 레벨로 자동적으로 라벨링하는 제2 이미지 분석 알고리즘을 사용함으로써 상기 제2 복수의 디지털 트레이닝 이미지들의 각 특정 디지털 트레이닝 이미지에서 핵심들의 그룹들에 대한 관련성 레벨을 결정하는 단계를 포함하고, 상기 제2 이미지 분석 알고리즘은 상기 제1 이미지 분석 알고리즘과 상이하다.

[0014] 예를 들어, (더 작은) 복수의 이미지들에 대해, 좀 더 복잡하거나 전문화된 이미지 분석 알고리즘이, 예를 들어, 디지털 이미지들의 특정 내용에 관련된 트레이닝 데이터를 뉴럴 네트워크에 제공하기 위해 사용될 수 있다. 이러한 특정 콘텐츠의 예로는 트래픽을 나타내는 이미지 콘텐트 또는 많은 사람들이 카메라 등으로 걷는 입구를 보여주는 이미지 콘텐트일 수 있다.

[0015] 본 실시예의 이점은, 제대로 트레이닝 되었으면, 뉴런 네트워크들은 제1 이미지 분석 알고리즘과 같은 수작업에 의한 알고리즘들에 비해 월등히 우수한 성능을 가질 잠재성이 있다는 것이다. 본 실시예의 이점은, 방대한 양의 트레이닝 데이터가 제1 이미지 분석 알고리즘으로부터 생성되어 그 알고리즘과 동등하게 알고리즘을 신속하게 수행할 수 있다는 것이다. 그 후, 뉴럴 네트워크는 제2 복수의 이미지들 및 (제2 이미지 분석 알고리즘에 의해 결정된) 그 레벨과 같은 다른 보다 "진보된(advanced)" 훈련 데이터로 미세 조정될 수 있다. 또한, 미세 조정은 통상적으로 초기 트레이닝(즉, 제1 복수의 이미지들을 이용하는 것)보다 훨씬 적은 데이터를 필요로 한다. 즉, 두번째 트레이닝 수행하는 목표는 사용자-별 관련성 레벨들을 제공하는 것이다. 이미지들의 일부 영역들은 일부 사용자에게는 중요하지만 다른 유형의 사용 사례들에는 관심이 없다. 이러한 제2 트레이닝을 추가하는 것(제2 복수의 이미지들 및 제2 이미지 분석 알고리즘을 사용함)은 비트 레이트 예산이 사용자들에 대한 관련 영역들에서 소비되는 것을 용이하게 할 수 있다.

[0016] 상기 제2 복수의 디지털 트레이닝 이미지들은 상기 제1 복수의 디지털 트레이닝 이미지들의 일부인 적어도 하나의 디지털 트레이닝 이미지를 포함할 수 있다. 제2 복수의 디지털 트레이닝 이미지들은 예를 들어 제1 복수의 트레이닝 이미지들의 서브 세트로 이루어질 수 있다. 상기 제2 복수의 디지털 트레이닝 이미지들은 상기 제1 복수의 디지털 트레이닝 이미지들의 일부가 아닌 적어도 하나의 디지털 트레이닝 이미지를 포함할 수 있다. 즉, 제2 복수의 디지털 트레이닝 이미지들은 제1 복수의 트레이닝 이미지들의 서브 세트가 아니다.

[0017] 일부 실시예들에 따라, 상기 트레이닝 데이터 세트는, 관련성 레벨을 갖는 상기 제1 복수의 디지털 트레이닝 이미지들 중에서 적어도 하나의 디지털 트레이닝 이미지의 핵심들의 그룹들을 수동으로 라벨링함으로써 또한 결정된다. 다른 실시예들에 따라, 상기 트레이닝 데이터 세트는, 관련성 레벨을 갖는 상기 제2 복수의 디지털 트레이닝 이미지들 중에서 적어도 하나의 디지털 트레이닝 이미지의 핵심들의 그룹들을 수동으로 라벨링함으로써 또한 결정된다. 트레이닝 데이터 세트의 이미지를 사이의 핵심들의 그룹들을 수동으로 라벨링하는 것은 트레이닝 데이터 세트를 미세 조정하기 위해 사용될 수 있다. 제2 복수의 이미지들 및 제2 이미지 분석 알고리즘의 사용과 관련하여 상기 논의된 것처럼 동일한 논거들을 사용하여, 이 실시예는 비트 레이트 예산이 사용자들에 대한 관련 영역들 상에 소비되는 것을 용이하게 할 수 있다.

[0018] 제2 양상에서, 본 발명은, 프로세싱 능력을 갖는 디바이스에 의해 실행될 때 제1 양상의 방법을 수행하도록 하는 명령어들을 구비한 컴퓨터 판독 가능 저장 매체를 포함하는 컴퓨터 프로그램 제품을 제공한다.

[0019] 제3 양상에서, 본 발명은, 복수의 입력 디지털 이미지들을 수신하고 그리고 각 특정 입력 디지털 이미지에 대해, 상기 특정 입력 디지털 이미지에서 핵심들의 그룹들에 대한 관련성 레벨을 결정하기 위한 데이터를 출력하는 뉴럴 네트워크를 트레이닝하도록 구성된 프로세서를 포함하는 컴퓨터를 제공하고, 상기 뉴럴 네트워크를

트레이닝하는 단계는, 제1 복수의 디지털 트레이닝 이미지들에 대해, 상기 픽셀들의 그룹을 관련성 레벨로 자동적으로 라벨링하는 제1 이미지 분석 알고리즘을 사용하여 상기 제1 복수의 디지털 트레이닝 이미지들의 각 특정 디지털 트레이닝 이미지에서 픽셀들의 그룹들에 대한 관련성 레벨을 결정함으로써 트레이닝 데이터 세트를 결정하는 단계와; 상기 제1 복수의 디지털 트레이닝 이미지들 및 상기 라벨들을 상기 트레이닝 데이터 세트로서 포함하는 단계와; 그리고 상기 뉴럴 네트워크의 트레이닝을 위해 상기 트레이닝 데이터 세트를 사용하는 단계를 포함한다.

[0020] 제4 양상에서, 본 발명은 비디오 카메라 및 컴퓨터를 포함하는 시스템을 제공한다. 상기 컴퓨터는 복수의 입력 디지털 이미지들을 수신하고 그리고 각 특정 입력 디지털 이미지에 대해, 상기 특정 입력 디지털 이미지에서 픽셀들의 그룹들에 대한 관련성 레벨을 결정하기 위한 데이터를 출력하는 뉴럴 네트워크를 트레이닝하도록 구성된 프로세서를 갖고, 상기 뉴럴 네트워크를 트레이닝하는 단계는, 제1 복수의 디지털 트레이닝 이미지들에 대해, 상기 픽셀들의 그룹을 관련성 레벨로 자동적으로 라벨링하는 제1 이미지 분석 알고리즘을 사용하여 상기 제1 복수의 디지털 트레이닝 이미지들의 각 특정 디지털 트레이닝 이미지에서 픽셀들의 그룹들에 대한 관련성 레벨을 결정함으로써 트레이닝 데이터 세트를 결정하는 단계와; 상기 제1 복수의 디지털 트레이닝 이미지들 및 상기 라벨들을 상기 트레이닝 데이터 세트로서 포함하는 단계와; 그리고 상기 뉴럴 네트워크의 트레이닝을 위해 상기 트레이닝 데이터 세트를 사용하는 단계를 포함한다. 상기 프로세서는 결과적으로 트레이닝된 뉴럴 네트워크를 상기 카메라에 제공하도록 추가로 구성되고, 그리고 상기 카메라는 상기 트레이닝된 신경망을 수신하도록 구성된다. 상기 카메라는, 복수의 디지털 이미지들을 캡처하고, 상기 복수의 디지털 이미지들의 이미지 데이터를 상기 트레이닝된 뉴럴 네트워크에 제공하며, 그리고 상기 복수의 디지털 이미지들의 각각의 특정 디지털 이미지에 대해, 상기 특정 디지털 이미지의 픽셀들의 그룹에 각각 대응하는 복수의 관련 레벨들을 획득하도록 구성된다.

[0021] "트레이닝된 뉴럴 네트워크(trained neural network)"라는 용어는, 본 명세서의 문맥에서, 예를 들어, 뉴럴 네트워크에서 노드들의 설정(노드들이 상호접속되는 방법) 및 뉴럴 네트워크에서 사용되는 가중치들(필터, 가중치 뱅크 등)을 특정하는 텍스트 파일로 이해되어야 한다. 컴퓨터와 카메라 사이에 트레이닝된 뉴럴 네트워크를 제공하는 다른 방법들은 예를 들어 바이너리 파일을 통해 동일하게 가능하다.

[0022] 일부 실시예들에 따라, 상기 카메라는, 상기 획득된 관련성 레벨들에 따라 상기 특정 디지털 이미지의 압축 정도를 제어함으로써 상기 특정 디지털 이미지를 인코딩하도록 또한 구성된다.

[0023] 압축 정도는 이미지의 특정 부분(영역 등)에 대한 압축비를 설정함으로써 제어 될 수 있다. 압축비는, 예를 들어, 0~51(H.264), 1~255(VP 9) 또는 1~100의 범위의 양자화 파라미터 값인, QP-값에 의해 구현될 수 있다. 본 설명에서, 용어들 "압축 정도(degree of compression)", "압축 비율(compression ratio)" 및 "압축 수준(compression level)"은, 넓은 의미에서, 원래의 압축되지 않은 픽셀들의 표현보다 적은 비트들을 사용하여 픽셀들의 인코딩을 나타내기 위해 상호 교환적으로 사용된다는 점을 알아야 한다. 상기에서 서술된 것처럼, 인코딩 프로세스의 다른 부분들은, 예를 들어, 상기 관련성 레벨에 기초하여 상기 인코딩된 이미지를 전송할 때의 에러 정정의 정도를 결정하기 위해, 에러 코딩과 같은 관련성 레벨에 기초할 수 있다.

[0024] 제2, 제3 및 제4 양상은 일반적으로 제1 양상과 동일한 피쳐들 및 이점들을 가질 수 있다.

도면의 간단한 설명

[0025] 본 발명의 상기의 목적들과 추가적인 목적들, 피쳐들 및 이점들은 첨부된 도면을 참조하여 본 발명의 실시예에 대한 다음의 예시적이고 비 제한적인 상세한 설명을 통해 더 잘 이해될 것이며, 유사한 요소들에 대해 동일한 참조 번호들이 사용된다.

도 1은 컨벌루션 뉴럴 네트워크(convolutional neural network)를 개략적으로 도시한다.

도 2는 뉴럴 네트워크가 실시예들에 따라 어떻게 트레이닝되는지를 도시한다.

도 3은 실시예들에 따른 비디오 카메라 및 컴퓨터를 포함하는 시스템을 도시한다.

도 4는 실시예들에 따라 뉴럴 네트워크를 트레이닝하는 방법을 도시한다.

발명을 실시하기 위한 구체적인 내용

[0026] 도 1은 일례로서 컨벌루션 뉴럴 네트워크(convolutional neural network; CNN)(100)를 도시한다. 본 명세서의 문맥에서, 입력 디지털 이미지에서 픽셀들의 그룹들의 관련성 레벨을 결정하기 위한 CNN의 사용은 단지 예시일 뿐이라는 것을 알아야 한다. 임의의 적절한 뉴럴 네트워크 구조가, 예를 들어, 다른 유형의 피드포워드

(feedforward) 뉴럴 네트워크(즉, CNN 이외의 뉴럴 네트워크), 순환형 네트워크 등이 이러한 목적을 위해 사용될 수 있다. CNN(100)에서, 2가지 유형의 층들인, 컨벌루션 층들(102) 및 완전히 접속된 층들(104)이 존재할 수 있다. 상기 완전히 접속된 층은 하나보다 많은 출력을 갖는 층으로 대체될 수 있다. CNN(100)에서, 임의의 수의 2개의 상이한 층들이 존재할 수 있다. 도 1에서, 2개의 컨벌루션 층들 (102a, 102b)이 존재한다. 컨벌루션 층들 (102)에, 2개의 회귀 헤드들(104)이 부가된다. 회귀 헤드(104)는, 이 예에서, 컨벌루션 층들(102)로부터의 출력 (106)이 공급되는 완전하게 접속된 층들(104a-b; 104c-d)의 세트이다. 이 문맥에서의 CNN의 이점은, 관련성 레벨들을 결정할 목적으로 (이미지 분석 목적들에 적합한 필터들 및 필터 가중치들로 구성된) 컨벌루션 층들(102)의 동일한 세트들이 사용될 수 있다는 점이다. 이 세트(102)에, 여분의 회귀 헤드(104)가 추가될 수 있다(컨벌루션 층들의 세트(102)는 이미 다른 이미지 분석 목적들을 위해 트레이닝된 다른 회귀 헤드(들)에 이미 접속되어 있다). 이후, 여분의 회귀 헤드는 컨벌루션 층들(102)로부터의 출력 데이터(106)를 사용하여 관련성 레벨들을 결정하도록 트레이닝될 수 있다. 회귀 헤드(104)의 계산 복잡도는 한 세트의 컨벌루션 층들(102)과 비교하여 종종 낮으며, 따라서 뉴럴 네트워크(100)를 구동하는 하드웨어에 대한 추가 요구가 거의 없다.

[0027] 도 2는 뉴럴 네트워크(100)를 트레이닝하기 위해 배열된 디바이스(200)의 일 예를 도시한다. 트레이닝의 실시예들은 이제 도 2 및 도 4와 관련하여 설명될 것이다. 디바이스(200)는, 이하에서 컴퓨터(200)로 언급되는 처리능력들을 갖는 임의의 디바이스일 수 있다. 컴퓨터(200)는 먼저 복수의 디지털 트레이닝 이미지들(208)을 수신함으로써 트레이닝 데이터 세트(212)를 결정할 수 있다. 이후, 디지털 트레이닝 이미지들(208)은, 관련성 레벨로 디지털 트레이닝 이미지들(208) 각각의 픽셀 그룹들을 결정(S402)하고 자동적으로 라벨링하도록 구성된 제1 이미지 분석 알고리즘(204)에 공급될 수 있다. 제1 이미지 분석 알고리즘(204)은 일부 실시예들에 따라 디지털 트레이닝 이미지들의 공간 통계적 측정들에 초점을 맞출 수 있다. 이 경우, 각각의 디지털 트레이닝 이미지는 제1 이미지 분석 알고리즘(204)에 의해 개별적으로 처리될 수 있다. 통상적인 공간 통계 측정은 예지 검출, 컬러 분포, 얼굴 검출 및 공간 잡음 검출일 수 있다. 선택적으로, 또는 부가적으로, 제1 이미지 분석 알고리즘(204)은 디지털 트레이닝 이미지들의 시퀀스에서 객체들의 이동과 같은 디지털 트레이닝 이미지의 시간적 특징을 또한 고려할 수 있다. 이러한 이유로, 제1 이미지 분석 알고리즘은, 상기 복수의 디지털 트레이닝 이미지들의 이미지들의 시퀀스에 대해 시간 필터링을 적용함으로써 각각의 특정 디지털 트레이닝 이미지를 내의 픽셀들의 그룹에 대한 시간 통계적 측정치를 계산하도록 구성될 수 있고, 상기 이미지들의 시퀀스는 특정 디지털 트레이닝 이미지를 포함한다. 이 경우에, 제1 이미지 분석 알고리즘(204)은, 알고리즘의 하나의 실행에서, 즉, 특정 디지털 트레이닝 이미지에서 특정 픽셀들의 그룹에 대한 시간 통계적 측정을 계산할 때 복수의 디지털 트레이닝 이미지들을 고려할 필요가 있다. 시간 통계적 측정들의 예들은 모션 검출, 일시적 노이즈 검출, 이미지들 간의 광 조건들의 변화의 검출 등이다.

[0028] 공간 통계적 측정 및 시간 통계적 측정 모두가 특정 픽셀 그룹에 대해 계산되는 경우에, 제1 이미지 분석 알고리즘(204)은, 픽셀들의 그룹에 대한 시간 통계적 측정 및 공간 통계적 측정을 가중함으로써 그리고 상기 가중된 통계적 측정에 기초하여 상기 픽셀들의 그룹을 라벨링함으로써 가중된 통계적 측정을 계산하도록 구성될 수 있다. 적용된 가중치는, 0과 1 사이의 임의의 것(시간 통계적 측정 및 공간 통계적 측정이 정규화되는 경우)일 수 있고, (그렇지 않으면 다른 가중치 범위들이 적용됨) 그리고 제1 이미지 분석 알고리즘(204)의 초점 영역에 의존할 수 있다.

[0029] 예를 들어, 제1 이미지 분석 알고리즘(204)이 움직이는 인간들을 포함하는 이미지들의 부분들에 대해 비트 레이트 예산을 소비하도록 적용하는 경우, 알고리즘은 이미지들의 그와같은 부분들을 높은 관련성 레벨로 라벨링해야 한다. 제1 이미지 분석 알고리즘은, 이 실시예에서, 이미지의 픽셀 그룹이 움직이는 인간과 대응하는지를 결정하기 위해 대응하는 공간적 및 시간적 통계 측정들을 계산할 필요가 있다. 또 다른 예는, 제1 이미지 분석 알고리즘(204)이 길거리(street)를 전체적으로 상세히 나타내는 영역들을 보존하는 것에 집중하는 것(즉, 그러한 영역들에 비트 레이트 예산을 지출하는 것)으로 배치일 수 있고, 이 경우 공간 통계적 측정만이 계산될 필요가 있다.

[0030] 요약하면, 제1 이미지 분석 알고리즘(204)은 각 디지털 트레이닝 이미지(208)의 특정 픽셀들의 그룹을 관련성 레벨로 자동 라벨링하도록 구성된다. 제1 이미지 분석 알고리즘(204)만이 이 목적을 위해 사용되는 실시예들에 대해, 복수의 디지털 트레이닝 이미지들(208) 및 계산된 라벨들은 트레이닝 데이터 세트(212)를 형성할 것이다.

[0031] 일부 실시예들에 따르면, 트레이닝 데이터 세트(212)의 결정은 제2 이미지 분석 알고리즘(206)을 통해 제2 복수의 디지털 트레이닝 이미지들을 실행하는 것을 포함한다.

[0032] 제2 복수의 디지털 트레이닝 이미지들은 제1 복수의 디지털 트레이닝 이미지들(208)의 서브세트 일 수 있다.

- [0033] 대안으로, 제2 복수의 디지털 트레이닝 이미지들은 제1 복수의 디지털 트레이닝 이미지들(208)의 서브 세트가 아니다.
- [0034] 예를 들어, 제2 복수의 디지털 트레이닝 이미지들은, 뉴럴 네트워크에 대한 특정 범위의 애플리케이션, 예를 들어, 교통 상황들, 카지노, 소매점, 은행, 비행기 모니터링을 목표로 할 수 있다. 이러한 이유로, 또한 이러한 특정 상황들을 목표로 할 수 있는 제2 이미지 분석 알고리즘(206)을 사용하여 그와 같은 상황들을 나타내는 이미지들(210)을 분석하는 것이 유리할 수 있다. 즉, 일부 실시예들에 따르면, 제1 이미지 분석 알고리즘(204)은 모든 종류의 이미지 컨텐츠에 대해 잘 기능하는 더 일반적인 알고리즘일 수 있는 반면에, 제2 이미지 분석 알고리즘(206)은 특정 이미지 컨텐츠를 목표로 한다. 일부 실시예들에 따르면, 제1 이미지 분석 알고리즘(204)은 계산적으로 덜 복잡할 수 있고 따라서 매우 많은 이미지들(예를 들어, 10000 또는 1000000보다 많은 이미지들)상에서 실행될 수 있는 반면에, 제2 이미지 분석 알고리즘(206)은 계산상 더 복잡할 수 있다.
- [0035] 따라서, 컴퓨터(200)는, 제2 복수의 디지털 트레이닝 이미지들에 대해, 제2 복수의 디지털 트레이닝 이미지들 중 각 특정 디지털 트레이닝 이미지에서의 픽셀들의 그룹들에 대한 관련성 레벨을, 픽셀들의 그룹을 관련성 레벨로 자동 라벨링하도록 구성된 제2 이미지 분석 알고리즘을 사용하여 결정(S404)하도록 구성될 수 있고, 상기 제2 이미지 분석 알고리즘은 상기 제1 이미지 분석 알고리즘과 상이하다. 위에서 서술된 것처럼, 제1 이미지 분석 알고리즘은 모든 유형들의 입력 이미지들에 대해 동등하게 기능하는 범용 알고리즘일 수 있는 반면에, 제2 이미지 분석 알고리즘은 보다 프로파일에 기초한 분석(즉, 일정한 특정 컨텐츠를 갖는 이미지들 또는 특정 상황들을 나타내는 이미지들을 목표로 함)을 제공할 수 있다.
- [0036] 일부 실시예들에 따르면, 트레이닝 데이터 세트(212)는, 관련성 레벨을 갖는 제1 복수의 디지털 트레이닝 이미지를 중 적어도 하나의 디지털 트레이닝 이미지에서 픽셀들의 그룹(214)을 수동으로(사람(214)에 의해) 라벨링함으로써 또한 결정된다. 대안으로 또는 부가적으로, 트레이닝 데이터 세트(212)는, 관련성 레벨을 갖는 제2 복수의 디지털 트레이닝 이미지를 중 적어도 하나의 디지털 트레이닝 이미지에서 픽셀들의 그룹을 수동으로 라벨링함으로써 또한 결정된다. 이 실시예는, 제1 이미지 분석 알고리즘 및/또는 제2 이미지 분석 알고리즘(204, 206)이 관련성 레벨로 정확하게 라벨링할 수 없는 디지털 트레이닝 이미지들의 일부 특정 피쳐들쪽으로 상기 트레이닝 데이터 세트가 미세 조정될 필요가 있는 경우에 유리할 수 있다. 또한, 트레이닝 데이터 세트(212)는, 일부 실시예들에 따라, 관련성 레벨을 갖는(제1/제2 복수의 디지털 트레이닝 이미지들의 일부가 아닌) 적어도 하나의 추가 디지털 트레이닝 이미지에서 픽셀들의 그룹을 수동으로 라벨링함으로써 결정될 수 있고 그리고 상기 적어도 하나의 추가 디지털 트레이닝 이미지 및 대응하는 라벨들을 트레이닝 데이터 세트에 포함할 수 있다. 이 실시예는 도 2에 포함되지 않는다.
- [0037] 따라서, 트레이닝 데이터 세트(212)는, 제1 및/또는 제2 이미지 분석 알고리즘(204, 206)에 의해 분석된 복수의 디지털 트레이닝 이미지들과 함께 사람(214)에 의해 미세 조정될 수 있는 라벨들을 포함한다.
- [0038] 이후, 트레이닝 데이터 세트(212)는 뉴럴 네트워크(100)를 트레이닝(S408)시키기 위해 사용된다. 트레이닝 데이터 세트(212)를 사용하는 뉴럴 네트워크(100)의 트레이닝은 구현할 당업자에게 맡겨지고 그리고 사용되는 뉴럴 네트워크(100)의 구조에 따라 수행된다. 일반적으로, 뉴럴 네트워크는, 트레이닝 디지털 이미지를 내의 픽셀들의 그룹들에 대한 검증 자료(ground truth)로서 손실 함수 및 라벨들을 사용하여 내부 가중치들을 조정함으로써 각 입력 디지털 이미지에 대한 관련성 레벨들의 맵을 제공하도록 트레이닝된다. 손실 함수는, 예를 들어, L2-놈(norm)에 기초할 수 있으며, 이는 평균 제곱 오차의 최소화를 유도한다. 손실 함수는, 예를 들어, 가능한 관련성 레벨들의 수, 입력 데이터의 크기 등에 기초하여 정의될 수 있다. 손실 함수가 정의되면, 일반적으로, 가중치는, 예를 들어, 옵티마이저(optimizer)에 대한 확률적인 그래디언트 디센트와 함께 표준화된 역-전파 알고리즘(backpropagation algorithm)을 통해 업데이트된다. 통상의 기술자에게 알려진 바와 같이, 확률적인 그래디언트 디센트는, 트레이닝 동안 입력 이미지들에 기초하여 원하는 출력을 생성할 수 있는 가능한 가장 가까운 모델을 얻도록 뉴럴 네트워크에서 가중치들을 업데이트하는 방법을 계산하기 위한 가장 잘 알려진 방법이다.
- [0039] 제2 복수의 트레이닝 이미지들이 트레이닝을 위해 사용되며 그리고 제1 복수의 트레이닝 이미지들의 서브세트인 경우, 뉴럴 네트워크가 제1 복수의 디지털 트레이닝 이미지들로 트레이닝된 후에, 제2 복수의 디지털 트레이닝 이미지들 및 그것의 대응하는 라벨은 통상적으로 뉴럴 네트워크 트레이닝을 위해 사용됨을 알 수 있다.
- [0040] 예를 들어, 트레이닝 디지털 이미지들의 일부가 아닌 디지털 이미지들 상에서 제1 및/또는 제2 이미지 분석 알고리즘(204, 206)과 비교 가능한(또는 제1 및/또는 제2 이미지 분석 알고리즘보다 양호한) 결과들을 생성할 수 있을 때까지 수 만개의 이미지들이 트레이닝 동안 뉴럴 네트워크(100)에 입력되고 그리고 뉴럴 네트워크(100)의

내부 가중치들이 조정되며, 이는 훨씬 더 빠르게 그리고 계산이 덜 복잡한 방식으로 수행된다.

[0041] 뉴럴 네트워크에서의 설계로 인해, 이용 가능한 유리한 영역은, ASIC(Application Specific Integrated Circuit)과 같은 뉴럴 네트워크를 실행하도록 특별히 설계된 하드웨어를 구비한 디바이스뿐 아니라(예를 들어, 제1/제2 이미지 알고리즘들을 실행하기에 충분하지 않은) 낮은 이용가능한 계산상의 자원들을 가질 수 있는 디바이스에도 존재한다. 이러한 이유로, 디바이스(200)는, 예를 들어, 트레이닝된 뉴럴 네트워크를 무선 네트워크(302)를 통해 그와 같은 디바이스(304)에 제공하도록 구성될 수 있으며, 이에 따라 디바이스(304)는 트레이닝된 뉴럴 네트워크를 구비하도록 구성된다(S410). 이것은 도 3에서 도시된다. 트레이닝된 뉴럴 네트워크는, 상기 트레이닝된 내부 필터들 및 가중치들을 포함하는 텍스트 파일과 같은 임의의 적절한 방식으로 전달될 수 있음을 알아야 한다. 또한, 컴퓨터 메모리(예를 들어, USB) 또는 유선 접속과 같은, 트레이닝된 뉴럴 네트워크를 카메라에 전달하는 임의의 다른 수단이 사용될 수 있음을 알아야 한다. 그 후, 카메라는 상기 트레이닝된 뉴럴 네트워크를 사용하여 카메라(304)에 의해 캡처된 이미지들의 관련성 레벨을 결정한 다음 그에 따라 이미지를 인코딩하도록 구성된다. 이러한 이유로, 상기 카메라(304)는,

- 복수의 디지털 이미지들을 캡처하고,

[0043] - 상기 복수의 디지털 이미지들의 이미지 데이터를 상기 트레이닝된 신경 네트워크에 제공하고, 그리고 상기 복수의 디지털 이미지들의 각 특정 디지털 이미지에 대해, 상기 특정 디지털 이미지의 픽셀들의 그룹에 각각 대응하는 복수의 관련성 레벨들을 획득하도록 구성될 수 있다.


[0044] 일부 실시예에 따르면, 카메라는 획득된 복수의 관련성 레벨들에 따라 특정 디지털 이미지의 압축 정도를 제어함으로써 특정 디지털 이미지를 인코딩하도록 구성될 수 있다. 관련성 레벨과 압축 정도 사이의 맵핑은 선형일 수 있다. 즉, 상대적으로 높은 관련성 레벨은 상대적으로 낮은 관련성 레벨과 비교하여 대응하는 픽셀들의 그룹의 낮은 압축 정도에 항상 대응할 수 있다. 다른 실시예들에 따르면, 매핑은 단계적이다. 즉, 관련성 레벨들의 범위는 동일한 정도의 압축으로 매핑된다. 상기 맵핑은, 이미지의 많은 영역들 또는 이미지들의 시퀀스가 관련성 있는 것으로 고려되는 이미지 콘텐트를 포함하는 경우 초과되지 않도록, 이용가능한 대역폭을 고려할 필요가 있다.

[0045] 상기에서 서술한 것처럼, 일부 실시예들에 따르면, 카메라(304)는 뉴럴 네트워크를 구동하기 위한 전용 하드웨어를 포함할 수 있다. 다른 실시예들에서, 뉴럴 네트워크의 소프트웨어 구현은 사용될 관련성 레벨을 획득하기 위해 사용된다. 어떤 경우든, 상기에서 서술된 바와 같이 뉴럴 네트워크를 사용함으로써 달성된 결과는 관련성 레벨을 얻기 위해 제1/제2 이미지 분석 알고리즘들(204, 206)을 실제로 실행하는 것과 비교하여 실질적으로 개선될 수 있다.

도면


도면1

100




도면2

200



도면3



도면4

