

(19) 대한민국특허청(KR)
(12) 공개특허공보(A)

(11) 공개번호 10-2022-0014209

(43) 공개일자 2022년02월04일

(51) 국제특허분류(Int. Cl.)

G06T 7/246 (2017.01) G06N 20/00 (2019.01)

G06T 7/11 (2017.01) G06V 10/40 (2022.01)

(52) CPC특허분류

G06T 7/246 (2017.01)

G06N 20/00 (2021.08)

(21) 출원번호 10-2020-0094016

(22) 출원일자 2020년07월28일

심사청구일자 2020년07월28일

(71) 출원인

계명대학교 산학협력단

대구광역시 달서구 달구벌대로 1095, 계명대학교
산학협력관 201호(신당동)

(72) 발명자

고병철

대구광역시 수성구 범어천로 107 범어 STX KAN,
101동 1002호

이지미

경상북도 경산시 삼풍로 13-7 태왕드림하이츠,
110동 1205호

(74) 대리인

김진우

전체 청구항 수 : 총 16 항


(54) 발명의 명칭 삼 랜덤 포레스트를 이용한 다수 객체 추적 방법 및 장치

(57) 요약

본 발명은 삼 랜덤 포레스트를 이용한 다수 객체 추적 방법에 관한 것으로서, 보다 구체적으로는 다수 객체 추적 방법으로서, (a) 학습 데이터를 이용해, 랜덤 포레스트(Random Forest, RF) 분류기와 삼 구조를 결합한 삼 랜덤 포레스트(이하, SiameseRF)를 학습하는 단계; 및 (b) 상기 학습된 SiameseRF를 이용해 객체를 추적하는 단계를

(뒷면에 계속)

대표도 - 도3



포함하며, 상기 단계 (a)에서는, 기준(anchor), 양성(positive) 또는 음성(negative)으로 각각 레이블 된 이미지를 포함하는 학습 데이터를 이용해, 트리를 구성하는 규칙을 공유하는 두 RF로 구성되는 상기 SiameseRF를 학습하되, 상기 학습 데이터로부터 {기준, 양성}의 제1쌍 및 {기준, 음성}의 제2쌍을 상기 두 RF에 각각 입력하여, 상기 제1쌍과의 유사성이 증가하는 방향과 상기 제2쌍과의 차이가 증가하는 방향으로 상기 SiameseRF를 학습하는 것을 그 구성상의 특징으로 한다.

또한, 본 발명은 삼 랜덤 포레스트를 이용한 다수 객체 추적 장치에 관한 것으로서, 보다 구체적으로는 다수 객체 추적 장치로서, 학습 데이터를 이용해, 랜덤 포레스트(Random Forest, RF) 분류기와 삼 구조를 결합한 삼 랜덤 포레스트(이하, SiameseRF)를 학습하는 학습 모듈; 및 상기 학습된 SiameseRF를 이용해 객체를 추적하는 객체 추적 모듈을 포함하며, 상기 학습 모듈은, 기준(anchor), 양성(positive) 또는 음성(negative)으로 각각 레이블 된 이미지를 포함하는 학습 데이터를 이용해, 트리를 구성하는 규칙을 공유하는 두 RF로 구성되는 상기 SiameseRF를 학습하되, 상기 학습 데이터로부터 {기준, 양성}의 제1쌍 및 {기준, 음성}의 제2쌍을 상기 두 RF에 각각 입력하여, 상기 제1쌍과의 유사성이 증가하는 방향과 상기 제2쌍과의 차이가 증가하는 방향으로 상기 SiameseRF를 학습하는 것을 그 구성상의 특징으로 한다.

본 발명에서 제안하고 있는 삼 랜덤 포레스트를 이용한 다수 객체 추적 방법 및 장치에 따르면, 랜덤 포레스트 분류기와 삼 구조를 결합하여 삼 랜덤 포레스트 구조를 제안하고, 학습 데이터로부터 {기준, 양성}의 제1쌍 및 {기준, 음성}의 제2쌍을 입력하여, 제1쌍과의 유사성이 증가하는 방향과 제2쌍과의 차이가 증가하는 방향으로 삼 랜덤 포레스트를 시킴으로써, 최종적으로 고속으로 학습 및 분류를 할 수 있고, 카메라 움직임이나 복잡한 보행자 형태에도 불구하고 강력한 추적 성능을 가질 수 있다.

(52) CPC특허분류

G06T 7/11 (2017.01)

G06V 10/40 (2022.01)

G06T 2207/20081 (2013.01)

G06T 2207/20084 (2013.01)

이 발명을 지원한 국가연구개발사업

과제고유번호	1345313705
과제번호	2019R1I1A3A01042506
부처명	교육부
과제관리(전문)기관명	한국연구재단
연구사업명	지역대학우수과학자지원사업(1년~5년)
연구과제명	역전과가 필요 없는 심층 랜덤 네트워크 모델 개발과 응용 연구
기 여 율	1/1
과제수행기관명	계명대학교
연구기간	2020.03.01 ~ 2021.02.28

명세서

청구범위

청구항 1

다수 객체 추적 방법으로서,

(a) 학습 데이터를 이용해, 랜덤 포레스트(Random Forest, RF) 분류기와 삼 구조를 결합한 삼 랜덤 포레스트(이하, SiameseRF)를 학습하는 단계; 및

(b) 상기 학습된 SiameseRF를 이용해 객체를 추적하는 단계를 포함하며,

상기 단계 (a)에서는,

기준(anchor), 양성(positive) 또는 음성(negative)으로 각각 레이블 된 이미지를 포함하는 학습 데이터를 이용해, 트리를 구성하는 규칙을 공유하는 두 RF로 구성되는 상기 SiameseRF를 학습하되, 상기 학습 데이터로부터 {기준, 양성}의 제1쌍 및 {기준, 음성}의 제2쌍을 상기 두 RF에 각각 입력하여, 상기 제1쌍과의 유사성이 증가하는 방향과 상기 제2쌍과의 차이가 증가하는 방향으로 상기 SiameseRF를 학습하는 것을 특징으로 하는, 삼 랜덤 포레스트를 이용한 다수 객체 추적 방법.

청구항 2

제1항에 있어서, 상기 두 RF는,

상기 제1쌍의 거리 벡터(이하, AP 거리 벡터) 및 상기 제2쌍의 거리 벡터(이하, AN 거리 벡터)를 각각 입력 벡터로 하는 것을 특징으로 하는, 삼 랜덤 포레스트를 이용한 다수 객체 추적 방법.

청구항 3

제2항에 있어서, 상기 AP 거리 벡터 및 AN 거리 벡터는,

신경망 기반의 객체 검출 장치에서 검출된 객체에 대한 특징 맵으로부터 생성된 압축 외관 특징(condensed appearance feature, CAF)의 차이인 것을 특징으로 하는, 삼 랜덤 포레스트를 이용한 다수 객체 추적 방법.

청구항 4

제1항에 있어서, 상기 단계 (a)는,

(1) 상기 학습 데이터로부터 특징 벡터를 추출하는 단계; 및

(2) 상기 추출된 특징 벡터를 이용해 상기 SiameseRF를 학습하는 단계를 포함하는 것을 특징으로 하는, 삼 랜덤 포레스트를 이용한 다수 객체 추적 방법.

청구항 5

제4항에 있어서, 상기 단계 (1)에서는,

(1-1) 객체 검출을 위한 신경망의 첫 번째 레이어 및 두 번째 레이어로부터 부분 특징 맵을 추출하는 단계;

(1-2) 상기 추출한 부분 특징 맵에 각각 글로벌 평균 풀링(global averaging pooling, GAP)을 적용해, 2개의 압축 특징을 생성하는 단계; 및

(1-3) 상기 생성된 2개의 압축 특징을 연결해 최종 압축 외관 특징(condensed appearance feature, CAF)을 생

성하는 단계를 포함하는 것을 특징으로 하는, 삼 랜덤 포레스트를 이용한 다수 객체 추적 방법.

청구항 6

제4항에 있어서, 상기 단계 (2)에서는,

K겹 교차 검증(K-fold cross validation)을 이용해 상기 Siamese RF를 학습하는 것을 특징으로 하는, 삼 랜덤 포레스트를 이용한 다수 객체 추적 방법.

청구항 7

제6항에 있어서, 상기 단계 (2)는,

(2-1) 상기 학습 데이터에서 선택된 K-1 폴드는 학습 세트로, 나머지 폴드는 검증 세트로 하는 단계;

(2-2) CAF를 이용해 상기 학습 세트에 포함된 샘플의 상기 제1쌍의 거리 벡터(이하, AP 거리 벡터) 및 상기 제2 쌍의 거리 벡터(이하, AN 거리 벡터)를 추정하는 단계;

(2-3) 규칙을 공유하는 상기 두 RF에 상기 학습 세트의 샘플 쌍을 입력하는 단계;

(2-4) 상기 입력된 샘플 쌍에 대해 상기 추정된 AP 거리 벡터 및 AN 거리 벡터를 이용해 상기 두 RF를 학습하는 단계;

(2-5) 상기 K-1 폴드 학습 후, 상기 검증 세트의 모든 샘플 쌍에 대해 추정된 AP 거리 벡터 및 AN 거리 벡터를 상기 단계 (2-4)에서 학습된 RF에 적용하여 검증하는 단계; 및

(2-6) 학습된 RF 구조 및 총 손실(total loss)을 저장하는 단계를 포함하며,

모든 K개의 폴드가 검증 세트로 사용될 때까지, 상기 단계 (2-1) 내지 단계 (2-6)을 반복하여 학습하는 것을 특징으로 하는, 삼 랜덤 포레스트를 이용한 다수 객체 추적 방법.

청구항 8

제7항에 있어서, 상기 단계 (2-6) 이후에는,

(2-7) 모든 K개의 폴드에 대한 학습이 완료되면, 총 손실이 가장 작은 RF를 최종 SiameseRF로 결정하는 단계를 더 포함하는 것을 특징으로 하는, 삼 랜덤 포레스트를 이용한 다수 객체 추적 방법.

청구항 9

제7항에 있어서, 상기 단계 (2)에서는,

K겹 교차 검증의 수렴 여부에 따라 공유 RF로 구성된 규칙 업데이트가 수행되는 것을 특징으로 하는, 삼 랜덤 포레스트를 이용한 다수 객체 추적 방법.

청구항 10

제1항에 있어서, 상기 단계 (b)에서는,

객체가 탐지되면, 상기 학습된 SiameseRF를 이용해 상기 탐지된 객체와 추적 객체 사이의 연관성을 측정해 객체를 추적하는 것을 특징으로 하는, 삼 랜덤 포레스트를 이용한 다수 객체 추적 방법.

청구항 11

제10항에 있어서, 상기 단계 (b)에서는,

상기 탐지된 객체와 상기 추적 객체의 압축 외관 특징을 상기 학습된 SiameseRF에 입력하고, 상기 SiameseRF의 출력인 두 객체의 유사성 확률(similarity probability)을 연관성 측정을 위한 외관 점수(appearance score)로 하는 것을 특징으로 하는, 삼 랜덤 포레스트를 이용한 다수 객체 추적 방법.

청구항 12

제11항에 있어서, 상기 단계 (b)에서는,

상기 SiameseRF의 역 유사성 확률값, 두 객체 중첩비(A_ratio) 및 두 객체 사이의 L1-중심 거리의 가중치 합으로 산출되는 연관 매칭의 비용 함수를 이용해, 상기 탐지된 객체와 추적 객체가 일치하는지 판단하는 것을 특징으로 하는, 삼 랜덤 포레스트를 이용한 다수 객체 추적 방법.

청구항 13

제12항에 있어서, 상기 단계 (b)에서는,

상기 탐지된 객체와 추적 객체가 일치하면 상기 탐지된 객체를 상기 추적 객체의 상태에 업데이트하고, 미리 정해진 개수의 프레임 동안 상기 추적 객체와 일치하는 탐지된 객체가 없으면 상기 추적 객체를 삭제하며, 상기 탐지된 객체가 상기 추적 객체와 일치하지 않으면 상기 탐지된 객체를 잠재적 추적 객체로 할당하고 미리 정해진 개수의 프레임에서 상기 잠재적 추적 객체와 탐지된 객체가 일치하면 상기 잠재적 추적 객체를 새로운 추적 객체로 할당하는 것을 특징으로 하는, 삼 랜덤 포레스트를 이용한 다수 객체 추적 방법.

청구항 14

다수 객체 추적 장치로서,

학습 데이터를 이용해, 랜덤 포레스트(Random Forest, RF) 분류기와 삼 구조를 결합한 삼 랜덤 포레스트(이하, SiameseRF)를 학습하는 학습 모듈(100); 및

상기 학습된 SiameseRF를 이용해 객체를 추적하는 객체 추적 모듈(200)을 포함하며,

상기 학습 모듈(100)은,

기준(anchor), 양성(positive) 또는 음성(negative)으로 각각 레이블 된 이미지를 포함하는 학습 데이터를 이용해, 트리를 구성하는 규칙을 공유하는 두 RF로 구성되는 상기 SiameseRF를 학습하되, 상기 학습 데이터로부터 {기준, 양성}의 제1쌍 및 {기준, 음성}의 제2쌍을 상기 두 RF에 각각 입력하여, 상기 제1쌍과의 유사성이 증가하는 방향과 상기 제2쌍과의 차이가 증가하는 방향으로 상기 SiameseRF를 학습하는 것을 특징으로 하는, 삼 랜덤 포레스트를 이용한 다수 객체 추적 장치.

청구항 15

제14항에 있어서, 상기 두 RF는,

상기 제1쌍의 거리 벡터(이하, AP 거리 벡터) 및 상기 제2쌍의 거리 벡터(이하, AN 거리 벡터)를 각각 입력 벡터로 하는 것을 특징으로 하는, 삼 랜덤 포레스트를 이용한 다수 객체 추적 장치.

청구항 16

제15항에 있어서, 상기 AP 거리 벡터 및 AN 거리 벡터는,

신경망 기반의 객체 검출 장치에서 검출된 객체에 대한 특징 맵으로부터 생성된 압축 외관 특징(condensed

appearance feature, CAF)의 차이인 것을 특징으로 하는, 삼 랜덤 포레스트를 이용한 다수 객체 추적 장치.

발명의 설명

기술 분야

[0001] 본 발명은 다수 객체 추적 방법 및 장치에 관한 것으로서, 보다 구체적으로는 삼 랜덤 포레스트를 이용한 다수 객체 추적 방법 및 장치에 관한 것이다.

배경 기술

[0002] 다수 객체 추적(Multiple Object Tracking, MOT)은 비디오 감시, 자율 주행, 인간-컴퓨터 인터페이스(HCI) 및 증강 현실(AR)과 같은 다양한 추적 기술에 필수적이다. 최근에는 많은 온라인 및 오프라인 MOT에 기존 추적 기술 대신 DNN(deep neural network)이 적용되고 있다.

[0004] 그러나 오프라인 추적은 실시간 경로 모니터링을 위해 모든 프레임을 고려해야 하므로 실시간 객체 모니터링 또는 기타 응용 프로그램에는 적합하지 않다. 또한, 온라인 MOT의 경우 Kalman 필터 또는 입자 필터 기반 방법이 주로 사용됐으나, 최근 DNN 기반의 MOT 시스템이 주목할만한 결과를 얻고 있다.

[0006] 특히, DNN, Deep Association Matching 및 4중 컨볼루션 신경망(quadruplet convolutional neural network)에서 추출된 특징을 사용하는 장기 외관 모델(long-term appearance models)은 우수한 추적 성능을 나타낸다. 그러나 네트워크 구조가 복잡하고 여러 프레임의 객체 추적 경로를 분석해야 하므로, 이를 온라인 추적에 적용하기에는 어려움이 있다.

[0008] 일반적으로 오프라인 및 온라인 MOT는 모두 TBD(Tracking-by-Detection) 패러다임을 사용한다. 이는 검출 성능에 따라 추적 성능이 다소 의존적이다. 그러나, 검출 방법의 우수성과 관계없이, 객체 또는 카메라 흔들림으로 인해 물체가 누락되거나 부정확한 물체가 검출되면 추적 성능이 현저하게 저하될 수 있다. 따라서, MOT 검출의 부정확성을 보상하기 위해 다양한 데이터 연관 방법(data association method)이 제안되어 왔다.

[0010] 특히, MOT의 실시간 추적은 데이터 연결의 효율성과 밀접한 관련이 있다. 삼 컨볼루션 신경망(삼 CNN) 기반 객체 추적은 실시간 추적 있어 상당한 관심을 받아 왔다. 삼 CNN은 같은 네트워크를 탐지 및 추적 객체에 적용하고 출력 특징값의 차이를 기반으로 유사성을 계산한다. 따라서 삼 CNN은 별도의 네트워크 구조를 유지할 필요가 없으며 빠른 추적의 장점이 있다.

[0012] 이와 같이, 삼 구조는 객체 간에 우수한 매칭 성능을 갖지만, 유사성 매칭을 위한 공유 네트워크(shared network)가 복잡한 구조를 갖기 때문에, 여전히 많은 초매개변수(hyper parameter)를 포함하고 느린 추적 속도를 가진다. 따라서 삼 CNN 기반 MOT 방법은 실제 환경에서 실시간 추적 또는 저가형 시스템에서의 실시간 추적에는 적합하지 않은 한계가 있다.

[0014] 한편, 본 발명과 관련된 선행기술로서, 공개특허공보 제10-2020-0040665호(발명의 명칭: 컨볼루션 신경망을 이용하여 POI 변화를 검출하기 위한 시스템 및 방법, 공개일자: 2020년 04월 20일) 등이 개시된 바 있다.

발명의 내용

해결하려는 과제

[0015] 본 발명은 기존에 제안된 방법들의 상기와 같은 문제점들을 해결하기 위해 제안된 것으로서, 랜덤 포레스트 분류기와 삼 구조를 결합하여 삼 랜덤 포레스트 구조를 제안하고, 학습 데이터로부터 {기준, 양성}의 제1쌍 및 {기준, 음성}의 제2쌍을 입력하여, 제1쌍과의 유사성이 증가하는 방향과 제2쌍과의 차이가 증가하는 방향으로

삼 랜덤 포레스트를 학습시킴으로써, 최종적으로 고속으로 학습 및 분류를 할 수 있고, 카메라 움직임이나 복잡한 보행자 형태에도 불구하고 강력한 추적 성능을 가질 수 있는, 삼 랜덤 포레스트를 이용한 다수 객체 추적 방법 및 장치를 제공하는 것을 그 목적으로 한다.

과제의 해결 수단

- [0016] 상기한 목적을 달성하기 위한 본 발명의 특징에 따른 삼 랜덤 포레스트를 이용한 다수 객체 추적 방법은,
- [0017] 다수 객체 추적 방법으로서,
- [0018] (a) 학습 데이터를 이용해, 랜덤 포레스트(Random Forest, RF) 분류기와 삼 구조를 결합한 삼 랜덤 포레스트(이하, SiameseRF)를 학습하는 단계; 및
- [0019] (b) 상기 학습된 SiameseRF를 이용해 객체를 추적하는 단계를 포함하며,
- [0020] 상기 단계 (a)에서는,
- [0021] 기준(anchor), 양성(positive) 또는 음성(negative)으로 각각 레이블 된 이미지를 포함하는 학습 데이터를 이용해, 트리를 구성하는 규칙을 공유하는 두 RF로 구성되는 상기 SiameseRF를 학습하되, 상기 학습 데이터로부터 {기준, 양성}의 제1쌍 및 {기준, 음성}의 제2쌍을 상기 두 RF에 각각 입력하여, 상기 제1쌍과의 유사성이 증가하는 방향과 상기 제2쌍과의 차이가 증가하는 방향으로 상기 SiameseRF를 학습하는 것을 그 구성상의 특징으로 한다.
- [0023] 바람직하게는, 상기 두 RF는,
- [0024] 상기 제1쌍의 거리 벡터(이하, AP 거리 벡터) 및 상기 제2쌍의 거리 벡터(이하, AN 거리 벡터)를 각각 입력 벡터로 할 수 있다.
- [0026] 더욱 바람직하게는, 상기 AP 거리 벡터 및 AN 거리 벡터는,
- [0027] 신경망 기반의 객체 검출 장치에서 검출된 객체에 대한 특징 맵으로부터 생성된 압축 외관 특징(condensed appearance feature, CAF)의 차이일 수 있다.
- [0029] 바람직하게는, 상기 단계 (a)는,
- [0030] (1) 상기 학습 데이터로부터 특징 벡터를 추출하는 단계; 및
- [0031] (2) 상기 추출된 특징 벡터를 이용해 상기 SiameseRF를 학습하는 단계를 포함할 수 있다.
- [0033] 더욱 바람직하게는 상기 단계 (1)에서는,
- [0034] (1-1) 객체 검출을 위한 신경망의 첫 번째 레이어 및 두 번째 레이어로부터 부분 특징 맵을 추출하는 단계;
- [0035] (1-2) 상기 추출한 부분 특징 맵에 각각 글로벌 평균 풀링(global averaging pooling, GAP)을 적용해, 2개의 압축 특징을 생성하는 단계; 및
- [0036] (1-3) 상기 생성된 2개의 압축 특징을 연결해 최종 압축 외관 특징(condensed appearance feature, CAF)을 생성하는 단계를 포함할 수 있다.
- [0038] 더욱 바람직하게는, 상기 단계 (2)에서는,
- [0039] K겹 교차 검증(K-fold cross validation)을 이용해 상기 Siamese RF를 학습할 수 있다.
- [0041] 더더욱 바람직하게는, 상기 단계 (2)는,

- [0042] (2-1) 상기 학습 데이터에서 선택된 K-1 폴드는 학습 세트로, 나머지 폴드는 검증 세트로 하는 단계;
- [0043] (2-2) CAF를 이용해 상기 학습 세트에 포함된 샘플의 상기 제1쌍의 거리 벡터(이하, AP 거리 벡터) 및 상기 제2쌍의 거리 벡터(이하, AN 거리 벡터)를 추정하는 단계;
- [0044] (2-3) 규칙을 공유하는 상기 두 RF에 상기 학습 세트의 샘플 쌍을 입력하는 단계;
- [0045] (2-4) 상기 입력된 샘플 쌍에 대해 상기 추정된 AP 거리 벡터 및 AN 거리 벡터를 이용해 상기 두 RF를 학습하는 단계;
- [0046] (2-5) 상기 K-1 폴드 학습 후, 상기 검증 세트의 모든 샘플 쌍에 대해 추정된 AP 거리 벡터 및 AN 거리 벡터를 상기 단계 (2-4)에서 학습된 RF에 적용하여 검증하는 단계; 및
- [0047] (2-6) 학습된 RF 구조 및 총 손실(total loss)을 저장하는 단계를 포함하며,
- [0048] 모든 K개의 폴드가 검증 세트로 사용될 때까지, 상기 단계 (2-1) 내지 단계 (2-6)을 반복하여 학습할 수 있다.
- [0050] 더더더욱 바람직하게는, 상기 단계 (2-6) 이후에는,
- [0051] (2-7) 모든 K개의 폴드에 대한 학습이 완료되면, 총 손실이 가장 작은 RF를 최종 SiameseRF로 결정하는 단계를 더 포함할 수 있다.
- [0053] 더더더욱 바람직하게는, 상기 단계 (2)에서는,
- [0054] K겹 교차 검증의 수렴 여부에 따라 공유 RF로 구성된 규칙 업데이트가 수행될 수 있다.
- [0056] 바람직하게는, 상기 단계 (b)에서는,
- [0057] 객체가 탐지되면, 상기 학습된 SiameseRF를 이용해 상기 탐지된 객체와 추적 객체 사이의 연관성을 측정해 객체를 추적할 수 있다.
- [0059] 더욱 바람직하게는, 상기 단계 (b)에서는,
- [0060] 상기 탐지된 객체와 상기 추적 객체의 압축 외관 특징을 상기 학습된 SiameseRF에 입력하고, 상기 SiameseRF의 출력인 두 객체의 유사성 확률(similarity probability)을 연관성 측정을 위한 외관 점수(appearance score)로 할 수 있다.
- [0062] 더더욱 바람직하게는, 상기 단계 (b)에서는,
- [0063] 상기 SiameseRF의 역 유사성 확률값, 두 객체 중형비(A_ratio) 및 두 객체 사이의 L1-중심 거리의 가중치 합으로 산출되는 연관 매칭의 비용 함수를 이용해, 상기 탐지된 객체와 추적 객체가 일치하는지 판단할 수 있다.
- [0065] 더더더욱 바람직하게는, 상기 단계 (b)에서는,
- [0066] 상기 탐지된 객체와 추적 객체가 일치하면 상기 탐지된 객체를 상기 추적 객체의 상태에 업데이트하고, 미리 정해진 개수의 프레임 동안 상기 추적 객체와 일치하는 탐지된 객체가 없으면 상기 추적 객체를 삭제하며, 상기 탐지된 객체가 상기 추적 객체와 일치하지 않으면 상기 탐지된 객체를 잠재적 추적 객체로 할당하고 미리 정해진 개수의 프레임에서 상기 잠재적 추적 객체와 탐지된 객체가 일치하면 상기 잠재적 추적 객체를 새로운 추적 객체로 할당할 수 있다.
- [0068] 상기한 목적을 달성하기 위한 본 발명의 특징에 따른 삼 랜덤 포레스트를 이용한 다수 객체 추적 장치는,

- [0069] 다수 객체 추적 장치로서,
- [0070] 학습 데이터를 이용해, 랜덤 포레스트(Random Forest, RF) 분류기와 삼 구조를 결합한 삼 랜덤 포레스트(이하, SiameseRF)를 학습하는 학습 모듈; 및
- [0071] 상기 학습된 SiameseRF를 이용해 객체를 추적하는 객체 추적 모듈을 포함하며,
- [0072] 상기 학습 모듈은,
- [0073] 기준(anchor), 양성(positive) 또는 음성(negative)으로 각각 레이블 된 이미지를 포함하는 학습 데이터를 이용해, 트리를 구성하는 규칙을 공유하는 두 RF로 구성되는 상기 SiameseRF를 학습하되, 상기 학습 데이터로부터 {기준, 양성}의 제1쌍 및 {기준, 음성}의 제2쌍을 상기 두 RF에 각각 입력하여, 상기 제1쌍과의 유사성이 증가하는 방향과 상기 제2쌍과의 차이가 증가하는 방향으로 상기 SiameseRF를 학습하는 것을 그 구성상의 특징으로 한다.
- [0075] 바람직하게는, 상기 두 RF는,
- [0076] 상기 제1쌍의 거리 벡터(이하, AP 거리 벡터) 및 상기 제2쌍의 거리 벡터(이하, AN 거리 벡터)를 각각 입력 벡터로 할 수 있다.
- [0078] 더욱 바람직하게는, 상기 AP 거리 벡터 및 AN 거리 벡터는,
- [0079] 신경망 기반의 객체 검출 장치에서 검출된 객체에 대한 특징 맵으로부터 생성된 압축 외관 특징(condensed appearance feature, CAF)의 차이일 수 있다.

발명의 효과

- [0080] 본 발명에서 제안하고 있는 삼 랜덤 포레스트를 이용한 다수 객체 추적 방법 및 장치에 따르면, 랜덤 포레스트 분류기와 삼 구조를 결합하여 삼 랜덤 포레스트 구조를 제안하고, 학습 데이터로부터 {기준, 양성}의 제1쌍 및 {기준, 음성}의 제2쌍을 입력하여, 제1쌍과의 유사성이 증가하는 방향과 제2쌍과의 차이가 증가하는 방향으로 삼 랜덤 포레스트를 시킴으로써, 최종적으로 고속으로 학습 및 분류를 할 수 있고, 카메라 움직임이나 복잡한 보행자 형태에도 불구하고 강력한 추적 성능을 가질 수 있다.

도면의 간단한 설명

- [0081] 도 1은 본 발명의 일실시예에 따른 삼 랜덤 포레스트를 이용한 다수 객체 추적 장치의 구성을 도시한 도면.
- 도 2는 본 발명의 일실시예에 따른 삼 랜덤 포레스트를 이용한 다수 객체 추적 방법의 흐름을 도시한 도면.
- 도 3은 본 발명의 일실시예에 따른 삼 랜덤 포레스트를 이용한 다수 객체 추적 방법 및 장치에서, SiameseRF의 학습 과정을 도시한 도면.
- 도 4는 본 발명의 일실시예에 따른 삼 랜덤 포레스트를 이용한 다수 객체 추적 방법에서, 단계 S100의 세부적인 흐름을 도시한 도면.
- 도 5는 본 발명의 일실시예에 따른 삼 랜덤 포레스트를 이용한 다수 객체 추적 방법에서, 단계 S110의 세부적인 흐름을 도시한 도면.
- 도 6은 본 발명의 일실시예에 따른 삼 랜덤 포레스트를 이용한 다수 객체 추적 방법에서, 단계 S120의 세부적인 흐름을 도시한 도면.
- 도 7은 본 발명의 일실시예에 따른 삼 랜덤 포레스트를 이용한 다수 객체 추적 방법 및 장치의 성능을 검증하기 위한 실험 결과를 도시한 도면.
- 도 8 내지 도 10은 본 발명의 일실시예에 따른 삼 랜덤 포레스트를 이용한 다수 객체 추적 방법 및 장치가 적용된 시연 영상의 일부를 도시한 도면.

발명을 실시하기 위한 구체적인 내용

- [0082] 이하, 첨부된 도면을 참조하여 본 발명이 속하는 기술분야에서 통상의 지식을 가진 자가 본 발명을 용이하게 실시할 수 있도록 바람직한 실시예를 상세히 설명한다. 다만, 본 발명의 바람직한 실시예를 상세하게 설명함에 있어, 관련된 공지 기능 또는 구성에 대한 구체적인 설명이 본 발명의 요지를 불필요하게 흐릴 수 있다고 판단되는 경우에는 그 상세한 설명을 생략한다. 또한, 유사한 기능 및 작용을 하는 부분에 대해서는 도면 전체에 걸쳐 동일한 부호를 사용한다.
- [0084] 덧붙여, 명세서 전체에서, 어떤 부분이 다른 부분과 ‘연결’되어 있다고 할 때, 이는 ‘직접적으로 연결’되어 있는 경우뿐만 아니라, 그 중간에 다른 소자를 사이에 두고 ‘간접적으로 연결’되어 있는 경우도 포함한다. 또한, 어떤 구성요소를 ‘포함’한다는 것은, 특별히 반대되는 기재가 없는 한 다른 구성요소를 제외하는 것이 아니라 다른 구성요소를 더 포함할 수 있다는 것을 의미한다.
- [0086] 도 1은 본 발명의 일실시예에 따른 삼 랜덤 포레스트를 이용한 다수 객체 추적 장치의 구성을 도시한 도면이다. 도 1에 도시된 바와 같이, 본 발명의 일실시예에 따른 삼 랜덤 포레스트를 이용한 다수 객체 추적 장치는, 학습 데이터를 이용해, 랜덤 포레스트(Random Forest, RF) 분류기와 삼 구조를 결합한 삼 랜덤 포레스트(이하, SiameseRF)를 학습하는 학습 모듈(100) 및 학습된 SiameseRF를 이용해 객체를 추적하는 객체 추적 모듈(200)을 포함하여 구성될 수 있다.
- [0088] 즉, 본 발명에서는, 정확도 높은 랜덤 포레스트와 빠르게 학습 및 분류를 할 수 있는 삼 구조를 결합한 삼 랜덤 포레스트 프레임워크를 제안한다.
- [0090] 한편, 본 발명은 삼 랜덤 포레스트를 이용한 다수 객체 추적 방법에 관한 것으로서, 본 발명의 특징에 따른 삼 랜덤 포레스트를 이용한 다수 객체 추적 방법은, 메모리 및 프로세서를 포함한 하드웨어에서 기록되는 소프트웨어로 구성될 수 있다. 예를 들어, 본 발명의 삼 랜덤 포레스트를 이용한 다수 객체 추적 방법은, 개인용 컴퓨터, 노트북 컴퓨터, 서버 컴퓨터, PDA, 스마트폰, 태블릿 PC, 자율주행차량 등에 저장 및 구현될 수 있다. 이하에서는 설명의 편의를 위해, 각 단계를 수행하는 주체는 생략될 수 있다.
- [0092] 도 2는 본 발명의 일실시예에 따른 삼 랜덤 포레스트를 이용한 다수 객체 추적 방법의 흐름을 도시한 도면이다. 도 2에 도시된 바와 같이, 본 발명의 일실시예에 따른 삼 랜덤 포레스트를 이용한 다수 객체 추적 방법은, 학습 데이터를 이용해 RF 분류기와 삼 구조를 결합한 SiameseRF를 학습하는 단계(S100) 및 학습된 SiameseRF를 이용해 객체를 추적하는 단계(S200)를 포함하여 구현될 수 있다.
- [0094] 단계 S100에서는, 학습 모듈(100)이 학습 데이터를 이용해, 랜덤 포레스트(Random Forest, RF) 분류기와 삼 구조를 결합한 삼 랜덤 포레스트(이하, SiameseRF)를 학습할 수 있다.
- [0096] 도 3은 본 발명의 일실시예에 따른 삼 랜덤 포레스트를 이용한 다수 객체 추적 방법 및 장치에서, SiameseRF의 학습 과정을 도시한 도면이다. 도 3에 도시된 바와 같이, 본 발명의 일실시예에 따른 삼 랜덤 포레스트를 이용한 다수 객체 추적 방법의 단계 S100에서는, 기준(anchor), 양성(positive) 또는 음성(negative)으로 각각 레이블된 이미지를 포함하는 학습 데이터를 이용해, 트리를 구성하는 규칙을 공유하는 두 RF로 구성되는 SiameseRF를 학습하되, 학습 데이터로부터 {기준, 양성}의 제1쌍 및 {기준, 음성}의 제2쌍을 두 RF에 각각 입력하여, 제1쌍과의 유사성이 증가하는 방향과 제2쌍과의 차이가 증가하는 방향으로 SiameseRF를 학습할 수 있다.
- [0098] 보다 구체적으로, 두 RF는, 제1쌍의 거리 벡터(이하, AP 거리 벡터) 및 제2쌍의 거리 벡터(이하, AN 거리 벡터)를 각각 입력 벡터로 할 수 있다. 또한, AP 거리 벡터 및 AN 거리 벡터는, 신경망 기반의 객체 검출 장치에서 검출된 객체에 대한 특징 맵으로부터 생성된 압축 외관 특징(condensed appearance feature, CAF)의 차이일

수 있다.

- [0100] 도 4는 본 발명의 일실시예에 따른 삼 랜덤 포레스트를 이용한 다수 객체 추적 방법에서, 단계 S100의 세부적인 흐름을 도시한 도면이다. 도 4에 도시된 바와 같이, 본 발명의 일실시예에 따른 삼 랜덤 포레스트를 이용한 다수 객체 추적 방법의 단계 S100은, 학습 데이터로부터 특징 벡터를 추출하는 단계(S110) 및 추출된 특징 벡터를 이용해 SiameseRF를 학습하는 단계(S120)를 포함하여 구현될 수 있다.
- [0102] 단계 S110에서는, 학습 데이터로부터 특징 벡터를 추출할 수 있다. 객체가 감지되면 기존 추적 객체와의 유사성을 측정하기 위해 SiameseRF에 감지된 객체를 입력해야 한다. 유사성 측정을 위한 가장 기본적인 중요한 단계는 단계 S110의 특징 추출 단계이다. RF는 표 형식 데이터에 대해 매우 우수한 성능을 보이지만, 이미지 및 비디오와 같은 조건 없는 데이터를 적용할 때 성능이 저하되는 단점이 있다. 따라서 SiameseRF의 전처리 과정으로, 객체를 효과적으로 구별할 수 있는 최적의 특징 추출 단계를 적용해야 한다.
- [0104] 도 5는 본 발명의 일실시예에 따른 삼 랜덤 포레스트를 이용한 다수 객체 추적 방법에서, 단계 S110의 세부적인 흐름을 도시한 도면이다. 도 5에 도시된 바와 같이, 본 발명의 일실시예에 따른 삼 랜덤 포레스트를 이용한 다수 객체 추적 방법의 단계 S110은, 객체 검출을 위한 신경망의 첫 번째 레이어 및 두 번째 레이어로부터 부분 특징 맵을 추출하는 단계(S111), 추출한 부분 특징 맵에 각각 GAP를 적용해 2개의 압축 특징을 생성하는 단계(S112) 및 2개의 압축 특징을 연결해 CAF를 생성하는 단계(S113)를 포함하여 구현될 수 있다.
- [0106] 단계 S111에서는, 객체 검출을 위한 신경망의 첫 번째 레이어 및 두 번째 레이어로부터 부분 특징 맵을 추출할 수 있다. 본 발명에서는, 특징 추출을 위한 계산 시간을 줄이기 위해 YOLOv3의 근간 네트워크인 darknet53의 서로 다른 레이어로부터 얻은 특징 맵들을 이용할 수 있다. 보다 구체적으로, darknet의 첫 번째 레이어와 두 번째 레이어의 출력 특징맵에서 부분 경계 상자 (bounding box, bbox)에 해당하는 특징 맵을 추출할 수 있다.
- [0108] 단계 S112에서는, 추출한 부분 특징 맵에 각각 글로벌 평균 풀링(global averaging pooling, GAP)을 적용해, 2개의 압축 특징(condensed feature)을 생성할 수 있다. GAP 방법은 3D 텐서의 공간 차수를 줄이는 데 사용되며, 모델의 총 매개변수 수를 줄여 과적합을 최소화할 수 있는 장점이 있다. 보다 구체적으로, 각각의 부분 특징 맵에 GAP를 적용해 2개의 $1 \times 1 \times C$ 특징 벡터를 생성할 수 있는데, 이를 압축 특징이라고 할 수 있다.
- [0110] 단계 S113에서는, 생성된 2개의 압축 특징을 연결해 최종 압축 외관 특징(condensed appearance feature, CAF)을 생성할 수 있다. 즉, 단계 S120에서 생성된 압축 특징(condensed feature)을 연결해 CAF가 될 수 있다. 이하에서 상세히 설명할 단계 S120에서 SiameseRF를 학습할 때에는, {기준, 양성}의 제1쌍의 CAF의 차이와 {기준, 음성}의 제2쌍의 CAF의 차이가 입력 벡터로 사용될 수 있다.
- [0112] 단계 S120에서는, 추출된 특징 벡터를 이용해 SiameseRF를 학습할 수 있다. SiameseRF의 학습 과정에서, 먼저 L 양상블 트리로 구성된 초기 RF를 생성할 수 있다. 두 RF가 입력으로 {기준, 양성}의 제1쌍 및 {기준, 음성}의 제2쌍을 각각 수신해 학습하지만, 두 RF는 같은 구조를 공유할 수 있다. 따라서 학습 과정에서 공유 RF(shared RF)는 제1쌍과의 유사성이 증가하는 방향과 제2쌍과의 차이가 증가하는 방향으로 학습될 수 있다. 두 개의 RF는 삼 CNN과 달리 가중치를 공유하지는 않지만, 트리를 구성하는 규칙을 공유할 수 있다.
- [0114] 보다 구체적으로, 단계 S120에서는, 제1쌍의 거리 벡터(이하, AP 거리 벡터) 및 제2쌍의 거리 벡터(이하, AN 거리 벡터)를 각각 두 RF의 입력 벡터로 하고, K겹 교차 검증(K-fold cross validation)을 이용해 Siamese RF를 학습할 수 있다. 여기서, AP 거리 벡터 및 AN 거리 벡터는, 신경망 기반의 객체 검출 장치에서 검출된 객체에 대한 특징 맵으로부터 생성된 압축 외관 특징(CAF)의 차이일 수 있다.

[0116] 즉, 각각의 RF의 입력으로서, 각 이미지의 외관 특징인 CAF 차이(AP_i , AN_i)가 특징으로 입력될 수 있다. 벡터 $AP \in \mathbb{R}^{1 \times m}$ 은 다음 수학적 식 1과 같은 경우에만 거리 벡터이다.

수학적 식 1

[0117] $AP_i = d(a_i, p_i)$, $AN_i = d(a_i, n_i)$, for $1 \leq i \leq m$

[0119] 여기서, d 는 L2 거리 함수, $a_i \in \text{anchor}$, $p_i \in \text{positive}$, $n_i \in \text{negative}$ 이고, m 은 anchor, positive, negative의 각 레이블에 포함된 샘플 수이다.

[0121] 한편, 단계 S120에서는, 공유 RF의 학습 단계를 반복하기 위해, 학습 과정에 대한 K겹 교차 검증을 채택해 모델의 정확성을 높였다. K겹 교차 검증은 과적합의 위험을 줄이면서 최적의 규칙 개수와 매개변수를 결정할 수 있다.

[0123] 도 6은 본 발명의 일실시예에 따른 삼 랜덤 포레스트를 이용한 다수 객체 추적 방법에서, 단계 S120의 세부적인 흐름을 도시한 도면이다. 도 6에 도시된 바와 같이, 본 발명의 일실시예에 따른 삼 랜덤 포레스트를 이용한 다수 객체 추적 방법의 단계 S120은, 학습 데이터에서 선택된 K-1 폴드는 학습 세트로, 나머지 폴드는 검증 세트로 하는 단계(S121), CAF를 이용해 학습 세트에 포함된 샘플의 AP 거리 벡터 및 AN 거리 벡터를 추정하는 단계(S122), 규칙을 공유하는 두 RF에 학습 세트의 샘플 쌍을 입력하는 단계(S123), 입력된 샘플 쌍에 대해 추정된 AP 거리 벡터 및 AN 거리 벡터를 이용해 두 RF를 학습하는 단계(S124), K-1 폴드 학습 후, 검증 세트의 모든 샘플 쌍에 대해 추정된 AP 거리 벡터 및 AN 거리 벡터를 학습된 RF에 적용하여 검증하는 단계(S125), 학습된 RF 구조 및 총 손실을 저장하는 단계(S126) 및 모든 K개의 폴드에 대한 학습이 완료되면 총 손실이 가장 작은 RF를 최종 SiameseRF로 결정하는 단계(S127)를 포함하여 구현될 수 있다.

[0125] 단계 S121에서는, 학습 데이터에서 선택된 K-1 폴드는 학습 세트로, 나머지 폴드는 검증 세트로 할 수 있다.

[0127] 단계 S122에서는, CAF를 이용해 학습 세트에 포함된 샘플의 제1쌍의 거리 벡터(이하, AP 거리 벡터) 및 제2쌍의 거리 벡터(이하, AN 거리 벡터)를 추정할 수 있다. 즉, 입력 벡터로 사용하기 위한 AP_i , AN_i 를 계산할 수 있다.

[0129] 단계 S123에서는, 규칙을 공유하는 두 RF에 학습 세트의 샘플 쌍을 입력할 수 있다. 이때, 단계 S120에서는, K겹 교차 검증의 수렴 여부에 따라 공유 RF로 구성된 규칙 업데이트가 수행할 수 있다.

[0131] 단계 S124에서는, 입력된 샘플 쌍에 대해 추정된 AP 거리 벡터 및 AN 거리 벡터를 이용해 두 RF를 학습할 수 있다. 즉, L 트리로 구성된 RF를 AP 거리 벡터 및 AN 거리 벡터를 사용해 학습을 수행할 수 있다.

[0133] 단계 S125에서는, K-1 폴드 학습 후, 검증 세트의 모든 샘플 쌍에 대해 추정된 AP 거리 벡터 및 AN 거리 벡터를 단계 S124에서 학습된 RF에 적용하여 검증할 수 있다.

[0135] 즉, 학습 세트 훈련 후, 검증 세트의 {기준, 양성}의 제1쌍 및 {기준, 음성}의 제2쌍으로부터 AP_i , AN_i 를 얻을

수 있다. 다음 수학적식 2에 따라, AP 거리 벡터 및 AN 거리 벡터를 학습된 RF에 적용하여 삼중 손실(triplet loss, L)을 계산할 수 있다. 이 프로세스는 검증 세트의 모든 n 쌍에 대해 수행될 수 있다.

수학적식 2

$$L(a, p, n)_k = \max(\|1 - \text{RF}_k(AP)\|^2 - \|\text{RF}_k(AN)\|^2 + \alpha, 0)$$

여기서, α 는 margin이다.

단계 S126에서는, 학습된 RF 구조 및 다음 수학적식 3에 따른 총 손실(total loss) J를 저장할 수 있다. 모든 K개의 폴드가 검증 세트로 사용될 때까지, 단계 S121 내지 단계 S126을 반복하여 학습할 수 있다.

수학적식 3

$$J_k = \sum_{i=1}^n L(a_i, p_i, n_i)_k$$

단계 S127에서는, 모든 K개의 폴드에 대한 학습이 완료되면, 총 손실이 가장 작은 RF를 최종 SiameseRF로 결정할 수 있다.

수학적식 4

$$k = \arg \min_{k \in K} J_k$$

단계 S200에서는, 객체 추적 모듈(200)이, 학습된 SiameseRF를 이용해 객체를 추적할 수 있다. 즉, 단계 S200에서는, 객체가 탐지되면, 학습된 SiameseRF를 이용해 탐지된 객체와 추적 객체 사이의 연관성을 측정해 객체를 추적할 수 있다. 보다 구체적으로, 단계 S200에서는, 탐지된 객체와 추적 객체의 압축 외관 특징(CAF)을 학습된 SiameseRF에 입력하고, SiameseRF의 출력인 두 객체의 유사성 확률(similarity probability)을 연관성 측정을 위한 외관 점수(appearance score)로 할 수 있다.

단계 S200에서는, SiameseRF의 역 유사성 확률값, 두 객체 종횡비 및 두 객체 사이의 L1-중심 거리의 가중치 합으로 산출되는 연관 매칭의 비용 함수를 이용해, 탐지된 객체와 추적 객체가 일치하는지 판단할 수 있다. 즉, 모든 프레임에서, 탐지 객체는 Hungarian 방법과 세 가지 측정, 즉 SiameseRF의 역 확률 값($\hat{P}_{\text{Siam}}$), 종횡비(aspect ratio)(A_{ratio}) 및 L1-중심 거리(L1-centered distance)(Dis)를 기반으로 추적 객체에 할당될 수 있다. 마지막으로, 연관 매칭(association matching)의 비용 함수(cost function, c)를 계산하기 위해, 다음 수학적식 5와 같이 가중치 합을 사용하여 세 가지 거리 측정값을 결합할 수 있다.

수학적식 5

$$c(\text{tr}^i, \text{d}^j) = \alpha \cdot \hat{P}_{\text{Siam}}(\text{tr}^i | \text{d}^j) + \beta \cdot A_{\text{ratio}}(\text{tr}^i, \text{d}^j) + \gamma \text{Dis}(\text{tr}^i, \text{d}^j)$$

- [0151] 여기서 α , β 및 γ 는 각각 0.6, 0.2 및 0.2의 가중치를 나타내며, 이들 가중치는 여러 실험에 기초하여 미리 설정되었다.
- [0153] 단계 S200에서는, 탐지된 객체와 추적 객체가 일치하면 탐지된 객체를 추적 객체의 상태에 업데이트하고, 미리 정해진 개수의 프레임 (τ 프레임) 동안 추적 객체와 일치하는 탐지된 객체가 없으면 추적 객체를 삭제하며, 탐지된 객체가 추적 객체와 일치하지 않으면 탐지된 객체를 잠재적 추적 객체로 할당하고 미리 정해진 개수의 프레임에서 잠재적 추적 객체와 탐지된 객체가 일치하면 잠재적 추적 객체를 새로운 추적 객체로 할당할 수 있다. 그렇지 않으면 잘못된 탐지로 인식되고 잠재적 추적 객체는 제거될 수 있다.
- [0155] 실험예 1
- [0157] 본 발명에서 제안하고 있는 삼 랜덤 포레스트를 이용한 다수 객체 추적 방법 및 장치의 성능을 확인하기 위해, 다양한 환경에서 여러 객체를 포함하는 스테레오 카메라에서 캡처한 MOTS Challenge 워크숍 2020 벤치마크 비디오 시퀀스에 적용하여 객체 추적을 수행하였다. 보다 구체적으로, 미리 제공된 고정밀 탐지 세트에서, 본 발명은 sMOTSA에 의해 상당히 정확한 추적 성능을 산출하였다. 즉, 1) MOTS20 보행자의 경우 60%, 2) KITTI 자동차의 경우 71.4%, 및 3) KITTI 보행자의 경우 60.9%의 정확도를 나타냈다. 계산 시간 측면에서 MOTS20 데이터 세트의 경우 평균 8.2fps, KITTI 데이터 세트의 경우 12.4fps가 소요되었다.
- [0159] 실험예 2
- [0161] 본 발명에서 제안하고 있는 삼 랜덤 포레스트를 이용한 다수 객체 추적 방법 및 장치의 성능을 확인하기 위해, MOT16 데이터의 추적 결과를 측정하였다. 실험을 위해, 동일한 이미지 시퀀스의 MOTS Challenge 2020이 사용되었다. 검출기로 YOLOv3를 사용하였고, 주어진 MOT16 훈련 데이터를 SiameseRF 학습에 사용하였다.
- [0163] 도 7은 본 발명의 일실시예에 따른 삼 랜덤 포레스트를 이용한 다수 객체 추적 방법 및 장치의 성능을 검증하기 위한 실험 결과를 도시한 도면이다. 도 7에서 확인할 수 있는 바와 같이, MOT16 테스트 데이터 세트의 비교 실험 결과는 SiameseRF (“Ours”)가 유사한 결과를 가진 다른 MOT 알고리즘보다 상대적으로 빠르다는 것을 보여준다. 또한, 최신 온라인 기반 MOT 방법과 비교하여 제안된 SiameseRF는 전체 성능 측면에서 탁월한 결과를 보여준다.
- [0165] 도 8 내지 도 10은 본 발명의 일실시예에 따른 삼 랜덤 포레스트를 이용한 다수 객체 추적 방법 및 장치가 적용된 시연 영상의 일부를 도시한 도면이다. 즉, 움직이는 카메라에서 촬영되는 영상에 SiameseRF를 적용한 객체 추적 결과로서, 도 8, 도 9, 도 10은 시간의 흐름에 따른 순서이다. 도 8 내지 도 10에 도시된 바와 같이, SiameseRF는 움직이는 카메라에서 촬영되는 영상에서 실시간으로 객체를 정확하게 추적하고 있음을 확인할 수 있다.
- [0167] SiameseRF는 역전파가 아닌 K접 유효성 검사를 사용하므로, 학습 속도가 빠르고 최적의 트리 규칙을 생성할 수 있으며, RF를 구성하는 트리의 규칙이 각 RF와 공유되므로 테스트 중에 메모리 요구량을 줄일 수 있다. 따라서 본 발명에서 제안하고 있는 삼 랜덤 포레스트를 이용한 다수 객체 추적 방법 및 장치는, 제한된 시스템 자원을 가진 임베디드 시스템에서 온라인 추적에 사용될 수 있다는 것이 실험적으로 확인되었다.
- [0169] 전술한 바와 같이, 본 발명에서 제안하고 있는 삼 랜덤 포레스트를 이용한 다수 객체 추적 방법 및 장치에 따르면, 랜덤 포레스트 분류기와 삼 구조를 결합하여 삼 랜덤 포레스트 구조를 제안하고, 학습 데이터로부터 {기준,

양성}의 제1쌍 및 {기준, 음성}의 제2쌍의 이미지를 입력하여, 제1쌍과의 유사성이 증가하는 방향과 제2쌍과의 차이가 증가하는 방향으로 삼 랜덤 포레스트를 시킴으로써, 최종적으로 고속으로 학습 및 분류를 할 수 있고, 카메라 움직임이나 복잡한 보행자 형태에도 불구하고 강력한 추적 성능을 가질 수 있다.

[0171] 이상 설명한 본 발명은 본 발명이 속한 기술분야에서 통상의 지식을 가진 자에 의하여 다양한 변형이나 응용이 가능하며, 본 발명에 따른 기술적 사상의 범위는 아래의 특허청구범위에 의하여 정해져야 할 것이다.


부호의 설명

[0172] 100: 학습 모듈
200: 객체 추적 모듈


S100: 학습 데이터를 이용해 RF 분류기와 삼 구조를 결합한 SiameseRF를 학습하는 단계
S110: 학습 데이터로부터 특징 벡터를 추출하는 단계
S111: 객체 검출을 위한 신경망의 첫 번째 레이어 및 두 번째 레이어로부터 부분 특징 맵을 추출하는 단계
S112: 추출한 부분 특징 맵에 각각 GAP를 적용해 2개의 압축 특징을 생성하는 단계
S113: 2개의 압축 특징을 연결해 CAF를 생성하는 단계
S120: 추출된 특징 벡터를 이용해 SiameseRF를 학습하는 단계
S121: 학습 데이터에서 선택된 K-1 폴드는 학습 세트로, 나머지 폴드는 검증 세트로 하는 단계
S122: CAF를 이용해 학습 세트에 포함된 샘플의 AP 거리 벡터 및 AN 거리 벡터를 추정하는 단계
S123: 규칙을 공유하는 두 RF에 학습 세트의 샘플 쌍을 입력하는 단계
S124: 입력된 샘플 쌍에 대해 추정된 AP 거리 벡터 및 AN 거리 벡터를 이용해 두 RF를 학습하는 단계
S125: K-1 폴드 학습 후, 검증 세트의 모든 샘플 쌍에 대해 추정된 AP 거리 벡터 및 AN 거리 벡터를 학습된 RF에 적용하여 검증하는 단계
S126: 학습된 RF 구조 및 총 손실을 저장하는 단계
S127: 모든 K개의 폴드에 대한 학습이 완료되면 총 손실이 가장 작은 RF를 최종 SiameseRF로 결정하는 단계
S200: 학습된 SiameseRF를 이용해 객체를 추적하는 단계

도면


도면1



도면2




도면3




도면4

S100




도면5

S110



도면6

S120




도면7

	Method	MOTA(%) ↑	MOTP(%) ↑	FAF ↓	MT(%) ↑	ML(%) ↓	FP ↓	FN ↓	IDsw ↓	Frag ↓	H _z ↑
Offline	LM CNN[3]	67.4	79.1	1.7	38.2	19.2	10,109	48,435	931	1,034	1.7
	KDNT [14]	68.2	79.4	1.9	41.0	19.0	11,479	45,605	933	1,093	0.7
	LMP _p [15]	71.0	80.2	1.3	46.9	21.9	6,213	44,564	434	587	0.5
	HDTR[17]	53.6	80.8	0.8	21.2	37.0	4,714	79,353	618	833	3.6
Online	JCSTD [13]	47.4	74.4	1.4	14.4	36.4	8,076	86,638	1,266	2,697	8.8
	Tracktor[16]	56.2	79.2	0.4	20.7	35.8	2,394	76,844	617	1,411	1.6
	MLT[18]	52.8	76.1	0.9	21.1	42.4	5,362	80,444	299	702	5.9
	DMAN[6]	46.1	73.8	1.3	17.4	42.7	7,909	89,874	532	1,616	0.3
	RAR16[4]	63.0	78.8	2.3	39.9	22.1	13,663	53,248	482	1,251	1.6
	Ours	57.9	79.3	1.4	28.5	22.1	8,196	66,538	2,051	2,549	7.8

도면8



도면9



도면10

