



(19) 대한민국특허청(KR)
(12) 공개특허공보(A)

(11) 공개번호 10-2015-0025508

(43) 공개일자 2015년03월10일

(51) 국제특허분류(Int. Cl.)

G06T 7/00 (2006.01)

(21) 출원번호 10-2013-0103540

(22) 출원일자 2013년08월30일

심사청구일자 2013년08월30일

(71) 출원인

계명대학교 산학협력단

대구광역시 달서구 달구벌대로 1095 (신당동)

(72) 발명자

고병철

대구광역시 수성구 동대구로 345 범어역우방유셀
3306호

정지훈

경상북도 포항시 북구 새천년대로1075번길 10 창
포주공1단지아파트 107동 201호

(뒷면에 계속)

(74) 대리인

김건우

전체 청구항 수 : 총 14 항


(54) 발명의 명칭 공유 지역 특징을 이용한 다시점 객체 검출 방법

(57) 요약

본 발명은 공유 지역 특징을 이용한 다시점 객체 검출 방법에 관한 것으로서, 보다 구체적으로는 (1) 객체를 포함하는 여러 시점(Multi-View)을 가지는 트레이닝 영상에서 임의의 위치와 크기를 가지는 후보 영역(Randomly N Regions)들을 생성하는 단계; (2) 각각의 후보 영역에 대해 OCS-LBP(Orientation Center Symmetric Local

(뒷면에 계속)

대표도 - 도1



Binary Patterns) 특징을 추출하는 단계; (3) 각각의 후보 영역별로 추출된 특징 벡터들을 랜덤 포레스트를 통해 지역 기반으로 학습하는 단계; (4) 테스트 영상을 학습된 랜덤 포레스트에 적용하여 확률 값을 추정된 다음 상위 값들을 가지는 지역 특징(Local Features)의 영역을 선택하는 단계; (5) 각 시점에 대해서 선택된 지역 특징의 영역에 대해 공유되는 영역을 찾아 선택하고, 공유된 지역 특징의 영역에 대해서 랜덤 포레스트로 학습하는 단계; (6) 트레이닝 과정 수행 후, 객체를 검출하기 위해서 테스트 영상이 입력되면, 각각의 관점별로 확률 값이 추정되고, 확률 값 히스토그램을 생성하는 단계; (7) 생성한 확률 값 히스토그램에서 추정된 확률 값들 중 최댓 값을 찾고, 최댓값을 가지는 주위 5개의 확률 값에 대해 가중치를 부과한 뒤 선형 결합하여 최종적인 확률 값을 추정하는 단계; 및 (8) 상기 추정된 최종적인 확률 값이 미리 지정한 임계값보다 큰 경우에 객체로 검출하는 단계를 포함하는 것을 그 구성상의 특징으로 한다.

본 발명에서 제안하고 있는 공유 지역 특징을 이용한 다시점 객체 검출 방법에 따르면, 정지 영상에서 다양한 관점을 가지는 객체에 대해 지역적 OCS-LBP 특징 추출과 공유 지역 기반의 랜덤 포레스트 분류기를 사용하여 학습 및 분류함으로써, 영상 내의 다양한 관점을 가지는 다시점의 객체에 대해서 빠르고 정확한 검출이 가능하도록 할 수 있다.

또한, 본 발명에 따르면, OCS-LBP 특징 추출을 사용함으로써, 방향 정보를 포함하는 적은 특징 차원 수에도 불구하고 매우 빠른 성능을 나타낼 수 있도록 하며, 랜덤 포레스트 분류기를 사용하여 생성된 모든 영역을 객체 분류에 사용하지 않고 최적의 공유 지역 특징을 사용하여 학습 및 분류함으로써, 적은 트레이닝 데이터를 사용하면서도 다양한 관점을 가지는 객체에 대해 빠른 학습 속도 및 검출 속도를 가질 수 있도록 할 수 있다.

뿐만 아니라, 본 발명에 따르면, 공유되는 지역 특징을 사용하여 부분 가림을 가진 복잡한 배경(백그라운드)에서도 다시점 객체의 검출이 가능하며, 특히 공유된 지역 특징을 각 클래스에 대해 독립적이기 보다 공동으로 공유하여 선택할 수 있도록 함으로써, 분류기의 수를 줄여 최소화하고, 계산의 복잡성을 줄여줄 수 있도록 할 수 있다.

(72) 발명자

남재열

대구광역시 수성구 지범로40길 11 서한화성아파트
103동 1401호

주영도

대구광역시 달서구 성서공단로11길 62 대구융합 알
앤디센터 12층

강정석

대구광역시 달서구 성서공단로11길 62 대구융합 알
앤디센터 12층

이 발명을 지원한 국가연구개발사업

과제고유번호 2012-05-A-03-031-12-010100

부처명 한국연구재단

연구관리전문기관 한국연구재단

연구사업명 지역혁신 인력양성 사업

연구과제명 시각장애인을 위한 비전기반 장면해석 기술 개발

기 여 율 1/1

주관기관 계명대학교

연구기간 2013.04.01 ~ 2014.03.31

특허청구의 범위

청구항 1

- (1) 객체를 포함하는 여러 시점(Multi-View)을 가지는 트레이닝 영상에서 임의의 위치와 크기를 가지는 후보 영역(Randomly N Regions)들을 생성하는 단계;
- (2) 각각의 후보 영역에 대해 OCS-LBP(Orientation Center Symmetric Local Binary Patterns) 특징을 추출하는 단계;
- (3) 각각의 후보 영역별로 추출된 특징 벡터들을 랜덤 포레스트를 통해 지역 기반으로 학습하는 단계;
- (4) 테스트 영상을 학습된 랜덤 포레스트에 적용하여 확률 값을 추정된 다음 상위 값들을 가지는 지역 특징(Local Features)의 영역을 선택하는 단계;
- (5) 각 시점에 대해서 선택된 지역 특징의 영역에 대해 공유되는 영역을 찾아 선택하고, 공유된 지역 특징의 영역에 대해서 랜덤 포레스트로 학습하는 단계;
- (6) 트레이닝 과정 수행 후, 객체를 검출하기 위해서 테스트 영상이 입력되면, 각각의 관점별로 확률 값이 추정되고, 확률 값 히스토그램을 생성하는 단계;
- (7) 생성한 확률 값 히스토그램에서 추정된 확률 값들 중 최댓값을 찾고, 최댓값을 가지는 주위 5개의 확률 값에 대해 가중치를 부과한 뒤 선형 결합하여 최종적인 확률 값을 추정하는 단계; 및
- (8) 상기 추정된 최종적인 확률 값이 미리 지정한 임계값보다 큰 경우에 객체로 검출하는 단계를 포함하는 것을 특징으로 하는, 공유 지역 특징을 이용한 다시점 객체 검출 방법.

청구항 2

제1항에 있어서, 상기 단계 (1)에서의 후보 영역들은,

상기 트레이닝 영상의 원본 이미지에서 객체가 포함된 80×40 의 크기로 조정하여 자른 윈도우 영역에서 수집된 N 개의 훈련 샘플인 것을 특징으로 하는, 공유 지역 특징을 이용한 다시점 객체 검출 방법.

청구항 3

제2항에 있어서, 상기 후보 영역들은,

상기 80×40 의 크기를 갖는 윈도우 영역에서 최소 10×10 의 크기로부터 최대 40×20 (윈도우 영역의 절반)의 크기를 갖는 지역 특징을 랜덤하게 생성한 것임을 특징으로 하는, 공유 지역 특징을 이용한 다시점 객체 검출 방법.

청구항 4

제1항에 있어서, 상기 단계 (1)에서의 후보 영역들은,

다시점 객체 검출에 필요한 회전 객체의 지역 특징을 위해 30° 간격으로 0° 에서 360° 의 범위에서 12 트레이닝 세트로 지정할 수 있도록 하는 것을 특징으로 하는, 공유 지역 특징을 이용한 다시점 객체 검출 방법.

청구항 5

제4항에 있어서, 상기 트레이닝 세트는,

지역 특징의 특정 위치와 크기를 선택하는 학습 그룹과, 테스트 그룹으로 똑같이 나누어지는 것을 특징으로 하

는, 공유 지역 특징을 이용한 다시점 객체 검출 방법.

청구항 6

제1항에 있어서,

네거티브 세트는 배경(백그라운드) 영역에서 추출하는 것을 특징으로 하는, 공유 지역 특징을 이용한 다시점 객체 검출 방법.

청구항 7

제1항에 있어서, 상기 단계 (2)에서는,

상기 후보 영역들 각각에 대해 4개(2×2)의 서브 영역으로 분할하고, 각 서브 영역에서 8차원의 OCS-LBP 특징을 추출하는 것을 특징으로 하는, 공유 지역 특징을 이용한 다시점 객체 검출 방법.

청구항 8

제7항에 있어서, 상기 후보 영역들은,

각 서브 영역에서 추출된 OCS-LBP 특징들을 연결하여 각 후보 영역 당 32(8×4) 차원의 특징 벡터를 추출하는 것을 특징으로 하는, 공유 지역 특징을 이용한 다시점 객체 검출 방법.

청구항 9

제1항에 있어서, 상기 단계 (3)에서의 랜덤 포레스트는,

의사 결정 트리를 기반으로 하는 앙상블 분류기인 것을 특징으로 하는, 공유 지역 특징을 이용한 다시점 객체 검출 방법.

청구항 10

제9항에 있어서, 상기 랜덤 포레스트는,

의사 결정 트리를 사용하여 높은 훈련 속도와 많은 양의 데이터를 처리할 수 있도록 기능하는 것을 특징으로 하는, 공유 지역 특징을 이용한 다시점 객체 검출 방법.

청구항 11

제9항에 있어서, 상기 랜덤 포레스트는,

각 트리의 구조를 이진 하향식(top-down) 방식으로 구현하는 것을 특징으로 하는, 공유 지역 특징을 이용한 다시점 객체 검출 방법.

청구항 12

제1항에 있어서, 상기 단계 (5)에서의 랜덤 포레스트는,

동일한 지역 특징을 공유하는 각 뷰 클래스에서 수집된 훈련 데이터를 사용하여 공유 분류기로 훈련하여 공유 지역 특징에 대한 멀티 클래스 분류기를 생성하는 것을 특징으로 하는, 공유 지역 특징을 이용한 다시점 객체 검출 방법.

청구항 13

제12항에 있어서, 상기 단계 (6)에서는,

각 공유 분류기들에서 공유되는 멀티 클래스 분류기의 히스토그램 확률 분포로부터 확률 값 히스토그램을 생성하는 것을 특징으로 하는, 공유 지역 특징을 이용한 다시점 객체 검출 방법.

청구항 14

제13항에 있어서, 상기 단계 (7)에서의 최댓값은,

생성한 확률 값 히스토그램에서 가장 기본이 되는 시점을 찾기 위한 최대 함수(Max Operation)를 이용하는 것을 특징으로 하는, 공유 지역 특징을 이용한 다시점 객체 검출 방법.

명세서

기술 분야

[0001] 본 발명은 공유 지역 특징을 이용한 다시점 객체 검출 방법에 관한 것으로서, 보다 구체적으로는 정지 영상에서 다양한 관점을 가지는 객체에 대해 지역적 OCS-LBP(Orientation Center Symmetric Local Binary Patterns) 특징과 공유 지역 기반의 랜덤 포레스트 분류기를 사용하여 영상 내의 다양한 관점을 가지는 객체에 대해서 빠르고 정확한 검출이 가능하도록 해주는 공유 지역 특징을 이용한 다시점 객체 검출 방법에 관한 것이다.

배경 기술

[0002] 일반적으로 객체 검출 시스템은 감시 시스템, 행동 인식, 증강 현실과 같은 컴퓨터 비전 분야에서 중요한 연구 분야 중 하나이다. 일반적인 영상에서의 객체 검출은 객체의 다양한 크기, 복잡한 배경, 가려짐 등에 의해 객체 검출이 어려운 문제가 있으며, 이러한 문제를 해결하기 위해 객체 검출과 관련된 활발한 연구가 진행되고 있다.

[0003] 객체 검출을 위한 선행기술로서는, 선행기술 1(대한민국 공개특허공보 제10-2011-0131727호, 발명의 명칭: 영상 처리 시스템에서의 객체 인식 방법)과, 선행기술 2(C. H. Chang, C. C. Wang, and J. J. Lien, "Multi-view vehicle detection using gentle boost with sharing HOG feature," in Proceedings of 22th IPPR Conference on Computer Vision, Graphics and Image Processing(IPPR, 2009), pp.1688-1694) 등의 참고 문헌이 개시된 바 있다. 선행기술 1은 정지 영상에서 소벨 필터(Sobel Filter), GIST 알고리즘을 이용한 특징 추출을 통해서 전역 특징 기반 방법과 지역 특징 기반 방법을 사용하여 객체를 인식하는 방법을 개시하고 있다. 선행기술 2는 객체를 포함하는 영상에 대해 패치를 생성하고 해당 패치에 대해 HOG(Histogram of oriented gradient) 특징을 추출하고, 특징 추출 후 Gentle Boost를 사용하여 학습 및 객체 검출을 하는 알고리즘을 개시하고 있다. 선행기술 2에서 사용된 알고리즘은 특징 추출 방법으로 HOG를 사용하며, HOG는 많은 특징 차원 수를 가지므로 매우 느린 연산 속도를 가지는 문제가 있었다.

발명의 내용

해결하려는 과제

[0004] 본 발명은 기존에 제안된 방법들의 상기와 같은 문제점들을 해결하기 위해 제안된 것으로서, 정지 영상에서 다양한 관점을 가지는 객체에 대해 지역적 OCS-LBP 특징 추출과 공유 지역 기반의 랜덤 포레스트 분류기를 사용하여 학습 및 분류함으로써, 영상 내의 다양한 관점을 가지는 다시점의 객체에 대해서 빠르고 정확한 검출이 가능하도록 하는, 공유 지역 특징을 이용한 다시점 객체 검출 방법을 제공하는 것을 그 목적으로 한다.

[0005] 또한, 본 발명은, OCS-LBP 특징 추출을 사용함으로써, 방향 정보를 포함하는 적은 특징 차원 수에도 불구하고

매우 빠른 성능을 나타낼 수 있도록 하며, 랜덤 포레스트 분류기를 사용하여 생성된 모든 영역을 객체 분류에 사용하지 않고 최적의 공유 지역 특징을 사용하여 학습 및 분류함으로써, 적은 트레이닝 데이터를 사용하고도 다양한 관점을 가지는 객체에 대해 빠른 학습 속도 및 검출 속도를 가질 수 있도록 하는, 공유 지역 특징을 이용한 다시점 객체 검출 방법을 제공하는 것을 또 다른 목적으로 한다.

뿐만 아니라, 본 발명은, 공유되는 지역 특징을 사용하여 부분 가림을 가진 복잡한 배경(백그라운드)에서도 다시점 객체의 검출이 가능하며, 특히 공유된 지역 특징을 각 클래스에 대해 독립적이기보다 공동으로 공유하여 선택할 수 있도록 함으로써, 분류기의 수를 줄여 최소화하고, 계산의 복잡성을 줄여줄 수 있도록 하는, 공유 지역 특징을 이용한 다시점 객체 검출 방법을 제공하는 것을 또 다른 목적으로 한다.

과제의 해결 수단

상기한 목적을 달성하기 위한 본 발명의 특징에 따른 공유 지역 특징을 이용한 다시점 객체 검출 방법은,

(1) 객체를 포함하는 여러 시점(Multi-View)을 가지는 트레이닝 영상에서 임의의 위치와 크기를 가지는 후보 영역(Randomly N Regions)들을 생성하는 단계;

(2) 각각의 후보 영역에 대해 OCS-LBP(Orientation Center Symmetric Local Binary Patterns) 특징을 추출하는 단계;

(3) 각각의 후보 영역별로 추출된 특징 벡터들을 랜덤 포레스트를 통해 지역 기반으로 학습하는 단계;

(4) 테스트 영상을 학습된 랜덤 포레스트에 적용하여 확률 값을 추정된 다음 상위 값들을 가지는 지역 특징(Local Features)의 영역을 선택하는 단계;

(5) 각 시점에 대해서 선택된 지역 특징의 영역에 대해 공유되는 영역을 찾아 선택하고, 공유된 지역 특징의 영역에 대해서 랜덤 포레스트로 학습하는 단계;

(6) 트레이닝 과정 수행 후, 객체를 검출하기 위해서 테스트 영상이 입력되면, 각각의 관점별로 확률 값이 추정되고, 확률 값 히스토그램을 생성하는 단계;

(7) 생성한 확률 값 히스토그램에서 추정된 확률 값들 중 최댓값을 찾고, 최댓값을 가지는 상위 5개의 확률 값에 대해 가중치를 부과한 뒤 선형 결합하여 최종적인 확률 값을 추정하는 단계; 및

(8) 상기 추정된 최종적인 확률 값이 미리 지정한 임계값보다 큰 경우에 객체로 검출하는 단계를 포함하는 것을 그 구성상의 특징으로 한다.

바람직하게는, 상기 단계 (1)에서의 후보 영역들은,

상기 트레이닝 영상의 원본 이미지에서 객체가 포함된 80×40 의 크기로 조정하여 자른 윈도우 영역에서 수집된 N 개의 혼련 샘플로 구성할 수 있다.

더욱 바람직하게는, 상기 후보 영역들은,

상기 80×40 의 크기를 갖는 윈도우 영역에서 최소 10×10 의 크기로부터 최대 40×20 (윈도우 영역의 절반)의 크기를 갖는 지역 특징을 랜덤하게 생성할 수 있다.

바람직하게는, 상기 단계 (1)에서의 후보 영역들은,

다시점 객체 검출에 필요한 회전 객체의 지역 특징을 위해 30° 간격으로 0° 에서 360° 의 범위에서 12 트레이닝 세트에 지정할 수 있도록 할 수 있다.

더욱 바람직하게는, 상기 트레이닝 세트는,

- [0023] 지역 특징의 특정 위치와 크기를 선택하는 학습 그룹과, 테스트 그룹으로 똑같이 나누어지도록 구성할 수 있다.
- [0024] 바람직하게는,
- [0025] 네거티브 세트는 배경(백그라운드) 영역에서 추출할 수 있다.
- [0026] 바람직하게는, 상기 단계 (2)에서는,
- [0027] 상기 후보 영역들 각각에 대해 4개(2×2)의 서브 영역으로 분할하고, 각 서브 영역에서 8차원의 OCS-LBP 특징을 추출할 수 있다.
- [0028] 더욱 바람직하게는, 상기 후보 영역들은,
- [0029] 각 서브 영역에서 추출된 OCS-LBP 특징들을 연결하여 각 후보 영역당 32(8×4) 차원의 특징 벡터를 추출할 수 있다.
- [0030] 바람직하게는, 상기 단계 (3)에서의 랜덤 포레스트는,
- [0031] 의사 결정 트리를 기반으로 하는 앙상블 분류기로 구성할 수 있다.
- [0032] 더욱 바람직하게는, 상기 랜덤 포레스트는,
- [0033] 의사 결정 트리를 사용하여 높은 훈련 속도와 많은 양의 데이터를 처리할 수 있도록 기능할 수 있다.
- [0034] 더욱 바람직하게는, 상기 랜덤 포레스트는,
- [0035] 각 트리의 구조를 이진 하향식(top-down) 방식으로 구현할 수 있다.
- [0036] 바람직하게는, 상기 단계 (5)에서의 랜덤 포레스트는,
- [0037] 동일한 지역 특징을 공유하는 각 뷰 클래스에서 수집된 훈련 데이터를 사용하여 공유 분류기로 훈련하여 공유 지역 특징에 대한 멀티 클래스 분류기를 생성할 수 있다.
- [0038] 더욱 바람직하게는, 상기 단계 (6)에서는,
- [0039] 각 공유 분류기들에서 공유되는 멀티 클래스 분류기의 히스토그램 확률 분포로부터 확률 값 히스토그램을 생성할 수 있다.
- [0040] 더욱더 바람직하게는, 상기 단계 (7)에서의 최댓값은,
- [0041] 생성한 확률 값 히스토그램에서 가장 기본이 되는 시점을 찾기 위한 최대 함수(Max Operation)를 이용할 수 있다.

발명의 효과

- [0042] 본 발명에서 제안하고 있는 공유 지역 특징을 이용한 다시점 객체 검출 방법에 따르면, 정지 영상에서 다양한 관점을 가지는 객체에 대해 지역적 OCS-LBP 특징 추출과 공유 지역 기반의 랜덤 포레스트 분류기를 사용하여 학습 및 분류함으로써, 영상 내의 다양한 관점을 가지는 다시점의 객체에 대해서 빠르고 정확한 검출이 가능하도록 할 수 있다.

[0043] 또한, 본 발명에 따르면, OCS-LBP 특징 추출을 사용함으로써, 방향 정보를 포함하는 적은 특징 차원 수에도 불구하고 매우 빠른 성능을 나타낼 수 있도록 하며, 랜덤 포레스트 분류기를 사용하여 생성된 모든 영역을 객체 분류에 사용하지 않고 최적의 공유 지역 특징을 사용하여 학습 및 분류함으로써, 적은 트레이닝 데이터를 사용하고도 다양한 관점을 가지는 객체에 대해 빠른 학습 속도 및 검출 속도를 가질 수 있도록 할 수 있다.

[0044] 뿐만 아니라, 본 발명에 따르면, 공유되는 지역 특징을 사용하여 부분 가림을 가진 복잡한 배경(백그라운드)에서도 다시점 객체의 검출이 가능하며, 특히 공유된 지역 특징을 각 클래스에 대해 독립적이기보다 공동으로 공유하여 선택할 수 있도록 함으로써, 분류기의 수를 줄여 최소화하고, 계산의 복잡성을 줄여줄 수 있도록 할 수 있다.

도면의 간단한 설명

[0045] 도 1은 본 발명의 일실시예에 따른 공유 지역 특징을 이용한 다시점 객체 검출 방법의 흐름을 도시한 도면.
 도 2는 본 발명의 일실시예에 따른 공유 지역 특징을 이용한 다시점 객체 검출 방법을 블록 다이어그램으로 도시한 도면.
 도 3은 본 발명의 일실시예에 따른 공유 지역 특징을 이용한 다시점 객체 검출 방법에서, 각 후보 영역에 대해 4개의 서브 영역으로 분할하여 OCS-LBP 특징을 추출하는 블록 다이어그램을 도시한 도면.
 도 4는 본 발명의 일실시예에 따른 공유 지역 특징을 이용한 다시점 객체 검출 방법에서, 정지 영상에서 12개의 뷰 클래스로부터 공유 지역 특징을 선택하는데 사용되는 과정의 블록 다이어그램을 도시한 도면.
 도 5는 본 발명의 일실시예에 따른 공유 지역 특징을 이용한 다시점 객체 검출 방법에 따른 4 가지 관점에서의 공유 지역 특징과 그 위치의 일례를 도시한 도면.
 도 6은 본 발명의 일실시예에 따른 공유 지역 특징을 이용한 다시점 검출 방법에 적용되는 알고리즘의 일례를 도시한 도면.
 도 7 내지 도 13은 본 발명의 일실시예에 따른 공유 지역 특징을 이용한 다시점 검출 방법에 따른 실험 결과를 도시한 도면.

발명을 실시하기 위한 구체적인 내용

[0046] 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.

[0047] 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.

[0048] 도 1은 본 발명의 일실시예에 따른 공유 지역 특징을 이용한 다시점 객체 검출 방법의 흐름을 도시한 도면이고, 도 2는 본 발명의 일실시예에 따른 공유 지역 특징을 이용한 다시점 객체 검출 방법을 블록 다이어그램으로 도시한 도면이다. 도 1에 도시된 바와 같이, 본 발명의 일실시예에 따른 공유 지역 특징을 이용한 다시점 객체 검출 방법은, 트레이닝 영상에서 임의의 위치와 크기를 가지는 후보 영역들을 생성하는 단계(S110), 각 후보 영역에 대해 OCS-LBP 특징을 추출하는 단계(S120), 각 후보 영역별로 추출된 특징 벡터들을 랜덤 포레스트를 통해 지역 기반으로 학습하는 단계(S130), 테스트 영상을 학습된 랜덤 포레스트에 적용하여 확률 값을 추정된 다음 상위 값들을 가지는 지역 특징의 영역을 선택하는 단계(S140), 각 시점에 대해서 공유되는 영역을 찾고, 공유된

지역 특징의 영역에 대해서 랜덤 포레스트로 학습하는 단계(S150), 테스트 영상이 입력되면, 각 관점별로 확률 값이 추정되고, 확률 값 히스토그램을 생성하는 단계(S160), 생성한 확률 값 히스토그램에서 최댓값을 가지는 클래스의 주위 5개의 확률 값에 대해 가중치를 부과한 뒤 선형 결합하여 최종적인 확률 값을 추정하는 단계(S170), 및 추정된 최종적인 확률 값이 미리 설정한 임계값보다 큰 경우에 객체로 검출하는 단계(S180)를 포함하여 구현될 수 있다.

[0049]

단계 S110에서는, 객체를 포함하는 여러 시점(Multi-View)을 가지는 트레이닝 영상에서 임의의 위치와 크기를 가지는 후보 영역(Randomly N Regions)들을 생성한다. 여기서, 단계 S110에서의 후보 영역들은 트레이닝 영상의 원본 이미지에서 객체가 포함된 80×40 의 크기로 조정하여 자른 윈도우 영역에서 수집된 N 개의 훈련 샘플로 구성한다. 또한, 후보 영역들은 80×40 의 크기를 갖는 윈도우 영역에서 최소 10×10 의 크기로부터 최대 40×20 (윈도우 영역의 절반)의 크기를 갖는 지역 특징을 랜덤하게 생성한 것을 사용한다. 또한, 단계 S110에서의 후보 영역들은 도 4에 도시된 바와 같이, 다시점 객체 검출에 필요한 회전 객체의 지역 특징을 위해 30° 간격으로 0° 에서 360° 의 범위에서 12 트레이닝 세트로 지정할 수 있도록 한다. 이는 하나의 뷰의 지역 특징은 $-15^\circ \sim +15^\circ$ 로 회전 객체를 검출할 수 있기 때문이다. 트레이닝 세트는 지역 특징의 특정 위치와 크기를 선택하는 학습 그룹과, 테스트 그룹으로 똑같이 나누어질 수 있도록 한다. 한편, 네거티브 세트는 배경(백그라운드) 영역에서 추출하여 사용할 수 있다.

[0050]

단계 S120에서는, 단계 S110에서 생성한 각각의 후보 영역에 대해 OCS-LBP(Orientation Center Symmetric Local Binary Patterns) 특징을 추출한다. 도 3에 도시된 바와 같이, 단계 S120에서는 후보 영역들 각각에 대해 4개(2×2)의 서브 영역으로 분할하고, 각 서브 영역에서 8차원의 OCS-LBP 특징을 추출한다. 여기서, 후보 영역들은 각 서브 영역에서 추출된 OCS-LBP 특징들을 연결하여 각 후보 영역당 $32(8 \times 4)$ 차원의 특징 벡터를 추출할 수 있다. 본 발명에서는 각 지역에 대해 개별적으로 OCS-LBP 특징을 계산하고, 계산 시간을 줄이기 위해 통합 히스토그램을 사용하여 지역 변화를 유지할 수 있도록 한다.

[0051]

도 3은 본 발명의 일실시예에 따른 공유 지역 특징을 이용한 다시점 객체 검출 방법에서, 각 후보 영역에 대해 4개의 서브 영역으로 분할하여 OCS-LBP 특징을 추출하는 블록 다이어그램을 도시한다. 도 3의 (a)는 후보 영역을 4개의 서브 영역으로 분할하는 과정을 나타내고, 도 3의 (b)는 분할된 서브 영역에서 8차원의 OCS-LBP를 추출하는 과정을 나타내며, 도 3의 (c)는 기울기 방향과 크기를 갖는 OCS-LBP 특징을 나타낸다.

[0052]

OCS-LBP 생성은 하기의 수학식 1에 적용된다.

수학식 1

$$OCS-LBP_{R,N}^k(x,y) = \begin{cases} \|n_i - n_{i+(N/2)}\|_1 & : (n_i - n_{i+(N/2)}) > T_1 \\ 0 & : otherwise \end{cases}$$

($0 < i < (N/2) - 1, k = 0 \dots 7$)

[0053]

[0054]

여기서, n_i 와 $n_{i+(N/2)}$ 는 반경 R을 가진 서클에서 N의 일정한 간격의 픽셀을 위한 픽셀 중심 대칭 쌍의 강도 값에 해당하고, K는 기울기(gradient) 방향의 빈(bin) 번호를 나타낸다.

[0055]

단계 S130에서는, 각각의 후보 영역별로 추출된 특징 벡터들을 랜덤 포레스트를 통해 지역 기반으로 학습한다. 상기 단계 S130에서의 랜덤 포레스트는 도 2 및 도 4에 도시된 바와 같이, 의사 결정 트리를 기반으로 하는 앙상블 분류기로 구성할 수 있으며, 랜덤 포레스트에 적용한 각 트리의 구조를 이진 하향식(top-down) 방식으로 구현하게 된다. 또한, 랜덤 포레스트는 의사 결정 트리를 사용하여 빠른 훈련 속도와 많은 양의 데이터를 처리할 수 있도록 기능한다. 특히, 본 발명에서의 랜덤 포레스트는 지역의 중요성을 기반으로 공유 지역 특징의 선

택에 사용된다. 즉, 본 발명은 지역의 체험적인 선택을 방지하기 위해 정규화 된 객체 윈도우에서 직사각형의 지역 특징의 랜덤 집합을 생성하고, 의미 있는 크기와 지역 특징의 위치를 결정하기 위해 랜덤 포레스트를 공유 분류기로 사용하게 된다.

[0056] 단계 S140에서는, 테스트 영상을 학습된 랜덤 포레스트에 적용하여 확률 값을 추정한 다음 상위 값들을 가지는 지역 특징(Local Features)의 영역을 선택한다.

[0057] 단계 S150에서는, 각 시점에 대해서 선택된 지역 특징의 영역에 대해 공유되는 영역을 찾아 선택하고, 공유된 지역 특징의 영역에 대해서 랜덤 포레스트로 학습한다. 단계 S150에서의 랜덤 포레스트는 동일한 지역 특징을 공유하는 각 뷰 클래스에서 수집된 훈련 데이터를 사용하여 공유 분류기로 훈련하여 공유 지역 특징에 대한 멀티 클래스 분류기를 생성한다. 또한, 일부 특징에 대해서는 다른 관점에서 여러 번 선택된다. 도 4는 정지 영상에서 12개의 뷰 클래스로부터 공유 지역 특징을 선택하는데 사용되는 과정의 블록 다이어그램을 나타낸다.

[0058] 단계 S160에서는, 트레이닝 과정 수행 후, 객체를 검출하기 위해서 테스트 영상이 입력되면, 각각의 관점별로 확률 값이 추정되고, 확률 값 히스토그램을 생성한다. 여기서, 단계 S160에서는 각 공유 분류기들에서 공유되는 멀티 클래스 분류기의 히스토그램 확률 분포로부터 확률 값 히스토그램을 생성하게 된다.

[0059] 단계 S170에서는, 생성한 확률 값 히스토그램에서 추정된 확률 값들 중 최댓값을 찾고, 최댓값을 가지는 클래스의 상위 5개의 확률 값에 대해 가중치를 부과한 뒤 선형 결합하여 최종적인 확률 값을 추정한다. 즉, 1번째 최댓값과 2번째 최댓값에 대해서 상위 5개 확률 값에 대해서 각각 가중치를 부과하고 이를 선형 결합하여 그 값이 더 큰 경우를 최종 확률 값으로 사용하게 된다. 단계 S170에서의 최댓값은 생성한 확률 값 히스토그램에서 가장 기본이 되는 시점을 찾기 위한 최대 함수(Max Operation)를 이용한다.

[0060] 단계 S180에서는, 추정된 최종적인 확률 값이 미리 지정한 임계값보다 큰 경우에 객체로 검출하게 된다. 도 5는 본 발명의 일실시예에 따른 공유 지역 특징을 이용한 다시점 객체 검출 방법에 따른 4 가지 관점에서의 공유 지역 특징과 그 위치의 일례를 나타낸다. 도 5의 (a)는 비행기를 나타내고, 도 5의 (b)는 자동차를 나타내며, 도 5의 (c)는 오토바이의 경우를 나타낸다. 즉, 본 발명에서는 공유 지역 특징에 대한 멀티 클래스 분류기를 생성하기 위해, 랜덤 포레스트를 사용하여 동일한 지역 특징을 공유하는 각 뷰 클래스에서 수집된 훈련 데이터를 사용하여 공유 분류기를 훈련하게 된다.

[0061] 도 6은 본 발명의 일실시예에 따른 공유 지역 특징을 이용한 다시점 검출 방법에 적용되는 알고리즘의 일례를 도시하고, 도 7 내지 도 13은 본 발명의 일실시예에 따른 공유 지역 특징을 이용한 다시점 검출 방법에 따른 실험 결과를 도시한다. 본 발명에서는 공유 지역 특징을 이용한 다시점 검출 방법에 도 6의 알고리즘을 이용하고, 도 7 내지 도 13을 통해 실험 결과를 검증하였다. 먼저, 다시점 객체 검출의 감지 성능을 평가하기 위해, 트레이닝에 여러 뷰를 포함하는 1200 객체 샘플을 사용하고, 배경에서 700 네거티브 샘플을 무작위로 선택하였다. PASCAL VOC 2012 데이터 집합은 서로 다른 규모와 다른 관점에서 총 9415 객체가 포함된 6475 이미지를 구성한다. 테스트 세트의 데이터는 도 8의 테이블과 도 13에 도시되는 다른 스케일과 다른 관점의 객체를 포함한다.

[0062] 도 7은 본 발명의 일실시예에 따른 공유 지역 특징을 이용한 다시점 검출 방법에서, 공유 지역 특징의 적정 개수를 결정하는 여섯 가지의 값을 사용한 실험 결과를 나타낸다. 즉, 임계값에 대한 6가지 값을 사용하여 처리 시간 대비 정밀도와 리콜의 측면에서 실험한 결과를 보여준다. 여기에서는 상대적으로 적은 왜곡과 일정한 형식 패턴 객체를 갖고 공유 지역 특징의 적절한 수를 결정하기 위해 테스트 범주에서 4개의 샘플(비행기, 자전거, 자동차, 오토바이) 객체가 선정되었다.

[0063] 하기의 수학적 식 2와 수학적 식 3은 정밀도와 리콜의 수식을 나타낸다.

수학적 식 2

[0064]
$$Precision = \frac{True\ Positive}{True\ Positive + False\ Positive}$$

수학적 식 3

[0065]
$$Recall = \frac{True\ Positive}{True\ Positive + False\ Negative}$$

[0066] 도 8은 본 발명의 일실시예에 따른 공유 지역 특징을 이용한 다시점 검출 방법에 따른 평균 정확도 결과와, 관점의 분류를 고려하지 않은 종래의 4가지 방법의 평균 정확도 결과의 비교를 나타낸다. 성능은 PASCAL VOC 2012 도전 데이터 집합을 동일하게 사용하여 모든 클래스에 대한 각 클래스의 평균 밀도에 따라 평가하였다. 본 발명은 종래의 4개의 알고리즘보다 우수한 객체 감지 성능을 보여준다. 알고리즘 1보다는 10.3%, 알고리즘 2보다는 8.7%, 알고리즘 3보다는 4.8%, 알고리즘 4보다는 12.6%의 정밀도가 높았다.

[0067] 도 9는 본 발명의 일실시예에 따른 공유 지역 특징을 이용한 다시점 검출 방법을 사용하여 PASCAL VOC 2012 데이터 집합에 따라 관점의 분류에 따른 정밀 평가를 나타내고, 도 10은 본 발명의 일실시예에 따른 공유 지역 특징을 이용한 다시점 검출 방법을 사용하여 PASCAL VOC 2012 데이터 집합에 따라 관점의 분류에 따른 리콜의 평가를 나타낸다. 도 11은 본 발명의 일실시예에 따른 공유 지역 특징을 이용한 다시점 검출 방법을 사용하여 PASCAL VOC 2012 데이터 집합에 따라 관점의 분류를 고려하지 않고 10 객체를 사용한 리콜 결과의 비교를 나타낸다.

[0068] 도 12는 본 발명의 일실시예에 따른 공유 지역 특징을 이용한 다시점 검출 방법을 사용하여 PASCAL VOC 2012 이미지 샘플 객체 검출 결과를 나타내는 것으로서, (a)는 비행기, (b)는 자전거, (c)는 배, (d)는 버스, (e)는 자동차, (f)는 개, (g)는 말, (h)는 오토바이, (i)는 소파, (j)는 기차를 나타낸다. 도 13은 다양한 객체 샘플에서의 샘플 검출 결과를 나타내는 것으로서, 전면 또는 후면 관점, 또는 배경에서 유사한 구조의 존재로 인해 객체의 심각한 중복이 발생하는 다양한 객체 샘플에서의 샘플 검출 결과를 나타내며, 파란색 사각형은 오류의 탐지를 표시하고, 빨간색 사각형은 정확한 탐지를 표시한다.

[0069] 본 발명의 일실시예에 따른 공유 지역 특징을 이용한 다시점 객체 검출 방법의 발명은 컴퓨터로 읽을 수 있는 기록매체에 컴퓨터가 읽을 수 있는 코드로서 구현하는 것이 가능하다. 컴퓨터가 읽을 수 있는 기록매체는 컴퓨터 시스템에 의하여 읽혀질 수 있는 데이터가 저장되는 모든 종류의 기록 장치를 포함한다. 컴퓨터가 읽을 수 있는 기록매체로는 예로는 ROM, RAM, CD-ROM, 자기 테이프, 플로피디스크, 광데이터 저장장치 등이 있으며, 또한 캐리어 웨이브(인터넷을 통한 전송)의 형태로 구현되는 것도 포함한다. 또한, 컴퓨터가 읽을 수 있는 기록매체는 네트워크로 연결된 컴퓨터 시스템에 분산되어 분산방식으로 컴퓨터가 읽을 수 있는 코드가 저장되고 실행될 수 있다.

[0070] 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

[0071]

S110: 트레이닝 영상에서 임의의 위치와 크기를 가지는 후보 영역들을 생성하는 단계

S120: 각 후보 영역에 대해 OCS-LBP 특징을 추출하는 단계

S130: 각 후보 영역별로 추출된 특징 벡터들을 랜덤 포레스트를 통해 지역 기반으로 학습하는 단계

S140: 테스트 영상을 학습된 랜덤 포레스트에 적용하여 확률 값을 추정한 다음 상위 값들을 가지는 지역 특징의 영역을 선택하는 단계

S150: 각 시점에 대해서 공유되는 영역을 찾고, 공유된 지역 특징의 영역에 대해서 랜덤 포레스트로 학습하는 단계


S160: 테스트 영상이 입력되면, 각 관점별로 확률 값이 추정되고, 확률 값 히스토그램을 생성하는 단계

S170: 생성한 확률 값 히스토그램에서 최댓값을 가지는 주위 5개의 확률 값에 대해 가중치를 부과한 뒤 선형 결합하여 최종적인 확률 값을 추정하는 단계


S180: 추정된 최종적인 확률 값이 미리 설정한 임계값보다 큰 경우에 객체로 검출하는 단계

도면


도면1




도면2




도면3



도면4



도면5



도면6

Algorithm 1: Exhaustive greedy selection of local features

Requirements: learning samples for P view classes and k randomly generated local features (regions) ($L_1 \sim L_k$) with a size ranging from a minimum of 10×10 to a maximum of 40×20 (half the size of the window) pixels.

- 1: Select k random seed locations and the sizes of the local features
- 2: For p = 1 to P do
// repeat process 3–8 for all P view classes
- 3: For i = 1 to k do
// repeat process 4 for all k random local features
Generate a set for the i-th local feature $\mathbf{L}_i^p$ with the same location and size from all samples of the p-th view class in the learning group
–The i-th local features of one sample L_i comprise its center position (cx_i, cy_i), the width and height of the local feature (w_i, h_i), and the view index p.
$$L_i = [cx_i, cy_i, w_i, h_i, p_i]^T$$


Extract the OCS-LBP descriptors from the local features in a set $\mathbf{L}_i^p$.
- 4: End For
- 5: Train a random forest using each local set to classify k local features.
Generate sets for the local features $\mathbf{L}_i^p \sim \mathbf{L}_k^p$ from the p-th view class in the test group and extract the OCS-LBP descriptors.
- 6: Use each test set to train a random forest for the p-th view class and compute the posterior probability of k local features.
- 7: Select the top M local features for the p-th view class, which have the highest probabilities among k local features.
- 8: End For
- 9: For m = 1 to $M \times P$
Local feature (L_i) becomes an element of a shared feature set $SF = \{\}$ if the number of overlapping local features among P view classes exceeds the threshold T_2 .

$$\begin{cases} L_m \in SF & \text{if } \sum_{n=0(m \neq n)}^{M \times P} (L_m \cap L_n) > T_2 \\ reject & \text{else} \end{cases} \quad (2)$$

Remarks:

- We set k = 1000, P = 12, and select M = 20 local features.

도면7



도면8

Object	Algorithm 1	Algorithm 2	Algorithm 3	Algorithm 4	Proposed (%)
aeroplane	47.5	45.4	65.1	50.2	60.4
bicycle	51.7	49.8	46.8	47.0	54.1
boat	12.6	16.0	24.6	3.8	40.1
bus	51.8	54.6	51.0	47.2	56.3
car	44.2	44.8	44.9	42.8	52.5
dog	16.9	26.0	40.2	21.3	54.4
horse	46.9	45.6	39.7	43.5	30.3
motorbike	50.9	49.6	51.5	46.4	62.9
sofa	23.6	28.5	33.5	21.5	26.1
train	44.3	45.7	48.0	43.1	55.4
Average	39.0	40.6	44.5	36.7	49.3


도면9

Object	Precision (%) of 12 different viewpoints												Average
	0°~30°	30°~60°	60°~90°	90°~120°	120°~150°	150°~180°	180°~210°	210°~240°	240°~270°	270°~300°	300°~330°	330°~360°	
aeroplane	67.3	66.3	48.0	40.4	67.6	60.7	74.6	65.8	60.7	41.7	56.9	75.5	60.4
bike	70.3	68.3	52.6	35.7	33.1	68.2	70.5	65.3	35.3	24.5	55.7	70.3	54.1
boat	48.0	33.5	63.9	20.7	50.0	43.9	42.6	70.4	23.8	33.8	32.8	17.5	40.1
bus	75.3	52.3	46.7	59.5	70.1	84.6	40.0	55.9	15.9	36.1	63.0	76.3	56.3
car	52.4	57.7	58.9	44.8	50.2	74.6	65.4	49.9	39.8	42.7	35.5	57.7	52.5
dog	30.6	62.7	64.1	66.4	57.3	57.7	68.5	42.6	41.3	51.1	48.2	62.0	54.4
horse	29.0	48.2	30.0	18.1	27.8	30.8	36.7	38.3	40.3	18.0	19.0	27.0	30.3
motorbike	71.8	63.1	46.4	47.8	66.6	82.2	65.1	85.5	70.3	18.1	64.7	73.8	62.9
sofa	25.2	19.9	29.0	14.1	21.7	19.3	40.7	14.6	48.8	22.1	31.8	26.1	26.1
train	42.9	64.3	45.0	43.9	60.1	57.2	68.9	75.0	39.3	20.0	93.8	54.6	55.4
Average	51.3	53.6	48.5	39.1	50.5	57.9	57.3	56.3	41.5	30.8	50.1	54.1	49.3

도면10

Object	Recall (%) of 12 different viewpoints												Average
	0°~30°	30°~60°	60°~90°	90°~120°	120°~150°	150°~180°	180°~210°	210°~240°	240°~270°	270°~300°	300°~330°	330°~360°	
aeroplane	75.4	79.3	62.5	59.1	76.5	72.2	81.0	91.7	66.7	48.2	59.9	81.5	71.2
bike	74.1	72.1	58.1	41.8	48.1	72.3	80.9	70.3	40.5	34.2	60.1	75.5	60.7
boat	52.9	45.8	74.3	24.9	62.9	47.3	53.6	72.1	27.9	48.4	52.9	20.5	48.6
bus	88.3	63.3	63.8	73.2	88.3	94.7	47.9	82.8	26.8	45.0	76.4	85.0	69.6
car	54.0	64.6	67.4	48.3	59.3	78.3	67.9	49.1	46.9	40.3	53.7	58.5	57.4
dog	32.1	75.2	75.3	73.2	67.4	72.2	77.9	50.7	60.0	52.9	60.0	72.5	64.1
horse	32.0	56.0	30.3	22.7	37.3	34.6	38.4	43.5	39.3	21.2	25.5	26.0	33.9
motorbike	78.2	83.0	45.5	59.6	74.7	98.9	70.5	96.2	85.8	22.3	74.7	77.2	72.2
sofa	32.1	20.9	30.3	86.0	45.0	13.5	52.1	6.3	94.0	22.8	35.7	34.5	39.4
train	65.0	81.0	60.4	57.1	75.0	73.3	80.0	75.0	50.0	30.0	99.0	55.1	66.7
Average	58.4	64.1	56.8	54.6	63.5	65.7	65.0	63.8	53.8	36.5	59.8	58.6	58.4

도면11



도면12



도면13

