



(19) 대한민국특허청(KR)  
(12) 공개특허공보(A)

(11) 공개번호 10-2023-0089990  
(43) 공개일자 2023년06월21일

(51) 국제특허분류(Int. Cl.)

G06V 20/40 (2022.01) G06N 3/04 (2023.01)  
G06N 3/08 (2023.01) G06V 10/48 (2022.01)  
G06V 10/74 (2022.01) G06V 20/70 (2022.01)

(52) CPC특허분류

G06V 20/41 (2022.01)  
G06N 3/045 (2023.01)

(21) 출원번호 10-2021-0178836

(22) 출원일자 2021년12월14일

심사청구일자 2021년12월14일

(71) 출원인

고려대학교 산학협력단

서울특별시 성북구 안암로 145, 고려대학교 (안암동5가)

(72) 발명자

김승룡

서울특별시 성북구 오패산로 46, 103동 1804호(하월곡동, 월곡두산위브아파트)

김지원

서울특별시 동작구 동작대로29길 110, 401동 303호(사당동, 신동아아파트)

(74) 대리인

송인호, 윤형근, 최관락

전체 청구항 수 : 총 7 항


(54) 발명의 명칭 특징 추출 네트워크와 비용 집적 네트워크의 공동 학습을 통한 시맨틱 매칭 방법 및 장치

### (57) 요약

본 발명은 특징 추출 네트워크와 비용 집적 네트워크의 공동 학습을 통한 시맨틱 매칭 방법 및 장치를 개시한다. 본 발명에 따르면, 프로세서; 및 상기 프로세서에 연결되는 메모리를 포함하되, 상기 메모리는, 특징 추출 네트워크에 소스 이미지 및 타겟 이미지를 입력하여 상기 소스 이미지에 대한 제1 특징맵 및 상기 타겟 이미지에 대

(뒷면에 계속)

대표도 - 도3



한 제2 특징맵을 추출하고, 상기 제1 및 제2 특징맵의 유사도를 계산하여 비용 볼륨을 생성하고, 비용 집적 네트워크를 통해 집적된 비용 볼륨을 생성하고, 신뢰도 기반 대조 손실 계산부를 통해 상기 비용 볼륨 및 상기 집적된 비용 볼륨 각각에 대한 자체 손실, 상기 특징 추출 네트워크에 의해 생성된 제1 의사 레이블(pseudo label)에 기초한 상기 비용 집적 네트워크의 손실 및 상기 비용 집적 네트워크에 의해 생성된 제2 의사 레이블에 기초한 상기 특징 추출 네트워크의 손실을 계산하고, 상기 계산된 손실을 이용하여 상기 특징 추출 네트워크 및 상기 비용 집적 네트워크를 공동 학습하여 시맨틱 매칭을 수행하도록, 상기 프로세서에 의해 실행 가능한 프로그램 명령어들을 저장하는 시맨틱 매칭 장치가 제공된다.

(52) CPC특허분류

**G06N 3/08** (2023.01)

**G06V 10/48** (2023.01)

**G06V 10/761** (2023.01)

**G06V 20/70** (2023.01)

이 발명을 지원한 국가연구개발사업

|             |                         |
|-------------|-------------------------|
| 과제고유번호      | 1711126325              |
| 과제번호        | 2020-0-01819-002        |
| 부처명         | 과학기술정보통신부               |
| 과제관리(전문)기관명 | 정보통신기획평가원               |
| 연구사업명       | 정보통신방송혁신인재양성(R&D)       |
| 연구과제명       | ICT명품인재양성(고려대학교)        |
| 기 여 율       | 1/1                     |
| 과제수행기관명     | 고려대학교산학협력단              |
| 연구기간        | 2021.01.01 ~ 2021.12.31 |

---

## 명세서

### 청구범위

#### 청구항 1

시맨틱 매칭 장치로서,

프로세서; 및

상기 프로세서에 연결되는 메모리를 포함하되,

상기 메모리는,

특징 추출 네트워크에 소스 이미지 및 타겟 이미지를 입력하여 상기 소스 이미지에 대한 제1 특징맵 및 상기 타겟 이미지에 대한 제2 특징맵을 추출하고,

상기 제1 및 제2 특징맵의 유사도를 계산하여 비용 볼륨을 생성하고,

비용 집적 네트워크를 통해 집적된 비용 볼륨을 생성하고,

신뢰도 기반 대조 손실 계산부를 통해 상기 비용 볼륨 및 상기 집적된 비용 볼륨 각각에 대한 자체 손실, 상기 특징 추출 네트워크에 의해 생성된 제1 의사 레이블(pseudo label)에 기초한 상기 비용 집적 네트워크의 손실 및 상기 비용 집적 네트워크에 의해 생성된 제2 의사 레이블에 기초한 상기 특징 추출 네트워크의 손실을 계산하고,

상기 계산된 손실을 이용하여 상기 특징 추출 네트워크 및 상기 비용 집적 네트워크를 공동 학습하여 시맨틱 매칭을 수행하도록,

상기 프로세서에 의해 실행 가능한 프로그램 명령어들을 저장하는 시맨틱 매칭 장치.

#### 청구항 2

제1항에 있어서,

상기 소스 이미지 및 타겟 이미지는 동일한 범주(category)에 속하며, 서로 다른 형태를 갖는 물체의 이미지인 시맨틱 매칭 장치.

#### 청구항 3

제1항에 있어서,

상기 신뢰도 기반 대조 손실 계산부는,

상기 비용 볼륨 및 상기 집적된 비용 볼륨 각각에 대해, 순방향-역방향 일관성 검사를 통해 순방향 및 역방향으로 미리 설정된 연산자를 적용하여 2개의 의사 매칭 맵(pseudo matching map)을 생성하고,

미리 설정된 일관성 제약 조건을 이용하여 이진 마스크를 생성하고,

상기 이진 마스크를 통해 상기 자체 손실, 상기 제1 의사 레이블에 기초한 상기 비용 집적 네트워크의 손실 및 상기 제2 의사 레이블에 기초한 상기 특징 추출 네트워크의 손실을 계산하는 시맨틱 매칭 장치.

#### 청구항 4

제3항에 있어서,

상기 의사 매칭 맵은 타겟 이미지를 소스 이미지에 맞게 와핑한 의사 매칭 맵과 소스 이미지를 타겟 이미지에 맞게 와핑을 수행한 의사 매칭 맵을 포함하는 시맨틱 매칭 장치.

#### 청구항 5

제1항에 있어서,

상기 특징 추출 네트워크는,

상기 특징 추출 네트워크에 대한 자체 손실 및 상기 비용 집적 네트워크에 의해 생성된 제2 의사 레이블에 기초한 상기 특징 추출 네트워크의 손실을 통해 학습되는 시맨틱 매칭 장치.

## 청구항 6

제1항에 있어서,

상기 비용 집적 네트워크는,

상기 비용 집적 네트워크에 대한 자체 손실 및 상기 특징 추출 네트워크에 의해 생성된 제1 의사 레이블에 기초한 상기 비용 집적 네트워크의 손실을 통해 학습되는 시맨틱 매칭 장치.

## 청구항 7

프로세서 및 메모리를 포함하는 장치에서 시맨틱 매칭하는 방법으로서,

특징 추출 네트워크에 소스 이미지 및 타겟 이미지를 입력하여 상기 소스 이미지에 대한 제1 특징맵 및 상기 타겟 이미지에 대한 제2 특징맵을 추출하는 단계;

상기 제1 및 제2 특징맵의 유사도를 계산하여 비용 볼륨을 생성하는 단계;

비용 집적 네트워크를 통해 집적된 비용 볼륨을 생성하는 단계;

신뢰도 기반 대조 손실 계산부를 통해 상기 비용 볼륨 및 상기 집적된 비용 볼륨 각각에 대한 자체 손실, 상기 특징 추출 네트워크에 의해 생성된 제1 의사 레이블(pseudo label)에 기초한 상기 비용 집적 네트워크의 손실 및 상기 비용 집적 네트워크에 의해 생성된 제2 의사 레이블에 기초한 상기 특징 추출 네트워크의 손실을 계산하는 단계; 및

상기 계산된 손실을 이용하여 상기 특징 추출 네트워크 및 상기 비용 집적 네트워크를 공동 학습하여 시맨틱 매칭을 수행하는 단계를 포함하는 시맨틱 매칭 방법.

## 발명의 설명

### 기술 분야

[0001] 본 발명은 특징 추출 네트워크와 비용 집적 네트워크의 공동 학습을 통한 시맨틱 매칭 방법 및 장치에 관한 것으로, 보다 상세하게는 같은 범주(category)에 속해 있지만, 서로 다른 형태를 띠고 있는 물체 영상에 대한 정합을 목표로 하는 시맨틱 매칭(semantic matching)에 관한 것이다.

### 배경 기술

[0002] 시맨틱 매칭(semantic matching)은 다양한 컴퓨터 비전 애플리케이션에서 필수적인 작업 중 하나이며, 일반적으로 의미론적으로 유사한 이미지 간에 픽셀 단위이지만 지역적으로 일관된 대응 관계를 설정하는 것을 목표로 한다.

[0003] 시맨틱 매칭을 찾는 것은 동일한 클래스 내에서 비강제 변형과 외형의 큰 변화로 인해 매우 어려운 작업이다.

[0004] 이를 위해, 최근에는 심층 CNN(Convolutional Neural Networks)을 설계하는 방식이 제안되고 있고, 네트워크는 보통 특징 추출(feature extraction) 및 비용 집적(cost aggregation) 단계로 구성된다.

[0005] 특징 추출 단계에서, handcrafted descriptor에 의존하는 대신 CNN의 표현력을 활용하는 것에 대한 관심이 증가하고 있으나 반복적인 패턴과 장애물로 인해 모호한 매칭 쌍이 존재할 수 있어 올바른 매칭을 결정하는데 어려움이 있다.

[0006] 비용 집적 네트워크는 학습을 통해 대다수의 고밀도 정보와 모호한 매칭 쌍 사이의 매칭을 줄이는 것을 목표로 한다.

[0007] 감독 학습(Supervised method)로 특징 추출 네트워크와 비용 집적 네트워크를 학습하려면 구축하기 어려운 대규

모의 실측데이터(ground truth)가 필요하다는 문제가 있다.

## 선행기술문헌

### 특허문헌

[0008] (특허문헌 0001) KR 등록특허 10-2289668

## 발명의 내용

### 해결하려는 과제

[0009] 상기한 종래기술의 문제점을 해결하기 위해, 본 발명은 특징 추출 네트워크와 비용 집적 네트워크를 공동으로 학습하여 의미론적 대응의 정확도를 높일 수 있는 시맨틱 매칭 방법 및 장치를 제안하고자 한다.

### 과제의 해결 수단

[0010] 상기한 바와 같은 목적을 달성하기 위하여, 본 발명의 일 실시예에 따르면, 시맨틱 매칭 장치로서, 프로세서; 및 상기 프로세서에 연결되는 메모리를 포함하되, 상기 메모리는, 특징 추출 네트워크에 소스 이미지 및 타겟 이미지를 입력하여 상기 소스 이미지에 대한 제1 특징맵 및 상기 타겟 이미지에 대한 제2 특징맵을 추출하고, 상기 제1 및 제2 특징맵의 유사도를 계산하여 비용 볼륨을 생성하고, 비용 집적 네트워크를 통해 집적된 비용 볼륨을 생성하고, 신뢰도 기반 대조 손실 계산부를 통해 상기 비용 볼륨 및 상기 집적된 비용 볼륨 각각에 대한 자체 손실, 상기 특징 추출 네트워크에 의해 생성된 제1 의사 레이블(pseudo label)에 기초한 상기 비용 집적 네트워크의 손실 및 상기 비용 집적 네트워크에 의해 생성된 제2 의사 레이블에 기초한 상기 특징 추출 네트워크의 손실을 계산하고, 상기 계산된 손실을 이용하여 상기 특징 추출 네트워크 및 상기 비용 집적 네트워크를 공동 학습하여 시맨틱 매칭을 수행하도록, 상기 프로세서에 의해 실행 가능한 프로그램 명령어들을 저장하는 시맨틱 매칭 장치가 제공된다.

[0011] 상기 소스 이미지 및 타겟 이미지는 동일한 범주(category)에 속하며, 서로 다른 형태를 갖는 물체의 이미지일 수 있다.

[0012] 상기 신뢰도 기반 대조 손실 계산부는, 상기 비용 볼륨 및 상기 집적된 비용 볼륨 각각에 대해, 순방향-역방향 일관성 검사를 통해 순방향 및 역방향으로 미리 설정된 연산자를 적용하여 2개의 의사 매칭 맵(pseudo matching map)을 생성하고, 미리 설정된 일관성 제약 조건을 이용하여 이진 마스크를 생성하고, 상기 이진 마스크를 통해 상기 자체 손실, 상기 제1 의사 레이블에 기초한 상기 비용 집적 네트워크의 손실 및 상기 제2 의사 레이블에 기초한 상기 특징 추출 네트워크의 손실을 계산할 수 있다.

[0013] 상기 의사 매칭 맵은 타겟 이미지를 소스 이미지에 맞게 와핑한 의사 매칭 맵과 소스 이미지를 타겟 이미지에 맞게 와핑을 수행한 의사 매칭 맵을 포함할 수 있다.

[0014] 상기 특징 추출 네트워크는, 상기 특징 추출 네트워크에 대한 자체 손실 및 상기 비용 집적 네트워크에 의해 생성된 제2 의사 레이블에 기초한 상기 특징 추출 네트워크의 손실을 통해 학습될 수 있다.

[0015] 상기 비용 집적 네트워크는, 상기 비용 집적 네트워크에 대한 자체 손실 및 상기 특징 추출 네트워크에 의해 생성된 제1 의사 레이블에 기초한 상기 비용 집적 네트워크의 손실을 통해 학습될 수 있다.

[0016] 본 발명의 다른 측면에 따르면, 프로세서 및 메모리를 포함하는 장치에서 시맨틱 매칭하는 방법으로서, 특징 추출 네트워크에 소스 이미지 및 타겟 이미지를 입력하여 상기 소스 이미지에 대한 제1 특징맵 및 상기 타겟 이미지에 대한 제2 특징맵을 추출하는 단계; 상기 제1 및 제2 특징맵의 유사도를 계산하여 비용 볼륨을 생성하는 단계; 비용 집적 네트워크를 통해 집적된 비용 볼륨을 생성하는 단계; 신뢰도 기반 대조 손실 계산부를 통해 상기 비용 볼륨 및 상기 집적된 비용 볼륨 각각에 대한 자체 손실, 상기 특징 추출 네트워크에 의해 생성된 제1 의사 레이블(pseudo label)에 기초한 상기 비용 집적 네트워크의 손실 및 상기 비용 집적 네트워크에 의해 생성된 제2 의사 레이블에 기초한 상기 특징 추출 네트워크의 손실을 계산하는 단계; 및 상기 계산된 손실을 이용하여 상기 특징 추출 네트워크 및 상기 비용 집적 네트워크를 공동 학습하여 시맨틱 매칭을 수행하는 단계를 포함하는 시맨틱 매칭 방법이 제공된다.

**발명의 효과**

[0017] 본 발명에 따르면, 본 발명은 특징 추출 네트워크와 비용 집적 네트워크를 공동으로 학습하여 의미론적 대응의 정확도를 높일 수 있는 장점이 있다.

**도면의 간단한 설명**

[0018] 도 1은 특징 추출 네트워크 및 비용 집적 네트워크 단독 학습 과정을 도시한 도면이다.  
 도 2는 본 실시예에 따른 특징 추출 및 비용 집적 네트워크의 공동 학습을 간략하게 도시한 도면이다.  
 도 3은 본 실시예에 따른 시맨틱 매칭을 위한 프레임워크를 도시한 도면이다.  
 도 4는 본 실시예에 따른 시맨틱 매칭 장치의 구성을 도시한 도면이다.

**발명을 실시하기 위한 구체적인 내용**

[0019] 본 발명은 다양한 변경을 가할 수 있고 여러 가지 실시예를 가질 수 있는 바, 특정 실시예들을 도면에 예시하고 상세하게 설명하고자 한다.

[0020] 그러나, 이는 본 발명을 특정한 실시 형태에 대해 한정하려는 것이 아니며, 본 발명의 사상 및 기술 범위에 포함되는 모든 변경, 균등물 내지 대체물을 포함하는 것으로 이해되어야 한다.

[0022] 본 실시예는 특징 추출 네트워크 및 비용 집적 네트워크의 공동 학습을 통한 시맨틱 매칭 방법을 제안한다.

[0023] 이하에서는, 특징 추출 네트워크 및 비용 집적 네트워크를 우선적으로 설명한다.

[0024] 도 1은 특징 추출 네트워크 및 비용 집적 네트워크 단독 학습 과정을 도시한 도면이다.

[0025] 도 1a를 참조하면, 특징 추출 네트워크 단독 학습에서 소스 이미지( $I_s$ )와 타겟 이미지( $I_t$ )가 특징 추출기에 입력되어, 이들의 특징맵  $D_s$  와  $D_t$  가 추출된다.

[0026] 이후, 각 특징맵의 코사인 유사도가 계산되어 비용 볼륨  $C(i, j)$  이 출력된다.

[0027] 단지 매칭 유사도에만 의존하는 것은 매칭 외측치(outlier)에 민감할 수 있기 때문에 도 1b와 같은 비용 집적 네트워크를 통해 집적된 비용  $A(i, j)$  에 도달하기 위해 초기 매칭 유사도를 개선한다.

[0028] 도 2는 본 실시예에 따른 특징 추출 및 비용 집적 네트워크의 공동 학습을 간략하게 도시한 도면이다.

[0029] 도 2에 도시된 바와 같이, 같이, 본 실시예에 따른 특징 추출 네트워크 및 비용 집적 네트워크에는 비용 볼륨(C)에 따른 손실과 집적된 비용(A)으로부터의 손실이 함께 적용되어 공동 학습이 수행된다.

[0030] 도 3은 본 실시예에 따른 시맨틱 매칭을 위한 프레임워크를 도시한 도면이다.

[0031] 도 3에 도시된 바와 같이, 본 실시예에 따른 프레임워크는 특징 추출기(Feature Extractor, 300) 및 비용 볼륨 생성부(302)를 포함하는 특징 추출 네트워크와 집적된 비용 볼륨을 생성하는 비용 집적부(304)를 포함하는 비용 집적 네트워크를 포함할 수 있다.

[0032] 특징 추출기(300)는 소스 이미지( $I_s$ )와 타겟 이미지( $I_t$ )를 입력으로 하여 이들의 특징맵  $D_s$  (제1 특징맵)와  $D_t$  (제2 특징맵)를 추출한다.

[0033] 여기서, 소스 이미지 및 타겟 이미지는 동일한 범주(category)에 속하며, 서로 다른 형태를 갖는 물체의 이미지이다.

- [0034] 비용 볼륨 생성부(302)는 소스 이미지에 대한 제1 특징맵과 타겟 이미지에 대한 제2 특징맵의 코사인 유사도를 입력으로 하여 비용 볼륨(Cost Volume)을 생성한다.
- [0035] 비용 집계부(304)는 비용 볼륨을 입력으로 하여 집계된 비용 볼륨(Aggregated Cost Volume)을 생성한다.
- [0036] 본 실시예에 따른 프레임워크는 소스 이미지와 타겟 이미지간 순방향 및 역방향 와핑을 통해 손실 함수를 계산하는 신뢰도 기반 대조 손실 계산부(Certainty-aware Contrastive Loss, 306)가 제공된다.
- [0037] 본 실시예에 따른 신뢰도 기반 대조 손실 계산부(306)는 특징 추출 네트워크 및 비용 집계 네트워크 자체의 손실 및 하나의 네트워크를 통해 생성된 의사 레이블(Pseudo label)을 통한 손실을 계산한다.
- [0038] 이하에서는 특징 추출 네트워크에서의 신뢰도 기반 대조 손실 계산 과정을 먼저 설명한다.
- [0039] 상기와 같이 생성된 비용 볼륨에 순방향 및 역방향으로 미리 설정된 연산자를 적용하여 2개의 의사 매칭 맵(pseudo matching map)을 생성한다.
- [0040] 여기서, 의사 매칭 맵은 타겟 이미지를 소스 이미지에 맞게 와핑한 의사 매칭 맵과 소스 이미지를 타겟 이미지에 맞게 와핑을 수행한 의사 매칭 맵을 의미한다.
- [0041] 보다 상세하게, 신뢰도 기반 대조 손실 계산부(306)는 순방향-역방향 일관성 검사(Forward-backward consistency check)를 기반으로 한 고전적인 불확실성 측정에서 시작하여, 순방향 및 역방향에 각각 2번씩  $\arg\max$  연산자를 비용 볼륨에 적용하여, 각각 의사 매칭 맵(pseudo matching map)  $F_{s \rightarrow t}^C$  (타겟 이미지를 소스 이미지에 맞게 와핑을 수행함),  $F_{t \rightarrow s}^C$  (소스 이미지를 타겟 이미지에 맞게 와핑을 수행함)를 생성한다.
- [0042] 신뢰도 기반 대조 손실 계산부(306)는 아래와 같은 일관성 제약(consistency constraint)을 만족하는지 여부를 판단하고, 일관성 제약을 만족하지 못하면, 장애물(occlusion)이 있거나 배경 클러터(background clutter, 배경과 유사한 색의 객체)가 있는 상황이라고 판단한다.

### 수학식 1

$$\|F_{s \rightarrow t}^C(i) + F_{t \rightarrow s}^C(i + F_{s \rightarrow t}^C(i))\|^2 < \alpha_1 (\|F_{s \rightarrow t}^C(i)\|^2 + \|F_{t \rightarrow s}^C(i + F_{s \rightarrow t}^C(i))\|^2) + \alpha_2.$$

- [0043]
- [0044] 신뢰도 기반 대조 손실 계산부(306)는 상기한 일관성 제약 조건을 이용하여 이진 마스크(binary mask)를 생성한다.
- [0045] 특징 추출 네트워크에서의 이진 마스크는  $M^C$  로 표시되며, 이를 통해 사용되지 않는 픽셀은 0으로, 사용되는 픽셀은 1로 표기하여, 대조 손실(contrastive loss)에 신뢰할 수 있는 특징점(reliable feature point)만 사용되도록 만든다.
- [0046] 이진 마스크를 통한 특징 추출 네트워크에서의 손실은 다음과 같이 정의된다.

### 수학식 2

$$\mathcal{L}_{ccl}^C = -\frac{1}{N^C} \sum_i M^C(i) \log \left( \frac{\exp(C(i, i + F_{s \rightarrow t}^C(i))/\gamma)}{\sum_j \exp(C(i, j)/\gamma)} \right)$$

- [0047]
- [0048] 여기서,  $N^C$ 는 가려지지 않은 픽셀의 수이고,  $\gamma$ 는 온도 하이퍼-파라미터이다.

[0049]  $\mathcal{L}_{ccl}^C$  는 특징 추출 네트워크 자체를 훈련하도록 공식화되지만, 해당 손실 함수는 비용 집적 네트워크를 훈련하는데 사용될 수 있는 손실 함수  $\mathcal{L}_{ccl}^A$  로 집적된 비용 볼륨  $A$  에 대해서도 정의할 수 있다.

[0050] 이를 위해, 집적된 비용 볼륨에 대해 순방향 및 역방향으로 미리 설정된 연산자가 적용되고, 일관성 제약의 만족 여부 및 이진 마스크 생성 과정이 동일하게 수행된다.

[0051]  $\mathcal{L}_{ccl}^A$  에서  $M^C$  는  $M^A$  로 표시되고, C는  $A$  로 변경된다.

[0052] 이하에서는, 본 실시예에 따른 공동 학습 과정을 상세하게 설명한다.

[0053] 본 실시예에 따른 신뢰도 기반 대조 손실 함수는 각각의 손실 함수( $\mathcal{L}_{ccl}^C$ ,  $\mathcal{L}_{ccl}^A$ )를 통해 특징 추출 및 비용 집적 네트워크를 학습하는데 독립적으로 사용될 수 있다.

[0054] 그러나 특징 추출 네트워크와 비용 집적 네트워크의 두 개의 의사 레이블(pseudo labels)에 상호 보완적인 정보가 있을 수 있으므로, 두 개의 의사 레이블을 공동 방식으로 사용하면 성능을 더욱 향상시킬 수 있다.

[0055] 여기서, 두 개의 의사 레이블은 특징 추출기(300)에 의해 생성되는 의사 레이블 및 비용 집적부(304)에 의해 생성되는 의사 레이블일 수 있다.

[0056] 예를 들어, 훈련 초기 단계에서 사전 훈련된 특징 추출기(300)에 의한 의사 레이블은 무작위로 초기화된 비용 집적 네트워크에 의한 것보다 더 신뢰할 수 있는 단서를 제공하며, 이는 비용 집적 네트워크가 훨씬 빠르게 수렴하는 데 도움이 될 수 있다.

[0057] 이와 반대로, 훈련이 진행됨에 따라, 잘 훈련된 비용 집적부(304)는 특징 추출기(300)에 의한 의사 레이블보다 우수한 대응 관계를 생성한다.

[0058] 훈련 중 상호 보완 정보를 활용하기 위해, 다음과 같이 정의된 각 모듈의 의사 레이블 출력, 즉 특징 추출기(300) 및 비용 집적부(304)를 모두 사용한다.

### 수학적식 3

$$\mathcal{L}_{ccl}^{A \rightarrow C} = -\frac{1}{N^A} \sum_i M^A(i) \log \left( \frac{\exp(\mathcal{C}(i, i + F_{s \rightarrow t}^A(i))/\gamma)}{\sum_j \exp(\mathcal{C}(i, j)/\gamma)} \right)$$

[0059]

[0060] 여기서,  $\mathcal{L}_{ccl}^{A \rightarrow C}$  는 비용 집적부(304)에 의해 생성된 의사 레이블에 기초하여 계산되는 특징 추출 네트워크의 손실이고,  $F_{s \rightarrow t}^A(i) = \arg \max_j A(i, j')$  이다.

[0061]  $\mathcal{L}_{ccl}^{C \rightarrow A}$  도 비슷하게 정의되며, 특징 추출기(300)에 의해 생성된 의사 레이블에 기초하여 계산되는 비용 집적 네트워크의 손실이다.

[0062]  $\mathcal{L}_{ccl}^{A \rightarrow C}$  및  $\mathcal{L}_{ccl}^{C \rightarrow A}$ 의 계산하는 과정에서, 비용 볼륨 및 집적된 비용 볼륨에 대해 순방향 및 역방향으로 미리 설정된 연산자가 적용되고, 일관성 제약의 만족 여부 및 이진 마스크 생성 과정이 동일하게 수행된다.

[0063] 도 3에 도시된 바와 같이, 본 실시예에 따른 특징 추출기(300)는 특징 추출 네트워크에 대한 자체 손실 및 상기 비용 집적 네트워크에 의해 생성된 제2 의사 레이블에 기초한 특징 추출 네트워크의 손실

( $\mathcal{L}_{ccl}^C + \mathcal{L}_{ccl}^{A \rightarrow C}$ )을 통해 학습된다.

[0064] 또한, 비용 집적부(304)는, 비용 집적 네트워크에 대한 자체 손실 및 특징 추출 네트워크에 의해 생성된 제1 의사 레이블에 기초한 비용 집적 네트워크의 손실( $\mathcal{L}_{ccl}^A + \mathcal{L}_{ccl}^{C \rightarrow A}$ )을 통해 학습된다.

[0065] 본 실시예에 따른 최종 손실 함수는 아래와 같이 정의된다.

[0065] 본 실시예에 따른 최종 손실 함수는 아래와 같이 정의된다.

#### 수학식 4

$$\mathcal{L} = \lambda^C (\mathcal{L}_{ccl}^C + \mathcal{L}_{ccl}^{A \rightarrow C}) + \lambda^A (\mathcal{L}_{ccl}^A + \mathcal{L}_{ccl}^{C \rightarrow A})$$

[0066]

[0067] 여기서,  $\lambda^C$  와  $\lambda^A$  는 하이퍼-파라미터이다.

[0068] 도 4는 본 실시예에 따른 시맨틱 매칭 장치의 구성을 도시한 도면이다.

[0069] 본 실시예에 따른 특징 추출 네트워크 및 비용 집적 네트워크의 공동 학습을 이용한 시맨틱 매칭은 프로세서(400) 및 메모리(402)를 포함하는 장치에서 수행될 수 있다.

[0070] 프로세서(400)는 컴퓨터 프로그램을 실행할 수 있는 CPU(central processing unit)나 그 밖에 가상 머신 등을 포함할 수 있다.


[0071] 메모리(402)는 고정식 하드 드라이브나 착탈식 저장 장치와 같은 불휘발성 저장 장치를 포함할 수 있다. 착탈식 저장 장치는 콤팩트 플래시 유닛, USB 메모리 스틱 등을 포함할 수 있다. 메모리(402)는 각종 랜덤 액세스 메모리와 같은 휘발성 메모리도 포함할 수 있다.

[0072] 본 실시예에 메모리(402)에는 프로그램 명령어들이 저장되며, 프로그램 명령어들은 특징 추출 네트워크에 소스 이미지 및 타겟 이미지를 입력하여 상기 소스 이미지에 대한 제1 특징맵 및 상기 타겟 이미지에 대한 제2 특징맵을 추출하고, 상기 제1 및 제2 특징맵의 유사도를 계산하여 비용 볼륨을 생성하고, 비용 집적 네트워크를 통해 집적된 비용 볼륨을 생성하고, 신뢰도 기반 대조 손실 계산부를 통해 상기 비용 볼륨 및 상기 집적된 비용 볼륨 각각에 대한 자체 손실, 상기 특징 추출 네트워크에 의해 생성된 제1 의사 레이블(pseudo label)에 기초한 상기 비용 집적 네트워크의 손실 및 상기 비용 집적 네트워크에 의해 생성된 제2 의사 레이블에 기초한 상기 특징 추출 네트워크의 손실을 계산하고, 상기 계산된 손실을 이용하여 상기 특징 추출 네트워크 및 상기 비용 집적 네트워크를 공동 학습하여 시맨틱 매칭을 수행할 수 있다.


[0073] 상기한 본 발명의 실시예는 예시의 목적을 위해 개시된 것이고, 본 발명에 대한 통상의 지식을 가지는 당업자라면 본 발명의 사상과 범위 안에서 다양한 수정, 변경, 부가가 가능할 것이며, 이러한 수정, 변경 및 부가는 하기의 특허청구범위에 속하는 것으로 보아야 할 것이다.

도면

도면1




(a) Learning feature extraction only




(b) Learning cost aggregation only

도면2



도면3



도면4

