(19) 대한민국특허청(KR)
(12) 공개특허공보(A)

(11) 공개번호 10-2025-0001211
(43) 공개일자 2025년01월06일

(51) 국제특허분류(Int. Cl.)
G06N 3/096 (2023.01) *G06N 3/0895* (2023.01)
(52) CPC특허분류
G06N 3/096 (2023.01)
G06N 3/0895 (2023.01)
(21) 출원번호 10-2023-0083473
(22) 출원일자 2023년06월28일
심사청구일자 2023년06월28일

(71) 출원인
이화여자대학교 산학협력단
서울특별시 서대문구 이화여대길 52 (대현동, 이화여자대학교)
(72) 발명자
강제원
서울특별시 마포구 독막로 145, 104동 904호(창전동,서강쌍용예가아파트)
유채화
서울특별시 은평구 통일로 925, 409호
(74) 대리인
특허법인(유한)아이시스

전체 청구항 수 : 총 8 항

(54) 발명의 명칭 **멀티 소스 도메인에서 블랙박스 도메인 적응 방법 및 데이터 처리 장치**

(57) 요 약

멀티 소스 도메인에서 블랙박스 도메인 적응 방법은 데이터 처리 장치가 타깃 모델과 타깃 샘플을 획득하는 단계, 상기 데이터 처리 장치가 상기 타깃 샘플을 입력받아 멀티 소스 모델들 각각이 출력하는 예측값들을 획득하는 단계, 상기 데이터 처리 장치가 상기 멀티 소스 모델들이 출력하는 예측값들을 사전에 학습된 네트워크에 입력하여 유사 라벨을 생성하는 단계 및 상기 데이터 처리 장치가 상기 유사 라벨과 상기 타깃 샘플을 이용하여 상기 타깃 샘플을 학습하는 단계를 포함한다. 상기 네트워크는 상기 멀티 소스 모델들이 출력하는 예측값과 상기 타깃 샘플을 입력받아 상기 타깃 모델이 출력하는 예측값을 모두 이용하여 크로스 어텐션을 수행한다.

대 표 도

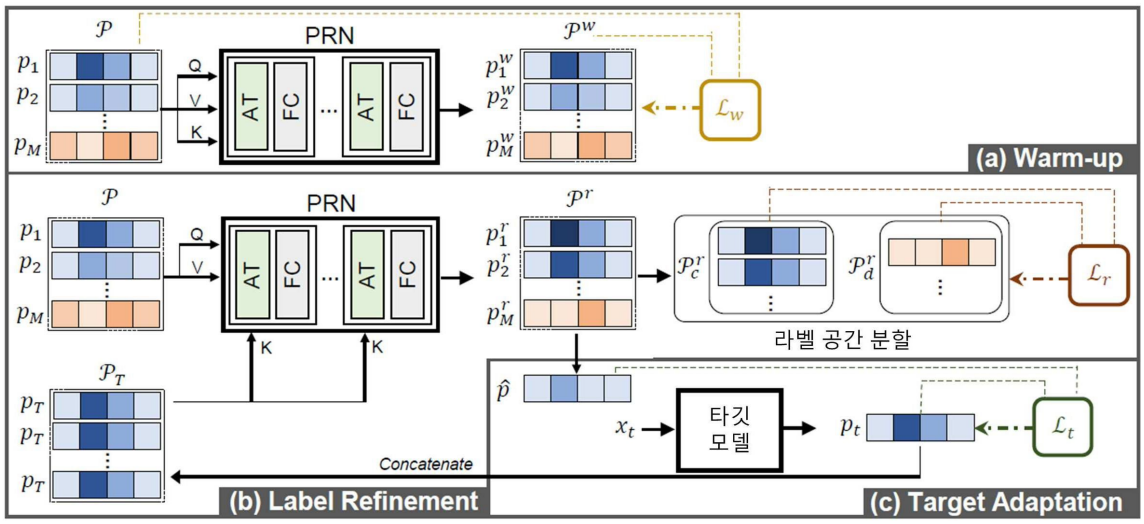

이 발명을 지원한 국가연구개발사업
과제고유번호 1711179344
과제번호 00155966
부처명 과학기술정보통신부
과제관리(전문)기관명 정보통신기획평가원
연구사업명 인공지능융합혁신인재양성(R&D)
연구과제명 인공지능융합혁신인재양성(이화여자대학교)
기 여 율 1/2
과제수행기관명 이화여자대학교산학협력단
연구기간 2023.01.01 ~ 2023.12.31
이 발명을 지원한 국가연구개발사업
과제고유번호 1711190368
과제번호 2022R1A2C4002052
부처명 과학기술정보통신부
과제관리(전문)기관명 한국연구재단
연구사업명 개인기초연구(과기정통부)
연구과제명 거대 공간을 표현하는 대용량 몰입형 비디오의 압축도메인 학습 방법과 입체 공간 피처 레벨 신호처리에 관한 핵심 기술 개발
기 여 율 1/2
과제수행기관명 이화여자대학교
연구기간 2023.03.01 ~ 2024.02.29

명 세 서

청구범위

청구항 1

데이터 처리 장치가 타깃 모델과 타깃 샘플을 획득하는 단계;

상기 데이터 처리 장치가 상기 타깃 샘플을 입력받아 멀티 소스 모델들 각각이 출력하는 예측값들을 획득하는 단계;

상기 데이터 처리 장치가 상기 멀티 소스 모델들이 출력하는 예측값들을 사전에 학습된 네트워크에 입력하여 유사 라벨을 생성하는 단계; 및

상기 데이터 처리 장치가 상기 유사 라벨과 상기 타깃 샘플을 이용하여 상기 타깃 모델을 학습하는 단계를 포함하되,

상기 네트워크는 상기 멀티 소스 모델들이 출력하는 예측값과 상기 타깃 샘플을 입력받아 상기 타깃 모델이 출력하는 예측값을 모두 이용하여 크로스 어텐션을 수행하는 멀티 소스 도메인에서 블랙박스 도메인 적응 방법.

청구항 2

제1항에 있어서,

상기 데이터 처리 장치는 상기 멀티 소스 모델들이 출력하는 예측값들과 상기 예측값을 입력받아 상기 네트워크가 출력하는 값의 분포의 차이가 최소가 되도록 학습된 상기 네트워크를 이용하여 상기 유사 라벨을 생성하는 멀티 소스 도메인에서 블랙박스 도메인 적응 방법.

청구항 3

제1항에 있어서,

상기 네트워크는 어텐션 계층과 전연결 계층이 연결되는 구조를 포함하고,

상기 어텐션 계층은 상기 멀티 소스 모델들이 출력하는 예측값을 쿼리와 값으로 입력받고, 상기 타깃 모델이 출력하는 예측값을 키로 입력받아 상기 크로스 어텐션을 수행하는 멀티 소스 도메인에서 블랙박스 도메인 적응 방법.

청구항 4

제1항에 있어서,

상기 네트워크가 출력하는 예측값들은 상기 멀티 소스 모델들이 출력하는 예측값들 중 진성 라벨에 가장 가까운 하나의 예측값을 기준으로 라벨 공간에서 임계값 범위 내에 위치한 예측값들로 구성되는 제1 라벨 공간과 상기 제1 라벨 공간에 속하지 않은 예측값들로 구성되는 제2 라벨 공간으로 구분되고,

상기 네트워크는 상기 제1 라벨 공간 및 상기 제2 라벨 공간 각각에서 예측값들이 최대한 집중되도록 학습되고, 상기 제1 라벨 공간과 상기 제2 라벨 공간의 거리가 최대한 가깝도록 학습되는 멀티 소스 도메인에서 블랙박스 도메인 적응 방법.

청구항 5

타깃 모델과 타깃 샘플을 입력받는 입력장치;

상기 타깃 모델에 대한 블랙박스 도메인 적응을 위한 유사 라벨을 생성하는 네트워크를 저장하는 저장장치; 및

상기 타깃 샘플을 입력받아 멀티 소스 모델들 각각이 출력하는 예측값들을 상기 네트워크에 입력하여 최종 유사 라벨을 생성하고, 상기 최종 유사 라벨과 상기 타깃 샘플을 이용하여 상기 타깃 모델을 구축하는 연산장치를 포함하되,

상기 네트워크는 상기 멀티 소스 모델들이 출력하는 예측값과 상기 타깃 샘플을 입력받아 상기 타깃 모델이 출

력하는 예측값을 모두 이용하여 크로스 어텐션을 수행하는 블랙박스 도메인 적응을 수행하는 데이터 처리 장치.

청구항 6

제5항에 있어서,

상기 연산장치는 상기 멀티 소스 모델들이 출력하는 예측값들과 상기 예측값을 입력받아 상기 네트워크가 출력하는 값의 분포의 차이가 최소가 되도록 학습된 상기 네트워크를 이용하여 상기 최종 유사 라벨을 생성하는 블랙박스 도메인 적응을 수행하는 데이터 처리 장치.

청구항 7

제5항에 있어서,

상기 네트워크는 어텐션 계층과 전연결 계층이 연결되는 구조를 포함하고,

상기 어텐션 계층은 상기 멀티 소스 모델들이 출력하는 예측값을 쿼리와 값으로 입력받고, 상기 타깃 모델이 출력하는 예측값을 키로 입력받아 상기 크로스 어텐션을 수행하는 블랙박스 도메인 적응을 수행하는 데이터 처리 장치.

청구항 8

제5항에 있어서,

상기 네트워크가 출력하는 예측값들은 상기 멀티 소스 모델들이 출력하는 예측값들 중 진성 라벨에 가장 가까운 하나의 예측값을 기준으로 라벨 공간에서 임계값 범위 내에 위치한 예측값들로 구성되는 제1 라벨 공간과 상기 제1 라벨 공간에 속하지 않은 예측값들로 구성되는 제2 라벨 공간으로 구분되고,

상기 네트워크는 상기 제1 라벨 공간 및 상기 제2 라벨 공간 각각에서 예측값들이 최대한 집중되도록 학습되고, 상기 제1 라벨 공간과 상기 제2 라벨 공간의 거리가 최대한 가깝도록 학습되는 블랙박스 도메인 적응을 수행하는 데이터 처리 장치.

발명의 설명

기 술 분 야

[0001] 이하 설명하는 기술은 멀티 소스 도메인 환경에서의 블랙박스 도메인 적응 기법에 관한 것이다.

배 경 기 술

[0002] 비지도 도메인 적응 (Unsupervised Domain Adaptation, UDA)은 라벨이 있는 소스 도메인의 정보를 전이하여 라벨이 없는 타깃 도메인에 적합한 타깃 모델을 구축하는 기법이다. UDA는 라벨링된 대량의 소스 도메인의 정보가 필요하다.

[0003] 블랙박스 도메인 적응 (Black-box Domain Adaptation, BDA)은 소스 도메인의 정보 없이 소스 모델의 예측만을 이용하여 타깃 모델을 구축하는 기법이다. BDA는 소스 예측으로부터 타깃 모델의 학습에 사용할 유사 라벨을 생성하고 생성된 유사 라벨을 타깃 모델의 자가 학습에 사용한다.

선행기술문헌

특허문헌

[0004] (특허문헌 0001) 미국공개특허 US 제2023-0015246호

발명의 내용

해결하려는 과제

[0005] 종래 BDA는 복수 개의 소스 예측이 있는 경우 소스 도메인 간의 관계성을 무시한다. 따라서, 종래 기법은 멀티

소스를 이용하는 경우 타깃 모델의 성능을 보장하기 어렵다.

[0006] 이하 설명하는 기술은 멀티 소스를 이용하는 경우에도 소스 도메인 간의 관계성 및 개별 소스와 타깃 도메인 간의 관계성을 동시에 사용하는 유사 라벨을 생성하는 기법을 제공하고자 한다.

과제의 해결 수단

[0007] 멀티 소스 도메인에서 블랙박스 도메인 적응 방법은 데이터 처리 장치가 타깃 모델과 타깃 샘플을 획득하는 단계, 상기 데이터 처리 장치가 상기 타깃 샘플을 입력받아 멀티 소스 모델들 각각이 출력하는 예측값들을 획득하는 단계, 상기 데이터 처리 장치가 상기 멀티 소스 모델들이 출력하는 예측값들을 사전에 학습된 네트워크에 입력하여 유사 라벨을 생성하는 단계 및 상기 데이터 처리 장치가 상기 유사 라벨과 상기 타깃 샘플을 이용하여 상기 타깃 모델을 학습하는 단계를 포함한다.

[0008] 블랙박스 도메인 적응을 수행하는 데이터 처리 장치는 타깃 모델과 타깃 샘플을 입력받는 입력장치, 상기 타깃 모델에 대한 블랙박스 도메인 적응을 위한 유사 라벨을 생성하는 네트워크를 저장하는 저장장치 및 상기 타깃 샘플을 입력받아 멀티 소스 모델들 각각이 출력하는 예측값들을 상기 네트워크에 입력하여 최종 유사 라벨을 생성하고, 상기 최종 유사 라벨과 상기 타깃 샘플을 이용하여 상기 타깃 모델을 구축하는 연산장치를 포함한다.

[0009] 상기 네트워크는 상기 멀티 소스 모델들이 출력하는 예측값과 상기 타깃 샘플을 입력받아 상기 타깃 모델이 출력하는 예측값을 모두 이용하여 크로스 어텐션을 수행한다.

발명의 효과

[0010] 이하 설명하는 BDA 기술은 멀티 소스를 대상으로 도메인 간의 관계성을 반영한 유사 라벨을 사용하여 성능이 높은 타깃 모델을 구축할 수 있다.

도면의 간단한 설명

[0011] 도 1은 멀티 소스 환경에서의 블랙박스 도메인 적응을 위한 유사 레이블을 개선하는 과정의 예이다.

도 2는 유사 레이블 개선 네트워크를 이용한 타깃 모델의 자가 학습 과정의 예이다.

도 3은 블랙박스 도메인 적응 기반의 타깃 모델을 제공하는 시스템에 대한 예이다.

도 4는 블랙박스 도메인 적응을 위한 유사 라벨을 생성하는 데이터 처리 장치에 대한 예이다.

발명을 실시하기 위한 구체적인 내용

[0012] 이하 설명하는 기술은 다양한 변경을 가할 수 있고 여러 가지 실시예를 가질 수 있는 바, 특정 실시예들을 도면에 예시하고 상세하게 설명하고자 한다. 그러나, 이는 이하 설명하는 기술을 특정한 실시 형태에 대해 한정하려는 것이 아니며, 이하 설명하는 기술의 사상 및 기술 범위에 포함되는 모든 변경, 균등물 내지 대체물을 포함하는 것으로 이해되어야 한다.

[0013] 제1, 제2, A, B 등의 용어는 다양한 구성요소들을 설명하는데 사용될 수 있지만, 해당 구성요소들은 상기 용어들에 의해 한정되지는 않으며, 단지 하나의 구성요소를 다른 구성요소로부터 구별하는 목적으로만 사용된다. 예를 들어, 이하 설명하는 기술의 권리 범위를 벗어나지 않으면서 제1 구성요소는 제2 구성요소로 명명될 수 있고, 유사하게 제2 구성요소도 제1 구성요소로 명명될 수 있다. 및/또는 이라는 용어는 복수의 관련된 기재된 항목들의 조합 또는 복수의 관련된 기재된 항목들 중의 어느 항목을 포함한다.

[0014] 본 명세서에서 사용되는 용어에서 단수의 표현은 문맥상 명백하게 다르게 해석되지 않는 한 복수의 표현을 포함하는 것으로 이해되어야 하고, "포함한다" 등의 용어는 설명된 특징, 개수, 단계, 동작, 구성요소, 부분품 또는 이들을 조합한 것이 존재함을 의미하는 것이지, 하나 또는 그 이상의 다른 특징들이나 개수, 단계 동작 구성요소, 부분품 또는 이들을 조합한 것들의 존재 또는 부가 가능성을 배제하지 않는 것으로 이해되어야 한다.

[0015] 도면에 대한 상세한 설명을 하기에 앞서, 본 명세서에서의 구성부들에 대한 구분은 각 구성부가 담당하는 주기능 별로 구분한 것에 불과함을 명확히 하고자 한다. 즉, 이하에서 설명할 2개 이상의 구성부가 하나의 구성부로 합쳐지거나 또는 하나의 구성부가 보다 세분화된 기능별로 2개 이상으로 분화되어 구비될 수도 있다. 그리고 이하에서 설명할 구성부 각각은 자신이 담당하는 주기능 이외에도 다른 구성부가 담당하는 기능 중 일부 또는 전부의 기능을 추가적으로 수행할 수도 있으며, 구성부 각각이 담당하는 주기능 중 일부 기능이 다른 구성부에 의

해 전담되어 수행될 수도 있음은 물론이다.

[0016] 또, 방법 또는 동작 방법을 수행함에 있어서, 상기 방법을 이루는 각 과정들은 문맥상 명백하게 특정 순서를 기재하지 않은 이상 명기된 순서와 다르게 일어날 수 있다. 즉, 각 과정들은 명기된 순서와 동일하게 일어날 수도 있고 실질적으로 동시에 수행될 수도 있으며 반대의 순서대로 수행될 수도 있다.

[0018] 이하 설명하는 기술은 블랙박스 도메인 적응 관련 기법이다. 특히 이하 설명하는 기술은 타깃 모델 구축을 위한 유사 라벨 생성 기법에 특징이 있다.

[0019] 타깃 도메인에 대한 타깃 모델은 다양한 학습모델 중 어느 하나일 수 있다. 타깃 모델은 딥러닝 기반의 모델로 영상, 오디오, 텍스트, 자연어 등 다양한 유형의 데이터들 중 적어도 하나를 처리하는 모델일 수 있다. 서비스 측면에서 타깃 모델은 영상 분류, 이미지 쿼리, 자연어 합성 등 다양한 애플리케이션 중 어느 하나에 대한 모델일 수 있다. 이하 설명에서 타깃 모델은 특정 유형의 모델이나 특정 애플리케이션으로 제한하지 않는다.

[0020] 이하 설명에서 데이터 처리 장치가 타깃 모델 학습을 위한 유사 라벨 생성 및 타깃 모델의 학습 등을 수행한다고 설명한다. 데이터 처리 장치는 특정 유형의 데이터 처리 및 타깃 모델 학습 등을 수행할 수 있는 컴퓨팅 장치이다. 데이터 처리 장치는 PC, 스마트기기, 네트워크의 서버, 데이터 처리 전용 칩셋 등 물리적으로 다양한 유형의 장치로 구현될 수 있다.

[0021] 비지도 도메인 적응은 라벨링 된 소스 도메인으로부터 얻어진 도메인 지식을 라벨링 되지 않은 타깃 도메인으로 전이하는 기법이다. 비지도 도메인 적응에서 주로 소스 도메인은 합성 데이터 세트를 사용하고, 타깃 도메인은 실제 데이터 세트를 사용한다. 비지도 도메인 적응의 주요 목표는 소스와 타깃 도메인 사이의 분포 차이의 영향을 줄여 타깃 도메인 데이터에 대한 라벨링 없이도 타깃 모델을 구하는 것이다. 비지도 도메인 적응은 기본적으로 라벨링 된 소스 데이터 또는 소스 데이터로 학습된 소스 모델의 파라미터를 알아야 한다.

[0022] 멀티 소스 도메인 적응 (Multi-source Domain Adaptation)은 비지도 도메인 적응의 확장으로, 다수의 소스 도메인들이 존재하고 타깃 도메인에 가장 가까운 소스를 정확하게 알 수 없는 환경을 고려한다. 이 경우 타깃 도메인의 분포는 멀티 소스 도메인의 가중 합으로 추정될 수 있다.

[0023] 블랙박스 도메인 적응은 소스 데이터와 소스 모델 파라미터의 접근 가능성을 모두 제한한 환경에서 타깃 모델을 구할 때 오직 타깃 샘플에 대한 소스 모델의 예측 값만을 이용한다. 이와 같은 제한된 자원 때문에 직관적인 블랙박스 도메인 적응은 소스 예측 자체를 타깃 샘플의 정답으로 사용하여 지도 학습을 수행한다. 이와 같은 학습 방법은 학습 데이터로부터 얻은 정보만을 사용하여 학습을 수행하는 자가 학습이라고 부른다. 다만, 소스 도메인과 타깃 도메인 간의 데이터 분포가 존재하여 소스 예측의 정확도가 높지 않다. 따라서 데이터 처리 장치는 블랙박스 도메인 적응을 위하여 소스 예측에 대한 디노이징(denoising) 등을 통해 획득한 유사 라벨을 이용한다.

[0024] 멀티 소스를 사용하는 경우, 데이터 처리 장치는 개별 소스 예측들 각각을 디노이징하고, 이 값들을 평균하여 유사 라벨로 정의할 수도 있다. 그러나, 이와 같은 유사 라벨은 소스 도메인들 간의 관계성을 반영하지 못한다는 한계가 있다.

[0026] 이하 데이터 처리 장치가 멀티 소스 환경에서 소스 도메인들 사이의 관계성을 고려하여 유사 라벨을 생성하는 과정을 설명한다.

[0027] 이하 M개의 라벨링된 소스 도메인 $D_S = \{D_1, D_2, \ldots, D_M\}$과 라벨링되지 않은 하나의 타깃 도메인 D_T를 가정한다. X_i 및 Y_i는 각각 D_i에서 추출한 입력 샘플들과 샘플에 대한 라벨(annotation) 세트라고 정의한다. 소스 도메인과 타깃 도메인은 동일한 라벨 공간을 공유한다고 가정한다. 이에 반하여 소스가 다른 입력 샘플들 $x_i \in X_i$과 $x_T \in X_T$는 소스 도메인과 타깃 도메인에서 서로 다른 입력 분포를 갖는다고 가정한다.

[0028] 소스 모델 $f_i \in f_S = \{f_1, f_2, \ldots, f_M\}$는 D_i를 이용하여 학습되고 타깃 도메인 학습에 활용된다. 데이터 처리 장치는 타깃 적응을 위한 가능한 모든 유사 라벨들 P 세트로부터 하나의 유사 라벨 $\hat{p}$를 생성한다. 즉, 데이터 처리 장치는 각 소스에 대하여 타깃 모델을 위한 하나의 유사 라벨을 생성한다($p_i = f_i(x_T) \in P$).

[0029] 이하 설명에서 y_T는 타깃 샘플의 진성 라벨이고, $h \in H$는 타깃 모델을 위한 가설(hypothesis)을 나타낸다. 유사 라벨 생성의 목표는 타깃 에러 $\epsilon(h, \hat{p})$와 오라클 에러(oracle error) $\epsilon(h, y_T)$간의 차이의 이론적인 상한을 찾는 것이다. 상한의 최소화가 위험성 완화 전략으로 유사 라벨을 적응에 유의성을 보장할 수 있다. 위험성의 상한과 관련된 이론적 배경을 간략하게 설명한다.

[0031] 타깃 에러와 오라클 에러 간의 차이에 대한 이론적인 상한은 아래 수학식 1과 같이 정의할 수 있다.

수학식 1

[0032] $$|\epsilon(h, \hat{p}) - \epsilon(h, y_T)| \leq \sum_i \alpha_i \epsilon(p_i, y_T)$$

[0033] 여기서 유사 라벨은 $\hat{p} = \sum_i \alpha_i p_i, \alpha_i \geq 0, \sum_i \alpha_i = 1$와 같이 정의된다.

[0035] 종전 블랙박스 도메인 적응은 소스 예측의 디노이징과 라벨 스무딩을 통해 경험적 에러를 줄이는 방향으로 연구되었다. 이하 설명하는 유사 라벨의 개선은 진성 라벨 없이 다루기 쉬운 항(term)을 이용하여 일반적인 상한을 조절한다.

[0036] 대표 예측 p_c는 가용한 소스 예측들 중 진성 라벨에 가장 가까운 하나의 예측이라고 정의한다. p_c를 고려하여 이론적인 상한은 아래 수학식 2와 같이 조절된다.

수학식 2

[0038] $$|\epsilon(h, \hat{p}) - \epsilon(h, y_T)| \leq \epsilon(p_c, y_T) + \eta$$

[0039] 여기서, $p_c = \arg\min_{p_i \in \mathcal{P}} \epsilon(p_i, y_T)$이고, $\eta = \sum_i \alpha_i \epsilon(p_c, p_i)$이다.

[0041] 수학식 2에서 η은 가중된 에러 항목들에 기인한 P_c의 중심으로부터 소스 예측들의 분산 정도를 나타낸다. η의 최소화는 유사 라벨의 유의성과 관련된 위험도의 상한을 줄일 수 있다. 그러나, 소스 예측들에 있는 일부 이상치들은 최적화를 어렵게 한다. p_c로부터 p_i가 대부분 분산된다면, 페널티를 회피하고자 p_c는 y_T로부터 멀리 위치할 필요가 있다.

[0042] 따라서, 유사 라벨의 개선 과정은 먼저 라벨 공간을 구분한다. 전체 라벨 공간을 P_c와 P_d와 같이 두 개의 서브세트가 있다고 가정한다. 이때 P_c는 위치한 샘플들이 p_c에 집중되는 공간이고, P_d는 위치한 샘플들이 p_c로부터 분산된 공간이라고 정의한다. P_c는 p_c를 기준으로 라벨 공간에서 일정한 임계값 범위 내에 위치한 예측들로 구성된다고 설명할 수 있다. 따라서, 분류 태스크라면 P_c에 속한 예측값들은 동일한 카테고리를 나타내는 값을 해석될 수 있다. P_d는 p_c를 기준으로 라벨 공간에서 일정한 임계값 범위 밖에 위치한 예측들로 구성된다고 설명할 수 있다.

[0043] P_c와 P_d는 수학적으로 아래 수학식 3과 같이 표현할 수 있다.

수학식 3

[0045] $$\mathcal{P}_c = \{p_i | \epsilon(p_c, p_i) \leq \xi\}, \quad \mathcal{P}_d = \mathcal{P} \setminus \mathcal{P}_c$$

[0046] ξ은 라벨 공간을 구분하기 위한 임계값을 나타낸다.

[0048] 그리고, 라벨 공간 P_c와 P_d 각각의 분산 정도 η_c 및 η_d는 각각 아래 수학식 4와 같이 정의할 수 있다.

수학식 4

[0050] $$\eta_c = \sum_{p_i \in \mathcal{P}_c} \alpha_i \epsilon(p_c, p_i), \quad \eta_d = \sum_{p_i \in \mathcal{P}_d} \alpha_i \epsilon(p_d, p_i)$$

[0052] 아래 수학식 5는 라벨 공간이 분할된 상태에서 리스크의 상한을 나타낸다.

수학식 5

[0053] $$|\epsilon(h, \hat{p}) - \epsilon(h, y_T)| \leq \epsilon(p_c, y_T) + \eta_c + \eta_d + \sum_{p_i \in \mathcal{P}_d} \alpha_i \epsilon(p_c, p_d)$$

[0054] p_d는 P_d에서 대표 예측으로 $p_d = \arg\min_{p_i \in \mathcal{P}_d} \epsilon(p_c, p_i)$ 이다.

[0056] 수학식 5에서와 같이 라벨 공간 P_c와 P_d에서 분산이 감소하면, p_c와 p_d 사이의 거리는 상한 보다 낮아진다.

[0058] 대표 예측 $p_c \in P_c$은 타깃 모델의 분류에서 해당 카테고리를 결정할 때 가장 높은 확률을 보이는 소스 예측으로 선택된다. P_d는 $P \setminus P_c$이다. 대표 라벨 $p_d \in P_d$은 p_c의 거리를 줄이기에 적절한 가장 낮은 확률을 갖는 소스 예측으로 선택된다. 이를 통해 수학식 5의 마지막 항목을 줄일 수 있다.

[0060] 이하 도면과 함께 유사 라벨의 개선 과정을 설명한다.

[0061] 데이터 처리 장치는 멀티 소스를 위한 유사 라벨의 개선 과정을 수행한다. 도 1은 멀티 소스 환경에서의 블랙박스 도메인 적응을 위한 유사 라벨을 개선하는 과정의 예이다.

[0062] 데이터 처리 장치는 타깃 모델의 학습에 다수의 소스 모델의 타깃 샘플에 대한 예측값만을 사용한다. 도 1에서 x_T는 타깃 모델에 대한 입력(타깃 샘플)이다. 멀티 소스 모델들은 M개의 소스 도메인 D_i에 대한 소스 모델 f_i로 구성된다. 각 소스 모델 f_i는 예측값 p_i를 출력한다.

[0063] 라벨 공간 P는 소스 예측들로 구성된다. 소스 도메인과 타깃 도메인의 분포 차이에 따라 소스 예측들은 유사 라벨을 만들 때 긍정적인 영향을 주는 소스 예측과 부정적인 영향을 주는 소스 예측으로 구분할 수 있다. 이와 같은 영향을 고려하지 않고, 데이터 처리 장치가 소스 예측들을 모두 합하여 유사 라벨을 생성한다면 유사 라벨의 유의성이 떨어질 수 있다.

[0064] 라벨 공간 P은 전술한 바와 같이 P_d와 P_c로 구분된다. P_c는 유사 라벨을 만들 때 긍정적인 영향을 줄 가능성이 큰 소스 예측이 위치하고, P_d는 유사 라벨을 만들 때 부정적인 영향을 줄 가능성이 큰 소스 예측이 위치한다. 다른 말로 하면 P_c는 소스 예측들 중 가장 특징적인 대표 예측 p_c와 유사한 예측들의 집합이고, P_d는 p_c로부터 멀리 떨어진 예측들의 집합이다.

[0065] 분리된 예측 공간은 대표 예측 p_c의 정의에 따라 달라진다. 비지도 환경에서 타깃 샘플의 실제 정답을 알 수 없기 때문에 p_c는 모델의 수행 태스크의 특성에 따라 다르게 정의될 수 있다.

[0066] 예컨대, K개의 카테고리를 분류하는 태스크에 대해서 p_c는 (i) 전체 소스 예측들 중 임의로 선택된 하나의 예측, (ii) 전체 소스 예측들 중 최대 확률 값이 가장 높은 소스 예측, 또는 (iii) 전체 소스 예측들 중 가장 많이 분류된 카테고리에 속한 예측들 중 가장 높은 최대 확률 값을 갖는 소스 예측 등과 같이 정의할 수 있다.

[0067] 데이터 처리 장치는 p_c를 정의하고, 라벨 공간을 p_c와 동일 카테고리에 속하는 예측들이 속한 공간 P_c와 p_c와 다른 카테고리에 속한 예측들이 속한 공간 P_d으로 분리할 수 있다.

[0068] 유사하게 P_d의 대표 예측 p_d도 (i) P_d에 속한 소스 예측들 중 임의로 선택된 하나의 예측, (ii) P_d에 속한 소스 예측들 중 최대 확률 값이 가장 작은 소스 예측, 또는 (iii) P_d에 속한 소스 예측들 중 최대 확률 값이 가장 높은 소스 예측 등과 같이 정의할 수 있다.

[0069] p_c와 p_d의 정의는 수행 태스크 및 사용자에 따라 다르게 정의될 수 있다.

[0071] 전술한 바와 같이 동일한 라벨 공간의 분산이 감소하고, 서로 다른 라벨 공간들 내지 해당 공간들의 예측값 사이의 거리가 감소하면 유사 라벨의 유의성이 증가한다(보장된다).

[0072] 데이터 처리 장치는 유사 라벨 개선을 위한 별도의 네트워크를 사용한다. 이하 이 네트워크를 유사 라벨 개선 네트워크 (Pseudo label refinery network, PRN)라고 명명하다. 이때 PRN은 멀티 소스 모델이 산출하는 예측값들에 대하여 동일한 라벨 공간에서 예측값들의 집중도(concentration)를 증가하게 하고(= 라벨 공간의 분산 감소), 서로 다른 라벨 공간 사이의 유사도(closeness)를 증가하게 하는 방향으로 학습된다. 도 1의 우측은 PRN을 이용하여 유사 라벨이 개선된 상태를 도시한다.

[0074] 도 2는 유사 라벨 개선 네트워크를 이용한 타깃 모델의 자가 학습 과정의 예이다.

[0075] PRN은 다수의 소스 예측들을 입력 받아 개선된 예측을 출력하는 네트워크이다. PRN은 서로 다른 소스 도메인들 간의 관계뿐만 아니라, 소스 도메인들과 타깃 도메인의 관계도 학습된다. PRN은 라벨 공간 내에 집중도를 높이고, 라벨 공간들 사이의 유사도를 높여 유사 라벨을 유의성을 향상시키도록 학습된다. PRN은 어텐션 계층(Attention layer, AT)과 전열결 계층(fully connected layer, FC)로 구성된 모듈이 연속적으로 반복되는 구조를 갖는다. 이때 AT는 입력 예측 간의 유사성(관계)를 계산하고, FC는 계산된 어텐션을 기준으로 개선된 예측을 출력한다. AT는 소스 예측들 간의 셀프 어텐션(self-attention) 또는 소스 예측과 타깃 예측 간의 크로스 어텐션(cross-attention)을 계산한다. 설명의 편의를 위하여 이하 PRN은 K개 카테고리를 분류하는 태스크를 수행하는 M개의 소스 예측들이 입력된다고 가정한다.

[0076] 도 2의 학습 과정은 (a) 웜-업(warm-up) 단계, (b) 라벨 개선(label refinement) 단계 및 (c) 타깃 적응(target adaptation) 단계로 구성된다.

[0078] **웜-업(warm-up) 단계**

[0079] PRN은 타깃 모델의 학습에 사용될 유사 라벨을 생성하는 네트워크로 원본 소스 예측 $P = [p_1,\ldots,p_M]^T$을 입력 받아 $P^W = [p_1^W,\ldots,p_M^W]^T$을 출력한다. 다만, PRN이 초기 임의의 파라미터를 그대로 사용할 경우 부정확한 유사 라벨을 생성할 수 있다. 웜-업 단계는 이를 방지하기 위해 타깃 모델 학습 이전에 입력 소스 예측과 유사한 예측

을 출력도록 유도한다. 웜-업 단계에서 데이터 처리 장치는 아래 수학식 6에 따른 손실 함수를 이용하여 PRN을 학습한다.

수학식 6

[0081] $$\mathcal{L}_w = \mathbb{E}_{x_t \in \mathcal{X}_T} \mathbb{E}_{i \in \mathcal{I}} \mathcal{KL}(p_i \parallel p_i^w)$$

[0082] KL은 쿨백-라이블러 발산(Kullback-Leiger divergence)이고, I는 카테고리 인덱스 세트이다. 쿨백-라이블러 발산은 두 개의 확률분포의 차이를 계산하는 함수이다. 따라서, 수학식 6의 손실함수는 원본 소스 예측과 PRN이 출력하는 값의 분포 차이가 최소가 되도록 한다.

[0083] 웜-업 단계가 완료되면, p_i^W가 타깃 모델 학습을 위한 초기 유사라벨로 사용될 수 있다. 웜-업 단계는 블랙박스 도메인 적응을 위한 필수적인 단계는 아닐 수도 있다. 이 경우 데이터 처리 장치는 웜-업 단계를 생략하고 라벨 개선 단계를 수행하여 PRN의 학습을 수행하고, 학습된 PRN을 이용하여 유사 라벨을 생성할 수 있다.

[0085] **라벨 개선(label refinement) 단계**

[0086] PRN은 웜-업 단계를 거친 후 타깃 모델의 학습이 시작되면 소스 예측과 타깃 모델의 예측을 동시에 사용하여 예측을 개선한다. 데이터 처리 장치는 PRN 학습에 소스 예측과 함께 타깃 모델이 타깃 도메인 샘플로부터 학습하는 지식을 함께 이용하여 소스 도메인과 타깃 도메인의 데이터 분포 차이에 따른 한계를 개선한다.

[0087] 이때 PRN에서 AT는 원본 소스 예측 P를 쿼리(query, Q)와 값(value, V)으로 사용하고, 타깃 모델의 예측 $p_T = f_T(x_T)$을 키(key, K)로 입력받아 크로스 어텐션을 계산한다. 라벨 개선 단계의 PRN의 출력 P^r은 아래 수학식 7과 같다. 크로스 어텐션은 라벨 공간에서 하나의 타깃 예측에 대하여 다수의 소스 예측들에 대한 어텐션 정도를 계산한다. 이를 통해 PRN이 소스 도메인과 타깃 도메인 사이의 관계성을 반영하도록 한다.

수학식 7

[0089] $$\mathcal{P}^r = [p_1^r \cdots p_M^r]^{\mathrm{T}} = \mathbf{PRN}(\mathcal{P}, \mathcal{P}_T)$$

[0090] $P_T = [p_T, \ldots, p_T]^T \in R^{M \times K}$이다.

[0092] 도 2와 같이 라벨 공간 P^r은 P^r_c와 P^r_d로 분할된다. 전술한 바와 같이 P^r_c는 몇 가지 기준으로 정의될 수 있다. 예컨대, P^r_c는 동일한 분류 결과를 나타내는 유사 라벨들의 다수가 속할 수 있다. 반대로 P^r_d는 서로 다른 분류 결과를 나타내는 유사 라벨들이 속할 수 있다. 데이터 처리 장치는 분리된 라벨 공간 각각에서의 집중도를 높이기 위하여 아래 수학식 8 및 수학식 9에 따른 손실함수를 사용하여 라벨 개선 단계를 수행한다.

수학식 8

[0094] $$\mathcal{L}_{cc} = \mathbb{E}_{x_T \in \mathcal{X}_T} \mathbb{E}_{p^r \in \mathcal{P}_c} \mathcal{KL}(p_c^r \parallel p^r)$$

[0095] $p^r_c \in P^r_c$이다.

수학식 9

[0096] $$\mathcal{L}_{cd} = \mathbb{E}_{x_T \in \mathcal{X}_T} \mathbb{E}_{p^r \in \mathcal{P}_d} \mathcal{KL}(p^r_d \parallel p^r)$$

[0097] $p^r_d \in P^r_d$이다.

[0099] 나아가, 두 개의 분리된 공간의 유사도를 높이기 위하여 데이터 처리 장치는 각 공간의 대표 라벨 간의 거리를 줄이도록 아래 수학식 10과 같은 손실함수를 함께 사용할 수 있다.

수학식 10

[0101] $$\mathcal{L}_{ld} = \mathbb{E}_{x_T \in \mathcal{X}_T} \mathcal{KL}(p^r_c || p^r_d)$$

[0103] 라벨 개선 단계에서 PRN에 적용되는 최종 손실함수는 아래 수학식 11과 같이 표현할 수 있다.

수학식 11

[0105] $$\mathcal{L}_r = \mathcal{L}_{cc} + \mathcal{L}_{cu} + \mathcal{L}_{ld}$$

[0107] **타깃 적응(target adaptation) 단계**

[0108] 타깃 모델의 학습을 위하여 사용하는 최종 유사 라벨 $\hat{p}$은 PRN이 출력하는 예측값들의 평균으로 정의될 수 있다.

수학식 12

[0110] $$\hat{p} = \frac{1}{M} \sum_{i=1}^{M} p^r_i$$

[0112] 데이터 처리 장치는 최종 유사 라벨 $\hat{p}$를 사용하여 타깃 모델의 자가 학습을 수행할 수 있다. 데이터 처리 장치는 아래 수학식 13과 같이 $\hat{p}$로 정의되는 자가 학습 손실을 사용하여 타깃 모델을 구축할 수 있다.

수학식 13

[0114] $$\mathcal{L}_{sl} = \mathbb{E}_{x_T \in \mathcal{X}_T} \mathcal{KL}(\hat{p} \parallel f_T(x_T))$$

[0116] 나아가, 추가적으로(선택적으로) 데이터 처리 장치는 타깃 적응 단계에서 타깃 모델의 출력 예측에 대한 확신을 높이고 타깃 샘플 간의 카테고리별 다양성(diversity)을 높이기 위해 아래 수학식 14와 같은 상호 정보(mutual information) 손실을 더 사용할 수도 있다.

수학식 14

[0118] $$\mathcal{L}_{im} = \mathcal{L}_{ent} + \mathcal{L}_{div} = \mathbb{E}_{x_T \in \mathcal{X}_T} H(f_T(x_T)) - H(\bar{f}_T(x_T))$$

[0119] 수학식 14에서 H는 조건부 크로스 엔트로피 함수이고 $\bar{f}_T(x_T) = \mathbb{E}_{x_T \in \mathcal{X}_T} f_T(x_T)$이다.

[0121] 수학식 14의 손실 함수까지 사용하는 경우, 타깃 적응 단계에서 최종 손실 함수는 $\mathcal{L}_t = \mathcal{L}_{sl} + \lambda_t \mathcal{L}_{im}$이다. λ_t는 하이퍼파라미터이다.

[0123] 연구자는 전술한 PRN을 사용하여 유사 라벨을 개선한 블랙박스 도메인 적응의 성능을 평가하였다. 성능 평가를 위한 데이터 세트는 종전 도메인 적응 연구에 사용된 데이터 세트 Office(Judy Hoffman, Eric Tzeng, Taesung Park, Jun-Yan Zhu, Phillip Isola, Kate Saenko, Alexei Efros, and Trevor Darrell. Cycada: Cycle-consistent adversarial domain adaptation. In International 370 conference on machine learning, pages 1989-1998. PMLR, 2018. 참고), Office-Caltech(Kate Saenko, Brian Kulis, Mario Fritz, and Trevor Darrell. Adapting visual category models to new domains. In European conference on computer vision, pages 213-226. Springer, 2010. 참고), Office-Home(Hemanth Venkateswara, Jose Eusebio, Shayok Chakraborty, and Sethuraman Panchanathan. Deep hashing network for unsupervised domain adaptation. In Proceedings of the IEEE conference on computer vision and pattern recognition, pages 5018-5027, 2017. 참고) 및 DomainNet(Xingchao Peng, Qinxun Bai, Xide Xia, Zijun Huang, Kate Saenko, and Bo Wang. Moment matching for multi-source domain adaptation. In Proceedings of the IEEE/CVF international conference on computer vision, pages 1406-1415, 2019. 참고)을 사용하였다.

[0124] Office는 31개의 카테고리를 갖는 3개의 도메인 Amazon (A), DSLR (D), 및 Web (W)으로 구성된다. Office-Caltech는 10개의 카테고리를 갖는 4개의 도메인 Amazon (A), CalTech (C), DSLR (D) 및 Web (W)으로 구성된다. Office-Home은 65개의 카테고리를 갖는 4개의 도메인 Art (Ar), Clipart (Cl), Product (Pr) 및 Real-Word (Rw)로 구성된다. DomainNet은 60만개의 이미지들에 대하여 345개의 카테고리를 갖는 6개의 도메인 Clipart (Clp), Infograph (Inf), Painting (Pnt), Quickdraw (Qdr), Real (Rel) 및 Sketch (Skt)로 구성된다.

[0125] 연구자는 단일 소스에 대한 블랙박스 도메인 적응으로 개발된 최신 모델 DINE(Jian Liang, Dapeng Hu, Jiashi Feng, and Ran He. Dine: Domain adaptation from single and multiple black-box predictors. In Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, pages 8003-8013, 2022.)과 제안 기법(LPR, Label Space-Induced Pseudo Label Refinement)의 성능을 비교하였다. 아래 표 1은 Office, Office-Caltech 및 Office-Home 데이터 세트를 사용하여 제안 기법(LPR)와 DINE의 성능을 비교한 결과이다. 아래 표 2는 DomainNet 데이터 세트를 사용하여 제안 기법(LPR)와 DINE의 성능을 비교한 결과이다. 아래 표에서 ResNET101, ViT16은 소스 모델의 모델 종류를 나타낸다. 아래 표 1과 표 2는 분류 정확도(accuracy,

%)를 평가 지표로 삼은 것이다. 성능 비교 결과를 살펴보면 제안 기법이 전반적으로 종전 모델 DINE 보다 성능이 높은 것을 알 수 있다. 따라서, 제안 기법이 멀티 소스 환경에서 종전 기법보다 나은 성능을 갖는 것으로 알 수 있다.

표 1

[0127]

f_S	Methods	Setting	Office				Office-Caltech					Office-Home				
			→A	→D	→W	Avg.	→A	→C	→D	→W	Avg.	→Ar	→Cl	→Pr	→Re	Avg.
ResNet101	DINE (w/o FT) [17]	MB	69.2	98.6	**96.9**	88.2	95.0	92.0	98.5	97.3	95.7	70.8	57.1	80.9	82.1	72.7
	LPR (Ours)	MB	**73.6**	**98.7**	96.8	**89.7**	**95.8**	**94.0**	**99.8**	**98.8**	**97.1**	**72.6**	**59.4**	**81.9**	**83.8**	**74.4**
ViT16	DINE (w/o FT) [17]	MB	80.7	98.4	97.1	92.1	96.4	96.0	99.4	98.2	97.5	82.4	61.0	**88.6**	90.8	80.7
	LPR (Ours)	MB	**80.9**	**98.5**	**97.7**	**92.4**	**96.8**	**96.4**	**99.6**	**99.3**	**98.0**	**82.9**	**62.2**	87.1	**91.4**	**80.9**

표 2

[0128]

f_S	Methods	Setting	→Clp	→Inf	→Pnt	→Qdr	→Rel	→Skt	Avg.
ResNet101	DINE (w/o FT) [17]*	MB	61.4	21.5	54.7	**13.4**	**70.9**	50.3	45.4
	LPR (Ours)	MB	**64.4**	**24.1**	**55.3**	12.0	70.3	**51.0**	**46.2**
ViT16	DINE (w/o FT) [17]*	MB	63.0	21.6	56.7	15.0	72.8	50.2	46.5
	LPR (Ours)	MB	**65.1**	**24.3**	**56.9**	**15.3**	**73.1**	**50.7**	**47.6**

[0130] 도 3은 블랙박스 도메인 적응 기반의 타깃 모델을 제공하는 시스템(100)에 대한 예이다.

[0131] 소스 모델 데이터베이스(110)는 멀티 도메인에서의 멀티 소스 모델들을 저장한다.

[0132] 데이터 처리 장치(120)는 소스 모델 DB(110)로부터 멀티 소스 모델을 획득할 수 있다. 데이터 처리 장치(120)는 개발하고자 하는 타깃 모델 및 타깃 샘플을 보유하고 있다고 전제한다.

[0133] 데이터 처리 장치(120)는 도 2에서 설명한 원-업 단계 및 라벨 개선 단계를 통하여 유사 라벨을 생성한다. 이때 PRN은 타깃 모델을 위한 유사 라벨을 생성하기 전에 각 단계의 손실함수를 이용하여 사전에 학습된 상태라고 가정한다. 데이터 처리 장치(120)는 PRN이 멀티 소스 모델과 타깃 모델을 이용하여 생성한 유사 라벨을 이용하여 타깃 모델을 구축한다(타깃 적응 단계).

[0134] 데이터 처리 장치(120)는 구축한 타깃 모델을 이식 대상인 클라이언트 장치(130)에 전달할 수 있다. 이후 클라이언트 장치(130)는 타깃 모델을 이용하여 일정한 서비스를 제공받을 수 있다.

[0136] 도 4는 블랙박스 도메인 적응을 위한 유사 라벨을 생성하는 데이터 처리 장치(200)에 대한 예이다. 데이터 처리 장치(200)는 생성한 유사 라벨을 이용하여 타깃 모델을 구축할 수도 있다.

[0137] 데이터 처리 장치(200)는 물리적으로 다양한 형태로 구현될 수 있다. 예컨대, 데이터 처리 장치(200)는 PC와 같은 컴퓨터 장치, 네트워크의 서버, 데이터 처리 전용 칩셋 등의 형태를 가질 수 있다.

[0138] 데이터 처리 장치(200)는 저장장치(210), 메모리(220), 연산장치(230), 인터페이스 장치(240), 통신장치(250) 및 출력장치(260)를 포함할 수 있다.

[0139] 저장장치(210)는 멀티 소스 모델들을 저장할 수 있다. 멀티 소스 모델들 각각은 서로 다른 소스 도메인들에서 학습된 모델들이다.

[0140] 저장장치(210)는 타깃 모델과 타깃 모델 학습을 위한 타깃 샘플을 저장할 수 있다. 타깃 모델은 애플리케이션에 따라 다양한 모델 중 어느 하나일 수 있다.

[0141] 저장장치(210)는 전술한 유사 라벨 개선 네트워크(PRN)를 저장할 수 있다. PRN은 전술한 바와 같이 멀티 소스 모델들과 타깃 모델을 이용하여 유사 라벨을 생성하도록 학습된 네트워크이다.

[0142] 메모리(220)는 블랙박스 도메인 적응을 위한 유사 라벨을 생성 과정 내지 타깃 모델 구축 과정에서 생성되는 데이터 및 정보 등을 저장할 수 있다.

[0143] 인터페이스 장치(240)는 외부로부터 일정한 명령 및 데이터를 입력받는 장치이다.

[0144] 인터페이스 장치(240)는 멀티 소스 모델들을 입력받을 수 있다.

[0145] 인터페이스 장치(240)는 타깃 모델과 타깃 샘플을 입력받을 수 있다.

[0146] 인터페이스 장치(240)는 블랙박스 도메인 적응으로 구축한 타깃 모델을 외부 객체에 전달할 수 있다.

[0147] 통신장치(250)는 유선 또는 무선 네트워크를 통해 일정한 정보를 수신하고 전송하는 구성을 의미한다.

[0148] 통신장치(250)는 멀티 소스 모델들을 수신할 수 있다.

[0149] 통신장치(250)는 타깃 모델과 타깃 샘플을 수신할 수 있다.

[0150] 통신장치(250)는 블랙박스 도메인 적응으로 구축한 타깃 모델을 사용자 단말 또는 서비스 서버와 같은 외부 객체에 송신할 수도 있다.

[0151] 인터페이스 장치(240)는 통신장치(250)를 통해 수신된 정보를 내부로 전달하는 구성일 수 있다.

[0152] 연산 장치(230)는 PRN에 대하여 전술한 웜-업 단계를 수행할 수 있다. 연산 장치(230)는 PRN에 대하여 수학식 6과 같은 손실함수를 적용하여 입력되는 소스 예측과 유사한 예측을 출력하도록 학습 과정을 수행할 수 있다. 이 과정에서 PRN은

[0153] 연산 장치(230)는 PRN에 대하여 최종 유사 라벨 $\hat{p}'$을 생성하도록 학습 과정을 수행할 수 있다. 연산 장치(230)는 소스 모델의 예측값과 타깃 모델의 예측을 동시에 사용하여 라벨 개선 과정을 수행한다. 구체적으로 연산 장치(230)는 PRN에서 AT가 원본 소스 예측 P를 쿼리(query, Q)와 값(value, V)으로 사용하고, 타깃 모델의 예측 $p_T = f_T(x_T)$을 키(key, K)로 입력받아 크로스 어텐션을 계산한다. 이 과정은 도 2에서 설명한 바와 같다.

[0154] 연산 장치(230)는 PRN이 출력하는 예측들에 대하여 P^r_c와 P^r_d로 라벨 공간을 분리한다. 연산 장치(230)는 분리된 라벨 공간 각각에서의 집중도를 높이기 위하여 수학식 8 및 수학식 9에 따른 손실함수를 사용하여 라벨 개선 단계를 수행한다. 또한, 연산 장치(230)는 두 개의 분리된 공간의 유사도를 높이기 위하여 각 공간의 대표 라벨 간의 거리를 줄이도록 수학식 10과 같은 손실함수를 함께 사용할 수 있다. 이 과정의 학습이 완료되면 PRN은 소스 도메인 간의 관계성뿐만 아니라, 소스 도메인과 타깃 도메인의 관계성이 반영된 최종 유사 라벨 $\hat{p}'$을 생성하게 된다. 이 과정은 도 2에서 설명한 바와 같다.

[0155] 연산 장치(230)는 생성한 유사 라벨 $\hat{p}'$을 이용하여 타깃 모델에 대한 블랙박스 도메인 적응을 수행한다. 이 과정은 도 2에서 설명한 바와 같다.

[0156] 나아가, 연산 장치(230)는 구축한 타깃 모델을 이용하여 일정한 서비스를 제공할 수도 있다.

[0157] 연산 장치(230)는 데이터를 처리하고, 일정한 연산을 처리하는 프로세서, AP, 프로그램이 임베디드된 칩과 같은 장치일 수 있다.

[0158] 출력장치(260)는 일정한 정보를 출력하는 장치이다. 출력장치(260)는 유사 라벨 생성 내지 타깃 모델 구축 과정에 필요한 인터페이스 등을 출력할 수 있다.

[0160] 또한, 상술한 바와 같은 멀티 소스 환경에서 블랙박스 도메인 적응을 위한 유사 라벨 생성 방법 내지 유사 라벨을 이용한 타깃 모델 구축 방법은 컴퓨터에서 실행될 수 있는 실행가능한 알고리즘을 포함하는 프로그램(또는 어플리케이션)으로 구현될 수 있다. 상기 프로그램은 일시적 또는 비일시적 판독 가능 매체(non-transitory

computer readable medium)에 저장되어 제공될 수 있다.

[0161] 비일시적 판독 가능 매체란 레지스터, 캐쉬, 메모리 등과 같이 짧은 순간 동안 데이터를 저장하는 매체가 아니라 반영구적으로 데이터를 저장하며, 기기에 의해 판독(reading)이 가능한 매체를 의미한다. 구체적으로는, 상술한 다양한 어플리케이션 또는 프로그램들은 CD, DVD, 하드 디스크, 블루레이 디스크, USB, 메모리카드, ROM (read-only memory), PROM (programmable read only memory), EPROM(Erasable PROM, EPROM) 또는 EEPROM(Electrically EPROM) 또는 플래시 메모리 등과 같은 비일시적 판독 가능 매체에 저장되어 제공될 수 있다.

[0162] 일시적 판독 가능 매체는 스태틱 램(Static RAM, SRAM), 다이내믹 램(Dynamic RAM, DRAM), 싱크로너스 디램(Synchronous DRAM, SDRAM), 2배속 SDRAM(Double Data Rate SDRAM, DDR SDRAM), 증강형 SDRAM(Enhanced SDRAM, ESDRAM), 동기화 DRAM(Synclink DRAM, SLDRAM) 및 직접 램버스 램(Direct Rambus RAM, DRRAM) 과 같은 다양한 RAM을 의미한다.

[0163] 본 실시예 및 본 명세서에 첨부된 도면은 전술한 기술에 포함되는 기술적 사상의 일부를 명확하게 나타내고 있는 것에 불과하며, 전술한 기술의 명세서 및 도면에 포함된 기술적 사상의 범위 내에서 당업자가 용이하게 유추할 수 있는 변형 예와 구체적인 실시례는 모두 전술한 기술의 권리범위에 포함되는 것이 자명하다고 할 것이다.

도면

도면1

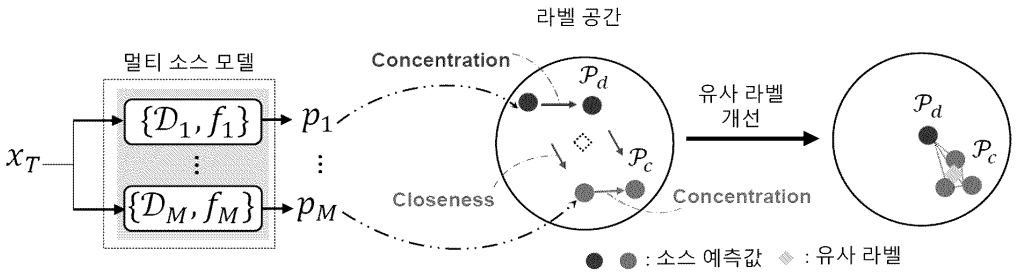

도면2

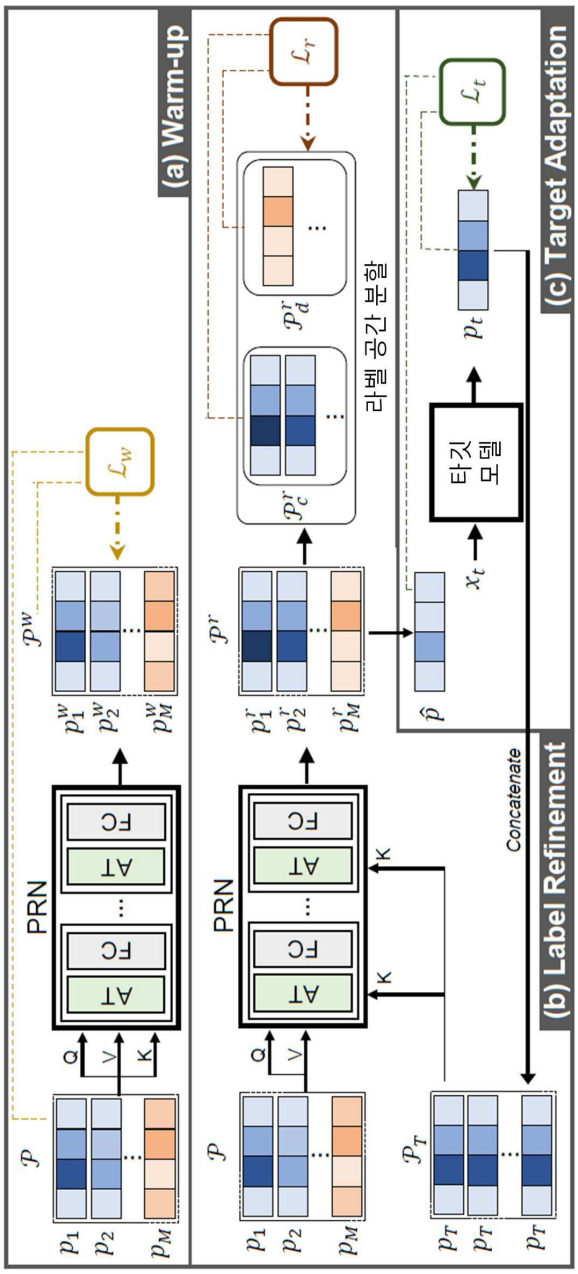
(a) Warm-up
(b) Label Refinement
(c) Target Adaptation
PRN
PRN
Q
V
K
AT
FC
라벨 공간 분할
타깃 모델
Concatenate

도면3

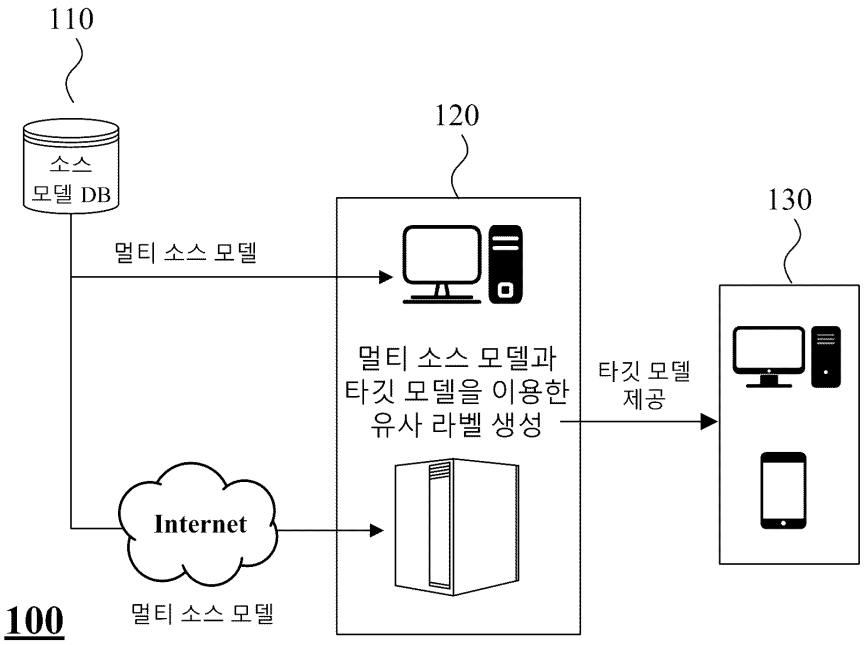
110
소스
모델 DB
120
130
멀티 소스 모델
멀티 소스 모델과
타깃 모델을 이용한
유사 라벨 생성
타깃 모델
제공
Internet
멀티 소스 모델
100

도면4

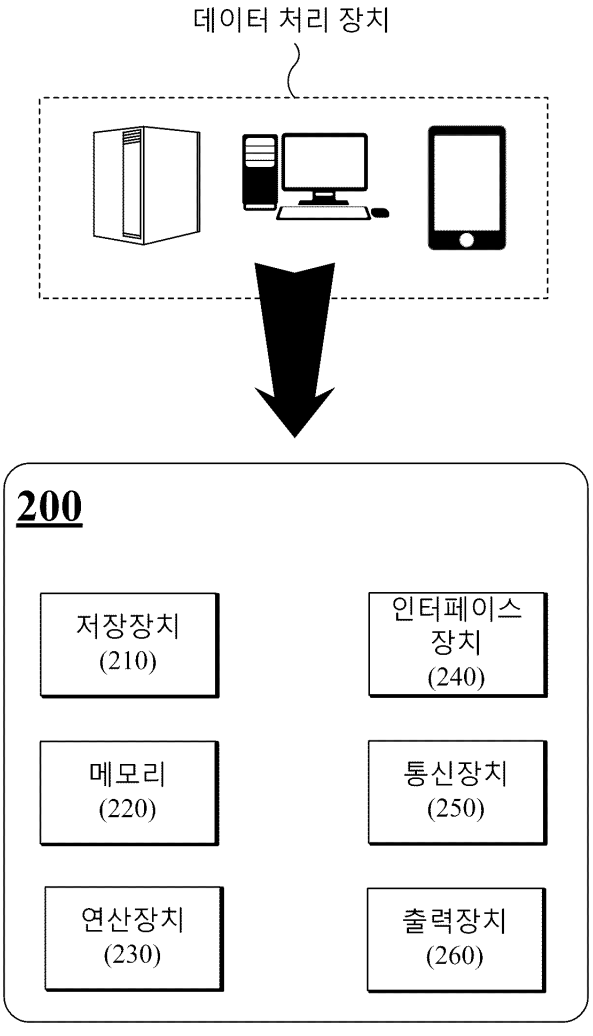
데이터 처리 장치
200
저장장치
(210)
인터페이스
장치
(240)
메모리
(220)
통신장치
(250)
연산장치
(230)
출력장치
(260)