

특집논문 (Special Paper)

방송공학회논문지 제27권 제4호, 2022년 7월 (JBE Vol.27, No.4, July 2022)

<https://doi.org/10.5909/JBE.2022.27.4.511>

ISSN 2287-9137 (Online) ISSN 1226-7953 (Print)

딥러닝 기반의 도메인 적응 기술: 서베이

나재민^{a)}, 황원준^{a)†}

Deep Learning based Domain Adaptation: A Survey

Jaemin Na^{a)} and Wonjun Hwang^{a)†}

요약

딥러닝 기반의 지도학습은 다양한 응용 분야에서 비약적인 발전을 이루었다. 그러나 많은 지도 학습 방법들은 학습 및 테스트 데이터가 동일한 분포에서 추출된다는 공통된 가정 하에 이루어진다. 이 제약 조건에서 벗어나는 경우, 학습 도메인에서 훈련된 딥러닝 네트워크는 도메인 간의 분포 차이로 인하여 테스트 도메인에서의 성능이 급격하게 저하될 가능성이 높다. 도메인 적응 기술은 레이블이 풍부한 학습 도메인 (소스 도메인)의 학습된 지식을 기반으로 레이블이 불충분한 테스트 도메인 (타겟 도메인)에서 성공적인 추론을 할 수 있도록 딥러닝 네트워크를 훈련하는 것이 학습의 한 방법론이다. 특히 비지도 도메인 적응 기술은 타겟 도메인에 레이블이 전혀 없는 이미지 데이터에만 접근할 수 있는 상황을 가정하여 도메인 적응 문제를 다룬다. 본 논문에서는 이러한 비지도 학습 기반의 도메인 적응 기술들에 대해 탐구한다.

Abstract

Supervised learning based on deep learning has made a leap forward in various application fields. However, many supervised learning methods work under the common assumption that training and test data are extracted from the same distribution. If it deviates from this constraint, the deep learning network trained in the training domain is highly likely to deteriorate rapidly in the test domain due to the distribution difference between domains. Domain adaptation is a methodology of transfer learning that trains a deep learning network to make successful inferences in a label-poor test domain (i.e., target domain) based on learned knowledge of a labeled-rich training domain (i.e., source domain). In particular, the unsupervised domain adaptation technique deals with the domain adaptation problem by assuming that only image data without labels in the target domain can be accessed. In this paper, we explore the unsupervised domain adaptation techniques.

Keyword : Deep Learning, Unsupervised Domain Adaptation

a) 이주대학교 인공지능학과(Dept. of Artificial Intelligence, Ajou University)

† Corresponding Author : 황원준(Wonjun Hwang)

E-mail: wjhwang@ajou.ac.kr

Tel: +82-31-219-2632

ORCID: <https://orcid.org/0000-0001-8895-0411>

※ 본 연구는 2022년도 과학기술정보통신부 및 정보통신기획평가원의 대학ICT연구센터육성지원사업 (IITP-2022-2018-0-01431), 2021년도 과학기술정보통신부의 재원으로 정보통신기획평가원 (No.2021-0-00951, (세부2)클라우드 기반 자율주행 AI 학습 SW 개발)과 교육부 및 한국연구재단의 4단계 두뇌한국21 사업(4단계 BK21 사업)으로 지원된 연구임.

• Manuscript May 17, 2022; Revised July 13, 2022; Accepted July 26, 2022.

Copyright © 2022 Korean Institute of Broadcast and Media Engineers. All rights reserved.

“This is an Open-Access article distributed under the terms of the Creative Commons BY-NC-ND (<http://creativecommons.org/licenses/by-nc-nd/3.0>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited and not altered.”

I. 서론

최근 딥러닝 기반의 지도 학습은 다양한 응용 분야에서 큰 성공을 거두고 있다. 그러나 많은 지도 학습 방법에서는 훈련 데이터와 테스트 데이터가 동일한 분포를 갖는다는 가정 하에 이루어진다. 이 가정에서 벗어나면 훈련 데이터에서 훈련된 딥러닝 네트워크는 도메인 간의 차이로 인해 테스트 도메인에서의 성능이 저하될 가능성이 높다. 이 문제를 해결하기 위한 방법 중 하나는 실제 적용할 환경의 데이터를 학습하는 것이다. 그러나 실제 시나리오에서는 이미지 데이터와 정답 레이블을 충분히 생성해야 하기 때문에 시간과 노동력이 많이 소요된다. 딥러닝의 학습 방법을 통해 이러한 문제를 해결하고자 연구되는 도메인 적응 기술은 훈련 도메인에서 학습된 딥러닝 네트워크가 테스트 도메인에서 성능의 큰 저하 없이 적응하는 것을 학습 목표로 한다. 특히, 비지도 학습 도메인 적응은 레이블이 지정된 소스 도메인과 레이블이 전혀 없는 타겟 도메인의 데이터만 학습 중에 사용할 수 있는 상황에서도 타겟 도메인에서의 성능 저하를 효과적으로 막는 방법이다.

본 논문에서는 딥러닝 기반의 비지도 도메인 적응 방법들^[1-10,12,13] 중 적대적 학습 기반의 방법, 슈도 레이블 기반의 방법, 그리고 데이터 증강^[14]을 통한 도메인 적응 방법들의 대표적인 연구들에 대해 탐구한다. 적대적 학습 기반의 방법은 도메인 간의 불변하는 특징을 학습하는 것을 목표로 하여 최근 많은 연구들의 기초모델로 사용된다. 준지도 학습에서 연구되어 온 슈도 레이블 기반의 방법론들은 자

가학습^[17,18]의 관점으로 도메인 적응 기술에 응용되어 좋은 성능 개선효과를 보이고 있다. 특히, 최근에는 도메인 증강 기술을 사용하여 훈련 도메인과 테스트 도메인 사이의 공간들을 생성하고 활용하는 연구들이 활발히 진행되고 있다.

II. 비지도 도메인 적응

1. 적대적 학습 기반의 방법

적대적 학습 기반의 도메인 적응 방법은 adversarial objective를 사용하여 서로 다른 도메인 간의 불일치를 줄이기 위한 방법이다. 도메인 적응에서의 적대적 학습 모델은 GAN(Generative Adversarial Networks)^[1]의 매커니즘을 통해 도메인 간의 불변하는 특징을 식별하기 위해 효과적인 방법이다. 적대적 학습 방법에는 특징을 추출하는 feature extractor와 입력이 어느 도메인의 데이터인지 판별하는 domain discriminator로 이루어진다. Feature extractor는 domain discriminator를 속이기 위해 도메인 간의 불변하는 특징을 학습하는 것을 목표로 한다.

DANN (Domain Adversarial Neural Network)^[2]은 적대적 학습을 이용한 최초의 도메인 적응 방법론이다. DANN은 소스와 타겟 도메인의 구별을 못하게 하는 특징들을 추출하도록 extractor를 학습하는 방법을 사용한다. 학습은 back-propagation시에 gradient에 음의 상수를 곱하여 두 도메인에 대한 특징 분포를 구별할 수 없도록 만드는 Gradi-

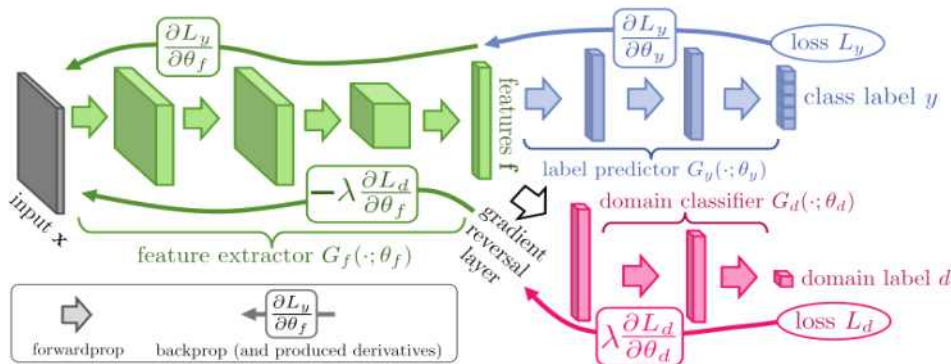


그림 1. DANN 아키텍처^[2]

Fig. 1. The architecture of domain adversarial neural networks (DANN) model^[2]

ent Reversal Layer (GRL)에 의해 달성된다. Domain discriminator는 다음의 cross-entropy를 최소화하는 손실 함수를 갖는다.

Adversarial discriminative domain adaptation (ADDA)은 GAN 손실을 사용하여 소스 및 타겟 도메인을 분할하고 특징을 별도로 학습할 수 있게 한다. ADDA의 학습은 크게 3단계로 이루어진다. 먼저, 레이블이 존재하는 소스 도메인의 데이터를 소스 인코더 CNN을 통해 학습한 다음 (pre-training 단계), 소스와 타겟 도메인을 구별할 수 없도록 domain discriminator를 학습한다 (adversarial adaptation 단계). 테스트하는 동안 타겟 이미지는 타겟 인코더를 사용하여 공유 기능 공간에 매핑되고 소스 분류기에 의해 분류된다 (testing 단계). 이를 통해 소스 분포와 일치하도록 타겟 모델을 수정하는 비대칭 매핑을 효과적으로 학습하게 된다. 이러한 학습 방법은 생성된 공간이 고정된 실제 공간과 구

별할 수 없을 때까지 업데이트 되는 원래의 GAN 학습 설정과 가장 유사하다.

2. 슈도 레이블 기반의 방법

도메인 적응에서 타겟 도메인 데이터에 대한 슈도 레이블 생성은 성능 향상에 도움이 되는 기술이다. 슈도 레이블은 일반적으로 예측된 클래스 확률에 기반하여 타겟 도메인에 대한 슈도 레이블이 생성된다. 일반적으로 비지도 학습 도메인 적응에서는 소스 도메인의 분류기가 타겟 도메인의 슈도 레이블을 생성하기 위한 초기 슈도 레이블러로 사용된다.

Moving semantic transfer network (MSTN)^[4]에서는 슈도 레이블을 얻기 위해 semantic matching과 domain adversary loss를 제안한다. Feature extractor는 레이블이 지정된

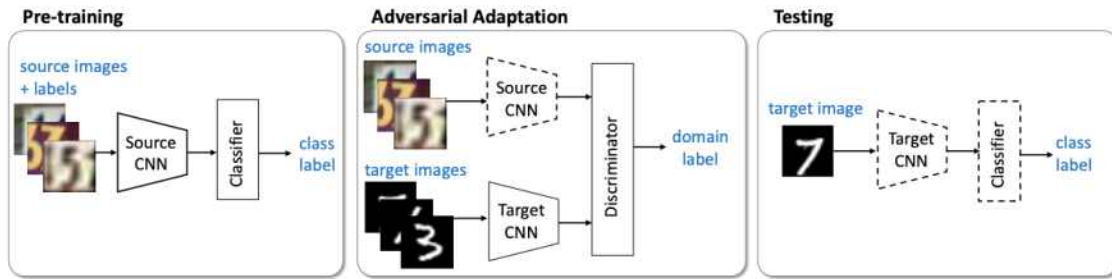


그림 2. ADDA 아키텍처^[3]

Fig. 2. The architecture of adversarial discriminative domain adaptation (ADDA) model^[3]

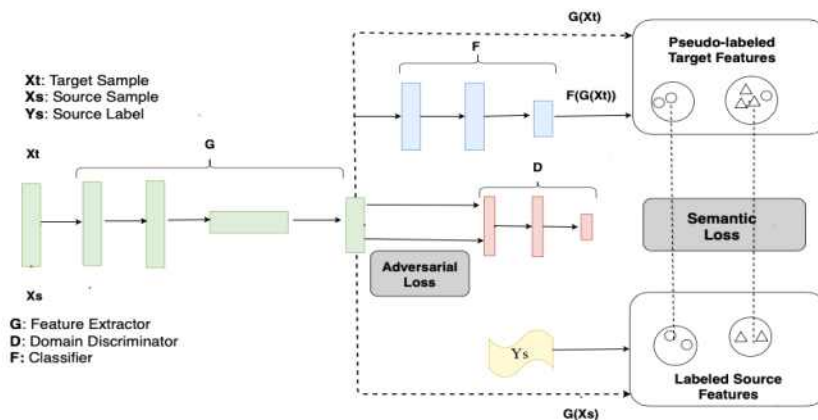


그림 3. MSTN 아키텍처^[4]

Fig. 3. The architecture of moving semantic transfer network (MSTN) model^[4]

타겟 샘플 없이 의미적으로 분포를 정렬하는 방법을 학습한다. 제한된 의미 표현 학습 모듈을 통해 사전 적대적 적응 방법의 능력을 크게 확장한다. 먼저 타겟 레이블 정보가 부족한 문제를 해결하기 위해 타겟 샘플에 슈도 레이블을 할당한다. 슈도 레이블에는 분명히 잘못된 레이블이 있으므로 잘못된 슈도 레이블이 지정된 샘플로 인해 발생하는 편향을 줄이기 위해 올바르게 슈도 레이블이 지정된 샘플을 사용하는 방법을 제안한다.

3. 데이터 증강 기반의 방법

도메인 불변의 특징을 학습하기 위한 비지도 도메인 적응 방법들은 대부분 소스 도메인에서 타겟 도메인으로의

직접적인 도메인 적응을 기반으로 한다. 그러나 이러한 방법들은 소스와 타겟 도메인 간의 차이가 큰 경우에는 효과적으로 처리하기 어렵다. 이러한 문제를 해결하기 위해 소스 도메인과 타겟 도메인 사이의 여러 중간 도메인들을 생성하는 연구들이 진행되었다.

FixBi^[5]는 큰 도메인 불일치를 효율적으로 보상하는 것을 목표로 하여 특성이 다르고 서로 보완적인 여러 중간 증강 도메인을 구성한다. 이를 달성하기 위해 고정 비율 기반 혼합을 제안한다. 제안된 혼합 접근법은 다음의 그림과 같이 소스와 타겟 샘플 사이의 다중 중간 도메인을 생성한다. 소스 도메인에 가까운 증강 도메인의 슈도 레이블은 더 신뢰할 수 있지만 타겟 도메인과의 상관관계는 낮다. 반대로 타겟 도메인에 가까운 도메인의 슈도 레이블은 신뢰하

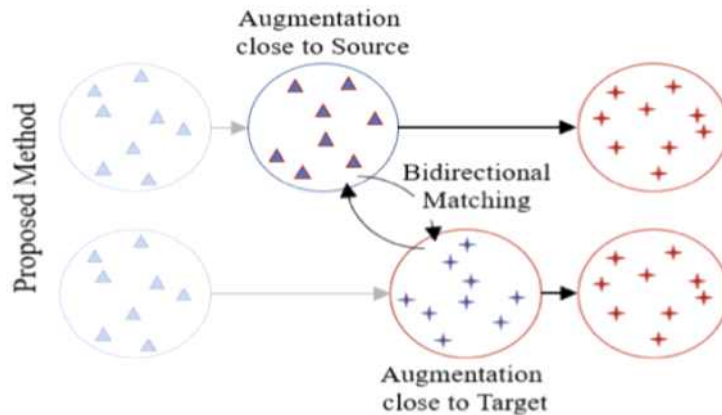


그림 4. 비지도 도메인 적응을 위한 브리징 도메인 공간의 개념도^[5]
 Fig. 4. The concept of bridging domain space for unsupervised domain adaptation^[5]

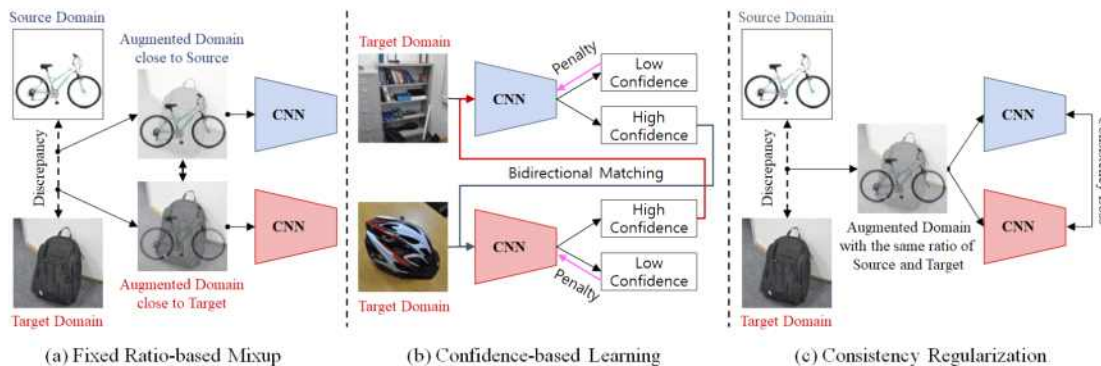


그림 5. FixBi의 제안하는 알고리즘^[5]
 Fig. 5. An algorithm of the FixBi^[5]

기 어렵지만 타겟 도메인과 높은 유사성을 갖는다.

이러한 증강된 도메인에서 소스와 타겟 도메인 사이를 연결하여 서로를 학습시키는 보완 모델을 훈련한다. 특히 타겟 샘플에 대한 각 모델의 높은 신뢰도 예측을 기반으로 하는 양방향 매칭 (그림 5. (b) Bidirectional Matching)을 도입하여 중간 영역을 타겟 영역으로 이동한다. 또한 자체 교육을 통해 성능을 향상시키기 위해 자체 모델에 페널티를 부여하는 자체 페널티 (그림 5. (b) Self-penalization)를 적용한다.

양방향 매칭과 자체 페널티에서는 학습 반복마다 변하는

모델의 특성을 적절하게 부여하기 위해 미리 정의된 것이 아닌 각 미니 배치의 신뢰 분포에 따른 적응 임계값을 사용한다. 마지막으로 서로 다른 영역에서 생성된 증강 모델의 발산을 방지하기 위해 소스 도메인의 샘플과 타겟 도메인의 샘플 비율이 동일한 증강 영역들을 사용하여 일관성 정규화를 적용한다. (그림 5. (c) Consistency Regularization)

Covi^[6]는 소스 도메인과 타겟 도메인 사이에 존재하는 인접 인스턴스 (vicinal instance)에서의 높은 불확실성을 갖는 인스턴스를 찾아 엔트로피를 최소화하는 인스턴스별 minimax 방법을 제안한다. Minimax 문제의 솔루션을 통해 인

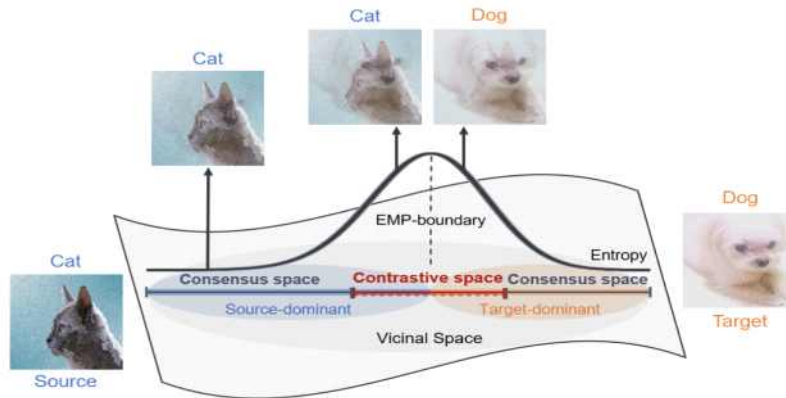


그림 6. 비지도 도메인 적응을 위한 대조적인 주변 공간의 개념도^[6]
 Fig. 6. The concept of contrastive vicinal space for unsupervised domain adaptation^[6]

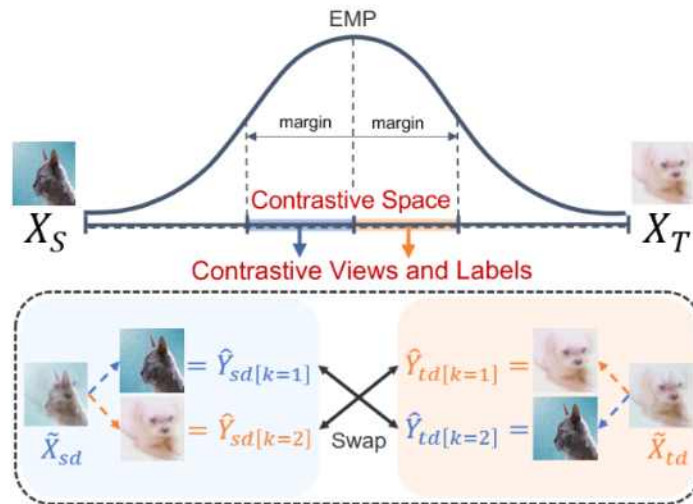


그림 7. 대조적 보기와 레이블 스와핑의 개념도^[6]
 Fig. 7. The concept of swapping contrastive views and labels^[6]

접 공간을 대조 공간과 합 의 공간의 두 부분 공간으로 나눈다. 대조 공간에서는 인스턴스가 대조적인 보기와 레이블을 갖도록 제안하여 도메인 간의 불일치를 완화하고, 합 의 공간에서는 도메인 내에서 생기는 클래스 간의 혼동을 줄인다.

소스 도메인과 타겟 도메인 사이에 존재하는 인접 인스턴스를 각각 대조적인 공간에서 생성하여 그림 7과 같은 대조적 보기를 확보한다. 두 개의 대조적인 보기는 각각 소스 지배적 인스턴스와 타겟 지배적 인스턴스로 구성되며, 이 보기들은 동일한 소스와 타겟 이미지로 구성이 되어있기 때문에, 상위 2개의 레이블이 동일하다는 제약 조건을 통해 일관성을 부여한다.

III. 실험

표준 UDA 프로토콜^[2]을 따라 레이블이 지정된 소스 도메인과 레이블이 존재하지 않은 타겟 데이터를 사용하여 UDA 방법론들의 성능을 비교하였다. UDA용 공개 벤치마크인 Office-31^[15]과 Office-Home^[16]에서 ResNet-50^[18,19]네트워크를 사용하여 비교실험을 진행하였다. 본 실험에서는

데이터 증강 기반의 방법, 슈도 레이블 기반의 방법, 그리고 적대적 학습 방법에서의 대표적인 도메인 적응 기술들의 성능을 비교하여 실험하였다. 본 실험에서는 Stochastic Gradient Descent (SGD) 방식의 학습 방식을 채택하였다.

표 1에서는 Office-31 벤치마크를 통해 도메인 적응 방법들에 대해 성능 비교 실험을 진행하였다. 공개 UDA용 벤치마크인 Office-31은 Amazon(A), Webcam(W), DSLR(D)의 3개 영역에 대해 31개의 범주를 갖는 4,100개의 이미지를 포함한다. 총 6가지 도메인 적응 작업에 대해 평가를 진행하였다. 데이터 증강 기반의 방법인 FixBi와 CoVi가 적대적 학습기반의 방법(DANN)과 슈도 레이블 기반의 방법(MSTN)에 비해 좋은 성능을 보였다. 특히, 데이터 증강 기반의 방법들은 D→A와 W→A와 같이 도메인 차이가 큰 태스크에서 적대적 학습 방법론보다 10% 정도 더 높은 성능 개선 효과를 보였다. 이러한 실험을 통해, 소스와 타겟 도메인 사이의 공간을 생성하고 활용하는 FixBi와 CoVi가 큰 도메인 분포 차이를 극복하는 것에 효과적임을 확인할 수 있다.

표 2에서는 Office-31보다 조금 더 어려운 상황을 가정한 Office-Home 벤치마크에서 실험을 진행하였다. Office-Home은 Artistic images (Ar), Clip art (Cl), Product images

표 1. 비지도 도메인 적응에 대한 Office-31의 정확도(%)

Table 1. Accuracy (%) on Office-31 for unsupervised domain adaptation (ResNet-50)

| Method | Category | A→W | D→W | W→D | A→D | D→A | W→A | Avg |
|-----------|----------------------|------|------|------|------|------|------|------|
| DANN [2] | Adversarial learning | 82.0 | 96.9 | 99.1 | 79.7 | 68.2 | 67.4 | 82.2 |
| MSTN [4] | Pseudo label | 91.3 | 98.9 | 100 | 90.4 | 72.7 | 65.6 | 86.5 |
| FixBi [5] | Augmentation | 96.1 | 99.3 | 100 | 95.0 | 78.7 | 79.4 | 91.4 |
| CoVi [6] | Augmentation | 97.6 | 99.3 | 100 | 98.0 | 77.5 | 78.4 | 91.8 |

표 2. 비지도 도메인 적응에 대한 Office-Home의 정확도(%)

Table 2. Accuracy (%) on Office-Home for unsupervised domain adaptation (ResNet-50)

| Method | Ar→Cl | Ar→Pr | Ar→Rw | Cl→Ar | Cl→Pr | Cl→Rw | Pr→Ar | Pr→Cl | Pr→Rw | Rw→Ar | Rw→Cl | Rw→Pr | Avg |
|-----------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|------|
| DANN [2] | 45.6 | 59.3 | 70.1 | 47 | 58.5 | 60.9 | 46.1 | 43.7 | 68.5 | 63.2 | 51.8 | 76.8 | 57.6 |
| MSTN [4] | 49.8 | 70.3 | 76.3 | 60.4 | 68.5 | 69.6 | 61.4 | 48.9 | 75.7 | 70.9 | 55 | 81.1 | 65.7 |
| FixBi [5] | 58.1 | 77.3 | 80.4 | 67.7 | 79.5 | 78.1 | 65.8 | 57.9 | 81.7 | 76.4 | 62.9 | 86.7 | 72.7 |
| CoVi [6] | 58.5 | 78.1 | 80.0 | 68.1 | 80.0 | 77.0 | 66.4 | 60.2 | 82.1 | 76.6 | 63.6 | 86.5 | 73.1 |

(Pr), 그리고 Real-world images (Rw)의 4가지 도메인으로 구성된다. 총 65개의 범주와 15,500개의 이미지를 포함하고 있다. Office-31에서의 실험결과와 유사하게, 데이터 증강 기반의 방법들 (i.e., FixBi, CoVi) 이 더 효과적인 도메인 적응 성능을 나타내었다. 특히, $Ar \rightarrow Cl$, $Pr \rightarrow Cl$, 그리고 $Rw \rightarrow Cl$ 와 같이 도메인 차이 (Domain shift)가 큰 테스트에서는 데이터 증강 기반의 방법이 적대적 학습 기반의 방법 (DANN)의 성능보다 10% 이상 향상된 결과를 보였다.

IV. 결 론

지도 학습의 경우 딥러닝 네트워크가 널리 사용되지만 이러한 네트워크의 학습을 위해 레이블이 할당된 큰 데이터 세트가 요구된다. 비지도 도메인 적응은 타겟 레이블이 없을 수도 있는 데이터 세트에 딥러닝 네트워크를 적응시키는 데 효과적으로 사용할 수 있다. 본 서베이에서 우리는 비지도 도메인 적응 방법에 대한 기존 연구들을 탐구하였다. 우리는 대표적인 비지도 도메인 적응 방법들을 크게 적대적 학습 기반의 방법, 슈도 레이블 기반의 방법, 그리고 데이터 증강 기반의 방법으로 분류하여 검토하였다. 또한, UDA용 공개 벤치마크에서 각 방법별로 성능을 비교하여 비지도 도메인 적응에 대한 효과를 관찰하였다. 최근 비지도 기반의 도메인 적응 기술들은 준지도 학습, 적대적 학습, 그리고 자가 학습 등의 방법론들과 접목하여 좋은 결과들을 도출해내고 있다. 부족한 레이블 문제를 해결하려는 다양한 분야의 방법론들의 융합된 형태의 기술 발전이 앞으로의 도메인 적응 기술의 발전에 큰 역할을 할 수 있음을 시사한다. 또한, 데이터 증강 기술의 발전은 도메인 적응에서의 큰 도메인 분포 차이를 극복해내기에 핵심적인 역할을 할 수 있을 것으로 기대한다.

참 고 문 헌 (References)

- [1] I. Goodfellow, J. Pouget-Abadie, M. Mirza, B. Xu, D. Warde-Farley, S. Ozair, A. Courville, and Y. Bengio, "Generative adversarial nets" *Advances in neural information processing systems*, Vol.27, 2014.
- [2] Y. Ganin, E. Ustinova, H. Ajakan, P. Germain, H. Larochelle, F. Laviolette, M. Marchand, and V. Lempitsky, "Domain-Adversarial Training of Neural Networks" *The journal of machine learning research*, Vol.17, 2016.
- [3] E. Tzeng, J. Hoffman, J. Saenko, and C. Chen, "Adversarial discriminative domain adaptation" *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2017.
doi: <https://doi.org/10.1109/cvpr.2017.316>
- [4] S. Xie, Z. Zheng, L. Chen, and C. Chen, "Learning semantic representations for unsupervised domain adaptation" *International conference on machine learning*. PMLR, 2018.
- [5] J. Na, H. Jung, H. Chang, and W. Hwang, "FixBi: Bridging Domain Spaces for Unsupervised Domain Adaptation" *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2021.
doi: <https://doi.org/10.1109/cvpr46437.2021.00115>
- [6] J. Na, D. Han, H. Chang, and W. Hwang, "Contrastive Vicinal Space for Unsupervised Domain Adaptation" *arXiv preprint arXiv:2111.13353*, 2021.
- [7] X. Gu, J. Sun, and Z. Xu. "Spherical space domain adaptation with robust pseudo-label loss" In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, pages 9101-9110, 2020.
doi: <https://doi.org/10.1109/cvpr42600.2020.00912>
- [8] K. Saito, Y. Ushiku, and T. Harada. Asymmetric tri-training for unsupervised domain adaptation. *International Conference on Machine Learning*, pages 2988 - 2997. PMLR, 2017.
- [9] G. Kang, L. Jiang, Y. Yang, and A. G. Hauptmann. Contrastive adaptation network for unsupervised domain adaptation. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, pages 4893 - 4902, 944 2019.
doi: <https://doi.org/10.1109/cvpr.2019.00503>
- [10] Mengxue Li, Yi Ming Zhai, You Wei Luo, Peng Fei Ge, and Chuan Xian Ren. Enhanced transport distance for unsupervised domain adaptation. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, pages 13936 - 13944, 2020.
doi: <https://doi.org/10.1109/cvpr42600.2020.01395>
- [11] Shimodaira Hidetoshi. Improving predictive inference under covariate shift by weighting the log-likelihood function. *Journal of statistical planning and inference* 90(2),227 - 244 (2000).
- [12] Xiao, N., Zhang, L.: Dynamic weighted learning for unsupervised domain adaptation. In: *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. pp. 15242 - 15251 (2021)
doi: <https://doi.org/10.1109/cvpr46437.2021.01499>
- [13] Yue, Z., Sun, Q., Hua, X.S., Zhang, H.: Transporting causal mechanisms for un-supervised domain adaptation. In: *Proceedings of the IEEE/CVF International Conference on Computer Vision*. pp. 8599 - 8608 (2021)
doi: <https://doi.org/10.1109/iccv48922.2021.00848>
- [14] Zhang, H., Cisse, M., Dauphin, Y.N., Lopez-Paz, D.: mixup: Beyond empirical risk minimization. *arXiv preprint arXiv:1710.09412* (2017)
- [15] Saenko, K., Kulis, B., Fritz, M., Darrell, T.: Adapting visual category models to new domains. In: *European conference on computer vision*. pp. 213 - 226. Springer(2010)

- doi: https://doi.org/10.1007/978-3-642-15561-1_16
- [16] Venkateswara, H., Eusebio, J., Chakraborty, S., Panchanathan, S.: Deep hashing network for unsupervised domain adaptation. In: Proceedings of the IEEE conference on computer vision and pattern recognition. pp. 5018 - 5027 (2017)
doi: <https://doi.org/10.1109/cvpr.2017.572>
- [17] Lee, D.H., et al.: Pseudo-label: The simple and efficient semi-supervised learning method for deep neural networks. In: Workshop on challenges in representation learning, ICML. p. 896 (2013)
- [18] H. Pham, Z. Dai, Q. Xie, and Q. V. Le. Meta pseudo labels. In Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, pages 11557-11568, 2021.
doi: <https://doi.org/10.1109/cvpr46437.2021.01139>
- [19] He, K., Zhang, X., Ren, S., Sun, J.: Deep residual learning for image recognition. In: Proceedings of the IEEE conference on computer vision and pattern recognition. 770-778 (2016)
doi: <https://doi.org/10.1109/cvpr.2016.90>
- [20] He, K., Zhang, X., Ren, S., Sun, J.: Identity mappings in deep residual networks. In: European conference on computer vision. pp. 630-645. Springer (2016)
doi: https://doi.org/10.1007/978-3-319-46493-0_38

저 자 소 개



나 재 민

- 2018년 3월 ~ 현재 : 아주대학교 인공지능학과 박사과정
- 2018년 2월 : 아주대학교 소프트웨어학과 학사 졸업
- ORCID : <https://orcid.org/0000-0002-8604-2839>
- 주관심분야 : 컴퓨터비전, 딥러닝, 도메인 적응



황 원 준

- 2020년 9월 ~ 현재 : 아주대학교 소프트웨어학과 및 인공지능학과 부교수
- 2016년 9월 ~ 2020년 8월 : 아주대학교 소프트웨어학과 조교수
- 2001년 2월 ~ 2016년 8월 : 삼성종합기술원 전문연구원
- 2016년 2월 : 한국과학기술원 전기 및 전자공학부 박사 졸업
- 2001년 2월 : 고려대학교 전자공학과 석사 졸업
- 1999년 2월 : 고려대학교 전자공학과 학사 졸업
- ORCID : <https://orcid.org/0000-0001-8895-0411>
- 주관심분야 : 컴퓨터비전, 패턴인식, 딥러닝