

비전 모델에 대한 테스트 시기 도메인 적응 기술 동향

윤지석, 박세웅

서울대학교 전기·정보공학부

jsyoun@netlab.snu.ac.kr, sbahk@snu.ac.kr

Trends in Test-Time Domain Adaptation for Vision Models

Jiseok Youn, Saewoong Bahk

Department of Electrical and Computer Engineering, INMC, Seoul National University

요약

딥 러닝 모델이 실상황에서 우수한 성능을 보이기 위해서는 도메인 변화에 의한 성능 저하 현상을 극복하여야 한다. 이를 위해, 실제 시나리오에서의 제약 아래서 변화하는 도메인에 모델을 적응시키는 테스트 시기 도메인 적응 개념이 고안되었다. 본 논문에서는 다양한 접근법 및 실용성 증대의 측면에서 테스트 시기 도메인 적응 기술 동향을 살펴본다.

I. 서론

어느덧, 딥 러닝(Deep learning)은 실생활에서의 여러 어플리케이션을 위해 적극적으로 이용되고 있다. 이는 모델 구조, 데이터 처리 기법, 학습 알고리즘 등 다방면에서의 발전에 따른 우수한 성능 덕분이다. 그러나 실제 시나리오에서 극복해야 할 현상이 여전히 존재하는 데, 대표적으로 도메인 변화(Domain shift)에 의한 테스트 성능 저하가 있다. 도메인 변화란, 모델의 학습에 사용한 데이터의 도메인(소스 도메인, Source domain)과 테스트에 투입되는 데이터의 도메인(타겟 도메인, Target domain) 사이의 차이를 뜻한다. 학계에서도 ImageNet-C [1], DomainNet [2]과 같이 이러한 도메인 변화를 모사한 데이터셋을 성능 평가에 사용하고 있다.

전이 학습(Transfer learning), 메타학습(Meta-learning) 등의 익히 알려진 기술은 모델을 타겟 도메인에 적응시킴으로써 테스트 성능 저하를 막을 수 있다. 그러나, 보다 실제에 가까운 시나리오에서는 ▶ 학습 단계 동작을 바꾸지 않을 것, ▶ 소스 도메인 데이터 접근을 금할 것, ▶ 타겟 도메인 데이터의 ground truth를 사용하지 않을 것 등의 추가 요건이 존재한다. 이 모든 요건을 만족하기 위해 테스트 시기 도메인 적응(Test-Time domain Adaptation, TTA)이 새로운 연구 갈래로 등장하였다.

본 논문에서는 CNN (Convolutional Neural Network), ViT (Vision Transformer) [3] 등의 비전 모델에 적용할 수 있는 TTA 기술 동향을 소개한다.

II. 본론

- 다양한 접근법을 가진 TTA 기법들

Tent [4]는 CNN 모델 구조에서 주로 채용하는 Batch Normalization (BN) 레이어의 affine parameter 및 statistics만을 타겟 데이터를 통해 조정함으로써 타겟 도메인에 적응한다. 먼저 사전 학습된 모델에 타겟 데이터를 입력으로 삼아 순전파 과정을 수행하는데, BN statistics는 항상 입력 batch의 statistics를 사용한다. 이후 도출된 softmax 출력의 entropy를 구하여 이를 손실 함수로 삼고 역전파 과정을 수행하는데, 최적화는 오직 BN affine parameter에 한하여 이루어진다.

T3A [5]는 feature space 상에서 각 class를 대표하는 지점인 pseudo-prototype을 타겟 데이터를 참고하여 정하고, 이를 기준으로 추론 과정을 진행함으로써 타겟 도메인에 적응한다. 먼저 각 class마다 support set을 두고, 타겟 데이터를 샘플(이미지) 단위로 입력시키며 support set(s) 내의 원소를 변화시킨다. 어떤 샘플이 모델을 통해 특정 class로 예측된 경우 해당 support set의 규모는 커지고, 어떤 샘플이 모델을 통과해 도출된 출력의 entropy가 기준보다 높을 경우 해당 support set의 규모는 작아진다. 이 과정이 끝나면 각 support set의 centroid를 pseudo-prototype으로 간주하여 이를 통해 타겟 데이터를 추론한다.

LAME [6]은 기존(특히 모델 파라미터를 조정하는) TTA 기법의 성능이 그 hyperparameter tuning의 정확도에 크게 의존한다는 한계점을 지적하며, 오직 모델의 출력만을 조정함으로써 타겟 도메인에 적응하는 접근법을 취한다. 모델 출력 최적화를 위한 손실 함수는 ▶ 유사성이 높은 샘플끼리 가깝게 묶을 것(Graph clustering), ▶ 원래 모델 출력과 너무 달라지지 않을 것 등을 의도하여 설계되었다. 해당 손실 함수는 concave term과 convex term의 합으로 표현되므로, 온전히 convex하면서도 tight한 손실의 상한(Upper bound)을 찾아 이에 convex 최적화 이론을 적용하였다.

- 실용성을 더 높이기 위한 TTA 기법들

지금까지는 타겟 도메인이 변하지 않는 상황을 가정하였으나, TTA가 시간에 따라 변화하는 타겟 도메인(예: 밤낮의 변화, 날씨의 변화, 카메라 센서의 노후화)에 맞춰 지속해서 적용 가능하다면 더 높은 실용성을 갖게 될 것이다.

SITA [7]는 타겟 데이터가 batch가 아닌 샘플 단위로 들어온다는 가정 아래서 각 샘플에 맞게 모델을 계속 적용해 나가는 기법이다. 먼저, 원본 샘플과 이를 서로 다른 무작위 방법으로 증강(Augmentation)시킨 샘플들을 합쳐 하나의 batch로 만든다. 이후 이를 입력 삼아 순전파 과정을 수행하는데, 이 과정에서 weighted average를 통해 BN 레이어의 statistics를 조정한다.

CoTTA [8]는 student 모델과 teacher 모델을 통해 지속적으로 도메인에 적응한다. Student 모델은 사전 학습된 모델로부터의 확률적 복원

(Stochastic restoration)을 통해 얻어지는데, 이는 catastrophic forgetting을 방지하기 위함이다. 원본 입력을 student 모델에 통과시켜 도출된 예측값과 다양한 방식으로 증강된 입력을 teacher 모델에 통과시켜 도출된 평균 예측값 사이의 consistency loss를 줄이는 방향으로 student 모델을 최적화한다. 한편, teacher 모델은 student 모델로부터의 moving average를 통해 얻어진다. 이 전 과정이 지속적으로, 반복적으로 이루어진다.

III. 결론

본 논문에서는 다양한 접근법 및 실용성 증대 측면에서 테스트 시기 도메인 적응(TTA) 기술 동향을 살펴보았다. TTA를 통해 실제 상황에서의 정확도는 높이면서 (재)학습에 필요한 비용은 절감하는 효과를 누릴 수 있다. 추후에는 연합 학습(Federated learning) 또는 모델 경량화(예: 프루닝, 양자화) 등으로 학습된 모델이 TTA에 어떻게 반응하는지에 대한 융합적 연구도 기대해볼만하다.

ACKNOWLEDGMENT

이 논문은 2022년도 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임 (No. 2022R1A5A1027646).

참 고 문 헌

- [1] D. Hendrycks and T. Dietterich, "Benchmarking Neural Network Robustness to Common Corruptions and Perturbations," in *Proceedings of the 7th International Conference on Learning Representations*, 2021.
- [2] X. Peng et. al., "Moment Matching for Multi-Source Domain Adaptation," in *Proceedings of 2019 IEEE/CVF International Conference on Computer Vision*, 2019.
- [3] A. Dosovitskiy et. al., "An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale," in *Proceedings of the 9th International Conference on Learning Representations*, 2021.
- [4] D. Wang, E. Shelhamer, S. Liu, B. Olshausen, and T. Darrell, "Tent: Fully Test-Time Adaptation by Entropy Minimization," in *Proceedings of the 9th International Conference on Learning Representations*, 2021.
- [5] Y. Iwasawa and Y. Matsuo, "Test-Time Classifier Adjustment Module for Model-Agnostic Domain Generalization," in *Proceedings of the 35th Conference on Neural Information Processing Systems*, 2021.
- [6] M. Boudiaf, R. Müller, I. B. Ayed, and L. Bertinetto, "Parameter-free Online Test-time Adaptation," in *Proceedings of 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2022.
- [7] A. Khurana, S. Paul, P. Rai, S. Biswas, and G. Aggarwal, "SITA: Single Image Test-time Adaptation," *arXiv preprint arXiv:2112.02355*, 2021.
- [8] Q. Wang, O. Fink, L. V. Gool, and D. Dai, "Continual Test-Time Domain Adaptation," in *Proceedings of 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2022.