

메타 학습을 활용한 Few-shot 분류기 성능 검증

최미희, 강재모

경북대학교 인공지능학과

mihuic@knu.ac.kr, jmkang@knu.ac.kr

Performance Verification of the Few-shot Classifier Using Meta-Learning

Choi Mi-Hui, Kang Jae-Mo


Kyungpook Univ.

요 약

딥러닝 모델을 학습하기 위해서는 많은 학습 데이터가 필요하기 때문에 데이터 확보 비용과 노동력의 문제를 해결하려는 연구가 활발히 진행되고 있다. 이러한 문제를 해결하기 위해 소량의 데이터만을 활용하여 효율적인 학습을 하는 퓨샷 러닝(Few-shot learning)을 활용한다. 본 논문에서는 퓨샷 러닝에 독일 교통 표지 인식 벤치마크 GTSRB(German Traffic Sign Recognition Benchmark) 데이터를 사용하여, 데이터 효율을 극대화를 위해 데이터 증강 기법 기반 메타 학습(Meta learning) 모델의 정확도를 향상했다.

I. 서 론

최근 인공지능의 활용도가 높아짐에 따라 데이터의 품질과 양에 대한 중요성이 대두되고 있다. 특히 딥러닝의 발전함에 있어 데이터의 양은 인공지능 모델의 성능에 큰 영향을 미치고 있다. 하지만 다양한 분야의 데이터를 충분히 수집하는 것에는 큰 어려움이 있다. 이러한 문제점을 해결을 위한 방법 중 퓨샷 러닝(Few-Shot Learning)이 있다. 퓨샷 러닝이란, 소량의 데이터만으로 학습한 모델이 학습 데이터에서 관찰하지 못한 새로운 데이터에도 좋은 성능을 도출하는 방법론이다. 퓨샷 러닝을 하기 위한 방법론 중 하나가 메타 학습(Meta Learning)이다. 학습하는 방법을 학습하는 것으로 알려진 메타러닝은 학습 데이터로 메타 모델을 만들어 새로운 태스크에 효율적인 학습을 할 수 있도록 한다. 본 논문에서는 데이터셋 GTSRB (German Traffic Sign Recognition Benchmark)를 활용하여 기존 퓨샷 러닝 알고리즘에 데이터 증강 기법을 적용시켰으며, 실험을 통해 성능을 검증하였다.



「그림 11 메타 학습 예시

II. 본론

딥러닝은 많은 데이터를 기반으로 학습을 진행하기 때문에 데이터 확보에 많은 비용과 시간이 소요되어 이를 해결하기 위한 많은 연구가 진행되고 있다. 퓨샷 러닝은 몇 가지 훈련 데이터만으로도 데이터의 기본 패턴을 학습하는 학습 방법으로 데이터 부족과 시간을 단축할 수 있다. 퓨샷 러닝은 일반적으로 N-way K-shot

태스크로 정의한다. N-way 의 N 은 클래스의 개수이고, K-shot 의 K 는 클래스 당 데이터의 개수이다. 퓨샷 러닝에서 보편적으로 쓰이는 실험값은 5-way 5-shot, 5-way 1-shot 등으로 본 논문에서도 이와 같은 실험값을 이용한다. [1]

메타 학습은 퓨샷 러닝을 수행할 수 있는 방법 중 하나로 새로운 태스크에 대해 빠르게 학습하는 접근 방식이 제안되었다. [3] 메타 학습은 일반적으로 태스크를 해결하는 내부모델 (Inner-level, base learning)과 학습한 모델이 내부모델의 일반화 성능, 학습 속도 등을 개선하도록 하는 외부모델(Outer-level, meta learning)로 2 개의 모델로 구성되어 있다. 메타 학습은 최적화 기반 접근 방식, 모델 기반 접근 방식, 메트릭 기반 접근 방식으로 나눌 수 있다. 최적화 기반 접근 방식에는 외부모델이 파라미터 초기값을 배우는 것에 초점을 두고 학습하여 새로운 태스크의 초기 파라미터 값으로 사용함으로 내부모델이 몇 번의 업데이트만으로 빠르게 찾아 적응하여 좋은 성능을 보일 수 있도록 한다. [3] 모델 기반 접근 방식은 새로운 데이터셋에 대해 기존 데이터셋을 활성화시켜, 이 상태를 기반으로 새로운 데이터셋에 대한 예측이 이뤄진다. 메트릭 기반 접근 방식은 같은 클래스 내 이미지의 유사성 정도를 이용하기 위해 데이터를 고차원에서 저차원 공간으로 임베딩(embedding)시켜 줌으로써 메트릭을 학습한다. 새로운 데이터에 학습된 메트릭을 사용하여 효율적인 학습이 수행된다. [2] 본 논문에서는 메트릭 기반 접근 방식인 prototypical networks 을 사용하여 퓨샷 분류기 문제를 해결하고자 한다. [4]

퓨샷 러닝은 충분한 데이터가 없기 때문에 과적합이나 과소적합이 될 확률이 있다. 데이터가 부족하여 데이터의 추가 확보가 필요하지만, 추가 확보가 쉽지 않은 경우 데이터 증강 기법이나 GAN(Generative Adversarial Networks)[5]을 통해 스스로 더 많은 데이터를 생산할 수 있다.

본 논문에서는 메타 학습에서 데이터 효율성을 극대화하기 위해 데이터 증강 기법을 사용한다. 분류기 문제에서 학습 데이터셋을 증강하기 위해 이미지에 무작위 수평 반전(Random Horizontal Flip), 회전(Rotate, 090°, 180°, 270°), 아핀 변환 (Affine Transformation)을 활용한다.

본 논문에서 성능 검증을 위해 사용한 데이터셋인 GTSRB 은 도로 표지판으로 구성된 이미지로, 43 개의 클래스와 50,000 개 이상의 학습 이미지를 가지며, 12,000 개의 테스트 이미지로 이뤄져 있다. [6]

본 논문에서는 5-way 에서 각각 클래스 당 1 개의 데이터를 사용하는 1-shot, 클래스 당 5 개의 데이터를

사용하는 5-shot 과 20-way 에서 각각 1-shot, 5-shot 실험을 진행했다. 실험에 사용한 Prototypical Networks (base model)에 데이터셋 GTSRB 를 적용한 결과 [표 1]과 같은 결과를 검증했다.

Dataset	5-way Acc.		20-way Acc.	
	1-shot	5-shot	1-shot	5-shot
GTSRB	78.6%	90.8%	48.5%	67.8%

[표 1]Prototypical Networks 에 GTSRB 데이터셋 성능

[표 2]는 데이터에 수평 반전 기법을 사용하여 증강하였을 때 기본 모델과 성능을 비교한 결과이다. 자체적 학습보다 데이터 증강 기법이 들어갔을 때 성능이 1-shot 에서 0.6%향상됐고, 5-shot 에서 0.7% 향상된 것을 보아 데이터 확보의 어려움을 겪는 상황을 해결함에 효과가 있다는 것을 확인할 수 있었다.

Model (GTSRB)	5-way Acc.	
	1-shot	5-shot
Base	78.6%	90.8%
+ Random Flip	79.2%	91.5%
+ Rotate	43.5%	70.5%
+ Affine	34.4%	70.3%

[표 2]기본 모델 + 무작위 수평 반전 기법에 따른 성능

III. 결론

본 연구는 퓨샷 분류기를 위한 메타 학습에서 데이터 증강 기법을 적용하여 실험을 진행했다. 기존 모델에서 학습 데이터셋에 데이터 증강 기법을 적용한 결과 성능이 향상된 것을 검증하고, 소량의 데이터에도 증강 기법 활용하여 모델 학습에 도움이 될 수 있음을 확인했다.

향후 연구에서는 데이터셋에 따른 데이터 증강 기법이 모델의 성능을 저하시킬 때, 그 이유를 분석하고 이유에 따라 다양한 데이터 증강 기법을 활용하여 정확도를 향상시킬 예정이다. 또한, 일반적인 데이터 셋을 활용을 통해 퓨샷 분류기 성능을 향상시킬 수 있는 데이터 증강 기법을 도입하여, 일반적인 분류 정확도를 향상시킬 예정이다.

ACKNOWLEDGMENT

Put sponsor acknowledgments.

참 고 문 헌

- [1] PARNAMI, Archit; LEE, Minwoo. "Learning from Few Examples: A Summary of Approaches to Few-Shot Learning," arXiv preprint arXiv:2203.04291, 2022.
- [2] HOSPEDALES, Timothy, et al. "Meta-learning in neural networks: A survey." IEEE transactions on pattern analysis and machine intelligence, 2021, 44.9: 5149-5169.
- [3] FINN, Chelsea; ABBEEL, Pieter; LEVINE, Sergey. "Model-agnostic meta-learning for fast adaptation of deep networks," In: International conference on machine learning. PMLR, 2017. p. 1126-1135.
- [4] SNELL, Jake; SWERSKY, Kevin; ZEMEL, Richard. "Prototypical networks for few-shot learning," Advances in neural information processing systems, 2017, 30.
- [5] GOODFELLOW, Ian, et al. "Generative adversarial networks," Communications of the ACM, 2020, 63.11: 139-144.
- [6] J. Stallkamp, M. Schlipsing, J. Salmen, C. Igel, Man vs. computer: Benchmarking machine learning algorithms for traffic sign recognition, Neural Networks, Available online 20 February 2012, ISSN 0893-6080, 10.1016/j.neunet.2012.02.016. (<http://www.sciencedirect.com/science/article/pii/S0893608012000457>) Keywords: Traffic sign recognition; Machine learning; Convolutional neural networks; Benchmarking