

준지도 학습에서 EMAN과 SCE를 이용한 Mean Teacher 모델의 성능 개선 연구

박기완, 남해운
한양대학교

{rldhks6889, hnam}@hanyang.ac.kr

Enhancing Mean Teacher Model Performance using EMAN and SCE in Semi-supervised Learning

Kiwan Park, Haewoon Nam

Hanyang Univ.

요약

본 연구는 준지도 학습 환경에서 Mean Teacher 모델의 성능을 개선하기 위해 EMAN과 SCE를 도입한다. 실험 결과, 이 조합은 CIFAR-10-C 데이터셋에서 기존의 RobustBN을 사용한 모델과 비교하여 우수한 성능을 보였으며, 특히 레이블 노이즈와 데이터 변형에 강건한 모습을 보여준다. 이러한 결과는 EMAN이 정규화 과정의 변동성을 효과적으로 관리하고, SCE가 레이블 노이즈에 대한 강건성을 증진시킨 덕분이다. 따라서, EMAN과 SCE의 조합은 준지도 학습 환경에서 Mean Teacher 모델의 강건성을 향상시키고, 일관된 성능을 유지할 수 있는 효과적인 방법임을 입증한다.

I. 서론

딥러닝 기술의 발전이 눈부시게 진행되고 있지만, 그 성능은 여전히 대규모 및 고품질의 레이블링된 데이터에 크게 의존하고 있다. 특히 준지도 학습과 같은 환경에서는 불완전하거나 잘못된 레이블 때문에 학습 과정에서 오류가 발생할 가능성이 높다. 이러한 문제를 해결하기 위해, 강화된 배치 정규화 기법인 Robust Batch Normalization(RobustBN) 등이 개발되었으나, 여전히 여러 한계점을 지니고 있다. 본 연구에서는 준지도 학습 환경에서 Mean Teacher 모델을 통해 EMAN(Exponential Moving Average Normalization)과 Symmetric Cross Entropy (SCE)의 적용 가능성을 탐구하여 기존 방법의 한계를 극복하고자 한다.

II. 본론

최근 딥러닝 기술의 급속한 발전에도 불구하고, 학습 데이터의 질과 양에 대한 의존도가 높아, 데이터가 부족하거나 불완전할 경우 모델의 성능이 저하될 수 있다. 특히, 레이블이 부정확하거나 소음이 많은 환경에서는 학습 과정에서 발생할 수 있는 오류들을 효과적으로 관리해야 한다. 이러한 문제를 해결하기 위해, Robust Batch Normalization (RobustBN)[1]과 같은 기술들이 개발되었다. RobustBN은 배치 정규화를 강화하여 네트워크의 안정성을 증진시키고, 특히 변동이 심한 데이터에서 모델의 일관된 성능을 유지하도록 설계되었다. 하지만, 이러한 접근법은 여전히 불완전한 레이블이나 소음에 취약한 문제를 완전히 해결하지 못했다.

이 연구에서는 Mean Teacher 모델을 중심으로 한 RoTTA 프레임워크 [2]의 준지도 학습 환경에서 EMAN(Exponential Moving Average Normalization)[3]과 Symmetric Cross Entropy(SCE)[4]의 적용을 통해 이러한 문제를 개선하는 방안을 제안한다.

Mean Teacher는 안정적인 교사 모델을 통해 학생 모델의 학습을 지도하는 방식으로, 모델의 일관성을 유지하며 불확실성을 관리한다. [1] 본 연구에서는 기존의 Robust Batch Normalization 방식을 EMAN으로 대체하고, 일반적인 Cross Entropy 손실 함수 대신 SCE 손실 함수를 적용하여, 교사 모델과 학생 모델 간의 일관성 손실을 최소화하였다.




그림 1. EMAN과 SCE가 적용된 RoTTA 네트워크 구조

EMAN은 각 층의 평균과 분산을 지수 이동 평균으로 계산하여 정규화 과정에서의 변동성을 줄인다. 이 방법은 특히 데이터셋의 변형이나 손상이 많은 환경에서 효과적이다. 또한, SCE는 레이블 노이즈에 강건하며, 잘못된 레이블로 인해 모델이 학습하는 부정확한 패턴을 줄여준다.

본 연구는 그림 1의 네트워크 구조와 같이 준지도 학습 환경에서 기존 Test-time adaptation 프레임워크의 Mean Teacher 모델 성능 개선을 위해 EMAN과 SCE를 통합적으로 적용하였다.

III. 데이터셋 및 실험 설계

실험에 사용된 CIFAR-10-C 데이터셋은 CIFAR-10의 변형된 형태로, 다양한 환경적 변화와 손상을 적용하여 모델의 Robustness를 평가하기에 적합하다. 이 데이터셋은 Gaussian, Blur, pixelate 등 다양한 유형의 corruption이 포함된 이미지로 구성되어 있으며, 이는 일반적인 분류 작업보다 더 도전적인 환경을 제공한다. [4]

모든 실험은 Pre-trained model의 Normalization 기법과 Teacher model과 Student model 사이 Consistency loss를 계산하는 방식을 제외하면 동일한 환경에서 다음과 같은 네 가지 설정으로 실험을 진행하였다:

- 1) Standard Batch Normalization
- 2) Robust Batch Normalization
- 3) Exponential Moving Average Normalization(EMAN)
- 4) EMAN과 SCE 조합. 그리고 실험에는 각 Corruption 마다 1만개의 샘플을 사용하였고, 이미지 오염도는 가장 높은 단계인 Lv5로 설정되어 진행하였다.

Methods	gaussian	shot	impulse	defocus	glass	motion	zoom	snow	frost	fog	brightness	contrast	elastic	pixelate	jpeg	avg.
BN	30.91%	31.13%	38.85%	32.58%	40.24%	32.32%	29.34%	34.38%	32.66%	34.99%	28.12%	38.96%	34.46%	32.52%	32.75%	33.61%
RobustBN	30.21%	25.45%	34.58%	18.08%	33.87%	14.65%	10.81%	16.32%	14.76%	14.10%	7.89%	12.08%	20.41%	16.75%	19.40%	19.29%
EMAN	29.15%	25.27%	34.91%	15.71%	33.12%	14.56%	11.27%	15.99%	15.20%	14.40%	8.16%	16.32%	20.31%	16.03%	19.52%	19.33%
EMAN+SCE	28.99%	24.77%	33.95%	15.22%	31.51%	13.47%	10.59%	15.70%	14.61%	13.98%	8.36%	14.29%	20.27%	15.64%	18.77%	18.67%

표 1. CIFAR-10-C의 Corruptions에서 각 method들의 성능 비교

IV. 실험 결과 및 분석

표 1의 결과는 CIFAR-10-C 데이터셋을 사용하여 다양한 corruption 유형에 대한 실험을 통해 얻은 데이터이다. 각 실험은 모델이 특정 유형의 corruption에 어떻게 반응하는지를 평가하기 위해 10,000회의 시행을 거쳤으며, 이 과정에서 발생한 에러의 확률을 계산하여 성능을 비교하였다.

EMAN은 각 층에서 추출한 평균과 분산을 지수 이동 평균을 통해 계산하므로, 일반적인 BN보다 시간에 따른 데이터 변화에 더 잘 적응한다. 이는 특히 데이터셋의 변형이나 손상이 심한 환경에서 모델이 일관된 출력을 유지하도록 지원한다. 예를 들어, EMAN은 fog corruption이 적용된 이미지에서 보다 정확한 특징 추출을 가능하게 하여, 결과적으로 더 높은 분류 정확도를 달성한 것으로 추측된다.

Symmetric Cross Entropy (SCE)는 레이블 노이즈에 강건한 속성 덕분에 잘못된 레이블이 모델 학습에 미치는 부정적인 영향을 크게 줄인다. SCE는 레이블의 정확도가 떨어지는 상황에서도 교차 엔트로피 손실에 비해 더 신뢰할 수 있는 그라디언트 정보를 제공하며, 이는 학습 과정에서 모델의 안정성을 높이는 데 기여한다. 특히, salt-and-pepper noise와 같이 레이블의 신뢰도가 크게 저하될 수 있는 corruption에서 SCE는 모델의 강건성을 유지하며 성능 저하를 최소화할 수 있다.

결과적으로, EMAN과 SCE의 결합은 기존의 RobustBN과 단순 BN을 사용했을 때보다 평균적으로 0.62% 더 우수한 성능을 보여주었다. 이는 EMAN이 제공하는 안정적인 정규화 기능과 SCE가 제공하는 레이블 노이즈에 대한 강건성이 서로 보완 작용하여, 특히 데이터 변형과 노이즈가 심한 환경에서 모델의 성능을 크게 향상시킨 것으로 해석된다.

V. 결론

본 연구에서 제안한 EMAN과 SCE의 결합은 Mean Teacher 모델의 성능을 개선하였다. 이 접근법은 특히 준지도 학습과 같이 불확실한 레이블이 존재하는 환경에서 모델의 일관성을 유지하고, 정확도를 향상시키는 데 효과적임을 입증하였다.

결론적으로, EMAN과 SCE의 도입은 Mean Teacher 모델의 강건성을 향상시키고, 다양한 환경에서의 일관된 성능을 보장하는 데 기여한다. 이러한 접근 방식은 모델이 레이블 오류와 데이터 변형에 보다 효과적으로 대응할 수 있게 하여, 실제 세계 응용에서의 사용 가능성을 높인다. 향후 연구에서는 이 기술들을 다양한 아키텍처와 확장된 데이터셋에 적용하여 그 범용성과 효율성을 더욱 검증할 계획이다.

ACKNOWLEDGMENT

이 논문은 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구입(No.2022R1A2C1011862)

참 고 문 헌

[1] Yuan, Longhui, Binhui Xie, and Shuang Li, "Robust test-time adaptation in dynamic scenarios," Proceedings of the IEEE/CVF

Conference on Computer Vision and Pattern Recognition, 2023.

[2] Wang, Yisen, et al., "Symmetric cross entropy for robust learning with noisy labels," Proceedings of the IEEE/CVF International Conference on Computer Vision, 2019.

[3] Cai, Zhaowei, et al., "Exponential moving average normalization for self-supervised and semi-supervised learning," Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021.

[4] Tarvainen, A., & Valpola, H., "Mean teachers are better role models: Weight-averaged consistency targets improve semi-supervised deep learning results," Advances in Neural Information Processing Systems, 30, 2017.