

다중 레이블 분류 작업에서의 Coarse-to-Fine Curriculum Learning 메카니즘 적용 방안

공희산^o, 박재훈*, 김광수*

^o성균관대학교 소프트웨어학과,

*성균관대학교 소프트웨어학과

e-mail: khtks@g.skku.edu^o, zlmwzladl@gmail.com*, kim.kwangsu@skku.edu*

Applying Coarse-to-Fine Curriculum Learning Mechanism to the multi-label classification task

Heesan Kong^o, Jaehun Park*, Kwangsu Kim*

^oDept. of Computer Science and Engineering, SungKyunKwan University,

*Dept. of Computer Science and Engineering, SungKyunKwan University

● 요약 ●

Curriculum learning은 딥러닝의 성능을 향상시키기 위해 사람의 학습 과정과 유사하게 일종의 ‘curriculum’을 도입해 모델을 학습시키는 방법이다. 대부분의 연구는 학습 데이터 중 개별 샘플의 난이도를 기반으로 점진적으로 모델을 학습시키는 방안에 중점을 두고 있다. 그러나, coarse-to-fine 메카니즘은 데이터의 난이도보다 학습에 사용되는 class의 유사도가 더욱 중요하다고 주장하며, 여러 난이도의 auxiliary task를 차례로 학습하는 방법을 제안했다. 그러나, 이 방법은 혼동행렬 기반으로 class의 유사성을 판단해 auxiliary task를 생성함으로써 다중 레이블 분류에는 적용하기 어렵다는 한계점이 있다. 따라서, 본 논문에서는 multi-label 환경에서 multi-class와 binary task를 생성하는 방법을 제안해 coarse-to-fine 메카니즘 적용을 위한 방안을 제시하고, 그 결과를 분석한다.

키워드: 커리큘럼 학습(curriculum learning), 다중 레이블 분류(multi-label classification)

I. Introduction

사람의 뇌 구조를 본 딴 딥러닝은 최근 엄청난 발전을 이루었다. 그러나, 딥러닝은 데이터의 구분 없이 임의의 순서에 따라 모델을 학습하는데 반면, 사람은 쉽게 배울 수 있는 것부터 점진적으로 더욱 어려운 것 까지 일종의 ‘curricula’를 따라 학습한다는 차이가 존재한다. 그렇기 때문에, 위와 같은 학습 과정의 차이에서 영감을 받아 curriculum-like 학습 전략을 도입함으로써 성능을 향상시킬 수 있는 curriculum learning이 제안되었다 [1].

현재 대부분의 연구는 학습 데이터를 난이도에 따라 스케줄링하는 방안에 초점을 맞추고 있다. 이와 반대로, coarse-to-fine 기법은 분류 task에서 학습 데이터의 개별 난이도 보다 고려되는 class의 유사성이 더욱 중요하다고 주장하며, 쉬운 task부터 어려운 task까지 여러 단계의 auxiliary task를 구성해 단계적으로 수행하는 메카니즘을 제안하였다. 그러나, 이 방법은 혼동행렬을 기반으로 오류를 발생시킬 수 있는 class를 결합해 다양한 난이도의 auxiliary task를 생성하기 때문에, 하나의 데이터가 여러 class에 속할 수 있는 multi-label 환경에 적용하기 어렵다는 한계점이 있다.

그렇기 때문에, 우리는 multi-label 환경에서 메카니즘을 적용하기 위해 multi-class와 binary auxiliary task를 생성해 순차적으로 학습함으로써 multi-label 분류의 성능을 향상시킬 수 있는 방법을 제안한다. 또한, 14개의 흉부 질환에 대한 multi-label을 제공하는 Chest X-ray14 [2]를 통해 제안한 방법을 적용할 때의 성능을 비교함으로써 유효성을 검증했다.

II. Preliminaries

1. Related works

1.1 Curriculum learning

Curriculum learning을 딥러닝에 도입하는 첫 시도는 [5]에서 처음 제안되었다. 이후 많은 연구에서 데이터의 순서를 스케줄링하는데 많은 노력을 기울였다[7]. 이 방법은 데이터의 난이도를 기준삼

으므로, 난이도 측정을 위한 별도의 방법이 필요하다. [6]에서는 NLP task에서 문장/문단의 길이를 기준으로 난이도 측정 방법을 제안했으며, [7]에서는 데이터 분포 밀도를 사용해 데이터의 다양성 측면에서 난이도를 측정하는 방법을 제안했다.

III. The Proposed Method

Multi-label 환경에서 coarse-to-fine 메카니즘의 적용 가능성을 확인하기 위해, 다음과 같은 방법으로 2단계의 auxiliary task를 생성하는 방법을 제안한다.

- 1) 단일 class에만 속한 데이터로 multi-class task 생성
- 2) Multi-class 데이터를 사용해 binary task 생성

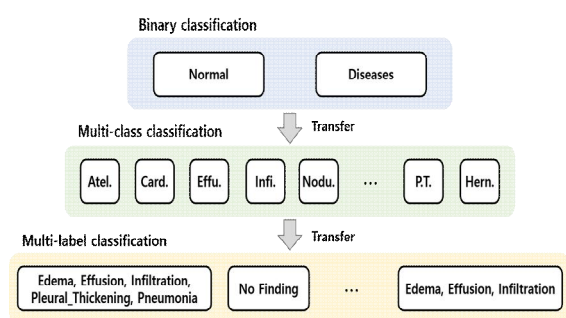


Fig. 1. Multi-label auxiliary task hierarchy

Chest X-ray14에 적용한 전체적인 그림은 Fig. 1.과 같다. 학습 과정은 task의 난이도를 기준으로 binary, multi-class, multi-label 순으로 진행되었으며, 각 auxiliary task에서 학습된 모델은 다음 단계로 전이 되어 사용한다.

실험을 위해 ResNet-18[4]을 사용했으며, optimizer로는 1e-4 weight decay와 0.9 momentum을 적용한 SGD를 사용해 최적화했다.

Table 1. Comparison of multi-label classification performance on curriculum learning

	Mean AUC	Improvement
Default	77.03%	-
1-stage	78.00%	0.97%
2-stage	78.47%	1.43%

Chest X-ray14 multi-label 분류에 대해 적용 결과는 Table. 1.과 같으며, 1-stage는 multi-class task만을 적용한 경우이고, 2-stage는 binary task 이후에 multi-class task를 적용한 경우이다. 단순히 curriculum learning을 적용한 것 만으로도 mean AUC가 약 1.4% 증가한 것을 확인할 수 있다.

IV. Conclusions

본 연구에서는 coarse-to-fine curriculum 메카니즘을 multi-label 환경에 적용하기 위한 연구를 진행했다. 실험 결과 auxiliary task를 단순하게 구성했음에도 불구하고 약 1.4%의 성능 향상을 달성했다는

것으로 보아 multi-label 환경에도 충분히 적용할 수 있다는 것을 확인했다. 또한, 향후 연구에서 auxiliary task를 더욱 세분화 시킨다면 추가적인 성능 향상을 기대할 수 있다.

ACKNOWLEDGEMENT

2022년도 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원의 지원을 받아 수행된 연구임 (No.2021-0-02068, 인공지능 혁신 허브 연구 개발)과 과학기술정보통신부 및 정보통신기획평가원의 지역지능화혁신인재양성(Grand ICT 연구센터) 사업의 연구 결과로 수행되었음 (IITP-2022-2015-0-00742)

REFERENCES

- [1] Soviany, Petru, et al. "Curriculum learning: A survey." International Journal of Computer Vision (2022): 1-40.
- [2] X. Wang, Y. Peng, L. Lu, Z. Lu, M. Bagheri and RM. Summers, "ChestX-ray8: Hospital-scale Chest X-ray Database and Benchmarks on Weakly-Supervised Classification and Localization of Common Thorax Diseases" in Proceedings of the IEEE conference on computer vision and pattern recognition, Hawaii Convention Center, pp. 2097-2106, 2017.
- [3] Stretcu, Otilia, et al. "Coarse-to-fine curriculum learning for classification." International Conference on Learning Representations (ICLR) Workshop on Bridging AI and Cognitive Science (BAICS). 2020.
- [4] He, Kaiming, et al. "Deep residual learning for image recognition." Proceedings of the IEEE conference on computer vision and pattern recognition. 2016.
- [5] Jeffrey L Elman. Learning and Development in Neural Networks: The Importance of Starting Small. Cognition, 48(1):71-99, 1993.
- [6] Cheng Wang, Qian Zhang, Chang Huang, Wenyu Liu, and Xinggang Wang. Mancs: A Multi-Task Attentional Network with Curriculum Sampling for Person Re-Identification. In European Conference on Computer Vision, pp. 365-381, 2018.
- [7] Y. Bengio, et al. Curriculum learning. In ICML, 41-48, 2009.
- [8] E. Platanios, et al. Competence-based curriculum learning for neural machine translation. In NAACL-HLT, 2019.