

망막 영상 분석을 위한 두 갈래 분류기

오영택 · 박현진*

성균관대학교 · 기초과학연구원 뇌 과학 이미징 연구단

Two-Branch Classifier for Retinal Imaging Analysis

Young-tack Oh · HyunjinPark*

Sungkyunkwan University · Center for Neuroscience Imaging Research, Institute for Basic Science

E-mail : wpfl2034@g.skku.edu / hyunjinp@skku.edu

요 약

세계는 안구 질병 치료, 시력 회복 서비스, 훈련된 안과 전문의의 부족 등 안과 측면에서 어려움에 직면해 있다. 안구 병리를 조기에 발견하고 진단하면 시각 장애를 예방할 수 있다. 하지만 기존의 망막 영상 공개 데이터 세트는 임상에서 발견되는 다양한 질병으로 구성되어 있지 않기 때문에 다양한 안구 질환을 분류하는 방법을 개발하기가 어렵다. 본 연구는 2021 ISBI challenge에서 공개된 데이터 세트인 Retinal Fundus Multi-disease Image Dataset (RFMiD) 을 이용하여 안구 질환을 분류하는 방법을 제안한다. 본 연구의 목표는 망막 이미지를 정상, 비정상 범주로 선별하기 위한 강력하고 일반화 가능한 모델을 개발하는 것이다. 제안된 모델의 성능은 수신자 조작 특성 곡선 아래 면적 점수로 비공개 테스트 데이터 세트에 대해 0.9782의 값을 보여준다.

ABSTRACT

The world faces difficulties in terms of eye care, including treatment, quality of prevention, vision rehabilitation services, and scarcity of trained eye care experts. However, it is difficult to develop a method for classifying various ocular diseases because the existing dataset for retinal image disclosure does not consist of various diseases found in clinical practice. We propose a method for classifying ocular diseases using the Retinal Fundus Multi-disease Image Dataset (RFMiD), a dataset published in the ISBI-2021 challenge. Our goal is to develop a robust and generalizable model for screening retinal images into normal and abnormal categories. The performance of the proposed model shows a value of 0.9782 for the test dataset as an area under the curve (AUC) score.

키워드

retinal fundus images, classification, class imbalance, ensemble network

1. 서 론

WHO에서 2019년에 발표한 보고서에 따르면 전 세계 시각 장애인의 수는 22억 명으로 추정되고, 이 중 최소 10억 명은 예방할 수 있거나 아직 다루어지지 않은 장애를 갖고 있다. 하지만 전문적으로 훈련된 안과 전문의의 부족으로 문제를 해결하기에 어려움이 있다 [1]. 일상적인 임상 설정에 나

타나는 다양한 질병으로 구성된 Retinal Fundus Multi-disease Image Dataset (RFMiD)은 두 명의 망막 전문가의 합의를 통해 주석이 달린 46개의 다른 질병으로 이루어진 총 3200개의 영상으로 구성된다. 우리의 목표는 망막 이미지를 정상, 비정상 범주로 선별하기 위한 강력하고 일반화 가능한 모델을 개발하는 것이다. 우리는 심각한 클래스 불균형을 해결할 수 있는 훈련 전략을 설계하는데 중점을 두고 efficientNet [2]을 기반으로 하는 두 갈래 분류기를 제안한다.

* corresponding author




그림 1. 전처리




그림 2. 두 갈래 분류기

LP는 13개의 클래스로 구성되었고, SP는 16개의 클래스로 구성되었다. 이렇게 생성된 각 분류기의 이름을 각각 LP분류기와 SP분류기로 지정한다. 이미지는 하나의 특징 추출기를 통과한 다음 두 개의 분류기에 입력으로 들어가 예측을 수행한다 (그림 2).

II. 방법

2.1 전처리

우리는 원본 이미지의 정보를 보존하면서, 특정한 디지털 안저 카메라에 의존하지 않기 위하여 간단한 전처리 과정을 수행한다. 불필요한 정보라고 생각되는 검은색 배경은 최대한 제거하고, 무작위 크기 조절과 무작위 자르기를 이용하여 카메라마다 얻어지는 형식이 아닌 모두 다른 형식의 데이터 세트를 구성하였다. 마지막으로 모든 이미지는 512x512로 크기가 조정된다.

2.2 데이터 증강

전처리 단계 이후 데이터 증강이 입력 데이터에 적용된다. 플립, 로테이션, 쉬프트, 블러, 엘라스틱 변형, 컷아웃 [3] 등 다양한 증강을 적용하여 모델이 훈련 중에 보지 못한 데이터에 대한 일반화 능력을 갖출 수 있도록 한다. 데이터 증강을 거친 후 모델에 입력되는 이미지의 크기는 456x456으로 조절이 된다. 마지막으로 ImageNet으로 사전 훈련된 모델을 사용하므로 데이터를 ImageNet의 평균 및 표준으로 정규화 한다.

2.3 두 갈래 분류기

훈련 세트에 대한 각 클래스의 양성/음성의 수를 관찰한 결과, 클래스 불균형이 매우 크다는 것을 알 수 있다. 그래서 우리는 클래스 불균형을 해결하는 데 초점을 맞춘 네트워크를 설계한다. 다음 전략은 소수의 양성 샘플을 가진 클래스를 보다 민감하게 분류하고 전반적인 학습을 용이하게 하기 위해 취해진다.

우리는 전체 클래스를 상대적으로 많은 수의 양성 샘플이 있는 클래스(LP)와 상대적으로 적은 수의 양성 샘플이 있는 클래스(SP)로 나눈다. 이를 나누는 임계 값 T 는 40으로 설정했다. 최종적으로

2.4 양의 가중 이진 교차 엔트로피 손실 함수

대부분의 클래스에서 음성 라벨이 양성 라벨을 지배하기 때문에 손실 함수는 양성 라벨을 감지하는 데 더 민감하도록 조정되어야 한다 [4]. 우리는 양의 가중 이진 교차 엔트로피를 손실 함수로 사용한다.

$$L = \frac{1}{N} \sum_{n=1}^N [-\alpha \cdot y_n \cdot \log \sigma(x_n) - (1 - y_n) \cdot \log(1 - \sigma(x_n))] \quad (1)$$

N 은 배치 크기, y_n 와 x_n 은 n 번째 이미지의 진실 라벨과 예측 라벨을 의미한다. 양의 가중치 α 는 다음과 같이 정의된다.

$$\alpha = \frac{L^{neg}}{L^{pos}} \quad (2)$$

L^{pos} 와 L^{neg} 는 최종적으로 LP 분류기의 손실과 SP 분류기의 손실을 합쳐주어 전체 손실을 정의하였다. Beta는 각 분류기의 비율을 정하는 초매개변수이다. 실험적으로 우리는 $\beta=0.55$ 로 설정 해주었다.

$$L_{total} = \beta \cdot L_L + (1 - \beta)L_S \quad (3)$$

III. 실험 및 결과

3.1 Retinal Fundus Multi-disease Image Dataset (RFMiD)

RFMiD는 망막 전문가가 3대의 디지털 안저 카메라를 사용하여 획득했으며 각 장치의 해상도는 각각 4288x2848 픽셀, 2144x1424 픽셀

및 2048x1536 픽셀이다. 전체 45개의 질병 중 10개 이상의 이미지를 가지는 질병은 독립 분류에 속하고 다른 모든 질병 범주는 병합되어 “Other”로 표기되었다. 최종적으로 28개의 클래스를 갖는 3200장의 데이터 세트로 구성된다. 전체 데이터는 60%를 학습 데이터 세트로, 20%를 평가 데이터 세트, 마지막 20%를 비공개 테스트 데이터 세트로 나뉜다.

3.2 실험 세부사항

우리는 Pytorch를 기반으로 4장의 NVIDIA GeForce GTX 1080 GPU를 이용하여 학습을 진행하였다. Adam 최적화 알고리즘을 사용하였으며, 초기 학습률은 3×10^{-4} 로 설정하였다. 또한 우리는 ImageNet으로 사전학습된 EfficientNet을 특징 추출기로 사용하였다.

3.3 테스트 시간 증감

Matsunaga et al. 과 Jin et al.은 테스트 이미지의 여러 변환 버전에 대한 예측을 결합하면 성능이 향상된다는 사실을 경험적으로 발견했다 [5,6,7]. 이러한 이유로 학습 과정에서 적용되는 증강 기법을 테스트 이미지에 적용하여 더 나은 결과를 얻을 수 있었다. 또한 세 가지 다른 버전(efficientNet-b0,b1,b2)의 특징 추출기로 모델을 훈련하고 통합하여 보다 일반화되고 강인한 모델을 얻을 수 있었다.

3.4 결과

우리는 평가 데이터 세트에 대하여 0.9626의 AUC 점수를 얻었고, 비공개 테스트 데이터 세트에 대하여 0.9782의 점수를 얻었다 (표 1).

표 1. 제안된 모델의 성능

	Disease Risk AUC
평가 데이터	0.9626
비공개 테스트 데이터	0.9782

IV. 결 론

우리가 제안한 방법은 로컬 GPU의 한계로 인해 상대적으로 낮은 용량의 모델을 사용 함에도 불구하고 만족스러운 성능을 보였다. 이 도전의 목표는 다양한 질병을 포함하는 데이터를 이용하여 일반화된 모델을 만드는 것이므로 양성 샘플 수가 적은 클래스여도 모든 데이터를 사용하고자 하였다. 따라서 더 많은 양의 양성 데이터가 수집되면 더 좋은 성능을 보일 수 있을 것으로 기대한다. 향후에는 질병의 유무를 검사하는 것뿐만 아니라 다양

한 질병에 대한 분류 또한 진행 할 수 있을 것이다.

Acknowledgment

This research was supported by National Research Foundation (NRF-2020M3E5D2A01084892), Institute for Basic Science (IBS-R015-D1), Ministry of Science and ICT (IITP-2020-2018-0-01798), IITP grant funded by the AI Graduate School Support Program (2019-0-00421), and ICT Creative Consilience program (IITP-2020-0-01821).

References

- [1] Anonymous, “Retinal Fundus Multi-Disease Image Dataset (RFMiD): A Dataset for Multi-Disease Detection Research.,” *Data*, vol. 6, no. 2, p. 14, 2021.
- [2] Mingxing Tan and Quoc V Le, “EfficientNet: Rethinking model scaling for convolutional neural networks.,” In *International Conference on Machine Learning*, 2019.
- [3] T. DeVries and G. W. Taylor, “Improved regularization of convolutional neural networks with cutout.,” *arXiv preprint arXiv:1708.04552*, 2017.
- [4] K.P. Murphy, “Machine learning: a probabilistic perspective,” in *MIT press*, 2012.
- [5] K. Matsunaga, A. Hamada, A. Minagawa, H. Koga, “Image classification of melanoma, nevus and seborrheic keratosis by deep neural network ensemble.,” *arXiv:1703.03108*, 2017.
- [6] I. Radosavovic, P. Dollár, R. Girshick, G. Gkioxari, K. He, “Data distillation: towards omni-supervised learning.,” *arXiv:1712.04440*, 2017.
- [7] Wang, G., et al, “Aleatoric uncertainty estimation with test-time augmentation for medical image segmentation with convolutional neural networks.,” *Neurocomputing*, vol. 338, pp. 34 - 45, 2019.