

양안 안저 이미지를 활용한 딥러닝 모델 기반 녹내장 분류

이태관, 김소연, 손경아
아주대학교

qwan96@ajou.ac.kr, jebi1771@ajou.ac.kr, kasohn@ajou.ac.kr

Deep Learning-Based Glaucoma Classification Using Binocular Retinal Images

Tae Kwan Lee, So Yeon Kim, Kyung-Ah Sohn
Ajou Univ.

요 약

녹내장은 시신경의 손상으로 인해 발생하는 질병으로, 실명의 주요 원인 중 하나이다. 그러나 초기 단계에서는 증상이 경미하여 정확한 조기 진단이 필수적이므로 안저 이미지를 활용한 자동화된 녹내장 예측 모델에 대한 연구가 증가하고 있다. 본 논문에서는 단일 안저 이미지의 정보만을 사용하는 기존 분류 모델의 한계를 극복하기 위해 양안 이미지를 활용하는 모델 파이프라인을 제안한다. 또한, 이미지 전처리 기법인 Contrast Limited Adaptive Histogram Equalization(CLAHE)을 적용하여 안저 이미지의 특징을 강화함으로써 모델의 성능을 개선하였다.




그림 1. 모델 파이프라인

I. 서론

녹내장은 전 세계적으로 2020년 기준 7천만 명 이상의 환자가 겪고 있는 심각한 안과 질환으로[1], 시신경 손상으로 인해 발생하며 적절한 치료가 이루어지지 않을 경우 영구적인 시력 상실로 이어질 수 있다. 특히 초기 단계에서는 뚜렷한 시야 결손이 나타나지 않고 손상된 시신경은 회복되지 않으므로, 조기 진단이 필수적이다.

안저 이미지는 비침습적인 방법으로 환자의 질병을 진단하거나 치료 경과를 모니터링할 수 있는 유용한 도구로 활용된다. 최근에는 딥러닝 기술의 발전에 따라 안저 이미지를 기반으로 한 녹내장, 당뇨병망막증, 백내장 등 다양한 안과 질환을 예측 및 진단하는 연구가 활발히 진행 중이다[2]. 그러나 안저 이미지 내에 다른 안과 질환이 혼재되어 있을 경우, 진단의 정확성이 저하될 수 있다는 문제가 존재한다.

본 논문에서는 이러한 문제를 해결하기 위해 이미지 향상 전처리 기법 중 하나인 CLAHE[3]를 통해 안저 이미지의 특징을 효과적으로 강조함으로써 녹내장 진단 성능을 개선하는 방안을 분석하였다. 또한, 환자가 가진 다양한 정보를 종합적으로 활용하기 위해 딥러닝 기반 모델을 통해 학습된 양안에서 추출한 특징을 결합하여, 안저 이미지의 특징을 보다 정밀하게 학습하고 녹내장 진단의 정확성을 높이는 방법을 제안한다. 동시에, 제안하는 방법들을 적용한 모델들의 비교를 통해 성능 개선을 입증하였다.

II. 본론

II-1. 데이터셋

본 논문은 PAPILA 데이터셋[4]과 GRAPE 데이터셋[5]을 함께 활용한다. PAPILA 데이터셋은 각 안저 이미지가 healthy, suspect, glaucoma로 레이블링된 데이터로, 본 연구에서는 이진 분류 기반의 녹내장 예측을 수행하기 위해 healthy와 glaucoma로 레이블링된 이미지만을 사용하였다. GRAPE 데이터셋은 환자의 녹내장 진행 경과를 기록한 데이터로, 모든 이미지가 녹내장으로 레이블링 되어있다. GRAPE 데이터셋을 모두 사용할 경우, 학습된 환자의 안저 이미지 정보가 평가 데이터에서 중복될 수 있다는 문제점이 있으므로 환자들끼리 처음 촬영한 이미지만을 사용하였다. 따라서 총 658개의 안저 이미지가 사용되었으며 이 중 녹내장은 325개, 정상은 333개이다.

II-2. 모델 파이프라인 및 제안 방법

본 논문에서 제안하는 녹내장 분류 및 예측 모델 구조는 그림 1과 같다. 그림 1에 표현된 구조는 안저 이미지 Foundation 모델인 RETFound[6]를 기반으로 한다. 제안된 파이프라인은 안저 이미지를 딥러닝 모델에 학습시켜서 안저 이미지의 특징을 추출한다. 이후, 환자의 양안에서 추출된 특징들을 결합하여 MLP Classifier를 통해 녹내장을 분류한다. 이러한 접근법은 단일 안저 이미지로는 불충분한 환자의 녹내장 관련 정보를 추가적으로 반영함으로써, 모델 성능을 향상시키는데 기여한다. 또한, 본 논문에서는 CLAHE를 안저 이미지에 적용하여 결과

를 분석한다. CLAHE는 여러 작은 이미지 패치의 밝기를 각각 균등화하여 이미지의 대비(contrast)를 향상시키고 노이즈를 줄이면서 지역적인 특징을 강조한다(그림 2). 이러한 전처리 기법은 안저 이미지에서 녹내장 관련 특징을 보다 명확하게 부각시켜, 분류 모델의 성능을 향상시키는 데 기여한다.




그림 2. 각 데이터셋의 원본 이미지와 CLAHE가 적용된 이미지

II-3. 실험 및 결과 분석

본 연구에 사용된 모델은 PAPILA 데이터셋 연구에서 사용된 CNN 기반의 VGG16, ResNet50, InceptionV3, DenseNet121과 약 90만장의 안저 이미지만을 사용하여 사전 학습된 ViT 기반 모델인 RETFound로 구성하였다. 안저 이미지의 크기는 InceptionV3 모델만 299×299로 재조정하여 학습하였고, 이외의 모델들은 224×224로 재조정하여 학습을 진행하였다. 환자의 안저 이미지가 중복되지 않도록 학습 및 검증 데이터를 구성하였고, 5 fold로 교차 검증하여 성능을 비교 분석하였다.

Model	Original		CLAHE	
	Acc	AUC	Acc	AUC
VGG16	0.8839	0.9302	0.8667	0.9431
ResNet50	0.8707	0.9430	0.8869	0.9431
InceptionV3	0.8939	0.9325	0.8687	0.9437
DenseNet121	0.8758	0.9362	0.8899	0.9442
RETFound	0.8939	0.9463	0.8737	0.9442

표 1. 안저 이미지의 원본 이미지와 CLAHE를 적용한 이미지를 학습한 각 모델의 성능.

표 1은 각 모델이 원본 이미지와 CLAHE를 적용한 이미지를 학습한 결과를 나타낸다. CLAHE를 적용했을 경우, ImageNet으로 사전 학습된 모델들의 AUC 성능이 모두 향상된 것을 확인할 수 있으며, 이 중 DenseNet121이 0.9442의 AUC로 가장 높은 성능을 보였다. 반면에 안저 이미지만으로 사전 학습된 모델인 RETFound는 약간의 성능 저하가 발생하여 CLAHE를 활용한 이미지 전처리 기법이 ImageNet으로 사전 학습된 모델에 한정된 성능 향상 기법으로 확인된다.

Model	Pre	Sen	F1	Acc	AUC
DenseNet121	0.926	0.851	0.887	0.897	0.952
RETFound	0.910	0.906	0.908	0.913	0.961

표 2. 양안 안저 이미지 특징을 결합하여 MLP classifier로 분류한 성능 (Pre: Precision, Sen: Sensitivity)

환자의 양안을 활용한 방법은 표 2에서 DenseNet121과 RETFound 모두 성능이 향상됨을 확인할 수 있다. 특히 RETFound로 추출한 양안의 특징을 사용한 경우, 표 1을 포함한 모든 녹내장 예측에서 가장 높은 성능을 보였다. 이는 안저 이미지로 사전 학습된 모델이 ImageNet으로 사전 학습된 모델보다 안저 이미지의 특징을 더 잘 포착하여 성능 개선에 기여했음을 시사한다. 그림 3은 GradCAM[7]과 RELPROP[8]을 통해 DenseNet121과 RETFound의 학습 과정에서 녹내장과 관련된 주요 특징을 시각화한 결과이다. 이 그림에서 빨간색으로 강조된

부분은 실제 녹내장 진단의 주요 기준인 optic disc를 나타내며, 두 모델 모두 PAPILA 데이터셋과 GRAPE 데이터셋에서 optic disc를 주요 특징으로 강조하였다. 이는 모델의 녹내장 판단 과정에서 실제 기준이 반영됨을 의미하며, 본 연구의 신뢰성을 높이는 결과이다. 결과적으로 본 논문에서 제안하는 이미지 전처리 기법과 환자의 양안을 모두 사용하는 방법이 대부분의 모델에 대해 효과적임을 확인할 수 있다.




그림 3. GradCAM과 RELPROP 기반 모델 학습 시각화

III. 결론

본 논문에서는 안저 이미지의 특징을 강조할 수 있는 이미지 전처리 기법과 환자의 양안을 활용하는 모델과 이프라인을 제안하였고, 제안된 방법들 모두 개선된 성능을 보였다. 특히 양안을 활용한 분류 성능은 단일 안저 이미지만을 사용했을 때보다 상당히 향상된 성능을 보였으며, 질병 진단 시 양안 활용의 중요성을 파악할 수 있었다. 그러나 제안된 모델에 적합한 추가적인 이미지 전처리 기법과 다양한 인종 및 특징을 가진 데이터셋에 대한 추가 연구가 필요하다.

ACKNOWLEDGMENT

이 성과는 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임 (No. NRF-2022R1A2C1007434).

참 고 문 헌

- [1] Thanh, Tai Ho Phuong, et al. "A real-time classification of glaucoma from retinal fundus images using AI technology." 2020 International Conference on Advanced Computing and Applications (ACOMP). IEEE, 2020.
- [2] Muchchuti, Stewart, and Serestina Viriri. "Retinal disease detection using deep learning techniques: a comprehensive review." Journal of Imaging 9.4 (2023): 84.
- [3] Salem, Nema, Hebatullah Malik, and Asmaa Shams. "Medical image enhancement based on histogram algorithms." Procedia Computer Science 163 (2019): 300-311.
- [4] Kovalyk, Oleksandr, et al. "PAPILA: Dataset with fundus images and clinical data of both eyes of the same patient for glaucoma assessment." Scientific Data 9.1 (2022): 291.
- [5] Huang, Xiaoling, et al. "GRAPE: A multi-modal dataset of longitudinal follow-up visual field and fundus images for glaucoma management." Scientific Data 10.1 (2023): 520.
- [6] Zhou, Yukun, et al. "A foundation model for generalizable disease detection from retinal images." Nature 622.7981 (2023): 156-163.
- [7] Selvaraju, Ramprasaath R., et al. "Grad-cam: Visual explanations from deep networks via gradient-based localization." Proceedings of the IEEE international conference on computer vision. 2017.
- [8] Chefer, Hila, Shir Gur, and Lior Wolf. "Transformer interpretability beyond attention visualization." Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. 2021.