

순환학습 기반 다중 안질환 분류 모델의 적용성 확장에 관한 연구

강홍구¹, 목다현², 양희규³, 추현승⁴

¹성균관대학교 AI시스템공학과 석사과정

²성균관대학교 전자전기컴퓨터공학과 석사과정

³성균관대학교 컨버전스연구소 연구원

⁴성균관대학교 전자전기컴퓨터공학과 교수

{honggu6851, dahyun1025, huigyuu, choo}@skku.edu

Enhancing the Applicability of a Multi-Disease Classification Model with Cyclic Learning

Honggu Kang¹, Dahyun Mok², Huigyuu Yang³, Hyunseung Choo²

¹Dept. of AI Systems Engineering, Sungkyunkwan University

²Dept. of Electrical and Computer Engineering, Sungkyunkwan University

³Convergence Research Institute, Sungkyunkwan University

요 약

고령화로 인해 실명을 유발하는 안질환의 발병률이 지속적으로 증가하고 있다. 이에 본 연구는 딥러닝 기반의 안저사진 분석을 통해 다중 안질환 분류 모델의 적용성을 향상시키고자 한다. Ocular Disease Intelligent Recognition (ODIR) dataset과 같은 다양한 공용 데이터셋에 순환학습과 regularization 기법을 적용하여 녹내장, 백내장, 황반변성 등의 질환을 효과적으로 분류를 돕는 기법을 제안한다. 이를 통해 안질환 진단의 정확성을 높이고, 임상에서 활용가능한 신뢰성 있는 안질환 진단 모델을 구축하고자 한다.

1. 서론

세계적인 고령화와 생활 습관의 변화로 인해 실명을 초래할 수 있는 안질환의 발생률이 급격히 증가하고 있다[1]. 미국 국립 안과 연구소는 자국 내 황반변성 환자 수가 2021년 기준 약 207만 명에서, 2050년에는 544만 명으로 증가할 것으로 예상된다[2]. 이러한 상황에서 인공지능과 딥러닝 기술의 발전은 안질환 진단의 정밀성과 효율성을 크게 향상시킨다. 특히, Convolutional Neural Network(CNN) 모델과 같은 딥러닝 기법은 이미지 내 특징을 세세히 분석하여 다양한 안질환을 높은 정확도로 분류한다[3]. 이러한 기술적 진보는 안과 전문의들의 진료 부담을 줄이고, 보다 일관성 있는 진단을 통해 환자의 삶의 질 향상에 기여한다.

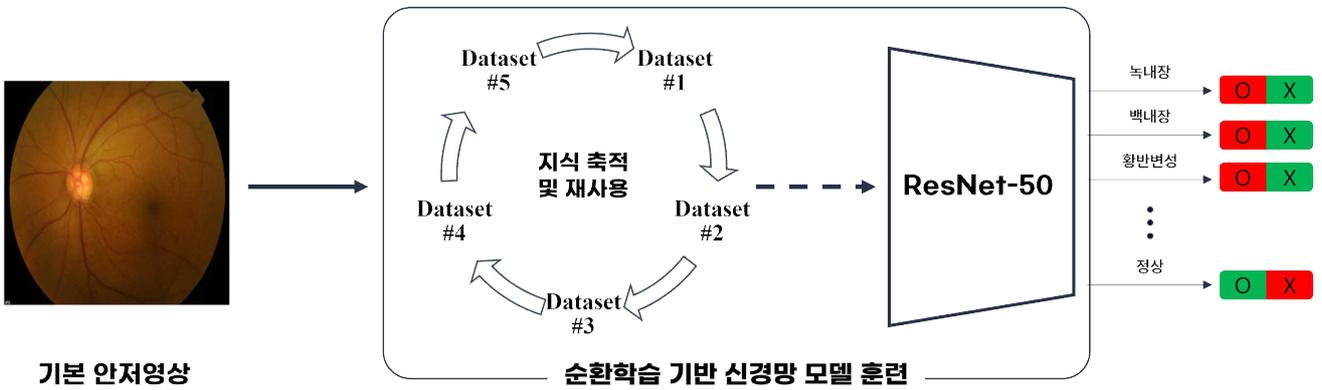
본 연구에서는 딥러닝 기반 안저검사의 적용성을 높이기 위해 다양한 공용 안질환 분류 데이터셋으로 훈련된 다중 안질환 분류 모델을 제안한다. 이는 다수의 공용 데이터셋으로 학습된 CNN 모델에 Conventional Fundus Image (CFI) 내 질병 여부를 파악하는 방식이다. 모델학습에 다수의 데이터셋을 다루는 것으로 다양한 임상 환경에서의 활용을 목표

로 한다. 이를 통해 기존의 단일 데이터셋만을 활용하는 딥러닝 모델들의 낮은 일반화 성능을 극복하고, 보다 신뢰성 있는 진단 결과를 제공할 수 있을 것으로 예상된다.

2. 관련 연구

의료 영상처리 분야에서 딥러닝 모델은 의료 이미지의 세부 특징을, 보다 정밀하게 학습하여 높은 정확도로 의료 영상 내 특이사항을 확인한다. Rayees Ahmad et al.[4]은 CNN 모델을 활용하여 흉부 Computer Tomography, Magnetic Resonance Imaging (MRI), 3D Mammography 등의 의료 영상에서 유방암을 진단한다. Khairandish et al.[5]은 support vector machine을 활용하여 뇌 MRI에 있는 종양을 감지하고 종류에 따라 분류한다.

딥러닝 기법을 활용한 CFI 내 안질환 진단도 우수한 성능을 보인다. Jinke Lin et al.[6]은 Graph Convolutional Network 기반의 MCGS-NET으로 다중 안질환 진단에서 F1-score 89.66%, Kappa 57.65%로, ResNet-50, DenseNet-121과 같은 CNN 모델보다 우수한 성능을 보인다. Jiaqi Wang et



(그림 1) 딥러닝 모델의 순차적 데이터셋 학습 구조

al.[7]은 6개의 공용 데이터셋, 2개의 사유 데이터셋 분류에 Vision Transformer을 사용하여 4가지 클래스에 대해 평균 분류 정확도 97%를 보인다. Murugan과 Roy[8]는 새로운 CNN 모델인 MicroNet으로 CFI 내 미세동맥류 자동 검출을 통한 당뇨병 망막병증 진단에서 Area Under the Curve (AUC) 92%의 성능을 보인다.

3. 데이터셋 및 모델 학습

3-1. 데이터셋

CFI는 망막을 비롯한 눈 내부 구조를 포괄적으로 보여주는 이미지 자료로, 시신경, 혈관 등의 상태를 확인할 수 있다. 이를 통해 망막의 손상 여부, 눈 혈관의 구조적 변화, 시신경의 크기 및 위치를 분석함으로써 안질환 여부를 진단할 수 있다.

연구에는 다중 안질환 진단 정보를 포함한 4개의 공용 CFI 데이터셋을 다룬다. 2019년 베이징 대학의 Intelligent Eye 대회에서 공개한 Ocular Disease Intelligent Recognition (ODIR) 데이터셋, 3종의 안저 카메라로 촬영한 CFI에 2명의 전문의가 주석을 단 Retinal Fundus Multi-Disease image Dataset (RFMiD), 여러 망막 질환 탐지 간 이미지 품질 보장을 위해 후처리 과정을 거친 Multi-Label Retinal Disease (MuReD) 데이터셋, Kaggle에서 제공하는 Eye Disease Classification (EDC) 데이터셋을 사용하며, 데이터셋별 이미지, 레이블 수는 표 1과 같다.

<표 1> 다중 안질환 분류 데이터셋

	ODIR	RFMiD	MuReD	EDC
CFI (장)	8,000	3,200	2,208	4,217
레이블 (개)	8	46	20	4

3-2. 모델 학습

딥러닝 모델로는 ResNet-50[9]을 사용한다. ResNet-50은 각 레이어에서의 residual learning으로 깊은 네트워크에서 복잡한 패턴을 학습할 때 발생할 수 있는 성능 저하를 효과적으로 완화한다. 특히, shortcut connection으로 입력 데이터를 출력층까지 직접 전달하여 네트워크가 깊어지더라도 정보 손실을 최소화하고, 안정적인 학습을 진행한다. 이를 통해 안저사진 내 혈관, 피부조직 등의 특징을 효율적으로 포착하는 것으로 CFI 내 안질환 진단 간 우수한 성능을 보인다.

모델의 순환학습에는 ODIR, RFMiD, MuReD 데이터셋을 사용한다. 3가지 데이터셋을 각각 train, validation, test set으로 나누어 활용한다. RFMiD는 데이터 분할 간 일부 레이블의 데이터가 10장 미만으로 그 양이 매우 적다. 이러한 데이터 불균형은 모델학습 시 overfitting으로 인한 성능 저하를 유발할 수 있다. 이를 방지하고자 해당 이미지들을 제외하여 전체 레이블 46개 중 26개에 해당하는 데이터만을 활용한다.

모든 CFI를 224x224 픽셀 크기로 리사이징하여 크기를 통일한다. 그림 1과 같이 딥러닝 모델에 각 데이터셋을 순차적으로 학습시켜 여러 데이터셋의 이미지 특징 축적 및 재사용한다. 위 과정의 반복을 통해 CNN 모델이 안저사진 내 다중 안질환 진단에 필요한 정보를 순차적으로 학습하여 학습 안정성을 높인다. 학습 간 하이퍼파라미터는 batch size 4, epoch 30, learning rate 0.0001로 설정한다.

4. 실험 결과

본 연구는 순환학습 기반 다중 안질환 진단 모델의 성능을 Area Under the Curve(AUC)로 확인한

다. AUC는 모델이 양성 및 음성 클래스 간의 구분을 얼마나 잘 수행하는지를 평가하며, 값이 클수록 성능이 우수함을 나타낸다. 순환학습 활용에 따른 성능 향상 확인을 위해 ODIR 데이터셋으로만 학습한 CNN 모델, 각종 regularization 기법을 적용한 CNN 모델의 성능을 제안기법의 것과 비교한다.

학습을 마친 모델들로 EDC 데이터셋을 분류한다. 모델학습에 사용한 데이터셋 3개는 EDC 데이터셋의 백내장, 당뇨성 망막병증, 녹내장, 질병없음 클래스를 모두 포함한다. 각 모델을 활용한 EDC 데이터셋 분류 결과는 표 2와 같다.

<표 2> 모델 구성에 따른 다중 안질환 분류 결과

No.	구성	AUC
1	ResNet-50	0.8708
2	ResNet-50 + Dropout	0.8790
3	ResNet-50 + Label smoothing	0.8669
4	ResNet-50 + Early stopping	0.8743
5	ResNet-50 + 순환학습	0.9157

ResNet-50으로 EDC 데이터셋을 분류한 결과 AUC 0.8708의 성능을 보인다. 모델학습 간 overfitting 방지 기반 학습 능력 향상을 위한 dropout, label smoothing, early stopping을 적용한 모델의 성능은 ResNet-50의 것보다 우수하다. 본 연구에서 다룬 순환학습 활용은 AUC 0.9157로 기본 CNN 모델 대비 약 5.16% 향상된 성능을 보인다.

5. 결론 및 향후 계획

본 논문은 CFI 내 다중 안질환 분류의 적용성 향상을 위해 CNN 모델인 ResNet-50에 여러 공용 데이터셋의 순환학습을 적용한다. 해당 구성의 성능 확인을 위해 동일한 환경에서 CNN 모델, regularization 기법에 대한 다중 안질환 분류 실험을 진행하였고, 제안기법이 가장 높은 AUC 수치를 보인다. 이는 딥러닝 모델 기반 CFI 분류에서 데이터셋 순환학습의 성능이 우수함을 보인다.

향후 연구에서는 모델의 순환학습 및 테스트에 보다 다양한 CNN 모델과 다중 안질환 분류 데이터셋을 활용할 것이다. 이를 통해 모델의 일반화 성능을 더욱 향상시킴으로써 임상 환경에서 신뢰성 있고 실용적인 안질환 모델을 구축할 수 있을 것이다.

사사문구

이 논문은 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원의 ICT명품인재양성사업(IITP-2024-2020-0-01821, 50%), (RS-2021-II212068, 인공지능 혁신 허브 연구 개발, 20%), (No.2019-0-00421, 인공지능대학원지원(성균관대학교), 20%)과 4단계 BK21 사업(10%)의 지원을 받아 수행된 연구임.

참고문헌

[1] Thinggaard BS, Pedersen F, Grauslund J, and Stockholm L. "Intravitreal Vascular Endothelial Growth Factor Inhibitor Therapy in Denmark and 5-Year Projections," JAMA Netw Open, Vol. 6, No. 9, 2023.

[2] J. Banks, "Looking Disease in the Eye," IEEE pulse, Vol. 12, No. 6, pp. 10-13, 2021.

[3] Neha Sengar, Rakesh Chandra Joshi, Malay Kishore Dutta, and Radim Burget, "EyeDeep-Net: a multi-class diagnosis of retinal diseases using deep neural network," Neural Comput & Applic, Vol. 35, pp. 10551 - 10571, 2023.

[4] Dar, Rayees Ahmad, Muzafar Rasool, and Assif Assad, "Breast cancer detection using deep learning: Datasets, methods, and challenges ahead," Computers in biology and medicine, Vol. 149, 2022.

[5] Khairandish, Mohammad Omid, Monica Sharma, Vishal Jain, Jyotir Moy Chatterjee, and N. Z. Jhanjhi, "A hybrid CNN-SVM threshold segmentation approach for tumor detection and classification of MRI brain images," Irbm, Vol. 43, No.4, pp. 290-299, 2022.

[6] Jinke Lin, Qingling Cai and Manying Lin, "Multi-Label Classification of Fundus Images With Graph Convolutional Network and Self-Supervised Learning," IEEE Signal Processing Letter, Vol. 28, pp. 454-458, 2021.

[7] Jiaqi Wang, Mengtian Kang, Yong Liu, Chi Zhang, Ying Liu, Shiming Li, Que Qi, WenjunXu, Chenyu Tang, Edoardo Occhipinti, Mayinuer Ysusfu, Nigli Wang, Weiling Bai, Shuo Gao and Luigi G. Occhipinti, "SSVT: Self-Supervised Vision Transformer For Eye Disease Diagnosis Based On Fundus Images", arXiv:2404.13386, 2024.

- [8] R Murugan, Parthapratim Roy, "MicroNet: microaneurysm detection in retinal fundus images using convolutional neural network," *Soft Computing*, Vol. 26, pp. 1057 - 1066, 2022.
- [9] He, K., Zhang, X., Ren, S., and Sun, J., "Deep residual learning for image recognition." *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 770-778, 2016.