

전이학습 기반 황반변성 진단모델의 개발

¹김경민*, ¹오세종**

¹단국대학교 소프트웨어학과

keung903@naver.com, sejongoh@dankook.ac.kr

Development of A Macular Degeneration Predictive Model Based on Transfer Learning

Kyung-Min Kim¹ Se-Jong Oh¹

¹Dept. of Software Science, Dankook University

요 약

본 논문은 황반변성 진단 모델 개발을 위해 안저 사진을 이용한 MobileNet2 전이학습 모델 개발과 안정적인 모델 성능을 위한 이미지 증강 방법 및 모델 성능 향상을 위한 파라미터 조정 방법을 제안한다. 보유하고 있는 이미지의 수가 매우 적다고 하더라도 적절한 전이학습 모델을 사용하고 이미지 증강 시 증강 방법과 증강한 이미지와 정상 이미지와의 비율을 적절히 고려할 경우 충분히 안정적인 결과를 얻어낼 수 있다. 또한 파라미터 조정을 통해서 성능 향상을 도모할 수 있다.

1. 서론

황반변성은 눈 조직 중 황반에 변성이 발생해 시력 저하를 유발하는 퇴행성 안과 질환이다 [1]. 나이가 주요 위험 인자로 작용하는 퇴행성 질환이기에 고령인구가 증가하면서 의료 비용 또한 계속 증가하는 추세이다. 조기에 진단된다면 진행을 늦추거나 완치될 수 있는 질환임에도 불구하고 안과 검사기기를 이용해 안과 의사가 모두 스크리닝 하는 것에 대한 한계가 있다. 따라서 환자의 황반변성 여부를 진단하는 황반변성 진단 시스템을 개발하여 안과진료 환경을 개선하는 것이 필요하다 [2].

본 연구에서는 안저사진(Fundus) 이미지를 대상으로 전이학습 모델을 사용하여 황반변성 진단 모델을 개발하였다. 정상/황반변성 두가지 클래스를 분류하였으며, 안정된 결과를 얻기 위해 이미지 데이터 증강을 실시하였다. 또한 파라미터 조율을 통해 성능 향상을 도모하였다.

2. 관련 연구

안저사진을 이용해 황반변성의 유무를 진단하는 기존 연구는 찾아보기 어렵다. 보통 황반변성의 유무보다는 황반변성의 진행 단계를 OCT 검사 데이터를 이용하여 분류하는 내용의 논문이 주를 이루고 있으며 [3]~[6], 전이학습을 이용해 황반변성의 유

무를 분류하는 연구 또한 드물었다. 2016 년 IEEE 에서 발표된 논문에 따르면 ImageNet 으로 사전 학습된 심층 합성곱 신경망을 사용해 안저사진의 특징 벡터를 추출하고 이를 다시 분류를 위한 LSVM 모델에 입력값으로 넣어 최종 분류 결과를 얻어낸다. 분류 모델에 들어갈 특징 벡터 추출을 위해서는 중앙부에 위치한 망막 영역이 황반변성 분류에 있어 중요한 단서를 제공하기 때문에 중심부를 기준으로 서로 크기만 다른 정방향 사각형 영역 4 개를 지정하였고 각 영역별로 계산한 특징 벡터들을 하나의 단일 벡터로 연결해 4096 개의 요소로 구성된 최종 특징 벡터를 얻어낸다. 해당 연구 또한 황반변성 진행 단계를 분류하는 연구였으나 다양한 단계의 이미지를 조합해 데이터셋을 구성하였고 그 중 정상/황반변성 두가지 클래스로 구성되어 분류를 진행해 95%의 성능을 얻어낸 것을 확인할 수 있었다 [7].

3. 황반변성 진단모델의 개발

3.1. 데이터 전처리


본 연구에 사용한 안저사진 데이터는 Kaggle[8] 과 Baibu[9]를 통해 정상 이미지 4578 장, 황반변성 이미지 548 장으로 총 5126 장을 확보하였으며 학습데이터와 테스트 데이터로 나누어 진행한다.

이미지 크기의 통일성과 학습 시 과도한 계산량을 줄이기 위해 원본 이미지에서 더 짧은쪽 면을 800 픽셀로 조정하고 다른 한 면은 식 1 을 이용하여 계산해 조정하도록 하였다.

$$800 * (\text{이미지의 긴 변의 길이} / \text{이미지의 짧은 변의 길이}) \quad (1)$$

3.2. 전이학습모델 개발

진단 모델은 빠른 구축과 실험 결과 도출을 위해 전이 학습 이미지 분류 모델 중 비교적 연산량이 적고 모델 사이즈가 작으면서도 CNN 이미지 분류에 있어 높은 성능을 보이는 MobileNet2 를 사용하였다. 기본적으로 Karas 에서 제공하는 MobileNet2 모델을 import 해 사용했으며 input size 는 800 x 800 으로 설정하였고 매개변수가 너무 많아지는 것을 방지하기 위해 globalMaxPooling2D Layer 를 마지막 layer 로 추가하여 flatten 과 fully



(그림 1)

3.3. 이미지 증강

보유하고 있는 전체 이미지 데이터의 수는 충분하지만 황반변성 이미지 데이터가 정상 이미지 데이터에 비해 현저히 적어 모델이 황반변성 이미지를 제대로 학습하지 못하고 과적합이 발생할 가능성이 존재하였기 때문에 이를 황반변성 이미지 데이터 증강 작업을 통해 해결하고자 했다.

증강 작업을 위해 opencv 라이브러리를 사용해 기존 황반변성 원본 이미지에 다양한 효과를 넣어 < 표 1> 과 같이 3 가지 데이터셋을 얻었다. 데이터셋 1 의 정상데이터 와 황반변성 데이터의 비율은 약 2:1 이고 훈련 데이터와 테스트 데이터의 비율 또한 2:1 로 나누어 실험 1 을 진행했다. 그 결과 정확도 94% loss 27% 라는 상당히 높은 성능의 결과를 얻었고, 훈련 그래프 또한 안정적인 양상을 띄고 있는 것을 확인할 수 있었다. (그림 2)


실험 1 에서 안정적이고 높은 정확도를 얻어냈지만 여전히 황반변성 데이터가 정상 데이터에 비해 적다고 판단하여 데이터의 비율이 1:1 이 되도록 증

강 작업을 다시 진행하여 데이터셋 2 를 얻어냈다. 훈련 데이터와 테스트 데이터의 비율 또한 6:4 로 재분리해 실험 2 를 진행하였고 정확도 96%, loss 21% 로 실험 1 보다 2% 상승한 정확도를 얻어냈다. (그림 3)


데이터셋 1 과 데이터셋 2 에서 사용한 증강 데이터의 일부는 RGB 가 전환된 파란색 이미지가 포함되어 있다. 하지만 이는 현실에서는 존재하지 않는 이미지로 실제 의료 현장에서 사용할 진단 모델을 학습시키는데 있어 적합하지 않다고 판단하였다. 따라서 이미지 증강 중 RGB 를 전환하는 작업을 생략하고 데이터셋 3 을 새롭게 얻어 실험 3 을 진행한 결과 정확도 96%, loss 18% 라는 결과를 얻어낼 수 있었다.(그림 4) 정확도는 실험 2 와 동일하나 loss 가 4% 감소했기 때문에 현실 반영을 고려한 이미지 증강 방식이 성능 향상에 어느 정도 도움이 되었다고 판단한다.

<표 1> 데이터셋 별 성능 비교표

	데이터셋	증강 방법	Acc (%)	Loss (%)
실험 1	데이터셋 1 (황반변성 2883 장 정상 4579 장)	(1) 좌우 반전 (2) 상하 반전 (3) 좌우반전 이미지의 상하반전 (4) 원본 이미지 + 1,2,3 이미지의 회전 (5) 원본 이미지 + 1,2,3 이미지의 밝기 조정 및 RGB 반전	94%	27%
실험 2	데이터셋 2 (황반변성 4579 장 정상 4579 장)	1) 좌우 반전 2) 상하 반전 3) 좌우반전 이미지의 상하반전 4) 원본 이미지 + 1) 2) 3) 이미지의 회전 5) 원본 이미지 + 1) 2) 3) 4) 이미지의 밝기 조정 및 RGB 반전	96%	21%
실험 3	데이터셋 3 (황반변성 4579 장 정상 4579 장)	1) 좌우 반전 2) 상하 반전 3) 좌우반전 이미지의 상하반전 4) 원본 이미지 + 1) 2) 3) 이미지의 회전 5) 원본 이미지 + 1) 2) 3) 4) 이미지의 밝기 조정	96%	18%



(그림 2) 실험 1 훈련 그래프 (그림 3) 실험 2 훈련 그래프



(그림 4) 실험 3 훈련 그래프

3.4. 파라미터 조율

이미지 증강을 통해 가장 높은 성능의 데이터셋을 얻은 후 모델을 최적화할 수 있도록 파라미터 조정 작업을 진행했다. learning_rate 와 momentum 은 각각 $1e-4$, 0.9 으로 설정해주었을 때 가장 안정적인 학습 그래프를 나타냈다. 또한 alpha 는 0.35, epoch 은 100 으로 설정했고 batch size 는 이미지 증강 작업 이후 데이터 수가 많아져 60 이상일 때 제대로 된 성능을 발휘하지 못했다. 실험 1-3 에서는 batch size 를 40 으로 설정해 실험하여 얻은 결과이고 가장 높은 성능을 보인 데이터셋 3 에서 50 으로 변화를 주었을 때 정확도는 변함이 없었지만 loss 가 16% 까지 떨어진 것을 확인할 수 있었다.

4. 결론

본 논문에서는 전이학습을 이용하고, 이미지 증강 방법과 파라미터 조정을 통해 성능의 안정성과 향상 과정을 보였다. 이는 일반적인 방식이지만 이미지의 현실성과 데이터 간의 비율이 성능에 미칠 영향에 대해 중점적으로 고려한 진단 모델이다. 또한 ImageNet 을 사용해 이미지의 특징 벡터를 추출했던 선행 연구보다 발전된 형태로서, 전이학습 모델을 사용해 모델 구축과 데이터 처리면에서 더욱 간단하고 편리한 방법임에도 기존 연구 대비 2~3% 의 성능 향상을 보였다.

Acknowledgement

이 논문은 2022 년도 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원의 지원을 받아 수행된 연구임 (2018-0-00242. 빅데이터 기반 인공지능 안과 진단기술 및 스마트 진료 플랫폼 개발)

참고문헌

[1] 서울아산병원, "건강정보|의료정보|질환백과|황반변성", 서울아산병원 홈페이지, 서울아산병

원, <https://www.amc.seoul.kr/asan/healthinfo/disease/diseaseDetail.do?contentId=31165>, 2022.09.06.

- [2] 오세종, 연구개발계획서: 빅데이터 기반 인공지능 안과 진단기술 및 스마트 진료 플랫폼 개발, 과학기술정보통신부: 정보통신기획평가원, 2022.
- [3] Arun Govindaiah; Abdul Baten; R. Theodore Smith; Siva Balasubramanian, "Optimized Prediction Models from Fundus Imaging and Genetics for Late Age-Related Macular Degeneration", Journal of Personalized Medicine, vol 11, no.11, pp.1-14, 2021
- [4] Philippe M Burlina et al. , "Automated Grading of Age-Related Macular Degeneration From Color Fundus Images Using Deep Convolutional Neural Networks", JAMA Ophthalmol, vol.135, no.11, pp.1170-1176, 2017
- [5] Yao-Mei Chen; Wei-Tai Huang; Wen-Hsien Ho; Jinn-Tsong Tsai, "Classification of age-related macular degeneration using convolutional-neural-network-based transfer learning", BMC Bioinformatics, vol.22, no.99, 2021
- [6] Jen HongTan et al. , "Age-related Macular Degeneration detection using deep convolutional neural network", Future Generation Computer Systems, vol.87, pp.127-135, 2018
- [7] D. E. Freund; N. Joshi; Y. Wolfson; N. M. Bressler, "Detection of Age-Related Macular Degeneration Via Deep Learning" IEEE 13th International Symposium on Biomedical Imaging (ISBI), 13th, pp.184-188, 2016.
- [8] Kaggle, Ocular Disease Recognition [Data set], <https://www.kaggle.com/andrewmvd/ocular-disease-recognition-odir5k/version/2>, 2021.
- [9] Baidu, Dataset| iChallenge-AMD [Data set], <https://ai.baidu.com/broad/introduction?dataset=amd>, 2021.