

ResU-Net을 활용한 망막혈관 분할에 관한 연구

조유상, 송호중, 김용석*

건양대학교, *건양대학교

22806506@konyang.ac.kr, 20806608@konyang.ac.kr, *yskim@konyang.ac.kr

A Study on Retinal Vascular Segmentation Using ResU-Net

Cho You Sang, Song Ho Jung, Kim Yong Suk*

Konyang Univ., *Konyang Univ.

요 약

본 논문은 전문의의 망막혈관 라벨링 지식을 인공지능 모델에게 학습시켜 망막혈관의 특징을 추출하고 생성하는 기술을 연구하였다. DRIVE(Digital Retinal Images for Vessel Extraction) 데이터셋을 활용해 이미지를 회전시켜 데이터를 구성하였다. 데이터 전처리에는 검은색의 마스크 부분을 이미지의 평균값의 색으로 적용시킨 후 CLAHE(Contrast Limited Adaptive Histogram Equalization)를 사용하여 망막혈관의 특징을 강조시켰다. ResNet의 특징과 U-Net의 특징을 결합한 ResU-Net을 사용하여 망막혈관 분할에 대해 학습을 진행하였다. 후처리로 NLM(Non-local means) Denoising를 거쳐 모델 결과에 노이즈를 제거하였다. 히스토그램 분포를 비교하여 모델의 분할 결과를 평가하였으며 Correlation, 카이제곱, Intersection, 바타차리야 거리 측정기법 EMD(Earth Moving Distance), 총 5가지의 방법을 사용하였다. 향후 연구로는 망막혈관의 손실 없이 노이즈를 제거하는 방법에 대해 연구할 계획이다.

I. 서 론

안저 영상은 망막, 시신경, 망막혈관 등을 확인할 수 있으며 녹내장 등의 3대 안저 질환을 조기에 발견하는 데 널리 쓰이고 있다.[1] 그중에서 망막혈관은 인체에서 비침습적으로 확인할 수 있는 유일한 혈관이다. 이러한 망막혈관은 다른 분야에서도 혈관성 질환의 검출을 위해 활발히 활용되고 있으며 임상학적으로 활용에 많은 가치를 갖는 데이터이다. 하지만 안저 영상에서 망막혈관 데이터를 추출하여 획득하는 기존의 방식은 전문의의 수작업을 통한 망막혈관 라벨링으로 진행되고 있다. 이는 다량의 데이터가 필요한 빅데이터 기술로써는 데이터 획득의 많은 어려움을 갖는다. 따라서 본 논문에서는 전문의의 망막혈관 라벨링 지식을 인공지능 모델에게 학습시켜, 입력된 안저 영상에 대하여 망막혈관 라벨링을 추출하고 생성하는 기술을 연구하였다.

II. 본론

(1) 활용 데이터

연구에 활용한 데이터는 안저 영상에서 망막혈관 분할 연구를 위해 공개된 Grand Challenges의 DRIVE(Digital Retinal Images for Vessel Extraction) 데이터셋을 사용하였다. DRIVE 데이터셋은 네덜란드의 당뇨병 망막 병리 검사 프로그램에서 획득하였으며 각각 크기 (512, 512, 3)인 20장의 학습 데이터와 20장의 테스트 데이터 총 40개로 구성되었다. 본 연구에서는 라벨링이 되어 있는 학습 데이터만을 사용하였다. 부족한 데이터를 보충하기 위해 각각의 이미지를 3도씩 회전시켜 데이터의 개수를 증강시켰다. 한 개의 안저 이미지당 120장씩, 총 2,400장으로 늘려 구성하였다.

(2)데이터 전처리

안저 이미지에서 연구에 해당하지 않는 검은 부분의 마스크를 이미지의

평균값의 색으로 변경하여 색상의 차이를 최대한 줄여 전처리를 진행하였다. 그 후 RGB 채널의 이미지를 LAB 체계로 변환하였다. 변환한 이미지에서 혈관의 특징을 강조시키며 손실을 줄이기 위해 CLAHE(Contrast Limited Adaptive Histogram Equalization)를 진행하였다.[2] 그 후 다시 LAB에서 RGB로 변환한 후 검은색 마스크 부분을 적용하였다. 모델의 학습을 원활하게 진행하기 위하여 전체 이미지를 입력하지 않고 (512, 512)의 데이터를 (64, 64)의 데이터 64개의 데이터로 분할한 후 Grayscale을 거쳐 학습을 진행하였다. 그림1의 (a)는 원본 이미지이며 (b)는 CLAHE와 마스크 적용의 전처리 과정이 끝난 이미지이다.



(a)

(b)

그림 1. 원본이미지와 전처리 이미지

(3)모델 구성

본 연구에서 사용한 모델은 ResNet의 Residual Block과 U-Net 모델의 Concatenate 특징과 Up sampling을 결합한 ResU-Net을 사용하였다.[3] Residual Block을 활용하여 연산량을 줄이고 오버피팅을 예방하였으며 Up sampling 과정으로 적은 학습 데이터로도 충분히 학습되도록 구축하였다. 6개의 Residual Block과 3번의 UpSampling을 거쳤으며

Concatenate로 이전 학습에서 나온 가중치를 합쳤다. 각 층의 활성화 함수는 ReLu함수를 사용하였으며 He_normal로 가중치를 초기화하였다. (64, 64, 1)의 학습 데이터와 각 학습 데이터에 맞는 라벨데이터들을 입력하여 학습을 진행하였다. 라벨데이터들 또한 학습데이터와 마찬가지로 64 등분으로 나누어 (64, 64, 1)로 입력하였다. Epoch은 100으로 설정하였으며 최적화 함수는 Adam, 손실함수는 이진 교차 엔트로피 함수를 사용하였다. 그림2는 본 연구에서 사용한 ResU-Net의 구조이다.




그림 2. ResU-Net 모델 구조

(4)후처리 및 결과

학습을 끝낸 모델이 출력한 망막혈관 분할 이미지를 다시 (512, 512, 1)로 병합한 후 후처리를 진행하였다. OpenCV의 NLM(Non-local means) Denoising 함수를 사용하여 중심의 픽셀을 기준으로 유사도를 판단하여 유사한 영역의 평균을 취해 노이즈를 제거하였다.[4] 그림 3의 (a)는 DRVIE 데이터셋의 전문가가 라벨링 한 데이터이며 (b)는 모델이 출력한 망막혈관 분할 이미지에 후처리를 거친 후의 결과이다.




그림 3. 망막혈관 라벨과 후처리 결과

후처리가 끝난 데이터와 망막혈관 라벨과의 유사도를 측정하여 모델의 결과를 평가하였다. 유사도 측정을 위해 OpenCV를 활용한 Correlation, 카이제곱, Intersection, 바타차리아 거리 측정기법 그리고 EMD(Earth Moving Distance), 총 5가지의 방법으로 히스토그램 분포를 비교하여 평가하였다. 1에 가까워야 유사도가 높은 Correlation과 Intersection의 경우 각각 1.0과 0.99의 높은 결과값이 나왔다.[5] 반대로 0과 가까워야 하는 카이제곱, 바타차리아 거리 측정기법, EMD는 각각 2.94, 0.21 0.29를 기록하

였다. 5가지 평가 방법에서 모두 뛰어난 결과를 보이는 것을 확인할 수 있었다.

III. 결론

본 논문에서는 인공지능 기술을 활용하여 안저 영상에서 망막혈관을 분할하였다. 픽셀값의 분포를 서로 비교하여 모델 평가를 진행하였으며 총 5가지의 방법을 사용하였다. Correlation와 Intersection의 방법에서는 각각 유사도가 높은 1.0과 0.9를 기록하였다. 카이제곱, 바타차리아 거리 측정기법, EMD의 경우 2.94, 0.21 0.29를 기록하였다. 3가지의 방법의 경우 유사도가 떨어지는 것을 확인할 수 있었는데 이는 아직 제거하지 못한 이미지의 노이즈와 노이즈를 제거하면서 발생한 미세혈관 특징의 제거로 인한 것으로 보인다. 검은색 마스크를 적용하는 과정에서도 노이즈가 발생하는 것을 확인할 수 있었다. 향후 연구로는 후처리 시 노이즈를 망막혈관의 손실 없이 제거하는 연구와 전처리 과정을 발전시켜 망막혈관을 효과적으로 분할하는 연구할 계획이다.

ACKNOWLEDGMENT

본 논문은 교육부와 한국연구재단의 재원으로 지원을 받아 수행된 3단계 산학협력 선도대학 육성사업(LINC 3.0)의 연구결과입니다.

참 고 문 헌

- [1] Michelessi, Manuele, et al. "Optic nerve head and fibre layer imaging for diagnosing glaucoma." Cochrane Database of Systematic Reviews 11 (2015).
- [2] Reza, Ali M. "Realization of the contrast limited adaptive histogram equalization (CLAHE) for real-time image enhancement." Journal of VLSI signal processing systems for signal, image and video technology 38.1 (2004): 35-44.
- [3] Zhang, Zhengxin, Qingjie Liu, and Yunhong Wang. "Road extraction by deep residual u-net." IEEE Geoscience and Remote Sensing Letters 15.5 (2018): 749-753.
- [4] Bhujle, Hemalata V., and Basavaraj H. Vadavadi. "NLM based magnetic resonance image denoising-A review." Biomedical Signal Processing and Control 47 (2019): 252-261.
- [5] Fu, Anthony Y., Liu Wenyin, and Xiaotie Deng. "Detecting phishing web pages with visual similarity assessment based on earth mover's distance (EMD)." IEEE transactions on dependable and secure computing 3.4 (2006): 301-311.