

전이학습 기반 사시 진단을 위한 안구운동영상 수집 및 소스 데이터 구성에 따른 성능 비교

주재한, 김동환, 최건호, 김석찬*

부산대학교, 부산대학교, 부산대학교, *부산대학교

jhjoo2018@pusan.ac.kr, dongh@pusan.ac.kr, 201624194@pusan.ac.kr, *sckim@pusan.ac.kr

A Study on Performance Comparison According to eye movement image Collection and Source Data Composition for Strabismus Diagnosis Based on Transfer Learning

Jaehan Joo, Donghwan Kim, Geonho Choi, Suk Chan Kim*

Pusan National Univ., Pusan National Univ., Pusan National Univ., *Pusan National Univ.

요 약

본 논문은 딥러닝 기반의 사시 판단 시스템을 설계하기 위해 비정형 데이터의 일종인 안구운동영상 수집 시 실제 의료진들의 진단 정확도, 선택률에 따른 합성곱 신경망의 성능을 비교하였다. 총 1700장의 사시환자 안구운동영상 데이터를 모델 훈련 및 테스트에 활용하였고, 데이터 클래스는 정상, 내사시, 외사시로 구분된다. 선택률에 따라 4개의 데이터 셋을 구성하였으며, 일반적으로 많이 이미지 구별 작업에 많이 사용되는 6개의 합성곱 신경망을 사용하여 각 데이터 셋에 대한 성능을 비교한다.

I. 서 론

최근 딥러닝 기반의 의료 영상 분석 및 진단 기술의 연구 · 개발이 활발하게 진행 되고 있다[1]. 의료 분야에서의 딥러닝 활용 분야는 크게 병의 유무와 종류를 판단하는 구별 작업(classification task), 컴퓨터단층촬영(Computed Tomography, CT), 자기공명영상(Magnetic Resonance Imaging, MRI), 초음파 영상(Ultrasound Image)과 같은 정형화된 영상 내부의 환부나 신체 영역을 분리하는 객체 탐지(Object Detection), 영상 분할(Segmentation) 작업이 있다.

최근에는 수집 가능한 데이터 수 부족, 개인정보보호법 및 의학연구윤리심의위원회(Institutional Review Board, IRB) 통과, 임상적 확률에 의해서 방범률이 낮은 질병에 대한 데이터 수집 한계와 같은 문제점을 극복하기 위해서 생산적적대모델(Generative Adversarial Networks, GANs) 기반의 데이터 생성 및 융합 분야도 활발하게 연구 되고 있다[2 ~ 4].

현재 딥러닝 모델 학습을 위해 사용되고 있는 데이터 셋은 DICOM(Digital Imaging and Communications in medicine)과 같은 정형화된 형태로 제공되는 자기공명영상, 컴퓨터단층촬영, 초음파영상이고, 환자의 환부나 움직임을 직접 촬영한 영상이 있다. 정형화된 데이터 셋의 경우 실제 임상환경에서 사용하기 위한 목적으로 수집 되기 때문에 환자의 질환명, 정도, 처방, 진단 기록 뿐만 아니라 성별, 나이와 같은 메타데이터를 기반으로 구성되어 있다. 하지만 개인정보가 다량으로 포함되어 있기 때문에 의료 기관과 환자의 동의 없이 연구, 개발을 위한 데이터 수집이 어렵고, 해당 데이터를 수집하는 과정에서 고가의 의료 장비가 필요하기 때문에 일반인들이 데이터 수집에 참여하기 어렵다. 비정형 데이터, 즉 직접 촬영한 데이터는 개인정보보호 문제, 데이터 수집의 물리적 한계에 대해서 정형화된 데이터 대비 연구, 개발에 장점이 있다. 하지만 각 개인의 촬영 환경이 너무 다양하고, 질환에 대한 명확한 판단에 어려움이 있

다. 따라서 비정형 데이터 기반의 딥러닝 모델 연구에는 높은 수준의 데이터 전처리 및 선별 과정이 필요하다.

본 연구에서는 딥러닝 기반의 사시 판단 시스템을 설계하기 위해 비정형 데이터의 일종인 안구운동영상 수집 시 실제 의료진들의 진단 정확도, 선택률에 따른 합성곱신경망(Convolutional Neural Networks, CNN)의 성능을 비교하고자한다. 안구운동영상은 사시 환자를 정면에서 촬영하며, 동공의 시선에 따라 총 9장의 영상으로 구성된다. 본 연구에서는 9개의 영상 중에서 정면을 응시하고 있는 영상을 사용한다.

II. 본론

(1) 입력 데이터

본 논문에서는 합성곱신경망의 입력 데이터로 사시 환자의 안구운동영상을 사용한다. 안구운동영상은 사시 환자를 정면에서 촬영하며, 동공의 시선에 따라 총 9장의 영상으로 구성된다. 본 연구에서는 9개의 영상 중에서 정면을 응시하고 있는 영상을 사용한다.

(2) 데이터 수집

본 논문에서 사용하는 안구운동영상은 양산부산대학교병원 안과학교실로부터 수집하였다. 표 1에 보이는것과 같이 총 1,700명의 환자 데이터를 수집하였고, 데이터 클래스는 정상, 내사시(Esotropia), 외사시(Exotropia)로 구분된다.

(3) 데이터 선별

본 논문에서는 데이터 선별에 따른 합성곱 신경망의 성능 비교를 위해 양산부산대학교병원의 안과 전문의 10명이 데이터 라벨링과 선별에

참여하였다. 데이터 셋 구분을 위해 한 장의 안구운동영상에 대한 의료진들의 사시 종류 선택률에 따라 총 4개(모든 데이터 사용, 60%, 70%, 80%) 데이터 셋을 구성하였고, 구성된 데이터 셋 내부의 안구운동영상 수는 아래 표 2와 같다.

(4) 딥러닝 모델 훈련 및 테스트

본 논문에서는 데이터 선택률에 따른 일반적인 합성곱 신경망의 성능 비교를 위해 Xception, ResNet50V2, ResNet101V2, ResNet152V2, VGG16, VGG19 모델을 사용하였다. 또한 구성된 데이터의 수가 부족하기 때문에 전이학습 기법 중 하나인 미세조정(fine tuning) 기법을 활용한다. 또한 4개의 데이터 셋 모두 훈련 데이터 셋, 검증 데이터 셋, 테스트 데이터 셋의 비율을 8:2:2로 구성하여 훈련 및 테스트를 진행하였다. 실험 훈련 파라미터는 표 3과 같다.

표 1. 데이터 수

Table. The number of Dataset

class	Normal	Esotroia	Exotropia
# Data	963	275	462

표 2. 각 데이터 셋의 안구운동영상 수

Table. The number of Data in each Dataset

Dataset	Normal	Esotroia	Exotropia
All	963	275	462
60%	925	249	435
70%	852	219	391
80%	753	192	337

표 3. 실험 훈련 파라미터

Table. Training Parameter

Dataset	Epoch	Learning Rate	batch size
Xception	100	0.0001	200
ResNet50V2	100	0.0001	200
ResNet101V2	100	0.0001	200
ResNet152V2	100	0.0001	200
VGG16	100	0.0001	200
VGG19	100	0.0001	200




그림. 1. 데이터 셋, 딥러닝 모델 별 구별 테스트 정확도

III. 결론

본 논문에서는 데이터 셋 구성 시 전문 의료진의 클래스 선별률에 따른 대표적인 합성곱 신경망 6개의 성능을 비교하였다. 6개의 합성곱 신경망을 4개의 데이터 셋으로 각각 훈련 및 테스트를 진행하였고, 그림 1은 4개의 데이터 셋에 대한 각 합성곱 신경망의 테스트 정확도를 나타낸다. 그림과 표에서 보이는 바와 같이 선택의 임계값을 크게 하였을 경우 훈련 데이터 셋의 수는 부족하지만, 훈련 및 테스트 정확도는 향상하는 것을 확인하였다. 또한 6개의 합성곱 신경망 중에서 ResNet101V2 모델을 의료진이 80% 이상 선택한 데이터 셋으로 학습하였을 때가 가장 성능이 좋은 것을 확인하였다. 하지만 현재 수집한 데이터 수가 적고, 클래스 간의 데이터 수 불균형으로 인하여 학습 과정에서 과적합 문제가 발생한 것을 확인하였고, 추후 연구에서는 생성적 적대 신경망과 같은 데이터 증강 기법을 활용하여 이러한 문제점을 해결하고자 한다.

ACKNOWLEDGMENT

본 연구는 2020년도 산업통상자원부의 재원으로 한국에너지기술평가원(KETEP)의 지원을 받아 수행한 연구 과제(No. 20204030200030)입니다. 이 논문은 국토교통부의 스마트시티 혁신인재육성사업으로 지원되었습니다.

참 고 문 헌

- [1] Shen, D., Wu, G., and H. L. "Deep Learning in medical image analysis," Annual review of biomedical engineering 19, (2017), pp. 221-248.
- [2] KER, Justin, et al. "Deep learning applications in medical image analysis," Ieee Access, June 2017, pp. 9375-9389.
- [3] Lundervol, Alexander S., and Arvid L. "An overview of deep learning in medical imaging focusing on MRI." Zeitschrift für Medizinische Physik 29.2 (2019), pp 102-127.
- [4] Cheng, Jie-Zhi, et al. "Computer-aided diagnosis with deep learning architecture: applications to breast lesions in US images and pulmonary nodules in CT scans," Scientific reports 6.1 (2016), pp. 1-13.
- [5] Gulrajani, Ishaan, et al. "Improved training of wasserstein gans." arXiv preprint arXiv:1704.00028 (2017).