

알츠하이머형 치매 진행단계 구분을 위한 딥러닝 성능 비교 연구

이사랑, 송은채, 강재환, 김준석*

동의대학교 산업ICT공학과, 인공지능그랜드ICT 연구센터

dltk812@gmail.com, aue020@naver.com, [jh.kang, *junsuk.kim]@deu.ac.kr

Classification of Alzheimer's Disease Progression using Deep Learning Algorithms

Sa Rang Lee, Eun Chae Song, Jae-Hwan Kang, Junsuk Kim*

Dong-Eui Univ.

요약

이 논문에서는 자기공명영상 (MRI) 을 이용하여 알츠하이머형 치매 진행의 5단계를 예측하는 딥러닝 모델들을 직접 설계하고 학습시켜 모델의 성능을 비교하는 실험을 하였다. 다양한 딥러닝 알고리즘 가운데 컨볼루션 신경망 (convolutional neural network)을 사용하고 추가로 전이학습 (transfer learning)을 활용하였으며 각 모델의 정확도와 오차율을 비교하였다. 결과적으로 전이학습을 사용한 딥러닝 모델이 단순 컨볼루션 신경망 보다 치매 진행단계 분류에서 뛰어난 성능을 보인다는 것을 확인하였다. 이 연구 결과는 딥러닝 기술을 사용한 MR 영상 기반 치매단계 구분 연구에 기초 자료가 될 것으로 생각된다.

I. 서론

알츠하이머는 치매를 일으키는 가장 흔한 퇴행성 질환으로 서서히 발병하며 점진적으로 진행되는 경과가 특징적이다 [1]. 치매의 진행 단계를 예측하는 다양한 방법들 중 자기공명영상이미지 (MRI)를 활용한 진단은 뇌 피질의 수축 및 뇌 심실의 확장을 시각적으로 확인할 수 있다는 장점에 의학적 가장 많이 사용되는 방법이다. 하지만 MR 이미지의 시각적인 정보만을 사용하여 치매의 진행 단계를 예측하기 위해서는 전문적인 임상 지식과 축적된 경험이 필수적이다. 최근 인간의 시각으로 추출해내기 힘든 바이오마커 (bio-marker) 추출, 의료진 부족으로 인한 물리적인 시간 부족 문제를 해결하기 위하여 딥러닝 알고리즘을 활용하는 다양한 연구가 진행중이며, 특히 컨볼루션 신경망 (CNN) 방법은 매우 우수한 성능을 보이는 것으로 보고되고 있다 [2,3].

이 논문에서는 알츠하이머형 치매 진행과 관련된 5단계 (Early Mild Cognitive Impairment: EMCI, Late Mild Cognitive Impairment: LMCI, Mild Cognitive Impairment: MCI, Alzheimer's Disease: AD, Cognitively Normal: CN)의 MR 이미지를 이용하여, 진행단계를 예측하기 위하여 CNN 기반 딥러닝 모델들을 직접 설계하고 학습시켜 모델의 정확도를 비교 및 분석하려고 한다.

II. CNN (convolutional neural network)

알츠하이머형 치매 진행의 5단계를 분류하기 위해 이미지 분석에 널리 활용되고 있는 CNN을 사용하였다. CNN은 이미지 및 비디오 인식, 추천 시스템, 이미지 분류, 의료 이미지 분석 및 자연어 처리에 다양하게 응용된다 [4]. CNN는 수십 또는 수 백개의 계층을 가질 수 있으며, 각 계층은 영상의 서로 다른 특징을 검출한다. CNN의 계층 중 Convolutional Layer는 Convolutional 필터와 활성화 함수 그리고 Pooling layer를 반복적으로 조합하여 특징을 추출한다. Convolution layer는 합성곱 연산을 통해 적절한 특징맵 (Feature Map)을 구성한다. 상위 Convolution layer는 하위 Convolution layer의 출력을 이용하여 좀 더 높은 수준의 특징들을 추출하게 된다. 또한 각 Convolution layer는 필터를 이용하여 특징을 추출하

게 되는데, 이 필터는 고정된 것이 아니라 학습에 의해 학습 데이터에 맞게 결정이 된다 [5]. 특징맵을 추출 후 특징맵에 활성화 함수를 적용하게 되는데 활성화 함수는 주로 비선형 함수로 되어 있으며 예를 들어 시그모이드 (Sigmoid), ReLu (Rectified Linear Unit) 등이 있다. 시그모이드 함수는 입력값이 아무리 커도 미분 값의 범위가 제한됨으로써 층이 많을수록 gradient 값이 0에 수렴하는 문제를 가지고 있다. 이로 인해 그래디언트 소실 문제를 야기한다. 이러한 문제를 해결 한 것이 ReLu 함수이다. ReLu 함수는 입력에 대한 출력을 특정 범위에 한정하지 않는 비선형 함수로 입력으로 양수 값이 들어오면 값을 그대로 출력하고 음수 값이 들어오면 0을 출력한다 [6]. 이 논문에서는 활성화 함수로 ReLu 함수를 사용하였다. Pooling layer는 입력 정보를 최댓값, 최솟값, 평균값 등으로 압축하여 데이터의 연산량을 줄여주는 절차다. 요약하면 CNN은 입력 데이터에 대해서 필터를 통해 이미지의 특징을 추출하고 (Convolution layer), 특징을 강화하고 이미지의 크기를 축소(Pooling layer)한다. 이 과정을 통해 입력된 2차원 데이터의 적절한 특징을 추출한다. 이후 Fully connected layer에서 1차원으로 변환된 feature map을 이용하여 최종 분류한다.

III. 실험 결과 및 분석

° 데이터 구성 및 전처리

실험에 사용되는 데이터는 kaggle 에서 알츠하이머의 진행단계에 따라 수집되어있는 오픈 데이터 셋을 사용하였다 (<https://www.kaggle.com/madhucharan/alzheimersdisease5classdatasetadn>) [7]. 분석에 사용된 MR 이미지의 피험자 정보는 모두 익명화 되어있으며, 뇌 이미지는 horizontal plane 이며 256x256 사이즈를 가지고 있다. 학습 이미지의 개수는 총 1,101개로 EMCI 204개, LMCI 61개, MCI 198개, AD 145개, CN 493개이며, 테스트 이미지의 개수는 총 195개로 EMCI 36개, LMCI 11개, MCI 35개, AD 26개, CN 87개이다. CNN 모델의 학습 데이터 개수를 증가시키기 위하여 Data augmentation을 적용하여 이미지를 임의로 변형 및 개수를 증가시켰다 [8]. 이 연구에서 사용한 Data augmentation 방식은 Horizontal flip, Width shift, Height shift이다. Horizontal flip은 50% 확률로 이미지를 수평으로 뒤집으며 뇌 영상과 같이 원본 이미지에 수평

비대칭성이 없을 때 효과적이다. Width shift, Height shift는 이미지를 수평 또는 수직으로 랜덤하게 평행 이동시키는 방법이다. 학습용의 배치 사이즈는 22, 테스트용의 배치 사이즈를 13으로 하였다.

° CNN 모델

Convolution layer에서는 층을 3개로 하였고 각 계층에서 필터의 개수는 32, 32, 64개로 진행하였다. 활성화 함수는 모두 ReLu 함수를 사용하였고, Pooling layer에서는 Max Pooling을 사용하였다. 마지막으로 Fully Connected Layer를 거쳐 softmax 함수를 통해 확률 값으로 변환하여 최종 결과를 출력한다 [6]. 본 논문에서는 모델을 실행할 epoch를 30으로 하였으며 학습 결과를 정확도로 평가하였다 (그림 1). 최종 정확도는 44.55% (baseline accuracy = 20%) 이고 오차율은 1.40 였다.




그림 1. CNN 모델 학습 결과 그래프

° 전이학습 (transfer learning)

CNN 모델에서 깊은 신경망을 훈련하기 위해서는 충분한 양의 데이터가 필요하기 때문에 많은 양의 데이터가 확보되지 않는 상황에서는 과적합 문제가 발생할 수 있다. 전이학습은 위와 같은 문제를 해결하기 위한 방법으로, 학습 데이터가 부족한 분야의 모델 구축을 위해 기존의 풍부한 데이터를 바탕으로 일반성을 학습한 모델의 일부 계층을 재사용함으로써 모델의 학습 속도를 높이고 분류 성능을 높인다고 알려져있다 [9].

기존 CNN 모델에 전이학습 방식을 적용해보았다. 학습 이미지의 배치 사이즈는 22, 테스트 이미지의 배치 사이즈는 13으로 지정하였고 이외의 데이터를 증가시키고 불러오는 작업은 기존 CNN 모델과 동일하게 진행하였다. 특히 VGG16의 학습된 가중치를 가져와서 적용하였다.




그림 2. 전이학습 모델 학습 결과 그래프

전이학습의 최종 정확도는 60.4% 오차율은 1.04로 나타났다. CNN의 최종 정확도인 44.55%와 비교하여 볼 때, 전이학습을 활용할 경우의 분류성

능이 우수하다고 볼 수 있다. 또한 학습 속도 및 추세 측면에서도 CNN 모델에 전이학습을 활용하는 것이 분류 성능 향상에 큰 도움을 주고 있음을 알 수 있었다. 그림 2를 보면, 에포크의 횟수가 증가할수록 빠른 속도로 loss가 감소하고 accuracy가 증가하는 것을 확인할 수 있다.

IV. 결론

본 논문에서는 알츠하이머형 치매 진행단계 구분을 위하여 CNN과 전이 학습 알고리즘을 구현하였다. 이를 통해, 치매 진행단계를 5단계로 구분하였으며 오차율과 정확도를 가지고 각각의 성능을 평가하였다. 결과적으로 단순 CNN보다 전이학습을 활용했을 때 정확도가 약 15%만큼 높게 나오며 오차율은 약 25% 가량 낮은 것을 확인하였다. 이 연구 결과를 통하여 의료 인공지능 분야에서 전이학습 활용의 중요성을 확인하였으며, 향후 유사 연구의 기초자료로 사용될 것으로 기대된다.

ACKNOWLEDGMENT

This work was supported by the National Research Foundation of Korea (2021R1F1A1055814) and the Grand Information Technology Research Center support program (IITP-2020-0-01791) grant funded by the Korea government (MSIT).

참 고 문 헌

- [1] Brookmeyer, Ron, et al. "Forecasting the global burden of Alzheimer's disease." *Alzheimer's & dementia* 3.3 (2007): 186-191.
- [2] Son, Joo Hyung, Kyeong Tae Kim, and Jae Young Choi. "Alzheimer's Disease Classification with Automated MRI Biomarker Detection Using Faster R-CNN for Alzheimer's Disease Diagnosis." *Journal of Korea Multimedia Society* 22.10 (2019): 1168-1177.
- [3] Kim, Ji-Yul, and Soo-Young Ye. "Diagnostic Classification of Chest X-ray Pneumonia using Inception V3 Modeling." *Journal of the Korean Society of Radiology* 14.6 (2020): 773-780.
- [4] Bae, Chang-Hui, et al. "An Experimental Comparison of CNN-based Deep Learning Algorithms for Recognition of Beauty-related Skin Disease." *Journal of the Korea Society of Computer and Information* 25.12 (2020): 25-34.
- [5] Lee, JeongHwan, Byeong Man Kim, and Yoon Sik Shin. "Effects of preprocessing and feature extraction on CNN-based fire detection performance." *Journal of the Korea Industrial Information Systems Research* 23.4 (2018): 41-53.
- [6] Choi, Gwang-Mi, and Yu-Jeong Jeong. "Efficient Iris Recognition using Deep-Learning Convolution Neural Network." *The Journal of the Korea institute of electronic communication sciences* 15.3 (2020): 521-526.
- [7] <https://www.kaggle.com/datasets>
- [8] Kim, Chisung, et al. "Development of Automatic Crack Detection Technology in Welded Surface using Laser Active Thermography and CNN Deep Learning." *Journal of the Korean Society for Nondestructive Testing* 40.3 (2020): 163-173.
- [9] Kim, Yeonho, and Namgyu Kim. "Deep Learning-based Pes Planus Classification Model Using Transfer Learning." *Journal of the Korea Society of Computer and Information* 26.4 (2021): 21-28.