

딥러닝/머신러닝 모델을 활용한 뇌파 기반 치매 조기진단에 관한 연구

김재영¹, 한구현¹, 안단태¹, 이시현¹, 김진욱², 임승의², 문기욱², 이기원², 김보형³, 서진욱¹
¹서울대학교 컴퓨터공학부 ²와이브레인 ³한국외국어대학교 바이오메디컬공학부
jykim@hcil.snu.ac.kr, ghhan@hcil.snu.ac.kr, dtan@hcil.snu.ac.kr, sihyeon@hcil.snu.ac.kr,
jinwook.kim@ybrain.com, seungeui.lim@ybrain.com, kiwook.moon@ybrain.com,
kiwon.lee@ybrain.com, bkim@hufs.ac.kr, jseo@snu.ac.kr

A Study on Electroencephalography-based Early Stage Diagnosis of Dementia Using Deep Learning/Machine Learning Model

Jaeyoung Kim¹, GuHyun Han¹, Dantae An¹, Sihyeon Lee¹, Jinwook Kim², Seungeui Lim²,
Kiwook Moon², Kiwon Lee², Bohyoung Kim³, Jinwook Seo¹

¹Department of Computer Science and Engineering, Seoul National University

²Ybrain

³Division of Biomedical Engineering, Hankuk University of Foreign Studies

요약

최근 딥러닝, 머신러닝 기술의 발달로 생체신호를 활용한 연구 역시 소기의 성과를 내고 있다. 하지만 뇌파(Electroencephalography) 데이터를 사용한 연구는 아직 그 수가 많지 않다. AI 기술과 뇌파(EEG)의 접목은 치매, 간질 등 뇌 관련 질환의 조기진단에 활용될 가능성이 있으나, 이를 검증하기 위해선 충분한 데이터와 많은 리소스, 시간, 기술이 요구된다. 본 논문에서는 175명분의 경도인지장애군(MCI)과 50명의 정상군(NL)의 19채널 뇌파(EEG) 데이터를 활용하여 머신러닝 및 딥러닝 모델을 학습시키고 테스트하였다. 실험 결과는 뇌파를 활용한 AI 기술이 치매의 조기진단에 활용될 가능성이 있음을 보인다.

1. 서론

딥러닝, 머신러닝 기술의 발전으로 생체신호를 활용한 연구는 많은 발전을 이루고 있다. 하지만 뇌파(EEG)와 AI 기술을 활용한 연구는 아직 그 수가 많지 않다. AI 기술과 뇌파(EEG)의 접목은 치매, 간질 등 뇌 관련 질환의 조기진단에 활용될 가능성이 있으나, 이를 위해서는 충분한 데이터와 많은 리소스, 시간이 요구된다. 본 논문에서는 175명분의 경도인지장애군(MCI), 50명 정상군(NL)의 뇌파(EEG) 데이터를 머신러닝 및 딥러닝 모델의 학습에 활용하여 AI를 활용한 치매의 조기진단 가능성에 대해 탐색하였다.

2. 배경지식 및 관련연구

2.1 뇌파의 측정 및 처리

뇌파(EEG)는 뇌내 신경의 활동으로 발생하는 전기적 신호를 두피에 전극을 부착하여 비침습적으로 측정된 생체신호이다. 뇌파는 두개골을 통과할 때 그 세기가 약해져, 신호를 다시 증폭하는 과정을 거친다. 이 과정에서 신체의 미세한 움직임 및 전류 신호 역시 같이 증폭되어 데이터에 노이즈로 섞이게 되는데 이를 아티팩트(Artifact)[1]라 한다. 아티팩트의 종류는 다양하고 그 처리 방식 역시 방대하다. 흔히 사용되는 제거 방법으로는 필터를 사용하는 방법과 선형회귀 방식이 있다[2]. 본 연구에서는 두개골의 19곳에 전극을 부착하여 건식으로 뇌파를 측정하는 방법으로 수집된 데이터를 사용하였다.

2.2 치매의 발병과정 및 진단

치매는 주로 노년층에 발병하는 질환으로 기억, 인지장애를 동

반한다. 치매는 경도인지장애/초기/중기/후기로 단계가 진행된다. 경도인지장애 및 초기 단계에서는 뇌 손상이 비교적 경미하여 치료를 통한 증상 완화와 중증화 지연이 가능하나 현재 치매의 진단은 큰 비용과 높은 전문성을 요구하여 조기진단 및 치료가 매우 어려운 실정이다.

치매의 발병 원인 역시 아직 명확히 규명되지 않았다. 현재까지 베타 아밀로이드 응집[3]과 타우 단백질 엉킴[4]이 치매의 주요 유발 원인으로 추측되었다. 그러나 이를 활용한 치매 진단 및 치료방식이 뚜렷한 성과를 내지 못함에 따라 뇌 기능의 변화에 민감하게 반응하는 뇌파(EEG)와 같은 생체신호를 통한 조기진단 기술의 필요성이 커지고 있다.

2.3 뇌파를 활용한 연구

뇌파(EEG)는 복잡한 생체 시그널로 이를 올바르게 해석하기 위해서는 고급 신호 처리 기술 및 feature 추출 방법론에 대한 방대한 지식을 요구한다. 특히 뇌파 데이터와 딥러닝, 머신러닝 기술을 의료분야에 접목시킨 연구는 아직 많지 않다[5]. 뇌파와 딥러닝 모델의 접목은 간질 탐지 및 예측, 수면 단계 평가, 스트레스 탐지, 감정 인식과 같은 분야에서 제한적으로 연구[6]되고 있으나 치매의 조기진단과 같은 분야에서는 아직 연구가 충분하지 않다는 점에서 본 연구는 의미를 가진다.

3. 뇌파 데이터 정보 및 전처리 과정

본 연구에서는 총 225개의 휴식상태에서 눈을 감은 상태로 측정된 5분 길이, 19채널 EEG 데이터를 사용하였다. 사용한 데이터의 메타데이터 정보는 표 1과 같다.

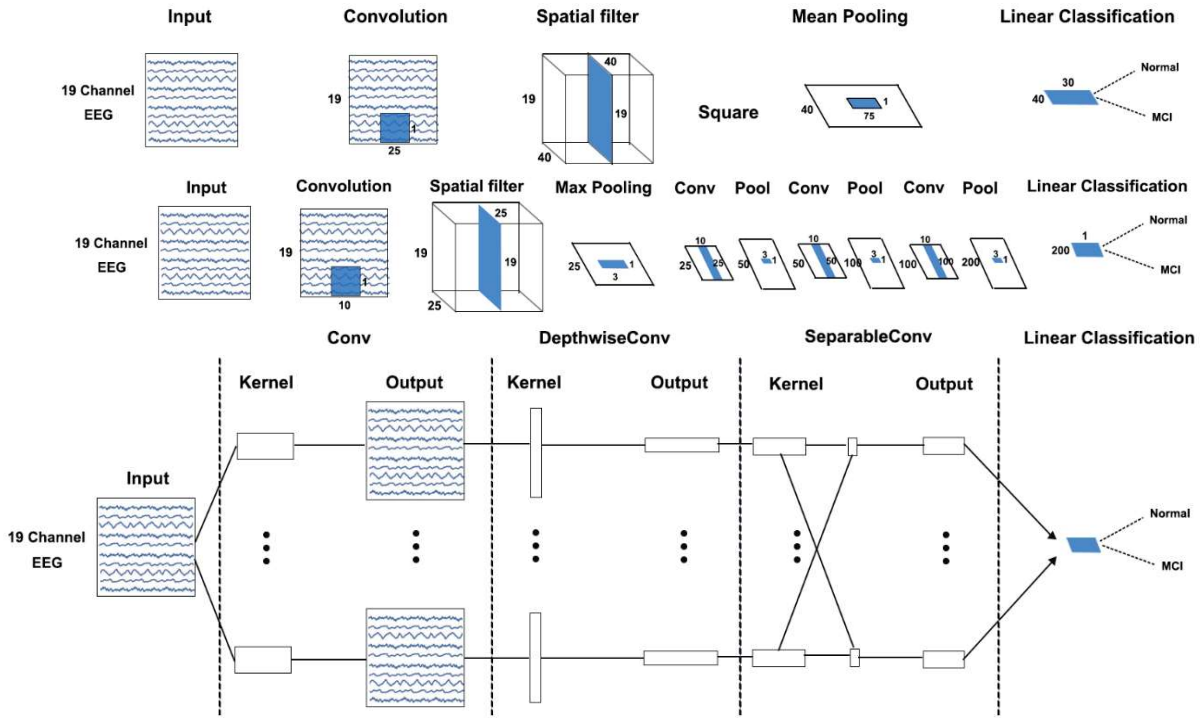


그림 1 ShallowFBCSPNet, Deep4Net, EEGNet 모델 아키텍처

표 1. 메타데이터 정보

	성별	연령	교육연수	수
MCI	남: 106	Mean: 74.79	Mean: 10.45	175
	여: 69	SD: 5.12	SD: 4.16	
NL	남: 32	Mean: 73.22	Mean: 10.23	50
	여: 18	SD: 4.59	SD: 4.11	

3.1 데이터 전처리 과정

수집된 뇌파(EEG) 데이터는 직류(DC) 아티팩트를 제거한 후, 노치필터를 활용하여 60Hz 교류 노이즈를 제거했다. 원활한 학습을 위해 Windowing을 활용하여 잡음이 있는 구간과 품질이 나쁜 채널을 제거하고 주변 위치에 있는 채널로 제거된 채널을 보간하였다. 이후 독립성분분석(ICA)을 활용하여 안전도(EOG), 심전도(ECG), 근전도(EMG) 아티팩트를 제거하고 500Hz로 다운샘플링하였다.

데이터의 마지막 1초는 전극 제거 등으로 인해 정상적으로 측정이 이루어지지 않았을 가능성이 크므로 잘라내고 $\pm 800\mu V$ 를 초과하는 물리적으로 발생 불가능한 신호가 있는 구간은 제거하였다. 민감성이 높은 뇌파의 특성상 미처 제거하지 못한 노이즈가 있을 가능성을 고려하여 데이터를 각 채널별로 Z-normalize하여 최종 데이터를 생성하였다. 이후 효율적인 연산을 위해 250Hz로 다운샘플링 하여 학습 데이터셋을 만들었다. 학습에 충분한 정보를 포함하고 있지 않다고 판단되는 3분 이하 혹은 5채널 이상 보간된 데이터는 학습에서 제외하였다. 결과적으로 147개(MCI: 113, NL: 34) 데이터가 실험에 사용되었다.

3.2 불균형 데이터 처리

수집한 데이터는 NL에 비해 MCI 레이블이 많은 불균형한 데이터셋이다. 데이터의 불균형을 처리하기 위해 본 연구에서는 언더샘플링(Undersampling), 클래스 가중치(Class weight), 데이터 증강(Data augmentation) 방법을 사용하여 실험을 진행하였다. 데이터 증강에는 각각의 채널에 랜덤한 가우시안 노이즈를 섞는 방식[7]과 각 채널별 frequency domain을 랜덤하게 shift 하는 방식을 사용하였다.

4. 실험

본 연구에서는 3개의 딥러닝 모델과 1개의 feature 기반 머신러닝 모델을 사용하여 실험을 진행하였다. 딥러닝 모델로는 ShallowFBCSPNet[8], Deep4Net[8], EEGNet[9]을 사용하였으며 머신러닝 모델은 Auto-sklearn[10,11] 기반의 AutoML을 사용하여 24시간 동안 학습을 진행하였다. 학습은 RTX Titan을 사용하여 진행되었으며 실험에 사용된 딥러닝 모델 파라미터는 표 2와 같다. 머신러닝 모델의 학습에 사용된 feature들은 표 3과 같다.

실험은 147개의 데이터를 소수 레이블(NL)을 기준으로 7:3으로 나누어 학습, 테스트셋으로 사용하였다. 딥러닝 모델의 실험결과 는 5회 평균치이며 모델별 가장 우수한 결과를 리포트하였다.

표 2 딥러닝 모델 파라미터 세팅

Model	lr	Input	Batch	Optimizer
Deep4	0.01	2500ms	32	Adamw
Shallow	0.001	2500ms	32	Adamw
EEGNet	0.0015	2500ms	32	Adamw

표 3 머신러닝 모델 학습 사용 Feature 목록

CWT/DWT	FT	Connectivity
Bounded variation	Maximum / Minimum	Phase Locking Value
Maximum / Minimum	Mean	
Mean	Peak frequency	
Power / Power Ratio	Power / Power Ratio	
Spectral entropy	Spectral entropy	
Variance	Variance / Value range	
Time-resolved features		
Detrended Fluctuation	Hurst exponent	Nonlinear energy
Energy	Kurtosis	Petrosian fractal dimension
Fisher information	Line length	Skewness /SVD entropy
Fractal dimension	Lyauponov exponent	Zero crossings
Higuchi Fractal dimension	Maximum / Minimum / Mean / Median	
Hjorth activity / complexity / mobility		

4.1 250Hz 데이터셋 실험

실험에는 19채널 건식 뇌파(EEG) 데이터를 250Hz로 다운샘플링한 데이터셋이 사용하였다. 본 실험에서는 불균형한 데이터셋을 처리하기 위해 클래스 가중치 방식을 통해 소수 레이블(NL)에 더 높은 가중치를 부여하는 방식으로 학습을 진행하였다.

표 4 250Hz 데이터셋 실험 결과

Model	Accuracy	Sensitivity	Specificity
Shallow[8]	55.6%	95.6%	15.6%
Deep4[8]	56.7%	100%	13.3%
EEGNet[9]	67.8%	100%	35.6%
Auto-Sklearn[10,11]	65%	70%	60%

표 4에 제시된 실험 결과에서 EEGNet은 가장 높은 분류 정확도를 보였다. Auto-sklearn을 제외한 딥러닝 모델들에서는 다수 레이블(MCI)에 치우친 예측 결과가 나오는 것이 관찰되었다. 이는 클래스 가중치 방식으로는 현 데이터셋의 불균형 문제를 해결하기 어려운 것을 보여준다.

4.2 불균형 데이터 처리 실험

불균형 데이터를 처리하기 위해 두 번째 실험에서는 3가지 방법을 시험하였다. 가우시안 노이즈 z에 대한 확률 밀도 함수는 그림2와 같으며 Frequency Shift는 ±10Hz 범위에서 수행되었다. 각각의 방법은 상기의 실험에서 가장 우수한 성능을 보인 EEGNet 모델에 대해 수행되었으며 표2의 파라미터 세팅을 사용하였다.

$$P_G(z) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(z-\mu)^2}{2\sigma^2}}$$

그림 2 Gaussian Noise 확률 밀도 함수

표 5 불균형 데이터 처리 실험결과

Method	Accuracy	Sensitivity	Specificity
Class Weight	67.8%	100%	35.6%
Gaussian Noise[7]	72.5%	60%	85%
Frequency Shift	67.5%	90%	45%
Undersampling	69%	62%	76%

표 5에 제시된 실험 결과에서 가우시안 노이즈, 언더샘플링 방법을 적용할 경우, 데이터셋의 불균형을 처리하는 데 효과적임을 보였다.

5. 결론

본 연구는 175명분의 19채널 건식 뇌파 데이터를 활용하여 ShallowFBCSPNet[8], Deep4Net[8], EEGNet[9] 모델과 Auto-sklearn[10,11]기반 머신러닝 모델을 사용한 치매 조기진단 가능성을 탐색하였다. 본 연구는 불균형한 소규모 데이터셋을 사용하여 실험을 진행하였다는 점에서 한계점을 갖는다. 추후 추가적인 데이터 보강을 한다면 더욱 신뢰성 높은 결과를 도출할 수 있을 것으로 기대된다.

6. 사사문구

이 논문은 2019년도 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(No. NRF-2019R1A2C1088900)

참고문헌

[1] Urigüen, J. A., & Garcia-Zapirain, B. (2015). EEG artifact removal—state-of-the-art and guidelines. *Journal of neural engineering*, 12(3), 031001.

[2] Gratton, G. (1998). Dealing with artifacts: The EOG contamination of the event-related brain potential. *Behavior Research Methods, Instruments, & Computers*, 30(1), 44-53.

[3] Klementieva, O., Willén, K., Martinsson, I., Israelsson, B., Engdahl, A., Cladera, J., ... & Gouras, G. K. (2017). Pre-plaque conformational changes in Alzheimer's disease-linked Aβ and APP. *Nature communications*, 8(1), 1-9.

[4] Binder, L. I., Guillozet-Bongaarts, A. L., Garcia-Sierra, F., & Berry, R. W. (2005). Tau, tangles, and Alzheimer's disease. *Biochimica et Biophysica Acta (BBA)-Molecular Basis of Disease*, 1739(2-3), 216-223.

[5] Roy, Y., Banville, H., Albuquerque, I., Gramfort, A., Falk, T. H., & Faubert, J. (2019). Deep learning-based electroencephalography analysis: a systematic review. *Journal of neural engineering*, 16(5), 051001.

[6] Craik, A., He, Y., & Contreras-Vidal, J. L. (2019). Deep learning for electroencephalogram (EEG) classification tasks: a review. *Journal of neural engineering*, 16(3), 031001.

[7] Wang, F., Zhong, S. H., Peng, J., Jiang, J., & Liu, Y. (2018, February). Data augmentation for eeg-based emotion recognition with deep convolutional neural networks. In *International conference on multimedia modeling* (pp. 82-93). Springer, Cham.

[8] Schirrmester, R. T., Springenberg, J. T., Fiederer, L. D. J., Glasstetter, M., Eggenberger, K., Tangermann, M., ... & Ball, T. (2017). Deep learning with convolutional neural networks for EEG decoding and visualization. *Human brain mapping*, 38(11), 5391-5420.

[9] Lawhern, V. J., Solon, A. J., Waytowich, N. R., Gordon, S. M., Hung, C. P., & Lance, B. J. (2018). EEGNet: a compact convolutional neural network for EEG-based brain-computer interfaces. *Journal of neural engineering*, 15(5), 056013.

[10] Feurer, M., Klein, A., Eggenberger, K., Springenberg, J., Blum, M., & Hutter, F. (2015). Efficient and robust automated machine learning. *Advances in neural information processing systems*, 28.

[11] Feurer, M., Eggenberger, K., Falkner, S., Lindauer, M., & Hutter, F. (2020). Auto-sklearn 2.0: Hands-free automl via meta-learning. *arXiv preprint arXiv:2007.04074*.