건식 뇌파 데이터를 활용한 경도인지장애 진단 인공지능 모델에 관한 연구

A Study on Artificial Intelligence Model for Diagnosis of Mild Cognitive Impairment Using Dry Electroencephalogram Data

김재영*, 한구현*, 안단태*, 이시현*, 임승의**, 이기원**, 문기욱[1)]**, 김보형[1)]***, 서진욱[1)]*

Jaeyoung Kim, GuHyun Han, Dantae An, Sihyeon Lee,
Kiwook Moon, Bohyoung Kim, Jinwook Seo

(08826) 서울특별시 관악구 관악로 1 서울대학교 공과대학 컴퓨터공학부*
(13449) 경기도 성남시 수정구 창업로 54 LH 판교제2테크노밸리 기업성장센터 228호 와이브레인**
(02450) 서울특별시 동대문구 이문로 107 한국외국어대학교 바이오메디컬공학부***
{jykim, ghhan, dtan, sihyeon}@hcil.snu.ac.kr,
{seungeui.lim, kiwon.lee, kiwook.moon}@ybrain.com, bkim@hufs.ac.kr, jseo@snu.ac.kr

요 약

치매는 기억, 인지장애를 동반하는 노인질환으로, 증상 완화와 중증화 지연을 위해선 조기진단이 매우 중요하다. 그러나 현재 치매의 진단은 큰 비용과 높은 전문성을 요구하여 조기진단 및 치료가 어려운 실정이다. 본 연구에서는 건식 방식으로 수집된 19채널 뇌파(electroencephalogram) 데이터(정상군 50명, 경도인지장애군 175명)를 머신러닝 및 딥러닝 모델의 학습 및 테스트에 사용하여 치매의 조기진단에 적합한 모델 및 하이퍼파라미터 세팅을 제안한다. 기존의 연구들이 습식 방식으로 수집된 64채널 고해상도 뇌파 데이터를 활용한 반면, 본 연구는 연구자 및 환자의 측정 부담이 적은 건식 방식의 19채널 뇌파 데이터를 활용했다는 점에서 차별성을 가진다. 실험은 앙상블 기반의 AutoML 머신러닝 알고리즘인 Auto-sklearn과 딥러닝 모델 3종(ShallowFBCSPNet, Deep4Net, EEGNet)으로 이진 분류기를 훈련한 후 성능을 비교하는 방식으로 진행되었다. 그 결과, EEGNet이 가장 우수한 성능(정확도=68.9%)을 냈다. 다음으로, 데이터 불균형으로 인한 과적합 문제를 해결하기 위해 EEGNet에 데이터 불균형 처리 알고리즘 4종(class weight, Gaussian noise, frequency shift, undersampling)을 각각 적용한 뒤 성능 개선 여부를 확인했다. 그 결과, EEGNet에 Gaussian Noise를 적용했을 때 가장 우수한 성능(정확도=78.9%)을 냈다. 본 연구 결과는 19채널 건식 뇌파 데이터와 제안된 방법의 조합이 치매의 조기진단에 활용될 가능성이 있음을 보인다.

Abstract

Dementia, characterized by memory and cognitive impairment, necessitates early detection for symptom mitigation and progression delay. However, existing diagnostic approaches are resource-

1) 공동교신저자

논문투고일자 : 2023. 02. 14 심사일자 : 2023. 03. 10 게재확정일자 : 2023. 04. 13 http://doi.org/10.23019/kingpc.19.2.202304.004

intensive, demanding both high cost and expertise, which complicates early intervention. In this study, we propose an optimal model and hyperparameter settings suitable for early dementia diagnosis using machine learning and deep learning models trained and tested on 19-channel electroencephalogram(EEG) data(50 normal subjects, 175 mild cognitive impairment subjects) collected via a dry methodology. While previous studies utilized 64-channel high-resolution EEG data acquired through a wet methodology, this study is distinct in its use of 19-channel dry EEG data, which reduces the burden on researchers and patients. The experiment was conducted by training a binary classifier using an ensemble-based AutoML algorithm, Auto-sklearn, and three deep learning models(ShallowFBCSPNet, Deep4Net, EEGNet), followed by a comparison of their respective performances. EEGNet demonstrated the best results(accuracy=68.9%). Next, to address the overfitting problem due to data imbalance, four data imbalance processing algorithms(class weight, Gaussian noise, frequency shift, and undersampling) were applied to EEGNet. The best performance(accuracy=78.9%) was achieved with Gaussian noise applied to EEGNet. This study's findings suggest the potential utility of combining 19-channel dry EEG data with the proposed method for early dementia diagnosis.

키워드: 뇌파, 치매, 머신러닝, 딥러닝
Keyword: Electroencephalogram, Dementia, Machine learning, Deep learning

1. 서론

치매(dementia)는 주로 노년층에 발병하는 질환으로 기억, 인지장애를 동반하는 특성을 가진다. 치매는 경도인지장애(mild cognitive impairment, MCI)/초기/중기/후기로 단계가 진행된다. 경도인지장애 및 초기 단계에서 치매를 진단할 경우 치료를 통한 증상 완화와 중증화 지연이 가능하나 현재 치매의 진단은 큰 비용과 높은 전문성을 요구하여 조기진단 및 치료가 어려운 실정이다.

치매의 조기진단 및 치료에 있어서 현재까진 치매의 유력한 발병 원인으로 추측되던 베타 아밀로이드 응집과 타우 단백질 엉킴을 활용한 치매 진단 기술 및 치료방식이 주로 연구되었다[1,2]. 하지만 이를 활용한 치매 진단기술 및 치료방식이 뚜렷한 성과를 내지 못함에 따라 신체의 변화에 민감하게 반응하는 다른 생체신호 및 데이터를 활용한 조기진단 연구의 필요성이 커지고 있다. 그중에서도 뇌파(electroencephalogram, EEG)는 뇌 기능의 변화에 민감하게 반응하는 특성을 가져 간질[3], 수면 단계 평가[4,5], 스트레스 탐지[6] 등 다양한 질환의 진단에 활용된 사례가 있었던 만큼 뇌파를 활용한 치매 조기진단 기술의 중요성 역시 커지고 있다.

뇌파는 뇌내 신경 활동으로 발생하는 전기적 신호를 두피에 전극을 부착하여 비침습적으로 측정한 생체신호이다. 뇌파는 기능적 자기공명영상(functional cagnetic resonance imaging, fMRI) 등 타 뇌 기능 측정 기술보다 접근성이 뛰어나며 비용적인 측면에서도 경제적이라는 이점을 가진다. 뇌파는 뇌에서 신호가 발생한 시점에서는 1~3mV 정도의 세기를 가지지만 두개골을 통과하며 그 세기가 20~100μV로 약해진다[3]. 따라서 진료나 연구에 활용하기 위해 신호를 다시 증폭하는 과정을 거친다. 이 과정에서 신체의 미세한 움직임 및 타 전류 신호 역시 같이 증폭되어 노이즈로 섞이게 되는데 이를 아티팩트(artifact)[4,5]라 한다.

아티팩트는 뇌파에서 의미 있는 패턴을 식별하기 어렵게 만들어 특히 뇌파를 활용한 질병 진단 연구에서는 아티팩트 제거 기술의 중요성이 크다. 민감하고 복잡한 뇌파 신호를 올바르게 해석하기 위해

서는 고급 신호처리 기술 및 특징(feature) 추출 방법론에 대한 방대한 지식을 요구한다. 따라서 뇌파 데이터와 딥러닝, 머신러닝 기술을 의료분야에 접목한 연구는 아직 그 수가 많지 않다[6].

본 연구는 대학병원과의 협업을 통해 건식 19채널(10-20 system) 기기로 수집된 175명분의 경도인지장애군(MCI), 50명분의 정상군(NL)의 EEG 데이터를 활용하여 머신러닝 및 딥러닝 모델을 학습하고, 이를 사용한 치매 조기진단에 관해 연구하였다(그림 1). 기존 연구들이 통제된 측정 환경과 전문가, 값비싼 기기를 사용한 습식 방식으로 측정된 고해상도 64채널(10-10 system) EEG 데이터를 활용했다는 점과 비교했을 때 본 연구는 기술 접근성이나 비용 측면에서 차별성을 가진다.

본 논문의 구성은 다음과 같다. 2장에서는 기존의 관련연구를 설명하고, 3장에서는 실험에 사용된 데이터와 특징, 데이터 전처리 알고리즘 및 진단모델에 관해 설명한다. 4장에서는 실험 결과 및 불균형 데이터 처리 실험 결과에 관해 설명한다. 마지막으로 5장과 6장에서는 논의 및 결론을 설명한다.

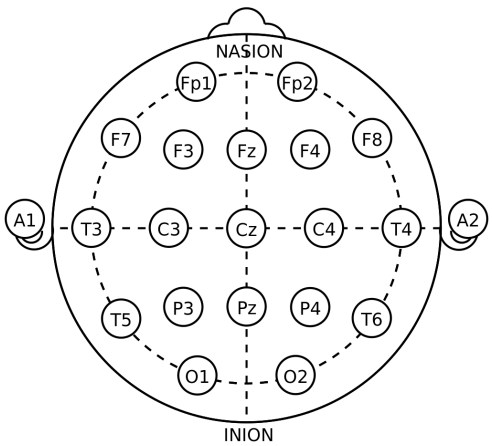

(그림 1) 19채널(10-20 system) EEG 전극 위치

2. 관련 연구

뇌파가 연구에 활용되는 분야에는 수면 단계 평가[4,5], 스트레스 탐지[6], 감정 인식[11-14], 간질[3], 우울증 탐지[15]과 같은 분야가 있다. 수면 단계 평가[4,5] 및 간질[3] 탐지 연구의 경우 전문의의 육안에 의존한 검사의 한계점을 보완하기 위해 뇌파 신호를 사용하여 육안으로 식별하기 힘든 병리학적 신호를 찾는 데 중점을 둔다. 반면 스트레스 탐지[6] 및 감정 인식[11-14] 연구의 경우 물리적으로 인식하기 어려운 추상적인 신호들을 뇌파를 통해 식별하는 데 중점을 둔다.

뇌파를 활용한 치매 진단 연구의 경우 아직 그 수가 많지 않다. 일반적으로 뇌파를 활용한 치매 진단 연구는 크게 치매 환자를 알츠하이머군(AD), 경도인지장애군(MCI), 정상군(NL) 세 그룹으로 나눠 연구를 진행한다. 일부 연구의 경우 경도인지장애군을 진행 정도에 따라 알츠하이머로 발전할 수 있는 mild cognitive impairment convertible(MCIc)와 인지 이상이 발생하지만, 알츠하이머로 발전하지는 않는 mild cognitive impairment non-convertible(MCInc)로 더 세부적으로 그룹을 나눠 진행하기도 하나 그 수가 많지는 않다[16].

머신러닝 기술을 활용한 정상군(NL)과 알츠하이머군(AD) 사이의 이진분류 연구가 가장 많이 연구된 주제이며 주로 사용된 방법은 support vector machine(SVM) [17-19], artificial neural network(ANN) [20-22], multi layer perceptron(MLP) [23], principal component analysis(PCA) [24], linear discriminant analysis(LDA) [23] 등이 있다. 분류 정확도는 76.47% ~ 100%까지 다양한 폭으로 분포하고 있다.

딥러닝을 활용한 알츠하이머군(AD), 경도인지장애군(MCI), 정상군(NL)간의 분류 연구 역시 일부 진행되고 있다. 주로 사용된 방법은 convolutional neural network(CNN)이다. Ieracitano et al.(2019)은 뇌파 데이터를 power spectral density (PSD) image로 변환하여 CNN 모델에 넣어 정확도를 확인하였다. 그 결과 three-way classification에서 83.33%의 정확도를 얻었고 MCI과 NL binary classification에서 91.88%의 정확도를 확인하였다[25]. You et al.(2020)은 환자의 보행 데이터

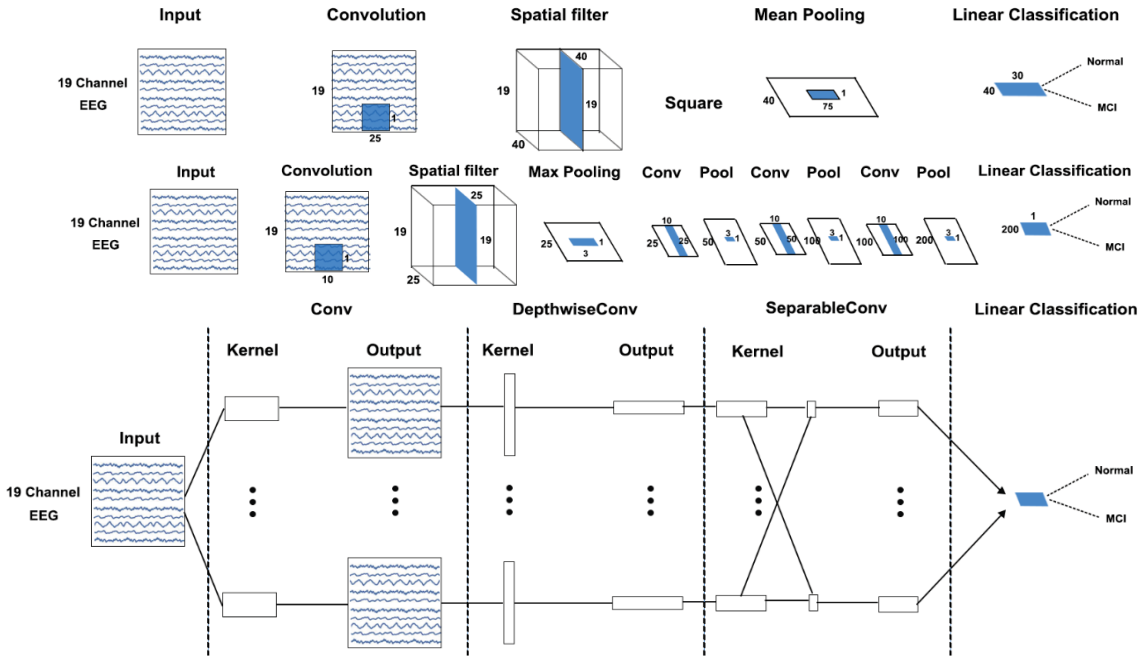

(그림 2) ShallowFBCSPNet, Deep4Net, EEGNet 모델 아키텍처

와 뇌파 데이터를 사용하여 graph convolutional network(GCN)와 convolutional neural network (CNN)이 결합된 cascade neural network를 사용하여 three-way classification에서 91.07%의 정확도를, NL과 MCI+AD 그룹 사이의 binary classification에서 93.09%의 정확도를 얻었다[26].

이렇듯 뇌파와 머신러닝, 딥러닝 기술을 활용한 다양한 치매 진단 연구들이 존재하나 각각의 연구들이 사용한 데이터 수집 방식과 데이터셋 크기, 입력 형식 등이 달라 이들 간의 객관적인 성능 비교는 어렵다.

3. 실험

3.1 실험 데이터 설명

본 연구에서는 대학병원 의사의 협조를 받아 휴식 상태에서 눈을 감은 상태로 측정된 5분 길이의 19채널 EEG 데이터를 사용하였다. 측정은 별도의 젤 도포가 필요 없는 건식 방식으로 Ybrain MINDD SCAN 기기를 사용하여 진행되었다. 치매가 주로 노년층에 발병하는 질환임에 착안하여 62~90세 사이의 실험참가자들의 데이터를 수집하였다. 실험참가자들은 전문의의 감독하에 인지기능검사 등 다양한 검사를 통해 175명의 경도인지장애군(MCI)과 50명의 정상군(NL)으로 분류되었다. (본 실험은 중앙보훈병원 임상윤리심의위원회의 승인을 받아 진행되었다. IRB No. BOHUM 2021-02-024). 수집된 뇌파 데이터의 메타데이터 정보는 <표 1>과 같다.

〈표 1〉 수집된 뇌파 데이터의 메타데이터 정보

	성별(남/여)	연령(M(SD))	교육연수(M(SD))	수(N)
MCI	106/69	74.79(5.12)	10.45(4.16)	175
NL	32/18	73.22(4.59)	10.23(4.11)	50

3.2 뇌파 데이터 전처리 과정

수집된 뇌파 데이터는 모델이 의미 있는 패턴을 식별할 수 있도록 아티팩트 제거 과정을 거쳤다. 아티팩트는 사람으로부터 유래된 생리학적 아티팩트와 외부로부터 유래된 비생리학적 아티팩트로 구분된다[27]. 데이터 전처리 과정에서는 우선 60Hz 노치필터를 활용하여 누설전류 등으로 인해 발생하는 비생리학적 아티팩트를 제거하였다. 데이터의 품질을 검사하기 위해 윈도잉(windowing)을 활용하여 뇌파 데이터를 잘라 아티팩트가 심한 구간과 측정 품질이 나쁜 채널을 제거하였다. 이후 EEGLAB을 사용하여 제거된 채널을 주변 전극으로 측정된 데이터를 활용하여 보간(interpolate)하고 독립성분분석(independent component analysis, ICA)를 적용하여 안전도(EOG), 심전도(ECG), 근전도(EMG), 호흡(respiration) 등의 생리학적 아티팩트를 제거하였다.

뇌파 데이터의 마지막 1초는 기기 제거 등으로 인해 정상적인 데이터가 기록되지 않았을 가능성이 크므로 데이터에서 제외하였다. 또한, 생체신호에서 물리적으로 발생 불가능한 ±800㎶를 초과하는 신호가 기록된 구간 역시 제거하였다. 민감성이 높고 복잡한 뇌파 데이터의 특성상 앞선 과정으로도 제거하지 못한 아티팩트 및 노이즈가 존재할 가능성이 있으므로 채널별로 Z-normalization을 적용하였다. 전처리 과정에서 너무 많은 정보가 손실되어 학습에 적절하지 않다고 판단되는 3분 이하 길이 혹은 4채널 이상 보간된 뇌파 데이터는 모델 학습 및 테스트에서 제외하였다. 결과적으로 115명분의 경도인지장애군(MCI)과 32명의 정상군(NL) 데이터가 실험에 사용되었다.

3.3 실험 과정

본 연구에서는 세 종류의 딥러닝 모델(Shallow FBCSPNet[28], Deep4Net[28], EEGNet[29])과 한 종류의 머신러닝 모델(Auto-sklearn [30,31])을 사용하여 실험을 진행하였다(그림 2). 실험에 사용한 모델은 뇌-컴퓨터 인터페이스(brain-computer interface, BCI)와 같은 뇌파 기반 관련 연구에서 사용한 모델을 기반으로 본 연구에서 확보한 데이터셋의 특징에 맞는 모델들을 선택하여 사용하였다.

모델의 학습은 RTX Titan 4개를 사용하여 진행하였으며 Auto-sklearn은 24시간 동안 학습을 진행하였다. 머신러닝 모델의 학습에 사용된 특징들은 <표 2>와 같다. 실험에 사용된 딥러닝 모델 파라미터는 반복실험을 통해 찾아내었으며 <표 3>과 같다. 실험은 147명분의 뇌파 데이터를 소수 레이블(NL)을 기준으로 7:3으로 나누어 각각 학습, 테스트 데이터로 사용하였다. 실험시간이 오래 소요되는 머신러닝 모델을 제외한 딥러닝 모델들은 5회 실험을 돌려 평균치를 보고하였다.

〈표 2〉 머신러닝머신러닝 모델 학습 사용 Feature 목록

Continuous/Discrete Wavelet Transform	**Fourier Transform**	**Connectivity**
Bounded variation Maximum / Minimum Mean Power / Power Ratio Spectral entropy Variance	Maximum / Minimum Mean Peak frequency Power / Power Ratio Spectral entropy Variance / Value range	Phase Locking Value
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		

〈표 3〉 딥러닝 모델 파라미터

Model	learning rate	Batch	Max epoch	Optimizer
Deep4[28]	0.001	32	50	Adamw
Shallow[28]	0.000625	32	50	Adamw
EEGNet[29]	0.00015	32	50	Adamw

3.4 데이터 불균형 처리 과정

전처리 과정을 거친 뇌파 데이터셋은 정상군(NL)에 비해 경도인지장애군(MCI) 레이블이 많은

불균형한 데이터셋이다. 데이터의 불균형을 처리하기 위해 생체데이터를 활용한 의료 도메인 연구들은 다양한 방법들을 제안하였다[32,33]. 본 연구에서는 그 중 뇌파 데이터 형식에 적용 가능하며 우수한 성능을 보인다고 보고한 방법론들을 추려 실험에 사용하였다.

본 연구에서 사용된 데이터 불균형 처리 알고리즘으로는 소수 레이블에 가중치를 더 줘서 학습하는 클래스 가중치(class weight) 방법과 소수 레이블의 수에 다수 레이블의 수를 맞추는 언더샘플링(undersampling) 방법, 소수 레이블 데이터를 사용하여 데이터를 생성하여 소수 데이터의 수를 늘리는 데이터 증강(data augmentation) 방법이 있다. 데이터 증강에는 각각의 뇌파(EEG) 채널에 랜덤한 화이트 가우시안 노이즈(Gaussian noise)를 섞는 방법[34-36], 단측파대 변조(single-sideband modulation) 방법을 사용하여 뇌파의 채널별 주파수 대역(frequency domain)을 이동하는 frequency shift 방법을 사용하였다.

가우시안 랜덤노이즈 z의 확률 밀도 함수는 (수식 1)과 같다. Frequency shift 방법에서 채널별 주파수 대역의 이동은 ±10Hz 범위에서 수행되었다. 데이터 불균형 처리 알고리즘 실험은 모델별 실험에서 가장 우수한 성능을 보인 모델을 선택하여 실험을 진행하였다.

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

Gaussian Noise 확률 밀도함수

4. 실험 결과

4.1 모델별 치매 조기진단 실험 결과

뇌-컴퓨터 인터페이스(BCI) 분야 및 뇌파를 활용한 질병 진단 연구들은 연산의 효율성을 위해 고해상도의 뇌파 데이터의 sampling frequency를 낮추는 작업을 거친다. 뇌파를 활용한 의료분야의 연구들은 대부분 250Hz로 데이터를 다운샘플링(downsampling)하여 실험을 진행한다. 본 연구에서는 건식 방식으로 수집된 500Hz 19채널 뇌파(EEG) 데이터와 이를 250Hz로 다운샘플링한 두 가지 데이터셋을 만들어 실험을 진행하였다. 그러나 두 데이터셋을 사용한 실험 결과에 유의미한 차이가 나타나지 않아 본 논문에서는 250Hz 데이터셋을 사용한 실험 결과만을 서술한다.

〈표 4〉 모델별 치매 조기진단 실험 결과

단위 (%)

Model	Accuracy	Sensitivity	Specificity
Shallow[28]	52.2	93.3	11.1
Deep4[28]	56.7	91.1	22.2
EEGNet[29]	68.9	95.6	42.2
Auto-Sklearn[30,31]	64.4	68.9	60

<표 4>에 제시된 실험 결과에서 EEGNet은 68.9%로 가장 높은 치매 조기진단 정확도를 보여주었다. 그러나 모든 딥러닝 기반 모델에서 sensitivity가 높게 나오고 specificity가 낮게 나오는 과적합(overfitting) 현상이 관찰되었다. 이는 실험에 사용한 데이터셋이 경도인지장애군(MCI)이 정상군(NL)에 비해 수가 많은, 치우친 데이터셋이기에 이를 기반으로 학습을 진행하는 딥러닝 모델들에서 과적합 현상이 일어난 것으로 추측할 수 있다.

반면 특징을 기반으로 하는 Auto-Sklearn기반의 AutoML 모델의 경우 정확도는 EEGNet에 비해 낮게 나왔으나 sensitivity나 specificity가 치우치지 않아 과적합 현상이 발생하지 않았다. 이러한 차이가 발생한 이유로는 첫째, Auto-Sklearn이 데이터로부터 정제된 특징을 추출해 이를 모델 학습에 사용하여 데이터 레이블의 쏠림에 영향을 덜 받았기 때문이다. 두 번째 이유는 Auto-Sklearn이 다양한 머신러닝 모델들을 앙상블해서 사용하는 방법이기에 각각의 머신러닝 모델들이 서로를 보완하여 모델 편향을 줄여 과적합 현상이 발생하지 않았기 때문이다.

4.2 데이터 불균형 처리 실험 결과

데이터 불균형으로 인한 과적합 문제를 해결하기 위해 두 번째 실험에서는 뇌파 데이터에 데이터 불균형 처리 알고리즘들을 적용하여 각각의 성능을 비교하였다. 실험은 첫 번째 실험에서 가장 우수한 성능을 보인 EEGNet 모델에 데이터 불균형 처리 알고리즘을 적용하여 진행하였다. 모델 파라미터 세팅은 <표 2>의 세팅을 사용하였다.

〈표 5〉 데이터 불균형 처리 실험 결과

단위 (%)

Algorithm	Accuracy	Sensitivity	Specificity
Vanilla EEGNet	68.9	95.6	42.2
Class Weight	70	88.9	51.1
Gaussian Noise[34-36]	78.9	82.2	75.6
Frequency Shift	76.7	80	73.3
Undersampling	71.1	77.8	64.4

<표 5>에 제시된 실험 결과에서 가우시안 노이즈(Gaussian noise)를 섞어 데이터를 증강하는 방법은 78.9%로 가장 높은 정확도를 보였다. Sensitivity와 specificity 역시 크게 개선되어 앞선 모델별 성능 실험에서 발생한 과적합 문제가 개선된 것을 볼 수 있었다. 마찬가지로 뇌파의 채널별 주파수 대역을 이동하는 frequency shift 방법 역시 76.7%의 정확도와 과적합 문제의 개선을 확인할 수 있었다. 소수 레이블에 데이터의 수를 맞추는 언더샘플링 방법은 71.1%의 정확도를 보였으며 과적합 문제를 개선하는 결과를 보여주었다. 각 레이블의 비율에 따라 클래스 가중치를 두는 방법은 70%의 정확도를 보여 데이터 불균형을 처리하지 않은 vanilla EEGNet 보다 약간 더 높은 정확도를 보였지만 여전히 sensitivity가 specificity에 비해 크게 나오는 과적합 현상이 관찰되어 데이터 불균형을 처리하지 못함을 보여주었다.

5. 논의

본 연구는 머신러닝 및 딥러닝 기술과 건식 뇌파 데이터를 사용한 치매의 조기진단 가능성에 대해 알아보았다. 19채널 뇌파 데이터에서 특징들을 추출하여 머신러닝 모델을 학습 및 테스트하였으며, 딥러닝 모델은 별도의 특징 추출 없이 전처리한 데이터를 사용하여 학습 및 테스트하였다. 데이터 불균형을 처리하기 위해 4개의 서로 다른 데이터 불균형 처리 방법을 시험하였고 그 결과 EEGNet과 가우시안 노이즈(Gaussian Noise)를 섞어 데이터를 증강하는 방법의 조합에서 78.9%의 정확도를 얻었다.

기존의 뇌파와 머신러닝, 딥러닝 기술을 조합한 치매 진단 연구들은 80% 초반에서 90% 이상의 높은 정확도를 보인다. 하지만 이러한 연구들은 전문가의 지시와 통제된 환경에서 습식으로 측정된 고해상도 의료용 측정 장비로 수집된 뇌파 데이터를 활용한다. 높은 진단 비용과 낮은 기술 접근성이 치매의 조기진단을 어렵게 하는 현 상황에 비추어 보았을 때 이러한 기기를 일반인들이 활용하는 것은 매우 어렵다. 따라서 본 연구에서 기존의 측정 장비들보다 접근성이 높은 건식 19채널 뇌파 장비를 사용하여 실험을 진행한 것은 기존의 연구와 비교했을 때 차별성을 가진다. 기존의 치매 조기진단 연구들에서 건식 방식으로 측정된 뇌파를 활용한 연구들은 없는 만큼, 새로운 방식으로 측정한 데이터에 관한 결과를 제시했다는 점에서 의미가 있다.

치매 환자의 뇌파 데이터는 그 수집이 쉽지 않고 개인정보 보호 등의 다양한 문제로 인해 공개된 데이터셋이 존재하지 않는다. 특히 경도인지장애군의 경우 데이터의 수집이 어려워 대부분의 연구에서 사용하는 데이터의 수가 제한적이다. 본 연구에서는 175명의 경도인지장애군과 50명의 정상군 데이터를 활용하여 실험을 진행한 만큼 학습된 모델이 일반화(generalization) 측면에서 더 나은 성능을 보여줄 것으로 기대된다. 향후 추가적인 데이터 수집을 통해 알츠하이머군(AD)과 정상군(NL) 데이터가 현 데이터셋에 보강된다면, 더욱 신뢰할 수 있는 결과를 도출할 수 있을 뿐만 아니라 기존에 데이터셋의 부족으로 시도해볼 수 없었던 방법

론이나 모델들을 사용하여 실험을 진행해 볼 수 있을 것이다.

6. 결론

본 논문은 건식으로 수집된 뇌파(EEG) 데이터를 활용하여 세 종류의 딥러닝 모델과 한 종류의 머신러닝 모델을 학습하여 경도인지장애군과 정상군의 분류 정확도를 확인한 연구다. 기존의 연구들이 전문가의 도움과 통제된 상황에서 고해상도 의료용 측정기기를 사용하여 습식 방식으로 측정된 뇌파 데이터를 사용한 반면, 본 연구는 더욱 간소화된 19채널 기기를 통해 건식 방식으로 측정된 뇌파 데이터를 사용했다는 점에서 차별성을 가진다. 또한, 경도인지장애 환자의 데이터 수집의 어려움으로 인해 기존의 연구들이 제한된 수의 뇌파 데이터를 사용한 반면, 본 연구에서는 225명분의 뇌파 데이터를 사용하여 실험을 진행했다는 점에서 두 번째 의의를 가진다. 향후 데이터셋을 보강하여 현 방법론에 대한 추가적인 검증을 하는 동시에 뇌파 데이터에 보행 데이터(gait data)와 같은 타 데이터를 결합한 멀티모달 방식의 치매 진단 연구 역시 진행할 필요가 있다. 또한, 최근 전이학습과 같은 새로운 모델 학습 기법이나 그래프 합성곱 신경망(graph convolutional network)와 같은 새로운 모델들이 뇌-컴퓨터 인터페이스(brain-computer interface, BCI) 분야에서 좋은 성능을 보이고 있는 만큼, 데이터가 충분히 보강된다면 이와 같은 방법론들을 치매 진단 분야에 적용하여 성능 향상에 도전해 볼 수 있을 것으로 기대된다. 또한 설명가능인공지능(explainable artificial intelligence, XAI) 기술을 학습된 모델에 결합하여 설명성을 제공한다면 치매 진단에 활용할 수 있는 바이오마커(biomarker)의 탐색에도 활용할 수 있을 것으로 기대된다.

Acknowledgments

본 연구는 2019년도 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행되었으며(No. NRF-2019R1A2C1088900) 보건복지부 및 과학기술정보통신부의 재원으로 치매극복연구개발 사업단선정, 한국보건산업진흥원의 보건의료기술연구개발사업 지원에 의하여 이루어진 것임(과제번호: HU20C0487)

참고문헌

〔1〕 Klementieva, O., et al. "Pre-plaque conformational changes in Alzheimer's disease-linked Aβ and APP." Nature communications 8.1 (2017): 14726.

〔2〕 Binder, Lester I., et al. "Tau, tangles, and Alzheimer's disease." Biochimica et Biophysica Acta (BBA)-Molecular Basis of Disease 1739. 2-3 (2005): 216-223.

〔3〕 Acharya, U. Rajendra, et al. "Deep convolutional neural network for the automated detection and diagnosis of seizure using EEG signals." Computers in biology and medicine 100 (2018): 270-278.

〔4〕 Aboalayon, Khald Ali I., et al. "Sleep stage classification using EEG signal analysis: a comprehensive survey and new investigation." Entropy 18.9 (2016): 272.

〔5〕 Ebrahimi, Farideh, et al. "Automatic sleep stage classification based on EEG signals by using neural networks and wavelet packet coefficients." 2008 30th Annual International Conference of the IEEE Engineering in Medicine and Biology Society. IEEE, 2008.

〔6〕 Berka, Chris, et al. "EEG correlates of task engagement and mental workload in vigilance, learning, and memory tasks." Aviation, space, and environmental medicine 78.5 (2007): B231-B244.

〔7〕 Malmivuo, Jaakko, and Robert Plonsey.

Bioelectromagnetism: principles and applications of bioelectric and biomagnetic fields. Oxford University Press, USA, 1995.

〔8〕 Urigüen, Jose Antonio, and Begoña Garcia-Zapirain. "EEG artifact removal—state-of-the-art and guidelines." Journal of neural engineering 12.3 (2015): 031001.

〔9〕 Gratton, Gabriele. "Dealing with artifacts: The EOG contamination of the event-related brain potential." Behavior Research Methods, Instruments, & Computers 30.1 (1998): 44-53.

〔10〕 Craik, Alexander, Yongtian He, and Jose L. Contreras-Vidal. "Deep learning for electroencephalogram (EEG) classification tasks: a review." Journal of neural engineering 16.3 (2019): 031001.

〔11〕 Bos, Danny Oude. "EEG-based emotion recognition." The influence of visual and auditory stimuli 56.3 (2006): 1-17.

〔12〕 son gui young, Won-Young Lee, Kyungjin Han, Sunghyon Kyeong.(2020).The study of feature vector generation and emotion recognition using EEG signals.The Journal of Korean Institute of Next Generation Computing,16(2),72-79.

〔13〕 GUIYOUNG SON, Wonyoung Lee, Jiwoong Lee, Minsong Ki.(2022).Machine Learning based Human emotion state classification using EEG signals.The Journal of Korean Institute of Next Generation Computing, 18(1),37-46.

〔14〕 Je-Woo Ryu, Woo-Hyun Hwang, KIM DEOKHWAN.(2019).Comparison of EEG Topography Labeling and Annotation Labeling Techniques for EEG-based Emotion Recognition. The Journal of Korean Institute of Next Generation Computing,15(3),16-24.

〔15〕 Acharya, U. Rajendra, et al. "Automated EEG-based screening of depression using deep convolutional neural network." Computer methods and programs in biomedicine 161 (2018): 103-113.

〔16〕 Mazaheri, Ali, et al. "EEG oscillations during word processing predict MCI conversion to Alzheimer's disease." NeuroImage: Clinical 17 (2018): 188-197.

〔17〕 Kulkarni, N. N., and V. K. Bairagi. "Extracting salient features for EEG-based diagnosis of Alzheimer's disease using support vector machine classifier." IETE Journal of Research 63.1 (2017): 11-22.

〔18〕 Trambaiolli, Lucas R., et al. "Improving Alzheimer's disease diagnosis with machine learning techniques." Clinical EEG and neuroscience 42.3 (2011): 160-165.

〔19〕 McBride, Joseph C., et al. "Spectral and complexity analysis of scalp EEG characteristics for mild cognitive impairment and early Alzheimer's disease." Computer methods and programs in biomedicine 114.2 (2014): 153-163.

〔20〕 Anderer, P., et al. "Discrimination between demented patients and normals based on topographic EEG slow wave activity: comparison between z statistics, discriminant analysis and artificial neural network classifiers." Electroencephalography and clinical neurophysiology 91.2 (1994): 108-117.

〔21〕 Pritchard, Walter S., et al. "EEG-based, neural-net predictive classification of Alzheimer's disease versus control subjects is augmented by non-linear EEG measures." Electroencephalography and clinical Neurophysiology 91.2 (1994): 118-130.

〔22〕 Rodrigues, Pedro, and João Paulo Teixeira. "Artificial neural networks in the discrimination of alzheimer's disease." ENTERprise Information Systems: International Conference, CENTERIS 2011, Vilamoura, Portugal, October 5-7, 2011, Proceedings, Part III. Springer Berlin Heidelberg, 2011.

〔23〕 Ruiz-Gómez, Saúl J., et al. "Automated multiclass classification of spontaneous EEG activity in Alzheimer's disease and mild cognitive impairment." Entropy 20.1 (2018): 35.

〔24〕 Ahmadlou, Mehran, Hojjat Adeli, and Anahita Adeli. "New diagnostic EEG markers of the Alzheimer's disease using visibility graph." Journal of neural transmission 117 (2010): 1099-1109.

〔25〕 Ieracitano, Cosimo, et al. "A convolutional neural network approach for classification of dementia stages based on 2D-spectral representation of EEG recordings." Neurocomputing 323 (2019): 96-107.

〔26〕 You, Zeng, et al. "Alzheimer's disease classification with a cascade neural network." Frontiers in Public Health 8 (2020): 584387.

〔27〕 Sazgar, Mona, et al. "EEG artifacts." Absolute Epilepsy and EEG Rotation Review: Essentials for Trainees (2019): 149-162.

〔28〕 Schirrmeister, Robin Tibor, et al. "Deep learning with convolutional neural networks for EEG decoding and visualization." Human brain mapping 38.11 (2017): 5391-5420.

〔29〕 Lawhern, Vernon J., et al. "EEGNet: a compact convolutional neural network for EEG-based brain–computer interfaces." Journal of neural engineering 15.5 (2018): 056013.

〔30〕 Feurer, Matthias, et al. "Efficient and robust automated machine learning." Advances in neural information processing systems 28 (2015).

〔31〕 Feurer, Matthias, et al. "Auto-sklearn 2.0: Hands-free automl via meta-learning." J Machine Learn Res 23.261 (2020): 1-61.

〔32〕 Chawla, Nitesh V., et al. "SMOTE: synthetic minority over-sampling technique." Journal of artificial intelligence research 16 (2002): 321-357.

〔33〕 Schwabedal, Justus TC, et al. "Addressing class imbalance in classification problems of noisy signals by using fourier transform surrogates." arXiv preprint arXiv:1806.08675 (2018)

〔34〕 Wang, Fang, et al. "Data augmentation for EEG-based emotion recognition with deep convolutional neural networks." MultiMedia Modeling: 24th International Conference, MMM 2018, Bangkok, Thailand, February 5-7, 2018, Proceedings, Part II 24. Springer International Publishing, 2018.

〔35〕 Cheng, Joseph Y., et al. "Subject-aware contrastive learning for biosignals." arXiv preprint arXiv:2007.04871 (2020).

〔36〕 Mohsenvand, Mostafa Neo, Mohammad Rasool Izadi, and Pattie Maes. "Contrastive representation learning for electroencephalogram classification." Machine Learning for Health. PMLR, 2020.

저자소개

◆ 김재영

- 2016년 성균관대학교 컴퓨터공학과 학사
- 2016년~현재 서울대학교 컴퓨터공학부 석박사통합과정
- 관심분야: HCI, Biomedical Informatics

◆ 한구현

- 2012년 서울대학교 컴퓨터공학부 학사
- 2012년 서울대학교 연합전공 정보문화학 학사
- 2013년~현재 서울대학교 컴퓨터공학부 석박통합과정
- 관심분야: HCI, 앰비언트 정보 시각화

◆ 안단태

- 2019년 서울대학교 컴퓨터공학부 학사
- 2019년~현재 서울대학교 컴퓨터공학부 석박사통합과정
- 관심분야: HCI, 음악 분석 및 생성, 뇌-컴퓨터 인터페이스

◆ 이시현

- 2023년 숭실대학교 AI융합학부 학사
- 2023년~현재 서울대학교 컴퓨터공학부 석박사통합과정
- 관심분야: Biomedical Informatics, Healthcare Analytics

◆ 임승의

- 2020년~현재 와이브레인 연구원
- 2021년 계명대학교 의공학과 석사
- 관심분야: 뇌파 분석

◆ 이기원

- 2012년 KAIST 신소재공학과 박사
- 2014년~현재 와이브레인 CEO/CTO
- 관심분야: 뇌파 분석, 생체신호 분석

◆ 문기욱

- 2013년 가톨릭대학교 의생명과학과 박사
- 2013년~현재 와이브레인 Innovation research
- 관심분야: 뇌파 분석, 생체신호 분석, 데이터 처리

◆ 김보형

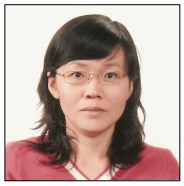

- 1995년 서울대학교 컴퓨터공학과 학사
- 1997년 서울대학교 컴퓨터공학과 석사
- 2001년 서울대학교 컴퓨터공학과 박사
- 2012년~2014년 분당서울대학교병원 영상의학과 조교수
- 2014년~2016년 분당서울대학교병원 영상의학과 부교수
- 2016년~현재 한국외국어대학교 바이오메디컬공학부 조교수
- 관심분야: 의료영상처리, 데이터 시각화

◆ 서진욱

- 1995년 서울대학교 컴퓨터공학과 학사
- 1997년 서울대학교 컴퓨터공학과 석사
- 2005년 메릴랜드대학교 컴퓨터공학과 박사
- 2009년~2012년 서울대학교 컴퓨터공학부 조교수
- 2012년~2017년 서울대학교 컴퓨터공학부 부교수
- 2017년~현재 서울대학교 컴퓨터공학부 교수
- 관심분야: HCI, 데이터 시각화