

Epileptic Seizure Detection Using CNN Ensemble Models Based on Overlapping Segments of EEG Signals

Min-Ki Kim[†]

ABSTRACT

As the diagnosis using encephalography(EEG) has been expanded, various studies have been actively performed for classifying EEG automatically. This paper proposes a CNN model that can effectively classify EEG signals acquired from healthy persons and patients with epilepsy. We segment the EEG signals into sub-signals with smaller dimension to augment the EEG data that is necessary to train the CNN model. Then the sub-signals are segmented again with overlap and they are used for training the CNN model. We also propose ensemble strategy in order to improve the classification accuracy. Experimental result using public Bonn dataset shows that the CNN can detect the epileptic seizure with the accuracy above 99.0%. It also shows that the ensemble method improves the accuracy of 3-class and 5-class EEG classification.

Keywords : Epileptic Seizure, EEG, CNN, Ensemble Model

뇌파의 중첩 분할에 기반한 CNN 앙상블 모델을 이용한 뇌전증 발작 검출

김민기[†]

요약

뇌파(electroencephalogram, EEG)를 이용한 진단이 확대되면서 EEG 신호를 자동으로 분류하기 위한 다양한 연구가 활발히 이루어지고 있다. 본 논문은 일반인과 뇌전증 환자에게서 추출한 EEG 신호를 효과적으로 식별할 수 있는 CNN 모델을 제안한다. CNN의 학습에 필요한 데이터를 확장하기 위하여 EEG 신호를 낮은 차원의 신호로 분할하고, 이것을 다시 여러 개의 세그먼트로 중첩 분할하여 CNN 학습에 이용한다. 이와 더불어 CNN의 성능을 개선하기 위하여 CNN 앙상블 전략을 제안한다. 공개된 Bonn 데이터셋으로 실험을 수행한 결과 뇌전증 발작을 99.0% 이상의 정확도로 검출하였고, 앙상블 방식에 의해 3-클래스와 5-클래스의 EEG 분류에서 정확도가 향상되었다.

키워드 : 뇌전증 발작, 뇌파, 합성곱 신경망, 앙상블 모델

1. 서론

뇌전증은 뇌 신경세포가 일시적인 이상으로 과도한 흥분 상태가 되어 의식 소실이나 발작을 일으키는 가장 일반적인 뇌 질환으로 국내 뇌전증 환자 수는 25만 명에서 36만 명 정도로 추정된다[1]. 뇌전증은 뇌자기 공명 영상, 양전자 방출 단층촬영법, 뇌파검사 등을 통해 진단이 이루어진다. 뇌파(electroencephalogram, EEG)는 뇌 신경세포들간의 정보 전달 과정에서 발생하는 전기적 신호를 두피 표면에서 측정 한 것으로, 뇌 활동을 분석하는데 유용한 정보를 제공한다 [2]. EEG 신호의 분석을 통해 뇌전증 발작을 비롯한 주의력

결핍 장애, 알콜 중독, 불안 장애 등의 진단에 사용될 뿐만 아니라 심각한 행동 장애가 있는 사람들을 지원하는 인터페이스로도 주목받고 있다[3-6].

신경과 전문의가 EEG 신호를 육안으로 분석하여 뇌전증 발작을 검출하기 위해서는 많은 시간과 노력이 요구된다. 따라서 EEG 신호를 자동으로 분석하는 컴퓨터 보조 진단 시스템(computer-aided diagnosis system)에 대한 요구가 나타나고 있으며, 이러한 시스템을 개발하기 위해서는 EEG 신호로부터 자동으로 뇌전증 발작을 검출하는 기술이 필수적이다. EEG 신호를 분석하여 발작 여부를 검출하는 것은 신호 분류의 문제로 볼 수 있다. 신호 처리의 측면에서 살펴보면 EEG 신호에는 관심 대상이 되는 신호 외에 눈의 깜박임이나 팔다리의 움직임에 의해 발생하는 잡파(artifact)가 내포되어 있고, 피험자에 따라 형태학적 특징이 조금씩 다르게 나타나기 때문에 일관된 특징을 추출하는데 어려움이 발생하고, 기

[†] 종신회원 : 경상대학교 컴퓨터학과 교수, 공학연구원(ERI) 자동화·컴퓨터연구센터 책임연구원

Manuscript Received : April 28, 2021

First Revision : June 17, 2021

Accepted : June 17, 2021

* Corresponding Author : Min-Ki Kim(mkkim@gnu.ac.kr)

계 학습의 측면에서 이 문제를 해결하기 위해서는 분류기를 학습시키기 위한 충분한 데이터를 확보해야 한다.

Ricardo 외[7]는 국소 푸리에 변환(short time Fourier transform)을 적용하여 시간-주파수의 2차원 영상으로 변환하였고, Mao 외[8]는 연속 웨이블릿 변환(continuous wavelet transform)을 적용하여 EEG 신호로부터 2차원 영상을 생성하여 특징을 추출하였다. EEG 신호의 시간-주파수 특징을 추출하기 위하여 EEG 신호를 연속적으로 다른 스케일을 갖는 신호로 분할하는 이산 웨이블릿 변환(discrete wavelet transform, DWT)이 여러 연구에서 사용되었다. Kumar 외[9]은 DWT를 3레벨, Hsu & Yu[10]는 4레벨까지 적용하여 특징을 추출하였다. EEG 신호를 5개의 서브 밴드로 분해하여 비선형 특징을 지지벡터머신(support vector machine, SVM)을 이용하여 분류한 Hsu & Yu[10]는 유전자 알고리즘을 적용하여 최적의 조합을 갖는 특징 부분집합을 선택하여 성능을 개선하였다. Savadkoobi 외[11]는 시간, 주파수, 시간-주파수라는 3개의 도메인에서 특징을 추출하였다. 각각 버터워스 필터, 푸리에 변환, 웨이블릿 변환을 적용한 후 각 도메인의 데이터가 갖는 통계적 특징을 추출하였다. 5개 주파수 대역에서 추출한 특징은 평균(mean), 분산(variance), 대칭도(skewness), 첨도(kurtosis)로 총 60개의 통계적 특징을 기반으로 K-NN(K-nearest neighbors)과 SVM 분류기로 신호를 식별하였다. Bhattacharyya 외[12]는 23개 채널을 갖는 다변량 EEG 신호에서 최소의 표준편차를 나타내는 신호를 포함하여 5개 채널을 자동으로 선택한 후 엠프리컬 웨이블릿 변환(empirical wavelet transform)을 이용한 순간 진폭과 주파수를 구하여 진폭의 평균, 진폭 변화 절대값에 대한 평균과 분산을 특징으로 이용하였다.

컴퓨터 비전 분야에서 합성곱 신경망(convolutional neural network, CNN)을 이용한 연구들이 우수한 성과를 나타냄에 따라 최근에는 CNN을 이용하여 EEG 신호의 특징을 추출하고 인식하는 연구들이 주목을 받고 있다. Mao 외[8]는 1차원 EEG 신호에 CWT를 적용하여 2차원 영상을 생성한 후 3쌍의 합성곱(convolution)과 맥스풀링(max pooling) 계층으로 구성된 2D-CNN을 이용하여 뇌전증을 식별하였다. EEG 신호를 두뇌-컴퓨터 인터페이스(brain-computer interface, BCI)에 적용하기 위하여 Schirmer 외[13]는 EEG 신호를 분류하는데 적합한 CNN 구조를 탐색하였다. BCI 대회에 사용된 공개된 EEG 데이터 세트를 사용하여 실험한 결과 EEG 신호를 디코딩하는데 널리 사용되는 필터뱅크 공통공간 패턴(filter bank common spatial pattern) 방식[14]보다 CNN을 이용한 방식이 정확도가 높게 나타났다. 그리고 2개의 컨볼루션 계층으로 구성된 얇은 CNN이 4개 컨볼루션 계층으로 구성된 깊은 CNN보다 좋은 성능을 나타내는 것으로 보고하였다. Sandheep 외[15]는 한 쌍의 컨볼루션과 맥스풀링 계층, 그리고 3개의 완전연결계층을 갖는 매우 단순한 신

경망으로도 우울증 검출이 가능함을 보였다.

CNN을 이용한 기존 연구들은 EEG 신호를 분류하는데 적합한 신경망의 구조에 중점을 두고 연구를 진행하였다. 일반적으로 CNN의 계층이 늘어나면 학습해야 할 파라미터의 개수가 증가하고 이에 따라 학습을 위하여 더 많은 데이터를 요구한다. 획득한 EEG 신호는 일정한 시간 또는 길이 간격으로 분할하여 분석하므로, EEG 신호의 단위 길이를 짧게 설정하면 입력 데이터로부터 더 많은 데이터를 생성할 수 있다. 그러나 EEG 신호가 짧으면 합성곱이나 맥스풀링 계층에서 사용되는 커널의 크기를 설정하는데 제약이 발생하게 된다. 이와 같이 EEG 신호의 단위 길이는 CNN의 내부 구조뿐만 아니라 데이터의 양적인 측면에도 영향을 준다. 따라서 본 연구에서는 뇌전증 발작을 검출하는데 적합한 EEG 신호의 길이를 탐색하고, 동일한 CNN 구조로 길이가 다른 EEG 신호를 학습시키고 앙상블을 통해 성능을 개선하는 방식을 제안한다.

본 논문의 구성은 다음과 같다. 서론에 이어 2장에서는 CNN을 이용하여 뇌전증 발작 신호를 검출한 기존 연구들을 살펴보고, 3장에서는 EEG 신호의 특징을 추출하고 분류하기 위해 제안한 방식에 대하여 설명한다. 4장에서는 공개된 EEG 데이터 세트를 이용한 실험 결과를 제시하고, 기존 연구와의 비교를 통해 제안된 방법의 타당성을 제시한다. 끝으로 5장에서는 본 연구의 결론과 향후 과제에 대하여 논의한다.

2. CNN을 이용한 기존의 뇌전증 검출 연구들

뇌전증 환자에게서 나타나는 EEG 신호의 특징을 분석하기 위하여 Acharya 외[16]와 Ullah 외[17]는 Bonn 대학의 데이터세트[2]를 이용하였다. 이 데이터세트는 뇌파를 측정하기 위한 표준화된 전극 위치에서 EEG 신호를 획득하였다. A부터 E까지 총 5개의 세트로 구성되어 있다. 세트 A와 B는 5명의 건강한 지원자로부터 획득한 EEG 신호로, 편안히 깨어있는 상태에서 눈을 뜬 상태(A)와 눈을 감은 상태(B)에서 측정되었다. 세트 C, D, E는 5명의 간질 환자에게서 측정된 신호로, 세트 C와 D는 간질 발작이 없는 상태에서 각기 다른 뇌 영역에서 측정되었다. 세트 E는 간질 발작이 발생할 때 측정된 EEG 신호이다. 데이터세트는 각 피험자로부터 100개씩, 총 500개의 단일 채널 인스턴스로 구성되어 있으며, 각각의 EEG 인스턴스는 23.6초 동안의 뇌의 활동을 기록한 것으로 4,097차원의 벡터 데이터이다.

Acharya 외[16]는 4,097차원의 EEG 벡터 인스턴스를 CNN의 입력층에 바로 적용하였다. CNN은 5쌍의 합성곱과 맥스풀링(max pooling) 층, 그리고 3개의 완전연결 층으로 설계하였다. 전체 데이터 중 90%를 훈련 세트, 10%를 테스트 세트로 하여 뇌전증 발작 유무에 대하여 90.33%, 정상인, 간질 환자 중 발작이 없는 경우, 발작이 발생한 경우, 이렇게 3-

class(AB vs CD vs E)에 대해서는 88.67%의 정확도(accuracy)를 보였다. Ullah 외[17]는 EEG 벡터 인스턴스를 1,024차원을 갖는 EEG 신호로 분할하여 CNN의 입력으로 사용하였다. CNN 입력으로 사용될 EEG 신호의 길이가 축소되어 정보의 손실이 발생하지만 CNN 학습을 위한 학습 데이터를 확장한 것이다. Conv-1, Conv-2, Conv-3, 그리고 2개의 완전연결 층으로 CNN의 구조를 설계하였으며, 각 Conv-n 층은 합성곱, 배치 정규화, ReLU 활성화 층으로 구성하였다. 전체 데이터 중 90%를 훈련 세트, 10%를 테스트 세트에 사용하여, 뇌전증 발작 유무와 ‘AB vs CD vs E’ 분류에 대하여 각각 99.7%, 99.1%의 정확도를 보고하였다.

Mao 외[8]와 Xu 외[18]는 뇌전증 환자와 일반인에게서 획득한 뇌파를 분류하기 위하여 Bonn 데이터세트를 1초 단위로 분할한 UCI 데이터세트[19]를 사용하였다. 분할된 EEG 신호는 178차원의 벡터로 UCI 데이터세트는 총 11,500개의 데이터로 구성되어 있다. Mao 외[8]는 EEG 신호를 연속 웨이블릿 변환(CWT)을 거쳐 2차원 영상으로 변환한 후, 2차원 합성곱 층 3개와 완전연결 층 2개로 구성된 2D-CNN을 구성하였다. 70%의 훈련 세트와 30%의 테스트 세트에 실험한 결과 5-class(A vs B vs C vs D vs E)에 대하여 74.49%의 정확도를 얻었다. Xu 외[18]는 CNN에 장단기메모리(Long Short-Term Memory, LSTM)를 결합하여 EEG 신호를 분류하였다. 제안한 CNN-LSTM 모델은 전반부에 1차원 합성곱 층 4개와 완전연결 층, 그리고 후반부에 LSTM 층 2개와 완전연결 층 3개로 구성되어 있다. 이 모델은 90%의 훈련 세트와 10%의 테스트 세트를 적용하여, 뇌전증 발작 여부를 식별하는 2-class(ABCD vs E)와 5-class(A vs B vs C vs D vs E)에 대하여 각각 99.39%와 82.00%의 정확도를 보고하였다.

3. 제안하는 방법

2장에서 살펴본 바와 같이 연구자에 따라 뇌전증 발작을 검출하기 위하여 CNN의 입력층에 서로 다른 길이를 갖는 단위 EEG 신호를 사용하였다. 충분한 길이의 EEG 신호를 사용하면 뇌전증 환자에게서 나타나는 많은 정보를 내포하는 장점이 있고, EEG 신호의 길이를 줄이면 일부 정보의 손실이 발생하지만 획득한 뇌파 데이터로부터 CNN을 학습시키는데 필요한 EEG 데이터를 확장할 수 있는 이점을 얻을 수 있다. 따라서 본 연구에서는 먼저 뇌전증 발작을 검출하는데 적합한 EEG 신호의 길이를 탐색한 후 EEG 신호를 효과적으로 분류할 수 있는 CNN 모델을 제안한다. 그리고 제안된 CNN 모델의 분류 정확도를 향상시키기 위하여 중첩 분할에 의한 EEG 세그먼트의 예측 결과를 앙상블하는 방식과 서로 다른 길이의 EEG 신호로 학습된 CNN의 예측 결과를 앙상블하는 방식을 제안한다. Fig. 1은 제안된 방식의 개괄적인 구성을 제시한 것이다.




Fig. 1. Overview of the Proposed Method

CNN-1, CNN-2, CNN-n은 EEG 신호를 각기 다른 길이로 분할한 EEG 신호로 신경망을 학습시킨 것이다. 동일한 EEG 데이터를 각기 다른 길이로 중첩 분할하여 동일한 구조를 갖는 여러 개의 CNN으로 분류한 후 그 결과를 결합하여 EEG 신호를 최종적으로 식별하게 된다.

3.1 CNN 구조

EEG 신호를 분류하기 위하여 제안한 CNN은 3층의 합성곱과 맥스풀링 층으로 구성된 전반부와 3개의 완전연결 층으로 구성된 후반부로 이루어져 있다. 합성곱과 맥스풀링 층을 2개로 구성할 경우 EEG 신호의 분류 정확도가 다소 낮게 나타났다, 이를 4개나 5개로 확장하였을 때 분류 정확도가 향상되지 않았다.

Table 1은 제안된 CNN 모델의 구조를 상세하게 제시한 것이다. 전반부는 상위층으로 갈수록 합성곱 층 커널의 크기는 작아지고 커널의 개수는 증가하도록 설계하였고, 후반부는 상위층으로 갈수록 완전연결 층 노드의 개수가 줄어들도록 설계하였다. CNN 학습 과정에서 나타나는 과적합을 줄이기 위하여 50%의 드롭아웃을 적용하였으며, 활성화 함수는 ReLU를 적용하였다.

3.2 EEG 데이터 차원 축소와 중첩 분할

본 연구에서는 뇌전증 환자에게서 나타나는 EEG 신호의 특징을 분석하는데 널리 사용되어온 Bonn 데이터세트[2]를 사용하였다. 뇌전증 환자를 다수 확보하여 뇌파를 획득하는 것이 간단치 않은 작업이기 때문에 소량의 데이터를 확장하

Table 1. The Details of the Proposed CNN Model

Layer Type	Number of Kernels	Kernel Size	Pool Size / Stride
Conv-1 & MP	64	1 × 7	2 / 3
Conv-2 & MP	128	1 × 5	2 / 2
Conv-3 & MP	256	1 × 3	2 / 2
Dropout (0.5), Flatten			
Dense-1	64		
Dense-2	32		
Dense-3	2 or 3 or 5		

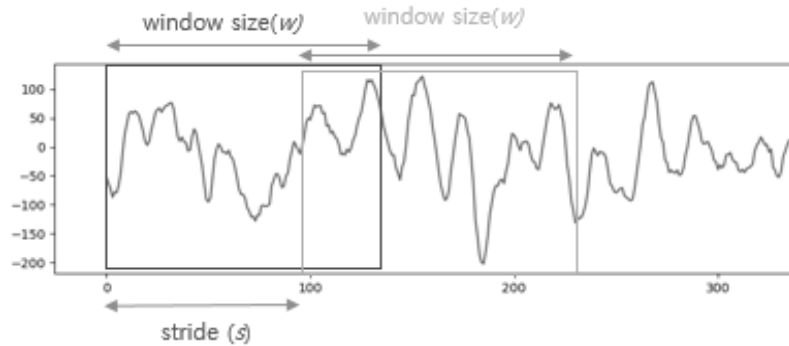


Fig. 2. Overlapping EEG Segments

기 위하여 4,097차원의 EEG 신호를 낮은 차원의 신호로 분할하는 방식으로 데이터를 확장하였다. 그러나 EEG 신호의 차원을 지나치게 줄이면 EEG를 식별할 수 있는 중요한 정보가 손실되므로 적절한 차원 축소가 필요하다. EEG 신호의 차원을 2048, 1024, 512, 256으로 줄여가면서 제안한 CNN으로 실험을 수행한 결과 단위 길이가 1,024인 EEG 신호가 적합한 것으로 파악되었다.

단일 길이의 EEG 데이터를 CNN의 입력으로 사용하는 기존 연구와는 달리, 본 연구에서는 서로 다른 길이를 갖는 EEG 데이터를 CNN의 입력으로 사용한다. EEG 신호를 낮은 차원의 세그먼트로 분할하여 특징을 추출하게 되면 눈의 깜박임이나 팔다리의 움직임에 의해 발생하는 잡파(artifact)로 인한 신호의 변형이 해당 세그먼트에만 영향을 미치게 되므로, 손상되지 않은 다른 세그먼트에서 안정적으로 특징을 추출할 수 있다. 그리고 Ullah 외[17]의 연구에서 제시된 바와 같이 EEG 데이터를 더 작은 차원의 데이터로 중첩 분할함으로써 CNN 학습을 위한 데이터를 확충할 수 있는 이점이 있다. Fig. 2는 EEG 데이터를 중첩 분할하는 방식을 도시한 것으로, 윈도우를 중첩하여 이동시키면서 신호를 분할한다. 윈도우는 전체 EEG 신호를 일정 길이로 분할하기 위한 것으로, 윈도우 크기 w 가 EEG 세그먼트의 길이가 되고, 윈도우를 이동시키는 거리 s 에 의해 이웃한 신호와의 중첩되는 비율이 결정된다. w 가 작아질수록 EEG 세그먼트에 내포된 정보의 손실이 커지나 세그먼트의 개수는 증가하고, s 가 작아질수록 중첩되는 비율이 늘어나 세그먼트의 개수가 증가하게 된다. 예를 들어 $w=512$, $s=256$ 인 경우 차원이 1,024차원인 한 개의 EEG 데이터로부터 3개의 EEG 세그먼트가 생성되며, $w=256$, $s=128$ 인 경우는 7개의 세그먼트가 생성된다.

3.3 CNN 학습과 예측 결과 앙상블

동일한 구조를 갖는 CNN을 서로 다른 길이의 EEG 세그먼트로 학습시키기 위하여 Table 2에 제시된 윈도우 크기 (w)와 이동 거리(s)로 EEG 데이터를 중첩 분할하여 EEG 세그먼트를 생성한 후 CNN의 입력으로 사용하였다.

Table 2. Window Size and Moving Distance

CNN	Window Size (w)	Stride (s)
CNN-1	1,024	1,024
CNN-2	512	256
CNN-3	512	128
CNN-4	256	128
CNN-5	128	112

각 CNN은 w 차원의 EEG 세그먼트 데이터를 사용하여 CNN을 학습시키고, 학습된 신경망으로 EEG 신호를 분류한다. CNN-1은 1,024차원을 갖는 1개의 세그먼트가 학습에 사용되는데 비하여, CNN-2, CNN-3, CNN-4, CNN-5는 각각 3개, 5개, 7개, 9개의 세그먼트로 확장되어 학습에 사용된다. 각 CNN에 의한 EEG 신호의 분류는 학습 과정에서 사용된 것과 동일한 방식으로 일정한 길이로 분할된 세그먼트가 사용되기 때문에 CNN-1은 1개의 예측 결과를 생성하지만, CNN-2, CNN-3, CNN-4, CNN-5는 각각 3개, 5개, 7개, 9개의 예측 결과를 생성하게 된다. 예측 결과는 EEG 신호가 특정 클래스에 속할 확률로 나타나므로, 2개 이상의 예측 결과를 생성하는 CNN은 이러한 예측 결과를 앙상블하는 규칙이 요구된다. 각 클래스별 확률 값을 더하는 합 규칙(sum rule)과 각 클래스별 확률 중 가장 큰 값을 취하는 최대 규칙(max rule)을 적용해본 결과 합 규칙을 사용한 앙상블 방식이 보다 우수한 것으로 나타났다. 그리고 서로 다른 길이를 갖는 EEG 세그먼트로 학습된 여러 CNN의 예측 결과에 합 규칙을 적용하여 EEG 신호를 분류한다. 한 개의 CNN에서 각 세그먼트 신호에서 예측한 결과를 앙상블하는 것은 내부 앙상블이라고 볼 수 있고, 여러 CNN에서 예측한 결과를 앙상블하는 것은 외부 앙상블로 볼 수 있다. 내부 앙상블은 EEG 신호가 중첩 분할을 통해 여러 개의 세그먼트 신호로 분할될 때 적용되는 것으로, Table 2의 경우 CNN-2부터 CNN-5까지 적용된다. Fig. 1에 제시된 각 CNN의 예측(predict)은 내부 앙상블의 결과이고, 최종 결정전에 이루어지는 앙상블은 외부 앙상블을 의미한다.

4. 실험 결과 및 분석

4.1 데이터 세트

제안한 CNN 앙상블 모델이 뇌전증 환자에게서 나타나는 EEG 신호를 효과적으로 분류할 수 있는지 확인하기 위하여 공개된 Bonn 데이터세트를 사용하였다. 이 데이터세트는 표준화된 전극 위치에서 뇌파를 측정된 것으로, 4,097차원인 EEG 신호 500개로 구성되어 있다. 이는 CNN을 학습시키는데 충분하지 않기 때문에 원래 신호를 1,024차원으로 축소하여 2,000개의 EEG 세그먼트로 데이터세트를 확장하였다. 전체 데이터의 90%를 훈련 세트로 설정하고, 나머지 10%를 테스트 세트로 설정하였다.

4.2 성능 측정

EEG 신호의 분류에 대한 성능은 두 가지 상황으로 구분하여 측정하였다. EEG 신호로부터 뇌전증 발작 여부를 판단하는 것은 2-class(ABCD vs E)로 분류하는 문제로 정확도 (accuracy), 민감도(sensitivity), 특이도(specificity)를 사용하여 성능을 측정하였다. 건강한 일반인, 뇌전증 환자 중 발작이 없을 때, 발작이 발생할 때 이렇게 3-class(AB vs CD vs E)로 분류하는 문제와 5-class(A vs B vs C vs D vs E)로 분류하는 문제는 정확도로 성능을 측정하였다.

정확도는 어떤 신호를 해당 클래스로 정확하게 분류하는 비율을 나타낸 것으로 2개 클래스로 분류할 때는 Equation (1)에 제시된 바와 같이 전체 샘플 중 참 양성(true positive, TP)과 참 음성(true negative, TN)의 비율로 계산되며, 3개 이상의 클래스로 분류할 때는 전체 샘플 중 해당 클래스로 올바르게 분류한 비율을 나타낸다. 민감도는 뇌전증 발작 증상이 있을 때 이것을 올바르게 진단한 비율을 나타내고, 특이도는 뇌전증 발작이 없을 때 이것을 올바르게 진단한 비율을 나타낸다. Equation (2)의 FN은 거짓 음성(false negative), Equation (3)의 FP은 거짓 양성(false positive)을 의미한다.

$$Accuracy(Acc) = \frac{TP + TN}{TP + FP + TN + FN} \times 100 \quad (1)$$

$$Sensitivity(Sen) = \frac{TP}{FN + TP} \times 100 \quad (2)$$

$$Specificity(Spe) = \frac{TN}{TN + FP} \times 100 \quad (3)$$

4.3 실험 결과 및 분석

CNN 모델을 훈련시키고 모델의 성능을 측정하기 위하여 10-겹 교차 검증(10-fold cross validation)을 사용하였다. 이 방식은 훈련 세트를 10개로 나눈 후 번갈아 가면서 1개를 검증 데이터로 사용하고 나머지 9개를 훈련 데이터로 사용한다. 이러한 교차 검증은 소규모 데이터 세트로 CNN 모델의

일반화 성능을 추정하는데 적합한 것으로 알려져 있다. Table 3은 뇌전증 발작 여부를 식별하는 2-class(ABCD vs E) 문제에 대하여 제안된 CNN의 교차 검증 결과를 제시한 것이다. 정확도와 특이도는 윈도우 크기와 이동 거리가 256, 128일 때, 가장 높게 나타났으며 민감도는 1,024, 1,024 일 때 가장 높게 나타났다. 그리고 정확도와 특이도에 비하여 민감도는 CNN 입력으로 사용된 EEG 신호의 차원에 따라 편차가 높게 나타났다.

Table 4는 3-class(AB vs CD vs E)와 5-class(A vs B vs C vs D vs E) 분류에 대한 CNN의 정확도를 제시한 것이다. 이번에는 윈도우 크기와 이동 거리가 512, 128일 때 가장 좋은 결과를 보였다. 2-class 분류에서는 EEG 세그먼트를 생

Table 3. 10-fold Cross Validation of 2-class Problem

Window Size (w) Stride (s)		Min	Max	Avg	Std
1024, 1024	Acc	97.22	100.0	98.83	1.03
	Sen	86.11	100.0	97.22	4.90
	Spe	96.53	100.0	99.24	1.16
512, 256	Acc	97.41	100.0	98.81	0.93
	Sen	88.89	100.0	96.48	3.51
	Spe	98.15	100.0	99.40	0.68
512, 128	Acc	97.44	99.89	98.88	0.86
	Sen	87.22	100.0	96.61	4.78
	Spe	98.19	100.0	99.44	0.61
256, 128	Acc	96.83	99.60	98.91	0.82
	Sen	85.32	99.60	95.87	4.37
	Spe	99.11	100.0	99.67	0.32
128, 112	Acc	96.67	99.32	98.45	0.99
	Sen	85.49	99.38	95.46	4.36
	Spe	97.99	99.85	99.20	0.64

Table 4. 10-fold Cross Validation of 3-class and 5-class Problems

Window Size (w) Stride (s)		Min	Max	Avg	Std
1024, 1024	3 class	91.11	99.44	95.50	2.64
	5 class	76.67	86.67	80.89	3.45
512, 256	3 class	93.15	99.26	96.15	2.23
	5 class	75.19	86.48	81.76	2.96
512, 128	3 class	94.78	99.67	97.34	1.87
	5 class	78.56	86.44	83.14	2.28
256, 128	3 class	92.54	98.49	96.01	2.12
	5 class	76.90	84.21	81.25	1.99
128, 112	3 class	90.62	96.48	94.29	1.97
	5 class	72.84	81.67	77.62	2.24

Table 5. Accuracy, Sensitivity, Specificity of 2-class Problem on Test Data with Intra-ensemble

Window Size (<i>w</i>) Stride (<i>s</i>)	Before Ensemble			After Ensemble		
	Acc	Sen	Spe	Acc	Sen	Spe
1024, 1024	100.0	100.0	100.0	100.0	100.0	100.0
512, 256	99.33	96.67	100.0	100.0	100.0	100.0
512, 128	99.00	97.00	99.50	99.50	97.50	100.0
256, 128	99.00	95.71	99.82	99.00	95.00	100.0
128, 112	98.50	96.11	99.10	99.00	95.00	100.0

성하는 방식에 따라 정확도 평균이 최대 0.46% 포인트의 미세한 차이를 나타냈으나, 3-class 분류에서는 최대 3.15% 포인트, 5-class 분류에서는 최대 5.52% 포인트의 차이를 보였다. 이것은 분류할 클래스의 개수가 증가함에 따라 CNN의 입력으로 사용되는 EEG 세그먼트 데이터가 CNN의 성능에 미치는 영향이 커진다는 것을 의미한다.

훈련 세트로 학습된 CNN을 이용하여 테스트 세트를 대상으로 EEG 신호를 분류하였다. Table 5는 뇌전증 발작 유무를 검출하는 2-class 분류에 대한 정확도, 민감도, 특이도를 제시한 것으로 합 규칙을 적용한 내부 앙상블 모델이 일부를 제외하고는 전체적으로 성능을 개선하는데 기여한 것으로 나타났다. 그렇지만 1,024차원의 EEG 데이터로 CNN을 학습시켰을 때 앙상블 없이도 100%의 정확도, 민감도, 특이도를 보여, 제안된 CNN이 뇌전증 발작을 효과적으로 검출하고 있음을 알 수 있다.

Table 6은 3-class와 5-class 분류에 대한 정확도를 제시한 것으로, 내부 앙상블에 의해 성능이 모두 향상되었으며 5-class 분류에서는 앙상블 전 최고 87.10%였던 정확도가 91.50%로 4.4% 포인트나 향상되었다.

Table 7은 각기 다른 EEG 신호로 학습한 여러 CNN의 예측 결과를 다시 합 규칙에 의해 외부 앙상블한 결과이다. 외부 앙상블에 사용된 CNN의 개수에 따른 정확도의 차이는 크지 않았으며, 5-class 분류에서만 성능이 개선된 것으로 나타났다. 실험을 통해 얻은 Table 6과 Table 7의 결과를 종합해 보면 클래스의 개수가 늘어나 클래스 간 EEG 신호의 유사도가 증가할수록 CNN 앙상블 모델이 EEG 신호 분류의 정확도를 개선하는데 효과적임을 확인할 수 있다.

Table 8은 제안된 CNN 앙상블 모델의 성능을 기존 모델과 비교하기 위하여 논문에 제시된 결과들을 정리한 것이다. 각 연구에서 사용한 훈련 세트와 학습 세트가 동일하지 않기 때문에 정확도에 대한 엄격한 비교는 곤란하지만 제안된 방식의 성능을 가늠해 볼 수 있다. 2-class와 3-class 분류에서

Table 6. EEG Classification Accuracy of 3-class and 5-class Problems on Test Data with Intra-ensemble

Window Size (<i>w</i>) Stride (<i>s</i>)	Before Ensemble		After Ensemble	
	3-class	5-class	3-class	5-class
1024, 1024	97.50	71.00	97.50	71.00
512, 256	98.00	84.50	98.00	87.50
512, 128	96.90	87.10	98.00	91.50
256, 128	95.71	83.71	99.00	89.50
128, 112	94.00	80.67	99.00	91.50

Table 7. EEG Classification Accuracy on Test Data by Inter-ensemble

Inter-Ensemble	2-class	3-class	5-class
2 CNNs	99.50	98.00	89.00
3 CNNs	99.00	98.50	93.00
4 CNNs	99.00	98.50	93.00
5 CNNs	99.00	98.50	92.50

Table 8. Comparison of EEG Classification Accuracy

	2-class	3-class	5-class
Mao 외[8]	NA	NA	74.49
Xu 외[18]	99.39	NA	82.00
Acharya 외[16]	90.33	88.67	NA
Ullah 외[17]	99.70	99.10	NA
Ensemble Model 1	100.0	99.00	91.50
Ensemble Model 2	99.00	98.50	93.00

Ullah 외[17]의 연구가 상대적으로 우수한 성능을 나타내고 있으며, 제안된 방식이 이에 견줄만한 성능을 나타내고 있음을 알 수 있다. 'Ensemble Model 1'은 분류할 클래스의 개수에 따라 최적의 데이터로 CNN을 학습시킨 후 내부 앙상블만 적용하여 EEG 신호를 분류한 결과이고, 'Ensemble Model 2'는 내부 앙상블과 외부 앙상블을 모두 적용한 결과이다. Xu 외[18]의 결과를 보면 2-class에 대하여 99.39%의 정확도를 나타내고 있지만 5-class는 정확도가 82.00%로 급격히 저하되는데 비하여, 본 연구에서 제안한 방식은 5-class에서도 각각 91.50%와 93.00%의 정확도를 유지하고 있다. 이러한 결과는 제안된 방식이 분류할 클래스의 개수가 증가할 때 보다 안정적임을 의미한다.

5. 결 론

뇌 신경세포들간의 정보전달 과정에서 발생하는 전기적 신호를 두피 표면에서 측정된 EEG 신호를 분석하여 뇌전증 발작을 진단할 수 있다. 그러나 신경과 전문의가 EEG 신호를 육안으로 분석하는 것은 많은 시간과 노력이 필요하므로, EEG 신호를 자동으로 분류할 수 있는 기술이 필요하다. 본 연구에서는 EEG 신호를 효과적으로 식별할 수 있는 CNN을 제안하였으며, CNN을 이용한 EEG 분류의 정확도를 개선하기 위하여 앙상블 방식을 제안하였다. 뇌전증 발작을 검출하는 2-class 분류에서는 제안된 CNN 모델만으로도 충분한 성능을 얻을 수 있었으며, 3-class와 5-class 분류가 요구되는 작업에서는 CNN 앙상블 모델이 정확도를 향상시키는데 효과적임을 확인할 수 있었다.

향후 연구에서는 보다 큰 규모의 뇌전증 EEG 데이터셋을 확보하여 제안된 방법이 실용성이 있는지 확인할 계획이다. 그리고 제안된 방식은 2-class 분류에 있어서 특이도에 비하여 민감도가 낮게 나타나고 있어, 이를 개선할 수 있는 방안에 대한 추가적인 연구를 수행할 계획이다.

References

- [1] K. Jung, "Epidemiology of epilepsy in Korea," *Epilepsia: Epilepsy and Community*, Vol.2, No.1, pp.17-20, 2020.
- [2] R. G. Andrzejak, K. Lehnertz, F. Mormann, C. Rieke, P. David, and C. E. Elger, "Indications of nonlinear deterministic and finite-dimensional structures in time series of brain electrical activity: Dependence on recording region and brain state," *Physical Review*, Vol.64, No.6, pp.1-8, 2001.
- [3] M. R. Mohammadi, A. Khaleghi, A. M. Nasrabadi, S. Rafieivand, M. Begol, and H. Zarafshan, "EEG classification of ADHD and normal children using non-linear features and neural network," *Biomedical Engineering Letter*, Vol.6, No.2, pp.66-73, 2016.
- [4] S. Bavkar, B. Iyer, and S. Deosarkar, "Detection of alcoholism: An EEG hybrid features and ensemble subspace K-NN based approach," In *International Conference on Distributed Computing and Internet Technology* (pp.161-168), Springer, Cham, 2019.
- [5] A. Demerdzieva, "EEG characteristics of generalized anxiety disorder in childhood," *Acta Informatica Medica*, Vol.19, No.1, pp.9-15, 2011.
- [6] D. J. McFarland and J. R. Wolpaw, "EEG-based brain-computer interfaces," *Current Opinion in Biomedical Engineering*, Vol.4, pp.194-200, 2017.
- [7] R. A. Ricardo, O. L. Arturo, and O. P. Ivan, "Analysis of EEG signal processing techniques based on spectrograms," *Research in Computing Science*, Vol.145, pp.151-162, 2017.
- [8] W. Mao, H. I. K. Fathurrahman, Y. Lee, and T. W. Chang, "EEG dataset classification using CNN method," *Journal of Physics: Conference Series*, Vol.1456, pp.1-7, 2020.
- [9] N. Kumar, K. Alam, and A. H. Siddiqi, "Wavelet transform for classification of EEG signal using SVM and ANN," *Bio-medical & Pharmacology Journal*, Vol.10, No.4, pp.2061-2069, 2017.
- [10] K. C. Hsu and S. N. Yu, "Detection of seizures in EEG using subband nonlinear parameters and genetic algorithm," *Computers in Biology and Medicine*, Vol.40, No.10, pp.823-830, 2010.
- [11] M. Savadkoobi, T. Oladunni, and L. Thompson, "A machine learning approach to epileptic seizure prediction using Electroencephalogram (EEG) signal," *Biocybernetics and Biomedical Engineering*, Vol.40, No.3, pp.1328-1341, 2020.
- [12] A. Bhattacharyya and B. Pachori, "A multivariate approach for patient specific EEG seizure detection using empirical wavelet transform," *IEEE Transactions on Biomedical Engineering*, Vol.64, No.9, pp.2003-2015, 2017.
- [13] R. T. Schirrmester, et al., "Deep learning with convolutional neural networks for EEG decoding and visualization," in *Human Brain Mapping*, Vol.38, No.11, pp.5391-5420, 2017.
- [14] K. K. Ang, Z. Y. Chin, H. Zhang, and C. Guan. "Filter bank common spatial pattern (FBCSP) in brain-computer interface," in *Proceedings of IEEE International Joint Conference on Neural Networks*, pp.2390-2397, 2008.
- [15] P. Sandheep, S. Vineeth, P. Meljo, and D. P. Subha, "Performance analysis of deep learning CNN in classification of depression EEG signals," in *Proceedings of IEEE Region 10 Conference*, pp.1339-1344, 2019.
- [16] U. R. Acharya, S. L. Oh, Y. Hagiwara, J. H. Tan, and H. Adeli, "Deep convolutional neural network for the automated detection and diagnosis of seizure using EEG signals," *Computers in Biology and Medicine*, Vol.100, pp.270-278, 2018.
- [17] I. Ullah, M. Hussain, E. Qazi, and H. Aboalsamh, "An automated system for epilepsy detection using EEG brain signals based on deep learning approach," *Expert Systems With Applications*, Vol.107, pp.61-71, 2018.
- [18] G. Xu, T. Ren, Y. Chen, and W. Che, "A one-dimensional CNN-LSTM model for epileptic seizure recognition using EEG signal analysis," *Frontiers in Neuroscience*, Vol.14, pp.1-9, 2020.
- [19] Epileptic Seizure Recognition Data Set [Internet], <https://archive.ics.uci.edu/ml/datasets/Epileptic+Seizure+Recognition>.



김민기

<https://orcid.org/0000-0001-8352-4763>

e-mail : mkkim@gnu.ac.kr

1989년 중앙대학교 전자계산학과(학사)

1994년 중앙대학교 전자계산학과(석사)

1998년 중앙대학교 컴퓨터공학과(박사)

1998년 ~ 1999년 KRIC 선임연구원

1999년 ~ 2000년 KERIS 책임연구원, 연구위원

2000년 ~ 2010년 경상대학교 컴퓨터교육과 부교수

2011년 ~ 현재 경상대학교 컴퓨터과학과 교수

2013년 ~ 2014년 미국 University of Notre Dame 방문학자

2014년 ~ 현재 경상대학교 공학연구원(ERI) 자동화·컴퓨터
연구센터 책임연구원

관심분야: 딥러닝, 생체인식, 패턴인식, 영상처리