

# 순환 합성곱 신경망을 이용한 다채널 뇌파 분석의 간질 발작 탐지

## Epileptic Seizure Detection for Multi-channel EEG with Recurrent Convolutional Neural Networks

유 지 현\*

Ji-Hyun Yoo\*

### Abstract

In this paper, we propose recurrent CNN(Convolutional Neural Networks) for detecting seizures among patients using EEG signals. In the proposed method, data were mapped by image to preserve the spectral characteristics of the EEG signal and the position of the electrode. After the spectral preprocessing, we input it into CNN and extracted the spatial and temporal features without wavelet transform.

Results from the Children's Hospital of Boston Massachusetts Institute of Technology (CHB-MIT) dataset showed a sensitivity of 90% and a false positive rate (FPR) of 0.85 per hour.

### 요 약

본 논문에서는 뇌파 신호를 이용하여 환자의 경련을 감지하는 순환 CNN (Convolutional Neural Networks)을 제안한다. 제안된 방법은 뇌파 신호의 스펙트럼 특성과 전극의 위치를 보존하기 위해 영상으로 데이터를 매핑하여 처리하였다. 스펙트럼 전처리 과정을 거친 후 CNN에 입력하고 공간 및 시간 특성을 웨이블릿 변환(wavelet transform)없이 추출하여 발작을 검출하였다. 여기에 사용된 보스턴 매사추세츠 공과 대학 (Boston Massachusetts Institute of Technology, CHB-MIT) 아동병원의 데이터셋 결과는 시간당 0.85의 민감도와 90 %의 위양성 비율 (FPR)을 보였다.

*Key words : recurrent CNN, deep learning, epileptic seizure detection, EEG, load balancin and simulation*

### 1. 서론

전 세계인구의 1%가 앓고 있을 정도로 비교적 흔한 질병이다[1]. 뇌전증 발작은 예측이 불가능하고 장소와 시간에 상관없이 발생하기 때문에 환자

들은 항상 신체손상의 위험에 노출되어 있으며, 독립된 일상생활이 제한되어 개인의 삶의 질이 심각하게 저하 시킨다. 이러한 이유로 신경과 전문가들은 뇌파를 통해 뇌의 활동을 모니터링 하는 것으로 환자의 발작을 진단한다.

\* Dept. of Internet Communications, Jangan University

Corresponding author

E-mail : [jihyun\\_yoo@jangan.ac.kr](mailto:jihyun_yoo@jangan.ac.kr)

※ Acknowledgment

This work was supported by Jangan University Research Grant in 2018.

Manuscript received Dec. 11, 2018; revised Dec. 18, 2018; accepted Dec. 19, 2018

This is an Open-Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (<http://creativecommons.org/licenses/by-nc/3.0>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

그러나 신경과 전문가들이 환자별로 매일 뇌파를 분석하는 일은 극심한 노동이다. 이러한 문제를 해결 하기 위해 자동으로 발작을 탐지하기 위한 방법이 광범위하게 연구되어 왔다.

일부 연구들은 뇌파로부터 수작업으로 특징들을 추출하여 발작을 검출하였다[2-4]. 그렇기 때문에 뇌파에서 수작업으로 특징들을 추출하여 발작을 검출하는 모델은 서로 다른 환자 사이에서 정확하게 발작을 검출하기 어렵다.

최근의 다양한 분야에서 딥러닝 모델들은 수작업으로 추출된 특징을 사용하는 모델보다 좋은 성능을 보인다. 이에 따라 뇌전증 환자의 발작을 검출하는 최근의 많은 연구들은 CNN과 RNN을 이용하여 EEG 뇌파 신호 분류에 적용한다[5-10].

본 논문에서는 시간적인 정보를 포함하는 filter를 사용하는 3D-CNN과 RNN을 결합하여 공간적, 시간적인 특성을 동시에 보존하며, 환자 사이에서 정확하게 발작을 검출하는 모델을 제안한다.

## II. 본론

### 1. 관련 연구

#### 가. Deep Neural Network(DNN)

DNN은 입력층(input layer)과 출력층(output layer) 사이에 여러 개의 은닉층(hidden layer)들로 이뤄진 인공신경망(Artificial Neural Network, ANN)이다. 심층 신경망은 일반적인 인공신경망과 마찬가지로 복잡한 비선형 관계(non-linear relationship)들을 모델링할 수 있다. 예를 들어, 물체 식별 모델을 위한 심층 신경망 구조에서는 각 물체가 영상의 기본적 요소들의 계층적 구성으로 표현될 수 있다. 이때, 추가 계층들은 점진적으로 모여진 하위 계층들의 특징들을 규합시킬 수 있다. 심층 신경망의 이러한 특징은, 비슷하게 수행된 인공신경망에 비해 더 적은 수의 유닛(unit, node)들 만으로도 복잡한 데이터를 모델링할 수 있게 해준다.

#### 나. Recurrent Neural Network (RNN)

RNN에 대한 기본적인 아이디어는 순차적인 정보를 처리한다는 데 있다. 기존의 신경망 구조에서는 모든 입력과 출력이 각각 독립적이라고 가정했지만, 많은 경우에 이는 옳지 않은 방법이다. 한 예로, 문장에서 다음에 나올 단어를 추측하고 싶다면

이전에 나온 단어들을 아는 것이 큰 도움이 될 것이다. RNN이 recurrent 하다고 불리는 이유는 동일한 태스크를 한 시퀀스의 모든 요소마다 적용하고, 출력 결과는 이전의 계산 결과에 영향을 받기 때문이다. 다른 방식으로 생각해 보자면, RNN은 현재지 계산된 결과에 대한 “메모리” 정보를 갖고 있다고 볼 수도 있다. 이론적으로 RNN은 임의의 길이의 시퀀스 정보를 처리할 수 있지만, 실제로는 비교적 짧은 시퀀스만 효과적으로 처리할 수 있다.

RNN은 많은 자연어처리 문제에서 성공적으로 적용되었다. 현재 전세계에서 RNN의 여러 종류 중 가장 많이 사용되는 것은 LSTM으로, 위에서 살펴본 기본 RNN 구조에 비해 더 긴 시퀀스를 효과적으로 잘 기억하기 때문이다.

#### 다. Convolution Neural Network (CNN)

CNN은 최소한의 전처리(preprocess)를 사용하도록 설계된 다계층 퍼셉트론(multilayer perceptrons)의 한 종류이다. CNN은 하나 또는 여러개의 합성곱 계층과 그 위에 올려진 일반적인 인공 신경망 계층들로 이루어져 있으며, 가중치와 통합 계층(pooling layer)들을 추가로 활용한다. 이러한 구조 덕분에 CNN은 2차원 구조의 입력 데이터를 충분히 활용할 수 있다. 다른 딥 러닝 구조들과 비교해서, CNN은 영상, 음성 분야 모두에서 좋은 성능을 보여준다. CNN은 또한 표준 역전달을 통해 훈련될 수 있다. CNN은 다른 피드포워드 인공신경망 기법들보다 쉽게 훈련되는 편이고 적은 수의 매개변수를 사용한다는 이점이 있다. 최근 딥 러닝에서는 합성곱 심층 신뢰 신경망(Convolutional Deep Belief Network, CDBN)가 개발되었는데, 기존 CNN과 구조적으로 매우 비슷해서, 그림의 2차원 구조를 잘 이용할 수 있으며 그와 동시에 심층 신뢰 신경망(Deep Belief Network, DBN)에서의 선훈련에 의한 장점도 취할 수 있다. CDBN은 다양한 영상과 신호 처리 기법에 사용될 수 있는 일반적인 구조를 제공하며 CIFAR와 같은 표준 이미지 데이터에 대한 여러 벤치마크 결과에 사용되고 있다.

### 2. Data sets

제안한 모델은 CHB-MIT Scalp EEG Database를 사용하여 발작 검출 성능을 테스트를 진행하였다.

이 데이터셋은 5명의 남자, 17명의 여자를 포함

하여 22명의 환자의 구성되어 있고, 환자별로 사용한 전극의 수가 다르다. 뇌파신호는 256Hz로 샘플링 하여 양극성 방식으로 뇌파 신호가 기록 되었다. 모든 환자에 대해서 사용한 전극이 다소 차이가 있기 때문에, 공통적으로 사용된 18개의 전극을 같은 순서로 재배열하여 사용했다.

### 3. The Proposed Method

#### 가. Pre-processing

본 논문에서 제안한 모델은 기록된 뇌파의 30초의 윈도우를 입력 데이터로 사용한다. 제안한 모델의 입력 데이터를 만들기 위해 3가지의 전처리 과정을 거친다.

첫째는 기록된 뇌파신호를 중첩없이 30초 단위로 분해하여 라벨링을 한다.

둘째는 STFT(Short-Time Fourier Transform) 알고리즘을 이용해 초 단위로 뇌파신호에서 주파수 특성을 추출했다. 발작은 일반적으로 30 Hz 이내에서 확인할 수 있기 때문에, 0Hz에서 30 Hz의 대역폭을 사용하였다.

셋째는 우리는 전극의 공간적인 위치를 유지하기 위해 2D grid approximation of the montage[6] 방식을 사용하여 2D image로 Mapping 했다.

2D image로 맵핑하는 것은 전극의 공간적인 위치를 유지하여 전극 간의 spatial correlation을 보존할 수 있는 수단으로 그림 1은 앞에서 제시된 전처리 과정을 보여준다. 맵핑된 2D image에서 전극 사이의 빈 공간은 0으로 채웠다. 제안한 모델의 입력 크기는 CHB-MIT 데이터셋의 경우 30 x 4 x 5 x 30(Time

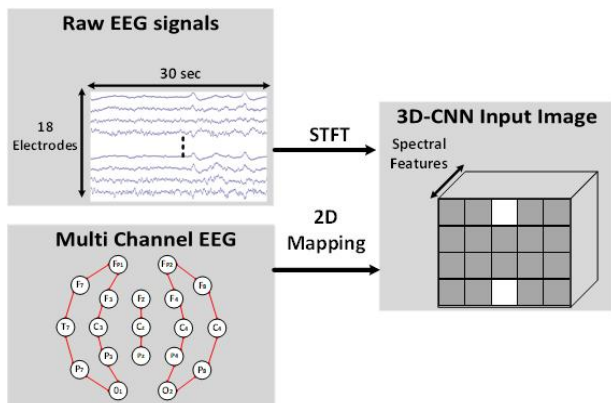


Fig. 1. Pre-processing process using EEG signals of CHB-MIT dataset.

그림 1. CHB-MIT 데이터셋의 EGG 시그널을 사용한 전처리 과정

samples Row x Column x Depth)을 사용했다.

#### 나. 제안 모델의 구조

본 논문에서는 환자 간의 극도로 다양한 EEG signal에서 발작을 검출하는 recurrent CNN의 구조를 제안한다. recurrent CNN은 비디오 분석에서는 2D filters를 사용하는 2D-CNN 달리 공간적 특성뿐만 아니라 시간적 특성까지 유지하기 때문에 여러 2D-CNN 구조보다 좋은 성능을 보여주고 있다[11].

제안하는 recurrent CNN은 그림 2. 에서와 같이 전처리 과정에서 2D image로 mapping된 30 x 4 x 5 x 30 크기의 데이터를 입력 받아 1 x 2 x 1 x 30(Time samples Row x Column x Depth), 1 x 3 x 1 x 30, 1 x 4 x 1 x 30의 multi-scale의 filters 사용해 각기 다른 전극 간의 spatial-correlation을 추출했다. 각기 다른 conv filter에서 얻은 구조 맵은 Bidirectional GRU(Bidirectional Gated Recurrent Unit)의 입력 값으로 사용했다.

GRU는 RNN기반의 셀의 한 종류로써, LSTM(Long-Short Term Memory)에 비해 계산 복잡성이 낮아 연산속도가 빠른 장점을 가진다. Bidirectional GRU는 양방향으로 연산한 결과를 결합하여 단일

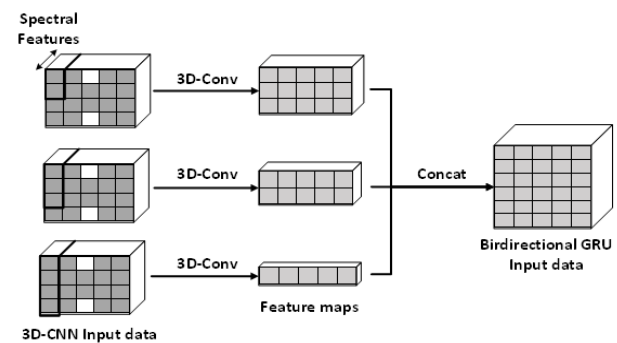


Fig. 2. Proposed CNN Architecture.

그림 2. 제안한 CNN 구조




Fig. 3. Proposed Classification Process.

그림 3. 제안한 분류 프로세스

방향에서 잃었던 정보를 일부 보존하는 기능을 가지며, 그림 3에서와 같이 convnet에 의해 추출된 30초 동안의 전극 간의 spatial-correlation 특징을 사용해 양방향의 시간적 변화를 고려한 특징을 추출한다.

#### 다. 실험 디자인

본 논문에서 제안한 모델을 학습 시 전체 환자에서 한 명의 환자를 제외한 데이터를 사용하고, 제외한 환자에 대해서 테스트를 진행했다.

이 과정을 전체 환자의 수만큼 반복하여 진행했다. 이를 통해 학습에서 제외된 환자의 발작 검출 성능을 확인할 수 있는 이점을 가진다. 우리는 제안한 모델을 최적화시키기 위해 다음과 같은

hyper-parameter 값을 사용했다.

Batch size = 128

Optimizer = Adam

Learning rate = 0.001

Dropout = 0.3

Recurrent dropout = 0.3

### III. 결론

제안한 모델은 CHB-MIT Scalp EEG Database를 이용해 학습하고 테스트했다. 이 데이터셋에서는 평균 sensitivity는 91%, 시간당 false positive rate은 0.85의 성능을 보였다. CHB EEG dataset의 환자 별 성능은 표 1에 제시했다.

제안한 모델은 cross-patient detector 방식의 테스트 방법을 이용하여 성능을 비교했다. 표 2에 결과를 나타내었다.

Table 1. Result for CHB-MIT Scalp EEG dataset.

표 1. CHB-MIT Scalp EEG 데이터셋 결과

Patients	Sensitivity(%)	FPR(per hour)
1	100	1.262
2	100	1.167
3	100	0.225
4	100	0.529
5	100	1.375
6	80	3.162
7	100	1.088
8	100	0.714

Patients	Sensitivity(%)	FPR(per hour)
9	100	2.442
10	100	0.058
11	100	0.4
12	70	0.269
13	75	0.939
14	25	0.074
15	90	0.205
16	50	2.526
17	100	2.364
18	100	0.189
19	100	0.065
20	100	0.172
21	100	0.091
22	100	0.094
23	100	0.286
24	0.94	0.667

Table 2. Performance of seizure detection method.

표 2. 발작 검출 성능

Seizure Detection Algorithms	Sensitivity (%)	FPR (per hour)
Thodoroff et al. [9]	85	0.8
Proposed Method	90	0.85

### References

- [1] D. Kim, S. Lee, S. Chung, H. Cheon, K. Jung, "Clinical characteristics of patients with treated epilepsy in Korea: a nationwide epidemiologic study," *Epilepsia, the Korean Epilepsy Society*, pp.67-75, 2014. DOI:10.1111/epi.12469
- [2] R. Meier, H. Dittrich, A. Schulze-Bonhage, and A. Aertsen, "Detecting epileptic seizures in long-term human EEG: a new approach to automatic online and real-time detection and classification of polymorphic seizure patterns," *Journal of Clinical Neurophysiology*, vol.25, no.3, 2008. DOI:10.1097/WNP.0b013e3181775993.
- [3] A. Chan, F. Sun, E. Boto, and B. Wingeier, "Automated seizure onset detection for accurate onset time determination in intracranial EEG,"

*Clinical Neurophysiology*, vol.119, no.12, 2008.

DOI:10.1016/j.clinph.2008.08.025

[4] A. Aarabi, R. Fazel-Rezai, and Y. Aghakhani, "A fuzzy rule-based system for epileptic seizure detection in intracranial EEG," *Clinical Neurophysiology*, vol.120, no.9, 2009. DOI:10.1016/j.clinph.2009.07.002

[5] 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*, 2017.

DOI:10.1016/j.combiomed.2017.09.017

[6] L. Vidyaratne, A. Glandon, M. Alam, and K. M. Iftekharuddin, "Deep recurrent neural network for seizure detection. In Neural Networks," *International Joint Conference, IEEE*, pp.1202-1207, 2016. DOI:10.1109/IJCNN.2016.7727334

[7] M. Golmohammadi, S. Ziyabari, V. Shah, E. Von Weltin, C. Campbell, I. Obeid, and J. Picone, "Gated recurrent networks for seizure detection," *In Signal Processing in Medicine and Biology Symposium (SPMB), IEEE*, pp.1-5, 2017.

DOI:10.1109/SPMB.2017.8257020

[8] P. Bashivan, I. Rish, M. Yeasi, and N. Codella, "Learning Representations from EEG with Deep Recurrent Convolutional Neural Networks," 2016.

[9] P. Thodoroff, J. Pineau, A. Lim, "Learning robust features using deep learning for automatic seizure detection," *In Machine Learning for Healthcare Conference*, pp.178-190, 2016.

[10] R. K. Maddula, J Stivers, M Mousavi, S Ravindran, and V. R.de Sa, "Deep recurrent convolutional neural networks for classifying P300 BCI signals," *In Proceedings of the Graz BCI Conference*, 2017.

[11] D. Tran., L. Bourdev., R. Fergus, L Torresani., and M Paluri, "Learning spatiotemporal features with 3d convolutional networks," *In Computer Vision (ICCV), 2015 IEEE International Conference on*, pp.4489-4497, 2015.

## BIOGRAPHY

### Ji-Hyun Yoo (Member)



1995 : BS degree in Computer Science and Engineering, Hanyang University.

2000 : MS degree in Computer Science and Engineering, Hanyang University.

2012 : PhD degree in IT Service Management, Soongsil University.

2014 ~ : Professor in the Department of Internet Communication, Jangan University