

# Epileptic Seizure Prediction from Spectral, Temporal, and Spatial Features of EEG Signals Using Deep Learning Algorithms

Nazanin Mohammadkhani Ghasvand, Foad Ghaderi\*

Human-Computer Interaction Lab, Faculty of Electrical and Computer Engineering, Tarbiat Modares University, Tehran, Iran

## Article Info:

Received: 17 July 2020

Revised: 10 Nov 2020

Accepted: 14 Dec 2020

## ABSTRACT

**Introduction:** Epilepsy is one of the most common brain disorders that greatly affect patients' life. However, early detection of seizure attacks can significantly improve their quality of life. In this study, we evaluated a deep neural network to learn robust features from electroencephalography (EEG) signals to automatically detect and predict seizure attacks.

**Materials and Methods:** The architecture consists of convolutional neural networks and long short-term memory networks. It is designed to simultaneously capture spectral, temporal, and spatial information. Moreover, the architecture does not rely on explicit channel selection algorithms. The method is applied to the Children's Hospital of Boston-Massachusetts Institute of Technology dataset (CHB-MIT). To evaluate the method, the proposed model is trained in the patient-specific approach. **Results:** The proposed architecture achieves a sensitivity of  $90.7 \pm 7.9$  percent, a false prediction rate of 0.12/h, and a mean prediction time of 36.8 minutes. Moreover, in the cases of focal seizures, the proposed model estimates the seizure focus. **Conclusion:** The proposed model achieved a high capability in seizure prediction. Moreover, by using the automated feature selection of the deep learning algorithm, the patterns of the pre-ictal period in EEG signals were determined. Furthermore, by specifying the seizure focus, the model can help neurologists to take further curative actions.

## Keywords:

1. Patients
2. Deep Learning
3. Electroencephalography

\*Corresponding Author: Foad Ghaderi

E-mail: fghaderi@modares.ac.ir

## پیش‌بینی تشنج صرعی از روی ویژگی‌های طیفی، زمانی و مکانی سیگنال‌های نوار مغزی با استفاده از الگوریتم‌های یادگیری عمیق

نازنین محمدخانی غیاثوند، فؤاد قادری\*

آزمایشگاه تعامل انسان و کامپیوتر، دانشکده مهندسی برق و کامپیوتر، دانشگاه تربیت مدرس، تهران، ایران

## اطلاعات مقاله:

پذیرش: ۲۴ آذر ۱۳۹۹

اصلاحیه: ۲۰ آبان ۱۳۹۹

دریافت: ۲۷ تیر ۱۳۹۹

## چکیده

**مقدمه:** صرع یکی از شایع‌ترین اختلالات دستگاه عصبی است که به میزان زیادی زندگی بیماران را تحت تاثیر قرار می‌دهد. تشخیص زودهنگام حملات صرعی، تأثیر زیادی بر کیفیت زندگی بیماران خواهد گذاشت. در این پژوهش، یک معماری با ساختار شبکه عصبی عمیق برای یادگیری ویژگی‌های ارزشمند از سیگنال‌های نوار مغزی (EEG) به منظور تشخیص و همچنین پیش‌بینی تشنج‌های صرعی ارائه شده است.

**مواد و روش‌ها:** معماری ارائه‌شده متشکل از شبکه‌های عصبی پیچشی و حافظه طولانی کوتاه-مدت است و به نحوی طراحی شده است که داده‌های مکانی، زمانی و طیفی سیگنال‌های EEG را به کار ببندد. علاوه بر این، شبکه طراحی‌شده بر روش‌های انتخاب صریح الکترودها تکیه ندارد. مدل ارائه شده روی مجموعه داده بیمارستان کودکان بوستون-مؤسسه فناوری ماساچوست (CHB-MIT) بکار بسته شده است. به منظور ارزیابی مدل، از رویکرد ارزیابی مختص بیمار (Patient-Specific) استفاده شده است. **یافته‌ها:** حساسیت معماری در پیش‌بینی تشنج برابر با  $90/7 \pm 7/9$ ، نرخ پیش‌بینی اشتباه تشنج برابر با  $0/12$  در ساعت و میانگین مدت زمان پیش‌بینی تشنج تا وقوع تشنج برابر با  $36/8$  دقیقه به دست آمد. همچنین مدل ارائه‌شده ناحیه کانون تشنج (در تشنج‌های کانونی) را نیز تخمین می‌زند. **نتیجه‌گیری:** مدل ارائه شده به توانایی بالایی در پیش‌بینی تشنج دست یافت. همچنین با استفاده از قابلیت استخراج خودکار ویژگی‌ها در یادگیری عمیق، الگوی سیگنال‌ها در بازه پیش از تشنج با دقت مناسبی تعیین شدند. به علاوه، مدل بوسیله تخمین ناحیه کانون تشنج، می‌تواند متخصصان اعصاب را در اقدامات درمانی مرتبط یاری نماید.

## واژه‌های کلیدی:

- بیماران
- یادگیری عمیق
- نوار مغز

\*نویسنده مسئول: فؤاد قادری

پست الکترونیک: fghaderi@modares.ac.ir

## مقدمه

صرعی است، بنابراین پیش‌بینی تشنج چالش بیشتری نسبت به تشخیص تشنج دارد. یکی از چالش‌های دیگر پیش‌بینی تشنج، کمبود داده‌های با بر چسب گذاری مناسب است، چرا که اکثر مجموعه داده‌های حوزه تشنج، سیگنال‌ها را در دو کلاس تشنج و نرمال کلاس‌بندی کرده‌اند، حال آن که به‌منظور پیش‌بینی تشنج، به کلاس سوم با عنوان پیش از تشنج نیز نیاز می‌باشد. این در حالی است که متخصصان هنوز برای تعریف و تعیین الگوی این بازه در سیگنال‌های EEG به اجماع نرسیده‌اند (۴). از چالش‌های دیگر این حوزه، می‌توان به جانمایی الکترودهای EEG روی پوست سر اشاره کرد. الکترودهای مذکور بر روی سر که سطحی سه‌بعدی می‌باشد، قرار می‌گیرند. حفظ و بهره‌گیری از موقعیت مکانی الکترودها، امکان تشخیص نوع تشنج و همچنین تعیین کانون تشنج در تشنج‌های کانونی را فراهم می‌کند. اما سه‌بعدی بودن مختصات مذکور، باعث افزایش شدید بار پردازشی شبکه عصبی می‌گردد. در اکثر پژوهش‌های پیشین، برای جلوگیری از افزایش بار پردازشی، موقعیت مکانی الکترودها به کلی نادیده گرفته شده و تنها به اطلاعات طیفی و زمانی سیگنال‌های EEG بسنده شده است (۱۹-۱۶).

حال آن که در، به‌منظور تشخیص خودکار تشنج، مختصات نقاط مذکور به وسیله نگاشت هم‌فاصله آزیموتی (Azimuthal equidistant projection) به نحوی در صفحه دوبعدی نگاشت شده است که فاصله میان نقاط حفظ گردد (۲۰). نتایج حاصله نشان می‌دهد که روش اخیر علاوه بر امکان تعیین کانون تشنج، نسبت به پژوهش‌های دیگر واجد حساسیت بالاتری در تشخیص تشنج می‌باشد. در این پژوهش، به‌منظور تشخیص و همچنین پیش‌بینی تشنج صرعی از یک معماری متشکل از شبکه‌های عصبی پیچشی<sup>۲</sup> (CNN) و حافظه طولانی کوتاه-مدت<sup>۳</sup> (LSTM) استفاده شده که توانایی استفاده هم‌زمان از اطلاعات طیفی، زمانی و مکانی را دارا می‌باشد. معماری ارائه شده روی مجموعه داده بیمارستان کودکان موسسه فناوری بوستون -ماساچوست<sup>۴</sup> (CHB-MIT) اعمال شده است. نتایج حاصله از ارزیابی معماری با رویکرد مختص بیمار (Patient-Specific) نشان می‌دهد که مدل ارائه شده از نظر حساسیت و میزان مثبت کاذب در پیش‌بینی تشنج از مدل‌های پیشین بهتر عمل کرده است. همچنین به دلیل حفظ اطلاعات مکانی الکترودها، در صورت وقوع تشنج کانونی، معماری ارائه‌شده کانون تشنج را تخمین می‌زند.

## مواد و روش‌ها

## معماری

در این پژوهش، جهت نیل به دو هدف تشخیص و

بیماری صرع (Epilepsy) عبارت است از مجموعه‌ای از اختلالات مزمن سیستم عصبی مرکزی که در آن فعالیت مغز مختل شده و موجب بروز تشنج (Seizure) در بیمار می‌گردد. امروزه در سراسر دنیا هفتاد میلیون نفر از این بیماری رنج می‌برند که این تعداد تقریباً ۱ درصد از مردم جهان را شامل می‌شود (۱). مبتلایان به این بیماری علاوه بر عواقب جسمی دچار عواقب روانی ناخوشایندی نیز می‌شوند که عموماً منجر به کناره‌گیری اجتماعی آن‌ها می‌گردد. تاکنون برای کاهش شدت و بسامد حملات، درمان‌های مختلفی از جمله مصرف دارو و عمل جراحی مورد استفاده قرار گرفته است. اما اثر بخشی درمان‌های مذکور، به تشخیص صحیح نوع تشنج بیمار وابسته است. تشنج‌ها به دو دسته عمومی (کلی) و کانونی (جزئی) تقسیم‌بندی می‌شوند. تشنج عمومی، تمام قسمت‌های مغز را درگیر می‌کند، در حالی که تشنج کانونی، ابتدا در یک ناحیه از مغز شروع می‌شود و ممکن است به قسمت‌های دیگر انتشار یابد (۲).

در صورت شناسایی صحیح کانون تشنج در مغز بیمار، می‌توان شدت بیماری را با عمل جراحی کاهش داد (۳). با در نظر داشتن تأثیری که حملات پی‌پی تشنجی بر زندگی روزمره بیماران دارد، پیش‌بینی تشنج امکان اجرای اقدامات مراقبتی پیش از تشنج را فراهم ساخته و کیفیت زندگی بیماران را به میزان قابل توجهی افزایش می‌دهد. از سوی دیگر، توسعه سیستم‌های تشخیص خودکار تشنج، منجر به تسریع در آگاهی از وضعیت بیماران و رسیدگی به آن‌ها می‌شود. نظارت بر فعالیت مغز از طریق تحلیل سیگنال‌های نوار مغز<sup>۱</sup> (EEG) یکی از رویکردهای متعارف تشخیص تشنج صرعی می‌باشد. در این رویکرد، متخصصان سیگنال‌های EEG را برای شناسایی الگویی که نمایانگر تشنج است تحلیل می‌کنند. این فرایند سخت و زمان‌بر است و به تجربه بالایی نیاز دارد. به‌منظور رفع محدودیت‌ها و موانع مذکور، تاکنون پژوهش‌های متعددی با انتخاب دستی ویژگی‌ها سعی بر تشخیص خودکار تشنج از سیگنال‌های EEG داشته‌اند (۱۲-۴). مدل‌های ارائه شده در اکثر پژوهش‌های مذکور بر اطلاعات طیفی سیگنال‌ها تکیه دارند، حال آن که در برخی از پژوهش‌ها از وابستگی زمانی سیگنال‌های مذکور نیز استفاده شده است (۱۴-۱۳). نتایج پژوهش‌ها نشان می‌دهد که پدیده صرع پدیده‌ای بسیار متغیر است و علاوه بر این که سیگنال‌های نمایانگر تشنج‌های صرعی در میان بیماران مختلف الگوی متفاوتی دارند، تشنج‌های یک بیمار واحد نیز دارای الگوهای غیر یکسان و متفاوتی می‌باشند (۱۵). به علاوه تفاوت الگوها در بازه پیش از شروع حمله، بیشتر از تفاوت الگوها هنگام حمله

<sup>1</sup> Electroencephalography; EEG

<sup>2</sup> Convolutional Neural Network

<sup>3</sup> Long Short Term Memory

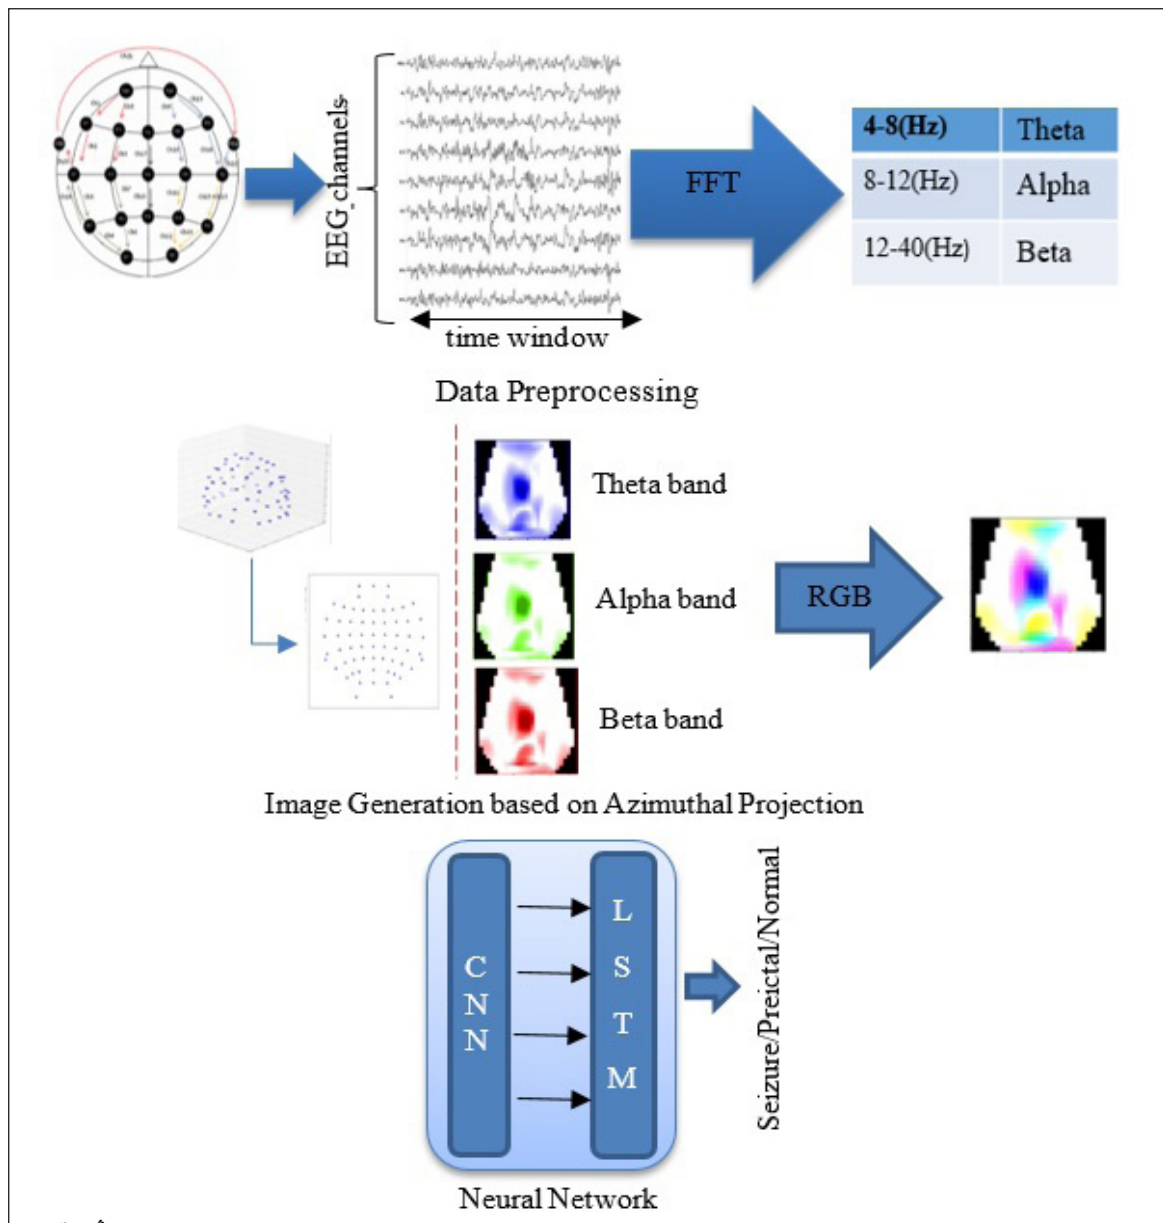
<sup>4</sup> Childrens Hospital Boston Institute of Technology

پیش پردازش

در معماری ارائه شده، به منظور پیش پردازش داده‌ها از تبدیل فوریه استفاده شده است. ابتدا از هر قطعه سیگنال که شامل n کانال است بازه محدودی را با استفاده از پنجره زمانی جدا کرده (پنجره زمانی به میزان ۵۰ درصد همپوشانی دارد) و تبدیل فوریه داده موجود در هر کانال را در این بازه محاسبه می‌کنیم.

طول هر پنجره برابر s ثانیه بوده که با توجه به فرکانس نمونه برداری شامل m نمونه در هر کانال است. سپس انرژی سیگنال در بازه پنجره‌های s ثانیه‌ای مذکور، با استفاده از روابط پارسوال محاسبه می‌گردد. بدین صورت که خروجی رابطه عددی مختلط می‌گردد

پیش‌بینی وقوع تشنج صرعی، یک معماری یادگیری عمیق با ساختاری مبتنی بر تصویرسازی و شبکه‌های عصبی مورد استفاده قرار گرفته است. این معماری از اطلاعات مکانی، زمانی و فرکانسی سیگنال‌های EEG بهره می‌گیرد و علاوه بر دقت مناسب در تشخیص و پیش‌بینی تشنج، توانایی تعیین موضع تشنج در مغز را نیز دارا می‌باشد. همچنین در این معماری با وزندهی به کلاس‌های تشنج، پیش از تشنج و نرمال، مشکل عدم توازن داده‌ها رفع شده است. معماری ارائه شده را می‌توان در قالب سه گام کلی پیش‌پردازش داده‌ها، تصویرسازی از سیگنال‌های EEG و در نهایت تحلیل تصاویر در شبکه‌های عصبی تقسیم‌بندی نمود. جزئیات هر بخش به تفصیل در ادامه توضیح داده شده است.



تصویر ۱- شمای کلی معماری ارائه شده

منبع

می‌شود. به‌منظور حفظ اندازه‌ها، فاصله هر نقطه از نقطه رأس در تصویر دو بعدی حاصله، برابر با فاصله کمائی مابین آن دو نقطه در سطح سه‌بعدی در نظر گرفته می‌شود (۲۱). شایان ذکر است که اگرچه در نگاشت هم‌فاصله آزیموتی فاصله مابین تمام نقاط از رأس به شکل دقیق حفظ می‌شود، اما فاصله مابین دو نقطه دلخواه (غیر رأس) در صورت کمتر بودن فاصله واقعی آن دو نقطه از سه هشتم محیط سطح سه‌بعدی مذکور با خطای جزئی و در صورت بیشتر بودن فاصله آن‌ها از سه هشتم محیط سطح سه‌بعدی مذکور با خطای قابل توجهی همراه است (۲۱). اما با توجه به اینکه الکترودها عموماً تنها در سطحی کمتر از نیمی از سطح سر جاگذاری می‌شوند، لذا خطای مذکور عموماً جزئی و قابل نظر نمی‌باشد. با نگاشت موقعیت مکانی الکترودها با نگاشت هم‌فاصله آزیموتی، تصویری دوبعدی به‌عنوان تصویر مینا حاصل می‌شود که موقعیت جدید الکترودها، با نقاطی در آن مشخص شده است. سپس با استفاده از داده‌های تانسور ویژگی ساخته شده،  $m$  تصویر رنگی  $RGB^6$  از تصویر مینا ساخته می‌شود. بدین صورت که در تصویر رنگی متناظر با هر بازه زمانی، نقطه نمایانگر مکان الکترودها در تصویر مینا رنگی متناسب با میزان انرژی آلفا، بتا و تتا در آن بازه زمانی دارد. سپس با استفاده از تکنیک درون‌یابی، برای هر تصویر رنگی، رنگ باقی‌مانده نقاط سطح سر، که معادل سطوح انرژی آلفا، بتا و تتا در هر نقطه از سر می‌باشد، محاسبه می‌شود. سپس تصاویر مذکور توسط شبکه عصبی مورد تحلیل قرار می‌گیرد.

### شبکه‌های عصبی پیچشی


در پژوهش‌های مختلفی که برای تحلیل سیگنال‌های EEG انجام شده‌اند شبکه‌های عصبی با معماری‌های متنوعی مورد استفاده قرار گرفته است. در توانایی این

که اندازه آن برابر با مقدار انرژی سیگنال می‌باشد. در پهنای باند فرکانسی مرتبط با تشنج، انرژی سیگنال در سه بازه تتا (۴ تا ۸ هرتز)، آلفا (۸ تا ۱۲ هرتز) و بتا (۱۲ تا ۴۰ هرتز) قرار دارد. همچنین از آنجایی که در حوزه صرع فرکانس‌های بالاتر از جمله بازه فرکانس برق شهری (۵۰ تا ۶۰ هرتز) مورد استفاده نیستند، نیازی به حذف فرکانس برق شهری از سیگنال‌ها نمی‌باشد.

### تصویرسازی با سیگنال‌های EEG

با استفاده از داده‌های حاصله از مرحله پیش‌پردازش، یک تانسور<sup>۵</sup> (بردار ویژگی) که شامل ویژگی‌ها است ایجاد می‌شود. ابعاد تانسور برابر با  $m \times n \times 3$  می‌باشد. بردار سه‌آرایه‌ای متناظر با هر کانال در هر بازه زمانی، متشکل از انرژی سیگنال در ناحیه فرکانسی تتا، آلفا و بتا، در کانال و بازه زمانی مذکور می‌باشد. علاوه بر تانسور مذکور، موقعیت مکانی الکترودهای قرار گرفته روی سر نیز برای افزایش حساسیت شبکه عصبی و همچنین جانمایی کانون تشنج در مغز مورد نیاز است.

برای کاهش پیچیدگی شبکه عصبی، نیاز است که موقعیت مکانی الکترودها روی یک صفحه تصویر شود. این پژوهش، به‌منظور حفظ موقعیت مکانی الکترودها در تصویر دوبعدی حاصله، از نگاشت هم‌فاصله آزیموتی استفاده شده است. با انتخاب هر نقطه دلخواه روی یک سطح سه‌بعدی بسته (هم‌چون سطح سیارات، سر) به‌عنوان نقطه رأس، پس از اعمال نگاشت هم‌فاصله آزیموتی بر سطح بسته مذکور نسبت به نقطه رأس، سطحی دو بعدی پدید می‌آید که در آن مسافت (نسبت مسافت) تمام نقاط نسبت به نقطه رأس به شکل دقیق حفظ می‌شود. بدین صورت که هر نصف‌النهار ما بین نقطه رأس و نقطه مقابل نقطه رأس (متقاطع) در سطح سه‌بعدی، پس از نگاشت به یک خط راست تبدیل



تصویر ۲- تفاوت نگاشت هم‌فاصله آزیموتی با تصویر قائم نسبت به افق: تصویر نگاشت شده از مجموعه‌ای از نقاط سه‌بعدی با استفاده از نگاشت هم‌فاصله آزیموتی ب: مکان واقعی نقاط در دستگاه سه‌بعدی (معرف مکان الکترودها روی سر) پ: تصویر قائم از نقاط مذکور نسبت به سطح افق (۲۲).

<sup>5</sup> Tensor

<sup>6</sup> Red, Green, Blue

## وزن‌دهی کلاس‌ها

در داده‌های مرتبط با تشنج، سیگنال‌های با برجستگی تشنج و پیش از تشنج بسیار کمتر از سیگنال‌های با وضعیت نرمال هستند. این عدم توازن داده‌ها از مواردی است که سبب انحراف مدل می‌گردد. به‌منظور رفع این مشکل، نسبت تعداد رخداد هر یک از کلاس‌ها به تعداد کل رخدادها با روابط ۱، ۲ و ۳ محاسبه شدند (۲۴).

بنابراین در تابع هزینه Adam با استفاده از تابع کاهش، عکس این نسبت به‌عنوان پینالتی در نظر گرفته شد و در داده‌ها تورش رخ نمی‌دهد، این در حالی است که بدون اعمال این تابع مشکل عدم توازن وجود داشت.

$$W(\text{seizure}) = \frac{\text{Num}(\text{seizure\_class})}{\text{Num}(\text{all-class})} \quad (1)$$

$$W(\text{preictal}) = \frac{\text{Num}(\text{preictal\_class})}{\text{Num}(\text{all-class})} \quad (2)$$

$$W(\text{normal}) = \frac{\text{Num}(\text{normal\_class})}{\text{Num}(\text{all-class})} \quad (3)$$

در روابط فوق،  $W(\text{seizure})$  وزن کلاس تشنج،  $W(\text{preictal})$  وزن کلاس پیش از تشنج،  $W(\text{normal})$  وزن کلاس نرمال،  $\text{Num}(\text{seizure\_class})$  تعداد رخداد تشنج،  $\text{Num}(\text{preictal\_class})$  تعداد رخداد تشنج،  $\text{Num}(\text{normal\_class})$  تعداد رخداد تشنج،  $\text{Num}(\text{all-class})$  تعداد کل رخدادها هستند.

## ارزیابی معماری پیشنهادی

در این پژوهش مجموعه داده بیمارستان کودکان بوستون مؤسسه فناوری ماساچوست CHB-MIT که رایج‌ترین مجموعه داده در حوزه تشنج صرعی است، برای آموزش و ارزیابی مدل انتخاب گردید. این مجموعه داده، حاوی سیگنال‌های EEG ثبت شده از ۲۱ بیمار بستری شده در بیمارستان کودکان بوستون است. بیماران مذکور همگی زیر ۲۲ سال سن دارند و جنسیت ۵ نفر از آنها مذکر و ۱۷ نفر مؤنث هستند. در مجموعه داده مذکور، برای هر بیمار بین ۲۴ تا ۷۰ ساعت سیگنال ضبط شده EEG وجود دارد. سیگنال‌های ضبط شده هر یک از بیماران این مجموعه داده به صورت پیوسته و غیرمنقطع بوده و هر یک از بیماران لااقل دارای ۵ تشنج ثبت شده هستند. داده‌های این مجموعه داده تنها دارای دو برجستگی تشنج و نرمال هستند. تعداد الکترودها برای ضبط سیگنال بین ۱۸ تا ۲۳ کانال می‌باشد (در بعضی از بیماران تعداد کانال‌ها کمتر بوده است). فرکانس نمونه‌برداری ۲۵۶ هرتز و وضوح بیتی ۱۶ بیت ضبط شده است. به‌منظور ارزیابی عملکرد معماری طراحی شده، از رویکرد اعتبارسنجی مختص بیمار (Patient-Specific) استفاده شده است. در این رویکرد که طی سال‌های اخیر در حوزه صرع مورد استفاده قرار گرفته است، سیگنال‌های EEG هر بیمار به طور مستقل از باقی

شبکه‌ها به‌طور خاص در استخراج و ارائه موقعیت مکانی برای تشخیص تشنج در مناطق مختلف مغز بررسی شده است (۲۳). در این پژوهش از ۲ لایه پیچشی تمام متصل به‌منظور استخراج ویژگی‌ها استفاده شده است که پس از هر لایه یک لایه تجمیع‌کننده با استفاده از مقدار بیشینه<sup>۷</sup> قرار دارد، توابع فعال‌ساز استفاده شده در همه لایه‌ها ReLU می‌باشد. فیلتر پیچشی برای همه لایه‌ها اندازه ۳\*۳ است.

## شبکه‌های عصبی بازگشتی

این شبکه‌ها دارای حلقه‌هایی هستند که اطلاعات ارزشمند را با گذشت زمان و توالی طولانی حفظ می‌کنند. به کمک این ویژگی می‌توان اطلاعات را طی مسیر طولانی با وابستگی‌های بلند مدت دریافت و نگهداری کرد. این امر به‌ویژه برای تجزیه و تحلیل سیگنال‌های EEG که در آن علائم تشنج به‌طور متوالی در گذر زمان رخ می‌دهد بسیار مفید است. پدیده صرع واجد ویژگی‌های پویای زمانی است، به عبارت دیگر، در هر بازه دارای ویژگی‌های سیگنالی مختص به خود است. بنابراین برای ارائه نتایج بهتر در پردازش این سیگنال‌ها از شبکه عصبی بازگشتی دوطرفه<sup>۸</sup> استفاده شده است که یک بار بازه زمانی از گذشته تا آینده را بررسی می‌کند و بار دیگر بازه زمانی را از آینده تا گذشته بررسی می‌کند. بدین صورت اطلاعات سیگنال‌ها در بازه‌های زمانی مختلف در حافظه ذخیره می‌گردد که به بهبود مدل کمک شایانی می‌کند. در واقع متخصصان نیز برای طبقه‌بندی یک پنجره زمانی به پنجره‌های گذشته و آینده سیگنال نگاه می‌کنند. معماری ارائه شده بازه s ثانیه‌ای را به‌عنوان ورودی دریافت می‌کند و تصویری با توانایی حفظ موقعیت مکانی و فرکانسی به شبکه ارائه می‌دهد.

## رویکرد پیش‌بینی تشنج

سیگنال‌های موجود در مجموعه داده CHB-MIT دارای دو برجستگی تشنج و حالت نرمال هستند. حال آنکه برای پیش‌بینی تشنج، سه برجستگی حالت نرمال، پیش از تشنج و تشنج مورد نیاز می‌باشد. بنابراین بخشی از بازه زمانی پیش از وقوع تشنج را با برجستگی پیش از تشنج برجستگی گذاری کردیم. سپس شبکه عصبی با مجموعه سیگنال‌های با برجستگی جدید، تحت آموزش قرار داده شد تا تفاوت سیگنال‌های پیش از تشنج، تشنج و نرمال را فرا بگیرد. لازم به ذکر است که پیش‌بینی تشنج با بررسی تنها یک قطعه سیگنال با بازه زمانی s ثانیه‌ای از دقت کافی برخوردار نیست. لذا به‌منظور پیش‌بینی تشنج ده قطعه سیگنال آخر بیمار مورد بررسی قرار گرفته و اگر ۸ عدد یا بیشتر از آن به‌عنوان بازه پیش از تشنج کلاس‌بندی شود، هشدار حمله صادر می‌شود.

<sup>7</sup> Max pooling

<sup>8</sup> Bidirectional recurrent neural network

اشتباه برابر با تعداد پیش‌بینی‌های تشنج اشتباه به ازای هر ساعت؛ و میانگین فاصله پیش‌بینی، برابر با میانگین مدت زمان مابین پیش‌بینی وقوع تشنج تا رخداد تشنج می‌باشد. همچنین با توجه به نحوه تصویرسازی از سیگنال‌های نوار مغز، در رخدادهای تشنج کانونی، کانون تشنج به صورت مصور تعیین گردید. تصویر ۳ تصویر حاصله از واحد تصویرسازی مدل در لحظه شروع تشنج یکی از بیماران را نمایش می‌دهد. از آنجایی که شدت رنگ هر ناحیه از تصویر، متناسب با میزان انرژی در آن ناحیه می‌باشد، ناحیه کانون تشنج ناحیه‌ای است که شدت رنگی بالاتری نسبت به باقی تشنج و هم در تشخیص تشنج ممکن می‌باشد. نمودار ۱، حساسیت روش پیشنهادی را با پژوهش‌های مشهور پیشین مقایسه کرده است. شایان ذکر است که روش‌های مذکور صرفاً به پیش‌بینی تشنج پرداخته‌اند و تلاشی بر تخمین کانون تشنج نداشته‌اند. در نمودار ۲، مقایسه نرخ پیش‌بینی اشتباه برای روش‌های مختلف ارائه شده است. همانگونه که مشاهده می‌شود

بیماران بررسی می‌گردد و نتایج حاصله صرفاً برای آن بیمار کاربرد دارد. با توجه به پیچیدگی الگوی تشنج و تفاوت این الگو میان بیماران مختلف، این رویکرد از دقت مناسبی برخوردار است. لذا در این رویکرد، داده‌های هر بیمار به صورت مستقل از سایر داده‌ها به دو بخش آموزش و آزمایش تقسیم‌بندی می‌شود.

### نکات عملی در پیاده‌سازی مدل

پیاده‌سازی معماری و الگوریتم‌های شبکه عصبی با زبان برنامه‌نویسی Python انجام شده است. از جمله کتابخانه‌های Python مورد استفاده می‌توان به Scikit-Learn, Keras, Tensorflow و Matplotlib اشاره کرد.

### یافته‌ها

نتایج حاصل از ارزیابی معماری ارائه شده با رویکرد مختص بیمار در جدول ۱ نمایش داده شده است. در جدول مذکور، حساسیت برابر با نرخ پیش‌بینی صحیح تشنج به تعداد تمام رخدادهای تشنج، نرخ پیش‌بینی


جدول ۱- نتایج حاصل از ارزیابی معماری با رویکرد مختص بیمار

بیماران	حساسیت (درصد)	نرخ پیش‌بینی اشتباه (بر ساعت)	میانگین فاصله پیش‌بینی (دقیقه)
بیمار ۱	۹۶	۰/۰۸	۲۵/۵
بیمار ۲	۹۵	۰/۰۶	۲۹/۰۵
بیمار ۳	۶۹	۰/۰۰	۲۲/۷۲
بیمار ۴	۹۴	۰/۰۶	۲۷/۹۸
بیمار ۵	۷۶	۰/۰۰	۱۲/۲۴
بیمار ۶	۸۵	۰/۱۰	۴۲/۰۵
بیمار ۷	۸۸	۰/۵۷	۴۵/۸
بیمار ۸	۹۷	۰/۰۶	۴۲/۸
بیمار ۹	۹۲	۰/۰۸	۵۵/۲۵
بیمار ۱۰	۹۵	۰/۰۹	۴۲/۲۷
بیمار ۱۷	۹۲	۰/۵	۲۲/۸۹
بیمار ۱۸	۹۴	۰/۱۲	۴۲/۲۲
بیمار ۱۹	۹۷	۰/۰۰	۴۷/۴۶
بیمار ۲۰	۹۵	۰/۰۰	۲۹/۴۴
بیمار ۲۱	۹۵	۰/۰۸	۴۲/۲۶
میانگین	$90.72 \pm 7.90$	۰/۱۲	۲۶/۸۲


شفاخته



تصویر ۳- دو تصویر حاصله از مدل در لحظه شروع تشنج. تصویر تکرنگ (راست) نقشه میزان انرژی پتا در سطح مغز را نمایش می‌دهد. تصویر رنگی (چپ) مجموع میزان انرژی آلفا، پتا و تتا در سطح مغز را نمایش می‌دهد. کانون تشنج در هر دو تصویر نمایان است. شایان ذکر است که کانون تشنج همواره در تصاویر تکرنگ که تنها یک بازه فرکانسی را نمایش می‌دهد، نمود پیدا نمی‌کند و تشخیص کانون تشنج می‌بایست بر اساس تصویر رنگی صورت پذیرد.



نمودار ۱- مقایسه میزان حساسیت روش پیشنهادی با روش‌های پیشین. خطای محاسبه‌شده از نوع خطای استاندارد می‌باشد. \*: خطای استاندارد گزارش نشده است.



نمودار ۲- مقایسه میزان نرخ پیش‌بینی اشتباه روش پیشنهادی با روش‌های پیشین. خطای محاسبه‌شده از نوع خطای استاندارد می‌باشد. \*: خطای استاندارد گزارش نشده است.

تشخیص زود هنگام تشنج، میزان حساسیت بالا و نرخ خطای پایین نیز از این مدل نتیجه می‌شود. این موضوع در جدول ۱ و نمودارهای ۱ و ۲ قابل مشاهده است. همچنین در روش ارائه شده با توجه به تصویرسازی دقیق که شامل چینش تمام نقاط بر روی مجموعه است

نرخ پیش‌بینی اشتباه در هر کدام از روش‌های پیشین بالاتر از روش پیشنهادی گزارش شده است.

### بحث و نتیجه‌گیری

مزیت اصلی مدل پیشنهادی این است که علاوه بر



توانایی تخمین ناحیه وقوع تشنج در مغز را فراهم کرده است که این مسئله گام مهمی در حوزه تشخیص و پیش‌بینی صرع می‌باشد. نکته قابل بررسی در بخش تولید تصویر، ارائه تصویری گویا از حرکات فرانسی سیگنال‌های EEG در کانال‌های مختلف مغز است، که این مهم به عصب شناسان حوزه صرع کمک می‌کند تا به راحتی عملکرد مغز را مورد بررسی بصری قرار دهند. شایان ذکر است که معماری ارائه شده کانال‌های خاصی را به‌منظور استخراج ویژگی انتخاب نکرده است و همه کانال‌ها به شبکه داده شده است. چرا که علائم تشنج ممکن است در هر یک از کانال‌ها نمود پیدا کند و مدل ارائه شده باید توانایی انتخاب کانال‌ها را داشته باشد. پیشنهادات نویسندگان برای پژوهش‌های آینده به شرح زیر می‌باشد:

۱- به‌منظور کشف بهتر الگوهای بازه تشنج و پیش از تشنج، استفاده از رویکرد ارزیابی اعتبارسنجی متقابل یک‌طرفه پیشنهاد می‌شود. چرا که رویکرد مذکور، نسبت به رویکرد مختص بیمار، واجد جامعیت بالاتری می‌باشد. اگرچه برای حصول جامعیت، به داده‌های بیشتری نیاز است.

۲- آموزش و ارزیابی مدل پیشنهادی با مجموعه داده‌های دیگر این حوزه به‌منظور گسترش مدل و افزایش جامعیت آن

امکان شناسایی کانون تشنج با استفاده از سیگنال‌های مغز فراهم می‌آید. در کنار دقت‌های نتیجه شده از روش پیشنهادی لازم است که این روش از ابعاد دیگر هم مورد بررسی قرار گیرد. در جدول ۲ روش‌های مختلف از نظر زمان و پیچیدگی مراحل پیش‌پردازش، استخراج ویژگی و آموزش طبقه‌بند مقایسه گردیده است. روش FFT + CNN + BiLSTM که شامل اعمال شبکه‌های BiLSTM و CNN بر داده پردازش شده توسط FFT است نسبت به سایر روش‌ها پیچیدگی محاسباتی کمتری در فاز پیش‌پردازش دارد. از سوی دیگر، هر سه روش به واسطه استفاده از شبکه‌های عصبی عمیق در مرحله آموزش با پیچیدگی محاسباتی زیادی مواجه هستند و در نتیجه دسترسی به سخت افزار مناسب و با توان پردازش بالا برای پیاده سازی این روش‌ها ضروری است.

معماری ارائه شده در پژوهش حاضر که مبتنی بر تصویرسازی با حفظ موقعیت مکانی سیگنال‌های مغزی و دیگر ویژگی‌های سیگنال EEG است، موفق به دستیابی به حساسیت بالا، کاهش نرخ مثبت کاذب و پیش‌بینی زود هنگام تشنج شده است و می‌تواند امکان تشخیص، پیش‌بینی، نظارت و برنامه‌ریزی درمانی برای بیماران مبتلا به صرع را فراهم کند. به‌علاوه تصویرسازی مبتنی بر حفظ موقعیت مکانی الکترودها،

جدول ۲- مقایسه روش پیشنهادی و مدل‌های دیگر از نظر زمان و پیچیدگی مراحل پیش‌پردازش و استخراج ویژگی

روش	پیش‌پردازش	استخراج ویژگی	پیچیدگی مرحله آموزش
ساختار FFT + CNN + BiLSTM	متوسط	سبک	زیاد
ساختار STFT + CNN + LSTM (۱۹)	زیاد	سبک	زیاد
ساختار CNN + تبدیل موجک (۱۱)	زمان بر	سبک	زیاد

## منابع

1. Thijs RD, Surges R, O'Brien TJ, Sander JW, "Epilepsy in adults. vol. 393, ed: The Lancet, 2019; p. 611-716.
2. Stafstrom CE, Carmant L. Seizures and epilepsy: An overview for neuroscientists." Cold Spring Harb Perspect Med, 2015.
3. Miller JW, Hakimian S. Surgical treatment of epilepsy. ed: CONTINUUM Lifelong Learning in Neurology, 2013.
4. Sharif B, Jafari AH. Prediction of epileptic seizures from EEG using analysis of ictal rules on Poincaré plane," Computer Methods and Programs in Biomedicine. 2017; 11-22.
5. Aarabi A and He B. Seizure prediction in patients with focal hippocampal epilepsy. Clinical Neurophysiology, 2017; 7: 1299-307.
6. Eftekhari A, Juffali W, El-Imad J, Constandinou TG, Toumazou C. Ngram-derived pattern recognition for the detection and prediction of epileptic seizures. PLoS ONE, 2014; 6.
7. Park Y, Luo L, Parhi KK, Netoff T. Seizure prediction with spectral power of EEG using cost-sensitive support vector machines. Epilepsia, 2011; 10: 1761-70.
8. Gadhomi K, Lina JM, Gotman J. Seizure prediction in patients with mesial temporal lobe epilepsy using EEG measures of state similarity. Clinical Neurophysiology, 2013; 9: 1745-754.
9. Rogowski Z, Gath I, Bental E. On the prediction of epileptic seizures. Biological Cybernetics, 1981; 1: 9-15
10. Mirowski P, Madhavan D, Lecun Y, Kuzniecky R.

Classification of patterns of EEG synchronization for seizure prediction. *Clinical Neurophysiology*, 2009; 11: 1927-940.

11. Beniczky S, Aurlien H, Brøgger JC, Fuglsang-Frederiksen A, Martins-Da-Silva A, Trinkka E et al. Standardized Computer-Based Organized Reporting of EEG: SCORE. *Epilepsia*, 2013; 6: 1112-24.

12. Winterhalder M, Schelter B, Maiwald T, Brandt A, Schad A, Schulze-Bonhage A et al. Spatio-temporal patient-individual assessment of synchronization changes for epileptic seizure prediction. *Clinical Neurophysiology*, 2006; 11: 2399-413.

13. Alexandros T, Markos G, Dimitrios G, Evaggelos C, Astrakas L, Konitsiotis S et al. Automated Epileptic Seizure Detection Methods: A Review Study. in *Epilepsy -Histological, Electroencephalographic and Psychological Aspects: InTech*, 2012.

14. Shoeb AH. Application of machine learning to epileptic seizure onset detection and treatment. ed: Massachusetts Institute of Technology, 2009.

15. Panayiotopoulos CP. A Clinical Guide to Epileptic Syndromes and their Treatment. Springer-Verlag London, 2010.

16. Zhang Z and Parhi KK. Low-Complexity Seizure Prediction From iEEG/sEEG Using Spectral Power and Ratios of Spectral Power. *IEEE Transactions on Biomedical Circuits and Systems*, 2016; 3: 693-706

17. Alickovic E, Kevric J, Subasi A. Performance evaluation of empirical mode decomposition, discrete

wavelet transform, and wavelet packed decomposition for automated epileptic seizure detection and prediction,” *Biomedical Signal Processing and Control*. 2018; 94-102.

18. Khan H, Marcuse L, Fields M, Swann K, Yener B. Focal onset seizure prediction using convolutional networks. *IEEE Transactions on Biomedical Engineering*, 2018; 9: 2109-118.

19. Truong ND, Nguyen AD, Kuhlmann L, Bonyadi MR, Yang J, Ippolito S et al. Convolutional neural networks for seizure prediction using intracranial and scalp electroencephalogram. *IEEE Transactions on Biomedical Engineering*. 2018; 104-111.

20. Thodoroff P, Pineau J, Lim A. Learning Robust Features using Deep Learning for Automatic Seizure Detection. *Journal of Machine Learning Research*, 2016.

21. Snyder JP. Map projections- a working manual in Geological Survey professional paper; 1395,” U.S. Geological Survey professional paper 1395, 1987. [Online]. Available: <http://pubs.usgs.gov/pp/1395/report.pdf>

22. Bashivan P, Rish I, Yeasin M, Codella N. Learning Representations from EEG with Deep Recurrent-Convolutional Neural Networks,” presented at the ICLR 2016.

23. Guo N, Yang Z, Jia Y, Wang L. Model updating using correlation analysis of strain frequency response function. *Mechanical Systems and Signal Processing*, 2016; 284-99.