

## Automatic Detection of Various Epileptic Seizures from EEG Signal Using Deep Learning Networks

Sobhan Sheykhivand<sup>1</sup>, Saeed Meshgini<sup>2</sup>, Zohreh Mousavi<sup>3</sup>

<sup>1</sup> PhD Student, Faculty of Electrical and Computer Engineering, University of Tabriz, Tabriz, Iran

s.sheykhivand@tabrizu.ac.ir

<sup>2</sup> Assistant Professor, Faculty of Electrical and Computer Engineering, University of Tabriz, Tabriz

Iran, meshgini@tabrizu.ac.ir

<sup>3</sup> PhD Student, Department of Mechanical Engineering, University of Tabriz, Tabriz, Iran  
zohreh\_mousavi@tabrizu.ac.ir

### Abstract:

Using an intelligent method to automatically detect epileptic seizures in medical applications is one of the most important challenges in recent years to reduce the workload of doctors in the analysis of epilepsy data through visual inspection. One of the problems of automatic detection of various epileptic seizures is the extraction of desirable characteristics, in such a way that these characteristics can make the most distinction between different phases of epilepsy. The process of finding the right features is usually a matter of time. This research presents a new approach for the automatic identification of epileptic episodes. In this paper, a deep convolutional network with eight convolutional layers and two fully-connected layers is provided to learn the characteristics hierarchically and automatically identify epileptic episodes using the EEG signal. The results show that the use of deep learning in applications such as learning characteristics hierarchically and identification of different stages of epilepsy has a higher success rate than other previous methods. The proposed model presented in this paper provides an average of 100% accuracy, sensitivity and specificity for the classification of three different epileptic seizures.

**Keywords:** EEG, Automatic detection of various epileptic seizures, Convulsion Neural Network, Seizure.

## شناسایی خودکار حالت‌های مختلف بیماری صرع از سیگنال EEG با استفاده از شبکه‌های یادگیری عمیق

سبحان شیخی‌وند<sup>۱</sup>، سعید مشگینی<sup>۲</sup>، زهره موسوی<sup>۳</sup>

۱- دانشجوی دکتری، دانشکده مهندسی برق و کامپیوتر - دانشگاه تبریز - تبریز - ایران

s.sheykhiwand@tabrizu.ac.ir

۲- استادیار، دانشکده مهندسی برق و کامپیوتر - دانشگاه تبریز - تبریز - ایران

meshgini@tabrizu.ac.ir

۳- دانشجوی دکتری، دانشکده مهندسی مکانیک - دانشگاه تبریز - تبریز - ایران

zohreh\_mousavi@tabrizu.ac.ir

**چکیده:** استفاده از روشی هوشمند برای تشخیص خودکار مراحل مختلف صرعی در کاربردهای پزشکی، برای کاهش حجم کار پزشکان در تجزیه و تحلیل داده‌های صرع با بازرسی بصری، یکی از چالش‌های مهم در سال‌های اخیر محسوب می‌شود. یکی از مشکلات شناسایی خودکار مراحل مختلف صرعی، استخراج ویژگی‌های مطلوب است؛ به گونه‌ای که این ویژگی‌ها بتوانند بیشترین تمایز را بین مراحل مختلف صرعی ایجاد کنند. فرآیند یافتن ویژگی‌های مناسب، عموماً امری زمان‌بر است. این پژوهش، رویکرد جدیدی را برای شناسایی خودکار مراحل مختلف صرعی ارائه می‌دهد. در این مقاله، یک شبکه کانولوشنال عمیق با ۸ لایه کانولوشن و ۲ لایه تماماً متصل برای یادگیری ویژگی‌ها به صورت سلسله‌مراتبی و شناسایی خودکار مراحل مختلف صرعی با استفاده از سیگنال EEG ارائه می‌شود. نتایج نشان می‌دهند استفاده از یادگیری عمیق در کاربردهایی همچون یادگیری ویژگی به صورت سلسله‌مراتبی و شناسایی مراحل مختلف صرعی، درصد موفقیت بالاتری نسبت به سایر روش‌های مشابه دارد. مدل پیشنهادی ارائه شده در این مقاله برای طبقه‌بندی ۳ حالت مختلف صرعی، مقدار ۱۰۰٪ را درباره معیارهای صحت، حساسیت و اختصاصیت فراهم می‌کند.

**واژه‌های کلیدی:** EEG، شناسایی خودکار حالت‌های مختلف تشنجات صرعی، شبکه عصبی کانولوشن، تشنج

### ۱- مقدمه

می‌برند [۱]. صرع، دومین اختلال مغزی شایع (بعد از سکته مغزی) است که با وقوع غیرمنتظره تشنج مشخص می‌شود [۱]. در این بیماری، سلول‌های عصبی در زمانی محدود با ایجاد سیگنالی به‌طور غیرطبیعی، سبب ایجاد رفتارهای غیرعادی، تشنج و از دست دادن هوشیاری می‌شوند [۲]. تشخیص صحیح و به‌موقع صرع برای شروع استفاده از داروهای کنترل‌کننده صرع و کاهش ریسک ابتلا به این بیماری، امری ضروری است [۳]. در حال حاضر، تشخیص صرع با آزمایش‌های نورولوژی و آزمایش‌های کمکی مثل تصاویر مغزی و EEG حاصل می‌شود. سیگنال‌های EEG

با توجه به گزارش‌های سازمان سلامت جهانی، نزدیک به ۵۰ میلیون نفر از بیماری صرع<sup>۱</sup> در سراسر جهان رنج

<sup>۱</sup> تاریخ ارسال مقاله: ۱۳۹۷/۱۱/۲۰

تاریخ پذیرش مقاله: ۱۳۹۸/۱۲/۱۹

نام نویسنده مسئول: سعید مشگینی

نشانی نویسنده مسئول: ایران - تبریز - دانشگاه تبریز - دانشکده مهندسی برق و کامپیوتر - گروه مهندسی پزشکی

شناسایی خودکار حالت‌های مختلف بیماری صرع از سیگنال EEG با استفاده از شبکه‌های یادگیری عمیق

می‌تواند ناهنجاری‌های مربوط به صرع *inter-ictal* و *ictal* را تشخیص دهند [۴]. به‌طور معمول، نوروها<sup>۲</sup> از طریق سیگنال‌های الکتریکی با هم در تماس‌اند؛ بنابراین، در فعالیت مغزی افراد عادی، این سیگنال‌های الکتریکی به‌طور نرمال تنظیم شده‌اند؛ در حالی که در حین صرع، یک فعالیت الکتریکی غیرطبیعی در شبکه<sup>۳</sup> عصبی شکل می‌گیرد که این فعالیت الکتریکی افزایش یافته، در یک محل باقی می‌ماند یا در کل سطح قشر مغز گسترش می‌یابد.

به‌طور سنتی، شناسایی ناهنجاری‌های صرعی با بازرسی پزشک متخصص اعصاب انجام می‌گیرد. تفسیر سیگنال‌های EEG با استفاده از ارزیابی شهودی، زمان‌بر و خسته‌کننده است و نتایج حاصل‌شده، متغیر و محدود به سطح دانش و تخصص پزشک مربوطه خواهد بود. همچنین داروهای ضد صرع دارای محدودیت‌اند و در ۳۰٪ بیماران، به کنترل تشنجات قادر نخواهند بود [۳]؛ بنابراین، ضروری است سیستم خودکار تشخیص کامپیوتری طراحی شود تا به‌طور خودکار، حالت‌های صرعی را از سیگنال EEG با استفاده از تکنیک‌های یادگیری ماشین تشخیص دهد. این سیستم، علاوه بر کمک به پزشک مربوطه در تشخیص بیماری، سبب درک و آشکارسازی مکانیزم‌های نهفته در بیمار خواهد شد.

مراحل مختلفی برای تشنج صرعی (فعالیت‌های مغزی فرد مبتلا به صرع) وجود دارد که در فرآیند پیش‌بینی این تشنجات نقش عمده‌ای دارند. پژوهش‌های پیشین نشان می‌دهند فرآیند تشنج به چهار مرحله *interictal* (فاصله بین تشنج‌ها) حالت *preictal* (پیش از تشنج)، *ictal* (حین تشنج) و حالت *postictal* تقسیم می‌شود. شواهد نشان می‌دهد تشنج‌ها از حالت شناسایی‌شده<sup>۴</sup> مغز به نام *preictal* به وجود می‌آیند که پیش‌بینی تشنج‌ها، تمایز قائل شدن بین حالت‌های *preictal* و *interictal* است [۴ و ۵].


اکنون، مطالعات اخیر انجام‌شده در حوزه شناسایی خودکار تشنجات صرعی بررسی می‌شود. پارک و همکاران [۶] با استخراج چگالی طیف توان<sup>۵</sup> سیگنال و با استفاده از طبقه‌بند ماشین بردار پشتیبان<sup>۶</sup> (SVM) حساس به هزینه، به طبقه‌بندی حالت‌های *preictal* و *interictal* تشنج پرداختند. آنها ثابت کردند طیف‌های توان در باند

*high gamma* بیشترین تمایز را بین حالت *interictal* و *preictal* دارند. الگوریتم پیشنهادشده<sup>۷</sup> آنها دارای حساسیت ۹۷٪ بود. پنگ و همکاران [۷] چند الگوریتم برای پیش‌بینی تشنج روی دو نمونه انسانی و پنج نمونه حیوانی مربوط ارائه کردند. ویژگی‌های استخراج‌شده از تمامی کانال‌های سیگنال EEG، شامل آنتروپی شانون<sup>۸</sup> در ۶۶ باند فرکانسی با استفاده از پنجره‌های ۶۰ ثانیه‌ای با همپوشانی ۵۰٪ بود. آنها از طبقه‌بندهای *Jasso LR*، *Logistic Regression*، *SVM* با هسته‌های *RBF*<sup>۹</sup> و *KNN*<sup>۱۰</sup> به منظور طبقه‌بندی حالت‌های صرعی استفاده کردند. نتیجه پژوهش آنها نشان داد طبقه‌بند *SVM* (برای نمونه حیوانی) و طبقه‌بند *lasso LR* (برای نمونه انسانی) بهترین عملکرد را برای طبقه‌بندی حالت‌های مختلف صرعی (با صحت ۹۷/۲٪، حساسیت ۸۱/۵٪ و دقت ۹۰/۹٪ برای نمونه حیوانی و صحت ۹۵/۴٪، حساسیت ۹۰٪ و دقت ۹۳/۸٪ برای نمونه انسانی) ارائه می‌دهد. ژانگ و همکاران [۲] از ویژگی‌های طیف توان شامل طیف توان نسبی<sup>۱۱</sup>، نسبت طیف توان<sup>۱۲</sup> و ضرایب همبستگی متقابل<sup>۱۱</sup> بین تمام جفت الکترودها به‌عنوان دو مجموعه مستقل از ویژگی‌ها استفاده کردند. آنها فیلتر کالمن<sup>۱۳</sup> مرتبه ۲ را به منظور مرتب‌سازی ویژگی‌های انتخاب‌شده استفاده کردند. همچنین، از ۳ طبقه‌بند شامل *AdaBoost*، *SVM* با استفاده از هسته *RBF* و شبکه‌های عصبی مصنوعی<sup>۱۳</sup> به منظور طبقه‌بندی حالت‌های مختلف صرعی استفاده کردند. بهترین نتایج طبقه‌بندی در این پژوهش با حساسیت ۱۰۰٪ و میانگین نرخ کاذب ۰/۰۳۲۴ گزارش شده است. ترونگو و همکاران [۸] از شبکه‌های یادگیری عمیق<sup>۱۴</sup> روی داده‌های EEG و با استفاده از پنجره‌های ۳۰ ثانیه‌ای با همپوشانی ۵۰٪ به منظور استخراج ویژگی بهره بردند و در نهایت، حساسیت آنها با تعداد ۶ کانال، ۸۹/۱٪ گزارش شد. شارما و همکاران [۹] با استفاده از تبدیل موجک تحلیل فرکانس تحلیلی<sup>۱۵</sup> و محاسبه ابعاد فراکتال<sup>۱۶</sup> به جداسازی حالت‌های *preictal* و *interictal* پرداختند. صحت روش آنها براساس طبقه‌بند *LS-SVM*، ۹۸/۵٪ گزارش شده است. آچاریا و همکاران [۱۰] با استفاده از شبکه‌های یادگیری عمیق و با به‌کارگیری ۱۰ لایه کانولوشنال و ۳ لایه تماماً متصل، به جداسازی خودکار مراحل *preictal*، *interictal* و نرمال

به کاررفته شامل ۳ گروه داده یعنی مجموعه B مربوط به حالت نرمال از ۵ فرد سالم، مجموعه D مربوط به حالت preictal از ۵ فرد مبتلا به صرع و مجموعه E مربوط به حالت interictal از ۵ فرد در حین تشنج است. به طور کلی، هر گروه داده (B, D, E) شامل ۱۰۰ اپیاک با فرکانس نمونه برداری ۱۷۳/۶ هرتز با طول ۲۳/۶ ثانیه است.

## ۲-۲- شبکه‌های عصبی مصنوعی (ANN)

به طور کلی، ANN دارای سه لایه است: لایه ورودی، لایه پنهان و لایه خروجی. شکل (۱) یک ANN را نشان می‌دهد [۱۲]. با توجه به شکل (۱)، شبکه از تعدادی واحد پردازشی به نام نورون یا گره در چندین لایه مختلف ساخته شده است. نورون‌های موجود در هر لایه، باهم هیچ‌گونه ارتباطی ندارند. به منظور حل مسئله با مدل شبکه عصبی، نیاز است وزن‌های مناسب برای هر لایه تعیین شوند. پس از تعیین پارامترهای مدل مانند نرخ یادگیری، تعداد لایه‌های پنهان، تعداد نورون‌های هر لایه و تابع فعال‌ساز، وزن‌های بهینه مرتبط با هر لایه به کمک دادگان آموزش، محاسبه و در نهایت، شبکه با دادگان آزمایش ارزیابی می‌شود؛ باین حال، مدل ANN حساس به تغییر و اعوجاج است که ممکن است به صحت طبقه‌بندی ضعیف منجر شود [۱۳].



شکل (۱): شمایی از لایه ورودی، لایه پنهان و لایه خروجی شبکه عصبی مصنوعی

## ۲-۳- شبکه‌های عصبی کانولوشن

شبکه عصبی کانولوشنال، شبکه عصبی بهبود یافته است. در این شبکه، چندین لایه با روشی قدرتمند در کنار هم آموزش می‌بینند [۱۴]. این روش، بسیار کارآمد بوده و یکی از رایج‌ترین روش‌ها در کاربردهای مختلف بینایی ماشین است. همانند ANN، تصمیم خروجی نهایی مدل CNN براساس وزن و بایاس لایه‌های قبلی در ساختار شبکه است.

پرداختند. روش پیشنهادی آنها دارای صحت ۸۸٪ و حساسیت ۹۵٪ گزارش شده است.

چالش عمده در الگوریتم‌های شناسایی خودکار تشنجات صرعی، انتخاب ویژگی متمایزکننده مراحل مختلف صرعی از یکدیگر است. در بیشتر مطالعات پیشین برای شناسایی خودکار تشنجات صرعی از روش‌های مرسوم آماری و پردازشی، ویژگی‌هایی استخراج شده و سپس با روش‌های کاهش ویژگی، ویژگی‌های مطلوب و بهینه انتخاب می‌شدند. استخراج این ویژگی‌ها به صورت غیر خودکار در طبقه‌بندی مراحل مختلف تشنجات صرعی، باعث پیچیدگی بار محاسباتی الگوریتم خواهد شد. همچنین، ویژگی‌های مطلوب و بهینه در یک مسئله ممکن است برای مسئله‌ای دیگر، ویژگی بهینه‌ای محسوب نشود؛ بنابراین، استفاده از روشی ضروری است که ویژگی‌های مناسب را بسته به نوع مسئله و داده یاد بگیرد. این مسئله نکته کلیدی این پژوهش است. در این مقاله، سامانه تماماً خودکار دسته‌بندی برای شناسایی خودکار حالت‌های مختلف یک تشنج صرعی، با صحت و سرعت پیش‌بینی بالا، با استفاده از سیگنال‌های EEG بر مبنای یادگیری عمیق و شبکه عصبی کانولوشنال طراحی شد تا سیگنال خام اولیه را به منظور یادگیری ویژگی‌ها و شناسایی خودکار مراحل مختلف تشنجات صرعی پردازش کند. این پژوهش مبتنی بر ۳ حالت تشنجات صرعی شامل حالت ictal, preictal و نرمال است.

ادامه مقاله به صورت زیر تدوین شده است. در بخش ۲ داده‌های آزمایشی، بررسی و شبکه عصبی مصنوعی تجزیه و تحلیل می‌شوند. سپس شبکه عصبی کانولوشنال توضیح داده می‌شود. در بخش ۳، معماری شبکه روش پیشنهادی ارائه می‌شود. در بخش ۴، نتایج شبیه‌سازی و مقایسه با پژوهش‌های پیشین بررسی می‌شوند. در نهایت، بخش ۵ مربوط به نتیجه‌گیری است.

## ۲- مواد و روش‌ها

### ۲-۱- مجموعه داده‌های EEG

ثبت داده استفاده شده برای آزمایش و ارزیابی، مربوط به دانشگاه بُن آلمان بوده است [۱۱]. مجموعه داده

شناسایی خودکار حالت‌های مختلف بیماری صرع از سیگنال EEG با استفاده از شبکه‌های یادگیری عمیق

انجام می‌دهد. خروجی کانولوشن را نگاشت ویزگی می‌نامند. عملگر کانولوشن به شرح زیر است:

$$y_k = \sum_{n=0}^{N-1} x_n h_{k-n} \quad (1)$$

که  $x$  سیگنال،  $h$  فیلتر،  $N$  تعداد عناصر در  $x$  و  $y$  بردار خروجی است.

**لایهٔ ادغام:** این لایه به کاهش نمونه<sup>۲۵</sup> هم معروف است و ابعاد نورون‌های خروجی از لایهٔ کانولوشن را کاهش می‌دهد و باعث کاهش محاسبات و همچنین جلوگیری از پدیدهٔ بیش‌برازش می‌شود. در این پژوهش، از لایهٔ ادغام بیشینه<sup>۲۶</sup> استفاده شده است که فقط مقادیر بیشینه در هر نگاشت ویزگی را انتخاب کرده و باعث کاهش تعداد نورون‌های خروجی شده است.

**لایهٔ FC:** دارای اتصال کامل به تمام فعال‌سازی‌ها در لایهٔ قبلی است.

**لایهٔ حذف تصادفی:** از این لایه به منظور جلوگیری از پدیدهٔ بیش‌برازش استفاده می‌شود [۱۵]. نحوهٔ کار آن به این صورت است که در هر مرحله از آموزش، هر نورون با احتمالی از شبکه بیرون انداخته می‌شود؛ به طوری که در نهایت یک شبکه کاهش داده شده باقی می‌ماند.

**لایهٔ نرمال‌سازی دسته‌ای:** این لایه به منظور نرمال‌سازی داده‌ها در داخل شبکه انجام می‌شود [۱۶]. زمانی که محاسبات مختلف روی دادهٔ ورودی اعمال شود، توزیع داده‌ها تغییر پیدا خواهد کرد. این لایه با هدف کاهش تغییر کوواریانس داخلی، سرعت آموزش شبکه را افزایش و باعث تسریع در همگرایی می‌شود. تبدیل لایهٔ نرمال‌سازی دسته‌ای به شرح زیر است:

$$\begin{aligned} \mu_B &= \frac{1}{n} \sum_{i=1}^n y_i^{(l-1)} \\ \sigma_B^2 &= \frac{1}{n} \sum_{i=1}^n (y_i^{(l-1)} - \mu_B)^2 \\ \hat{y}^{(l-1)} &= \frac{y^{(l-1)} - \mu_B}{\sqrt{(\sigma_B^2 + \varepsilon)}} \\ z^{(l)} &= \gamma^{(l)} \hat{y}^{(l-1)} + \beta^{(l)} \end{aligned} \quad (2)$$

که  $\mu_B$  و  $\sigma_B^2$  به ترتیب میانگین و واریانس دسته‌اند.  $\varepsilon$  یک ثابت کوچک برای ثبات عددی،  $l$  شماره لایه،  $y^{(l-1)}$  بردار ورودی به لایهٔ نرمال‌سازی،  $z^{(l)}$  بردار خروجی

در هر شبکهٔ عصبی کانولوشنال، دو مرحله برای آموزش وجود دارد؛ مرحلهٔ انتشار پیشرو<sup>۲۷</sup> و مرحلهٔ پس‌انتشار (BP) [۱۵]. BP روشی برای محاسبهٔ گرادیان تابع اتلاف نسبت به وزن‌ها است. BP سیگنال‌های خطا را در شبکه در حین آموزش پس می‌زند و باعث به‌روزرسانی وزن‌ها می‌شود. در مرحلهٔ نخست، داده‌های ورودی به شبکه اعمال می‌شوند و این عمل چیزی جز ضرب نقطه‌ای بین ورودی و پارامترهای هر نورون و در نهایت، اعمال عملیات کانولوشن در هر لایه نیست و در نهایت، خروجی شبکه محاسبه می‌شود. به منظور تنظیم پارامترهای شبکه یا به عبارت دیگر، آموزش شبکه، از نتیجهٔ خروجی برای محاسبهٔ میزان خطای شبکه استفاده می‌شود. برای این کار، خروجی شبکه با استفاده از یک تابع خطا<sup>۱۹</sup> با پاسخ صحیح، مقایسه و به این ترتیب، میزان خطا محاسبه می‌شود. در مرحلهٔ بعد، براساس میزان خطای محاسبه شده، مرحلهٔ پس‌انتشار آغاز می‌شود. در این مرحله، گرادیان هر پارامتر با توجه به قاعدهٔ زنجیره‌ای محاسبه می‌شود و تمامی پارامترها با توجه به تأثیر آنها بر خطای ایجاد شده در شبکه به‌روزرسانی می‌شوند. بعد از به‌روزرسانی پارامترها، مرحلهٔ بعدی انتشار پیشرو آغاز خواهد شد. بعد از تکرار تعداد مناسبی از این مراحل، آموزش شبکه به پایان می‌رسد. در این شبکه، خروجی هر لایه همان ویزگی‌هایی هستند که بعد کمتری نسبت به دادهٔ اصلی دارند.

به طور کلی، یک شبکهٔ کانولوشنال از سه لایهٔ اصلی تشکیل می‌شود که عبارت‌اند از: لایهٔ کانولوشن، لایهٔ ادغام<sup>۲۸</sup> و لایهٔ تمام متصل<sup>۲۱</sup> (FC) [۱۴]. برای جلوگیری از فرآیند بیش‌برازش<sup>۲۲</sup> و بهبود عملکرد شبکه از لایه‌های حذف تصادفی<sup>۲۳</sup> و نرمال‌سازی دسته‌ای<sup>۲۴</sup> نیز استفاده می‌شود. همچنین در شبکه‌های عصبی نیاز است پس از هر لایه از تابع فعال‌سازی استفاده شود که در ادامه، این لایه‌ها و توابع به‌اجمال معرفی می‌شوند.

**لایهٔ کانولوشن:** شامل فیلترهایی (کرنل‌هایی) است که روی سیگنال EEG می‌لغزند. یک کرنل، یک ماتریس است که با سیگنال ورودی EEG کانوالو می‌شود. این لایه، عمل کانولوشن را روی سیگنال EEG ورودی با استفاده از کرنل

می‌شود؛ (۳) خروجی معماری قبلی به یک ماتریس دو بعدی متصل می‌شود؛ (۴) دو لایه تمام متصل برای دسترسی به لایه خروجی استفاده می‌شود. در مجموع ۸۴۸۰۳ پارامتر در این شبکه وجود دارد. در این معماری، در لایه اول از فیلتر با اندازه بزرگ (۱۲۸×۱) و در لایه‌های بعدی، فیلترهایی با اندازه کوچک‌تر (۳×۱) به کار گرفته شده است. استفاده از فیلتر با اندازه بزرگ در لایه اول در مقایسه با فیلتر با اندازه کوچک، بهتر می‌تواند نویزهای فرکانس بالا را از بین ببرد. استفاده از فیلترها با اندازه کوچک در لایه‌های بعدی کانولوشن باعث بازنمایی بهتری از سیگنال ورودی می‌شود و در نتیجه، عملکرد شبکه را بهبود می‌بخشد. برای لایه اول کانولوشن از گام ۸ و برای بقیه لایه‌های کانولوشن گام ۱ و برای لایه‌های ادغام بیشینه گام ۲ در نظر گرفته شده است. جدول (۱) جزئیات معماری شبکه کانولوشنال پیشنهادی به کار گرفته را نشان می‌دهد. طبق جدول (۱) کاهش بعد در لایه‌های پنهان از ۴۰۹۷ (تعداد ویژگی‌های اولیه زمانی) به ۱۲۸ ادامه می‌یابد و در نهایت، بردار ویژگی انتخاب شده به دو لایه تمام متصل با تابع غیرخطی Relu و Softmax برای شناسایی خودکار مراحل مختلف صرعی استفاده می‌شود. شکل (۳) معماری شبکه پیشنهادی را نشان می‌دهد.

### ۳-۱-۱- آموزش شبکه عمیق پیشنهادی

برای تعیین ابر پارامترهای شبکه پیشنهادی از روش سعی و خطا استفاده شده است و در نهایت، تابع هدف کراس آنروپی<sup>۲۸</sup> و بهینه‌کننده آدم<sup>۲۹</sup> با نرخ یادگیری ۰/۰۰۱ انتخاب شده‌اند. روش مرسوم پس‌انتشار خطا با اندازه دسته‌ای ۱۰ برای آموزش شبکه استفاده شده است. تعداد کل اپاک‌های ۲۳/۶ ثانیه‌ای به کار گرفته در این مقاله، ۳۰۰ اپاک است که ۹۰٪ اپاک‌ها (۲۷۰) به عنوان مجموعه آموزشی و ۱۰٪ اپاک‌ها به عنوان مجموعه ارزیابی استفاده شده‌اند.

نرمال مربوط به یک نورون،  $\gamma^{(l)}$  و  $\beta^{(l)}$  به ترتیب پارامترهای مربوط به مقیاس و تغییر نرخ یادگیری‌اند.

**تابع فعال‌سازی:** پس از هر لایه کانولوشن، یک تابع فعال‌سازی اعمال می‌شود. تابع فعال‌سازی یک عملگر است که خروجی را به مجموعه‌ای از ورودی‌ها نگاشت می‌کند و برای غیرخطی کردن ساختار شبکه استفاده می‌شود [۱۲]. در این پژوهش از Relu به عنوان تابع فعال‌سازی در لایه‌های کانولوشن استفاده شد و این ویژگی را دارد که غیرخطی بودن و تنگی را به ساختار شبکه اعمال کند؛ بنابراین، در برابر تغییرات جزئی در ورودی مقاوم است. رابطه ۳ تابع Relu را نشان می‌دهد.

$$f(x) = \begin{cases} x & \text{if } x > 0 \\ 0 & \text{otherwise} \end{cases} \quad (3)$$

**تابع سافت مکس<sup>۳۰</sup>:** این تابع توزیع احتمالی کلاس‌های خروجی را محاسبه می‌کند؛ بنابراین، در لایه تمام متصل آخر از تابع سافت مکس برای پیش‌بینی اینکه کدام سیگنال ورودی به سالم، preictal و ictal مربوط است، استفاده می‌شود و رابطه آن به فرم زیر است:

$$p_i = \frac{e^{x_j}}{\sum_k e^{x_k}} \quad \text{for } j = 1, \dots, k \quad (4)$$

که در آن،  $x$  ورودی شبکه است و مقادیر خروجی  $p$  بین صفر و یک بوده که مجموع آنها برابر با یک است.

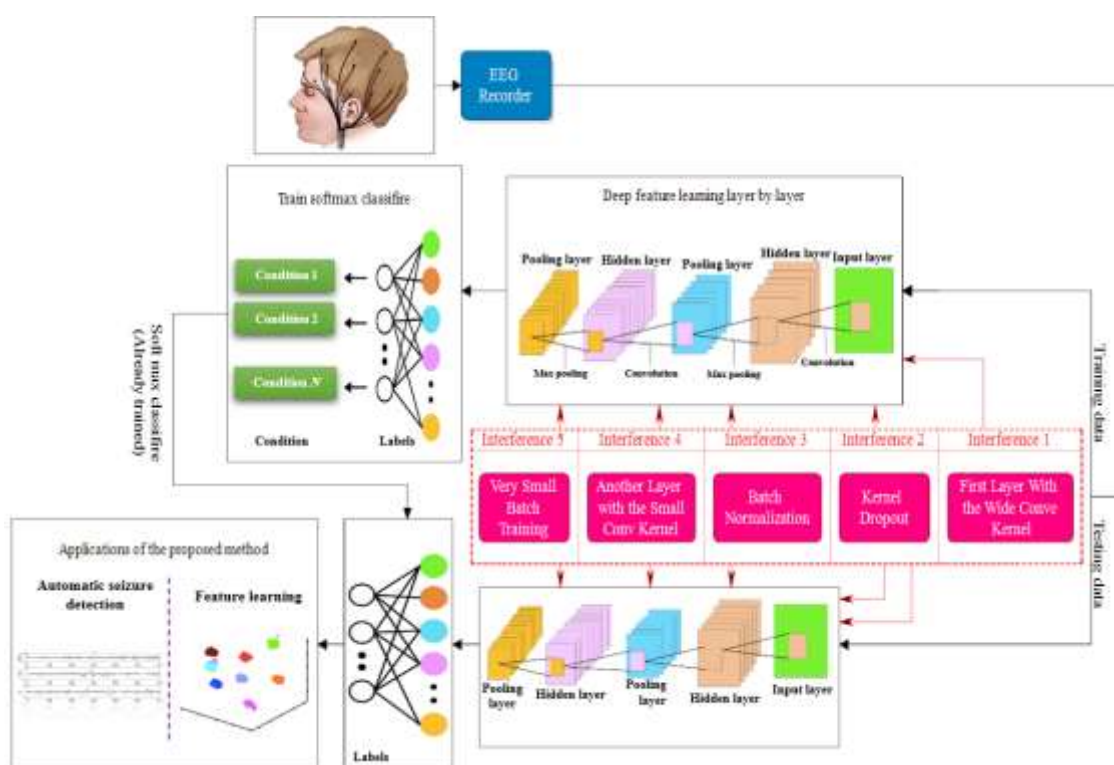
### ۳- روش پیشنهادی

در این بخش، روش پیشنهادی مقاله ارائه می‌شود. شکل (۲) ساختار کلی روش پیشنهادی را نشان می‌دهد.

### ۳-۱- معماری شبکه

برای پیاده‌سازی شبکه کانولوشنال از کتابخانه کراس در زبان برنامه‌نویسی پایتون استفاده شده است. معماری شبکه عصبی عمیق نیز به صورت زیر انتخاب شده است: (۱) یک لایه کانولوشن با تابع غیرخطی Relu همراه با Dropout و BN، سپس یک لایه ادغام max-pooling اضافه می‌شود؛ (۲) معماری مرحله قبل، ۷ بار دیگر تکرار

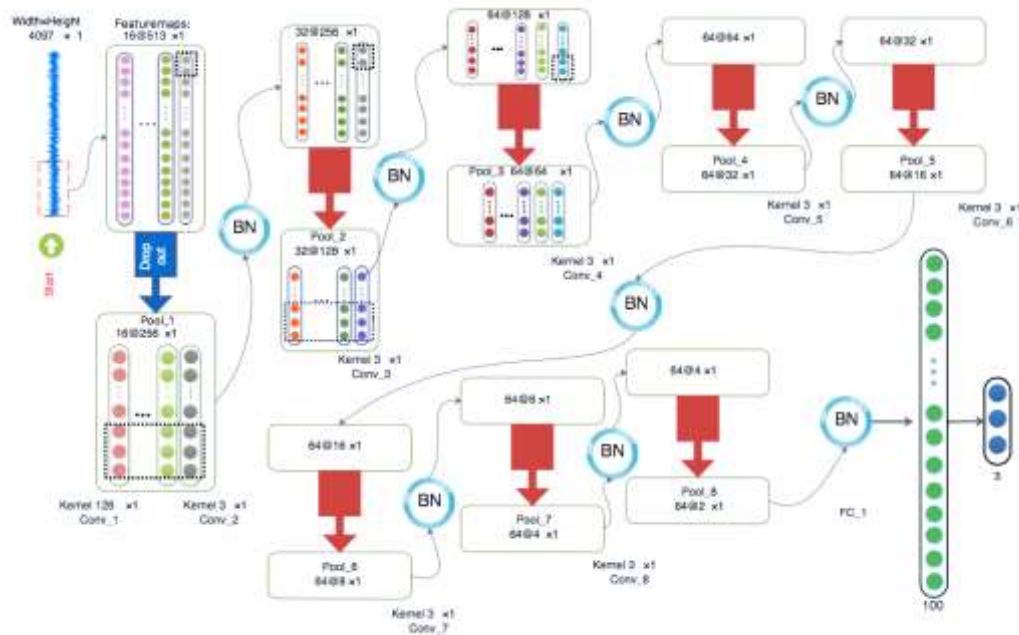
شناسایی خودکار حالت‌های مختلف بیماری صرع از سیگنال EEG با استفاده از شبکه‌های یادگیری عمیق



شکل (۲): فلوچارت کلی الگوریتم پیشنهادی

جدول (۱): جزئیات اندازه لایه‌های شبکه کانولوشنال

Number	Layer type	Size and filter steps	Number of filter	Output value	Padding
1	Convolution1	8×1/4×1	16	750×16	yes
2	Pooling1	2×1/2×1	16	375×16	no
3	Convolution2	3×1/2×1	32	375×32	yes
4	Pooling2	2×1/2×1	32	187×32	no
5	Convolution3	3×1/1×1	64	187×64	yes
6	Pooling3	2×1/2×1	64	93×64	no
7	Convolution4	3×1/1×1	64	93×64	yes
8	Pooling4	2×1/2×1	64	46×64	no
9	Convolution5	3×1/1×1	64	46×64	yes
10	Pooling5	2×1/2×1	64	23×64	no
11	Convolution6	3×1/1×1	64	23×64	yes
12	Pooling6	2×1/2×1	64	11×64	no
13	Convolution7	3×1/1×1	64	11×64	yes
14	Pooling7	2×1/2×1	64	5×64	no
15	Convolution8	3×1/1×1	64	5×64	yes
16	Pooling8	2×1/2×1	64	2×64	no
17	Convolution9	3×1/1×1	64	2×64	yes
18	Pooling9	2×1/2×1	64	1×64	no
19	Fully-connected	100	1	100	
20	Softmax	6	1	6	



شکل (۳): معماری شبکه پیشنهادی برای طبقه‌بندی مراحل مختلف حالت‌های صرعی



شکل (۴): تخصیص داده در الگوریتم پیشنهادی

نشان می‌دهد. مطابق شکل (۶)، مشاهده می‌شود صحت روش پیشنهادی برای دسته‌بندی خودکار مراحل مختلف صرعی از ایپاک ۱۴۰ به بعد به مقدار ثابت ۱۰۰٪ است. شکل (۷) نمودار پراکنندگی مراحل مختلف صرعی را در لایه‌های کانولوشن نشان می‌دهد. نمودار پراکنندگی شکل (۷) نشان می‌دهد معماری پیشنهادی در راستای طبقه‌بندی داده‌های صرعی، کارآمد بوده است. همچنین عملکرد روش پیشنهادی به‌طور جداگانه برای طبقه‌بندی ۳ حالت مختلف صرع در جدول (۲) مشاهده می‌شود. طبق جدول (۲)، ماتریس درهم‌ریختگی روش پیشنهادی برای ۳- کلاس مراحل مختلف صرعی براساس معیار ارزیابی 10-fold گزارش شده است. جدول (۳)، مقادیر صحت،

### ۳-۱-۲- ارزیابی شبکه پیشنهادی

بعد از آموزش شبکه پیشنهادی، ارزیابی مدل پیشنهادی با استفاده از ۱۰٪ از کل داده‌ها صورت می‌گیرد. شکل (۴) تخصیص داده سیگنال EEG استفاده‌شده در این مقاله را نشان می‌دهد.

### ۴- بررسی نتایج


مشخصات رایانه استفاده‌شده در این مقاله، اینتل Core (TM) i5-3470، پردازنده ۱/۶ گیگاهرتز و رم ۸ گیگابایت است. شکل (۵) نمودار خطا را نشان می‌دهد. طبق شکل (۵)، خطای شبکه از ۵ به حدود ۰ کاهش یافته است. شکل (۶) صحت روش پیشنهادی را برای ۲۰۰ تکرار




شناسایی خودکار حالت‌های مختلف بیماری صرع از سیگنال EEG با استفاده از شبکه‌های یادگیری عمیق

صحت پژوهش‌های [۱۰] و [۱۸] برای طبقه‌بندی مراحل صرعی که به ترتیب ۸۸٪ و ۹۹٪ هستند، صحت روش پیشنهادی ۱۰۰٪ است. در مجموع، نتیجه گرفته می‌شود عملکرد روش پیشنهادی این مقاله از لحاظ اعتبار و قابلیت اطمینان، امیدوارکننده است.

حساسیت و اختصاصیت روش‌های مختلفی را نشان می‌دهد که از مجموعه داده Bon-University استفاده کرده‌اند. با توجه به جدول (۳)، تمامی مقادیر گزارش شده برای روش پیشنهادی، ضریب صحت، حساسیت و اختصاصیت ۱۰۰٪ را ارائه می‌دهند. همچنین، طبق جدول (۳)، با توجه به



شکل (۵): خطای الگوریتم پیشنهادی برای ۲۰۰ تکرار



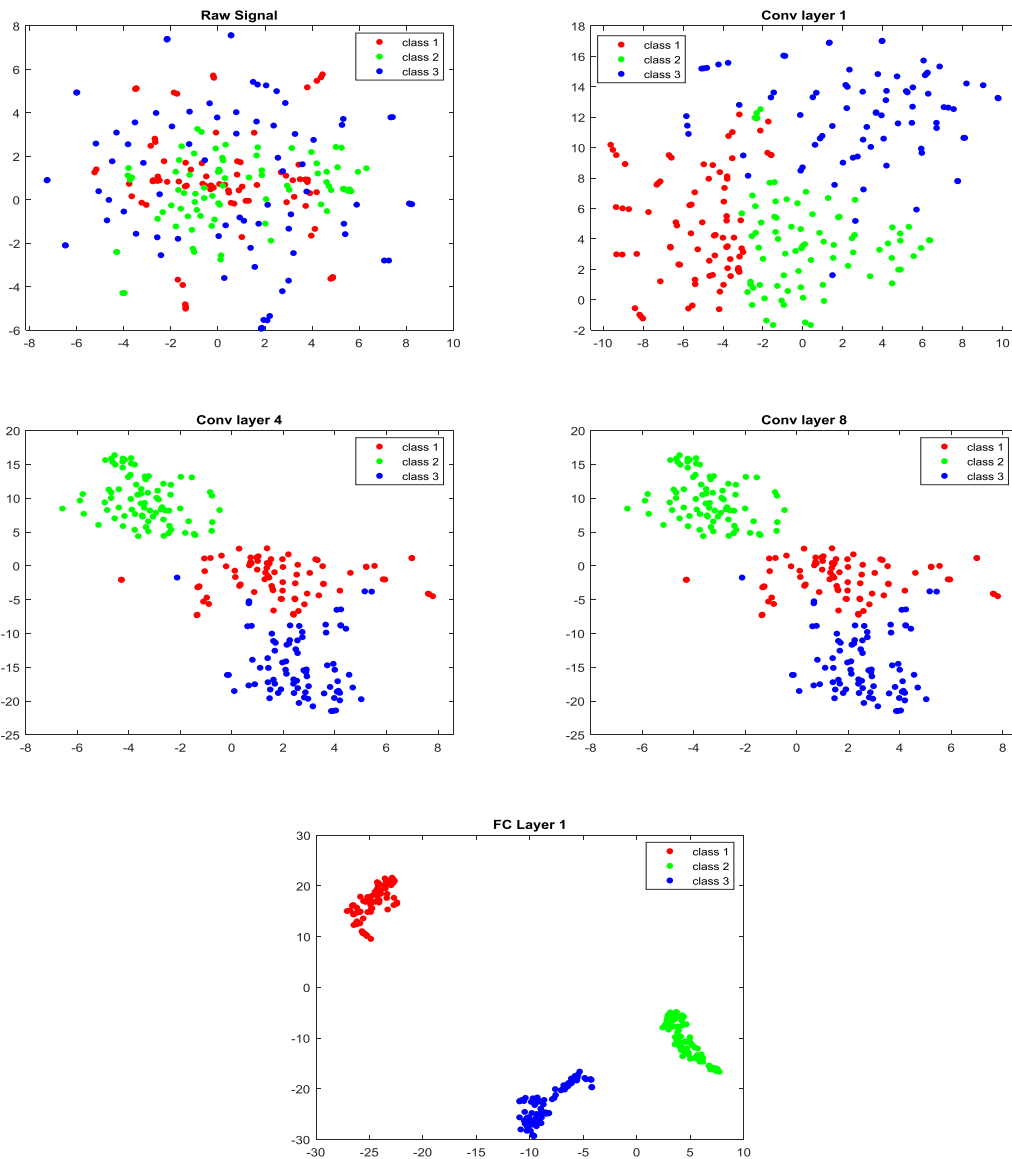
شکل (۶): صحت الگوریتم پیشنهادی برای ۲۰۰ تکرار

جدول (۲): ماتریس درهم‌ریختگی برای داده‌آزمون

	Normal	Preictal	Ictal
Normal	۱۰۰	۰	۰
Preictal	۰	۱۰۰	۰
Ictal	۰	۰	۱۰۰

جدول (۳): عملکرد الگوریتم پیشنهادی در مقایسه با پژوهش‌های پیشین در مجموعه داده خواب پایگاه Sleep-EDF

الگوریتم‌های مختلف	روش	طبقه‌بند	حساسیت	صحت	اختصاصیت
Trung et al. [1]	CNN	CNN	٪۸۱	-	-
Zhang et al. [2]	RLS	ANN	-	-	٪۹۷/۹
Bhattavharyya et al. [17]	Tunable Q-factor WT	SVM	-	٪۸۶/۶	-
Bhattavharyya et al. [18]	EMD	RF	٪۹۷/۹	٪۹۹/۴	-
Sharma et al. [9]	WT	LS-SVM	٪۱۰۰	-	-
Acharya et al. [10]	CNN	CNN	٪۹۵	٪۸۸/۸	٪۹۰
روش پیشنهادی	CNN	CNN	٪۱۰۰	٪۱۰۰	٪۱۰۰



شکل (۷): نمودار پراکندگی نمونه‌ها در لایه‌های شبکه کانولوشن برای مراحل مختلف صرعی براساس معیار 10-fold

## ۵- نتیجه‌گیری

در این مقاله، شناسایی خودکار مراحل مختلف صرعی با استفاده از یادگیری عمیق ارائه شد. در روش پیشنهادی، از سیگنال EEG برای تفکیک کلاس‌ها از یکدیگر استفاده شد. در این پژوهش، ویژگی‌ها به صورت سلسله‌مراتبی با استفاده از شبکه کانولوشنال پیشنهادی استخراج شدند. نتایج نشان دادند مدل پیشنهادی، ویژگی‌هایی را انتخاب می‌کند که بیشترین تمایز را در بین کلاس‌ها ایجاد می‌کند. نتایج الگوریتم برای طبقه‌بندی ۳- کلاس حالت‌های مختلف صرعی، ضرایب صحت، حساسیت و اختصاصیت ۱۰۰٪ را ارائه می‌دهد. باتوجه به بالابودن صحت الگوریتم، می‌توان از آن برای تشخیص خودکار مراحل مختلف صرعی برای داده‌های حجیم EEG استفاده کرد.

## مراجع

- [8] N. D. Truong, A. D. Nguyen, L. Kuhlmann, M. R. Bonyadi, J. Yang, and O. Kavehei, "A Generalised Seizure Prediction with Convolutional Neural Networks for Intracranial and Scalp Electroencephalogram Data Analysis," arXiv preprint arXiv: 1707.01976, 2017.
- [9] M. Sharma, R. B. Pachori, and U. R. Acharya, "A new approach to characterize epileptic seizures using analytic time-frequency flexible wavelet transform and fractal dimension," *Pattern Recognition Letters*, Vol. 94, pp. 172-179, 2017.
- [10] 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.
- [11] 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 E*, Vol. 64, No. 6, p. 061907, 2001.
- [12] N. Siddique and H. Adeli, *Computational intelligence: synergies of fuzzy logic, neural networks and evolutionary computing*. John Wiley & Sons, 2013.
- [13] M. Kallenberg et al., "Unsupervised deep learning applied to breast density segmentation and mammographic risk scoring," *IEEE transactions on medical imaging*, Vol. 35, No. 5, pp. 1322-1331, 2016.
- [14] Goodfellow. I., Bengio. Y., Courville. A., 2016. *Deep Learning*. MIT Press, <http://www.deeplearningbook.org>.
- [15] G. E. Hinton, N. Srivastava, A. Krizhevsky, I. Sutskever, and R. R. Salakhutdinov, "Improving neural networks by preventing co-adaptation of feature detectors," arXiv preprint arXiv: 1207.0580, 2012.
- [16] S. Ioffe and C. Szegedy, "Batch normalization: Accelerating deep network training by reducing internal covariate shift," arXiv preprint arXiv: 1502.03167, 2015.
- [17] A. Bhattacharyya, R. B. Pachori, A. Upadhyay, and U. R. Acharya, "Tunable-Q wavelet transform based multiscale entropy measure for automated classification of epileptic EEG signals," *Applied Sciences*, Vol. 7, No. 4, p. 385, 2017.
- [18] A. Bhattacharyya and R. 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.
- [1] T. Alotaiby, F. E. A. El-Samie, S. A. Alshebeili, and I. Ahmad, "A review of channel selection algorithms for EEG signal processing," *EURASIP Journal on Advances in Signal Processing*, Vol. 2015, No. 1, p. 66, 2015.
- [2] Z. Zhang and K. K. Parhi, "Seizure prediction using long-term fragmented intracranial canine and human EEG recordings," in *Signals, Systems and Computers*, 2016 50th Asilomar Conference on, 2016, pp. 361-365: IEEE.
- [3] K. Gadhomi, J.-M. Lina, F. Mormann, and J. Gotman, "Seizure prediction for therapeutic devices: A review," *Journal of neuroscience methods*, Vol. 260, pp. 270-282, 2016.
- [4] Harvard Health Publications, Harvard Medical School, 2014. Seizure overview. <http://www.health.harvard.edu/mind-and-mood/seizure-overview>.
- [5] A. Theodorakopoulou, "Machine learning data preparation for epileptic seizures prediction," 2017.
- [6] Y. Park, L. Luo, K. K. Parhi, and T. Netoff, "Seizure prediction with spectral power of EEG using cost-sensitive support vector machines," *Epilepsia*, Vol. 52, No. 10, pp. 1761-1770, 2011.
- [7] X. Pang, "Seizure forecasting," Stanford University, Autumn 2014.

<sup>1</sup> Epilepsy

<sup>2</sup> Neuron

<sup>3</sup> Electroencephalogram

<sup>4</sup> Power Spectral Density

<sup>5</sup> Support Vector Machine

<sup>6</sup> Shannon Entropy

- 7 Radial Basis Functions
- 8 K Nearest Neighbor
- 9 Relative Power Spectrum
- 10 Power Spectrum Ratio
- 11 Mutual Correlation
- 12 Kalman Filter
- 13 Artificial Neural Network
- 14 Deep Learning Networks
- 15 Analytic Time- Frequency Flexible Wavelet Transform
- 16 Fractal Dimension
- 17 Feedforward
- 18 Back Propagation
- 19 Loss Function
- 20 Pooling Layer
- 21 Fully Connected
- 22 Over Fitting
- 23 Dropout
- 24 Batch Normalization
- 25 Down Sampling
- 26 Max-Pooling
- 27 Softmax
- 28 Cross Entropy
- 29 Adam Optimizer

شناسایی خودکار حالت‌های مختلف بیماری صرع از سیگنال EEG با استفاده از شبکه‌های یادگیری عمیق