پیش‌بینی حملات صرعی در بیماران با صرع لوب تمپورال (TLE) بر اساس آنالیز کپستروم و مدل AR تعمیم‌یافته سیگنال EEG

بهار تاج‌الدینی*[۱]، سعیدرضا صیدنژاد [۲] و سهیلا رضاخانی [۳]

[۱ و ۲] بخش مهندسی برق، دانشکده فنی، دانشگاه شهید باهنر، کرمان، ایران

[۳] دانشکده علوم پزشکی، کرمان، ایران

چکیده

با توجه به این‌که تشنج‌ها موجب اختلال در هوشیاری بدون پیش‌آگاهی می‌شود، پیش‌بینی آن‌ها می‌تواند باعث کاهش فشار روانی و بهبود کیفیت زندگی شود. در این مقاله، امکان پیش‌بینی کوتاه‌مدت حمله صرع بدون حذف مصنوعات، با زمان و دقت مناسب با استفاده از مدل AR و کپستروم بهبودیافته بررسی شده است. ابتدا سیگنال EEG با تبدیل موجک، به‌دلیل تفاوت فرکانس حمله‌ها و مصنوعات هر بیمار با بیمار دیگر تفکیک می‌شود؛ سپس تشخیص تغییرات دوره حمله با استفاده از مدل‌سازی AR و روش کپستروم به‌دلیل متناوب‌بودن دامنه و فرکانس این دوره، انجام می‌پذیرد. در مرحله بعد با مقایسه دوره جاری با دوره پس‌زمینه و اعمال فیلتر میانه، خطای ناشی از مصنوعات (Artifact) و تخلیه‌های میان‌حمله‌ای کاهش داده می‌شود؛ درنهایت سیگنال با روش پنجره پیشرو متوسط‌گیری شده و منحنی پوش بالای نمودار محاسبه می‌شود. روش پیشنهادی روی مدل پیشنهادی صرعی بزرگسال و همچنین ۱۰ بیمار با داده‌های EEG طولانی‌مدت بدون حذف مصنوعات بررسی شده است. دقت و مقدار متوسط زمان پیش‌بینی، به‌ترتیب ۹۲٪، ۱۸/۵ ثانیه به‌دست آمده است.

واژگان کلیدی: پیش‌بینی حمله صرع، صرع لوب تمپورال، تبدیل موجک، مدل AR، کپستروم، فیلتر میانه، منحنی پوش، مدل صرعی بزرگسال.

Prediction of Epileptic Seizures in Patients with Temporal Lobe Epilepsy (TLE) based on Cepstrum analysis and AR model of EEG signal

Bahar Tajadini[1*], SaeidReza Seydnejad[2] & Soheila Rezakhani[3]

[1,2]Department of Electrical Engineering, Technical Faculty, Shahid Bahonar University, Kerman, Iran

[3]Neurology, Faculty of Medical Sciences, Kerman, Iran

Abstract

Epilepsy is a chronic disorder of brain function caused by abnormal and excessive electrical neurons discharge in the brain. Seizures cause disturbances in consciousness that occur without prior notice, so their prediction ability, based on EEG data, can reduce stress and improve quality of life. An epileptic patient EEG data consists of five parts: Ictal, Inter-Ictal, pre-Ictal, Post-Ictal, and IT (seconds before Ictal onset). The purpose of predicting an attack is to detect the period of pre-ictal or IT to create warnings for medical procedures that are actually determined hours or minutes before ictal and do not necessarily mean the exact time of ictal [4]. The aim of many studies has been to identify the pre-ictal period based on EEG data. However, the problem of reliable prediction of epileptic seizures remains largely unsolved [5].

* نویسندهٔ عهده‌دار مکاتبات

* Corresponding author

• تاریخ ارسال مقاله: ۱۳۹۹/۶/۲۹ • تاریخ پذیرش: ۱۴۰۱/۷/۲ • تاریخ انتشار: ۱۴۰۱/۱۲/۲۹ • نوع مطالعه: پژوهشی

[Downloaded from jsdp.rcisp.ac.ir on 2026-10-15]

[DOI: 10.61186/jsdp.19.4.149]

EEG and IEEG data types are used in detection and predicting methods. Due to the fact that artifacts and noises have a greater effect on EEG than IEEG, if there is IEEG, it has been tried to use it [6, 7]. Seizure warning methods that have a clinical application are generally based on the use on EEG [8].

Numerous studies have been performed to detect and predict seizures. The methods of signal processing and feature extraction are same in detection and prediction, but the difference is that, in detection, ictal and inter-ictal periods are compared, while in prediction, pre-ictal or IT and inter-ictal periods are being compared. Some algorithms use data modeling to extract features. References [13, 14], the coefficients AR model for the EEG data is obtained with least squares estimator, then the model coefficients are classified by SVM binary classification. In the article [15] the non-Gaussian EEG is considered using the ARIMA model (Autoregressive integrated moving average). In references [16, 17], predictions are performed based on the dynamic model with hidden variable and the sparse LVAR model, respectively. Also other features such as Mean Phase Coherency [18-20], Lag Synchronization Index to compare phase Synchronization between irregular oscillations [8,21], eigenspectra of space-delay correlation and covariance matrices [22], Largest Lyapunov Exponent [23, 25], decorrelation time, Hjorth parameters such as mobility and complexity, power spectrum in frequency bands, spectral edge frequency, the four statistical moments: mean, variance, kurtosis, skewness and there are features based on entropy and probability [6, 26-29]. Empirical mode decomposition (EMD) and wavelet transform methods have also been used to extract the feature [2, 30, 31, 37]. In articles [32, 33], the Cepstrum method has been used on short time multi channels EEG and IEEG in different patient states. Cepstrum is used to extract slow and periodic changes in speech that can be used to detect the ictal period from the inter-ictal, and has also been used to linearize the EEG [34]. In the paper [33], Cepstrum coefficients of multi-channel EEG are calculated and the 9 first coefficients are considered, then calculates the velocity and acceleration of the desired coefficients and uses a neural network to detect an epileptic seizure. The method of this paper was improved in 2014. In this way, first the signal energy and coefficients of Cepstrum are calculated and then the same process is followed. The accuracy values of velocity and acceleration coefficients in this study were 89.7% - 98.7% and 98.9% - 99.9%, respectively [32].

In this study, the period of IT was detected in patients with temporal lobe epilepsy (TLE), which is the most common type of epilepsy [38]. For this purpose, two long term EEG channels LTM (long term monitoring) with a sampling rate 256, which are facing each other have been used. First, the desired signal is considered by the moving window with a length if 5 seconds and 80% overlap. The desired signal is normalized and its linear trend is removed and band-pass filtered (220 order FIR filter, cutoff at 6-20 Hz). Then the filtered date will de decomposed using discrete wavelet transform with 6-levels and Daubechies4 mother wavelet. In this step we will have 12 outputs. Next, by windowing of 500 samples and 75% overlap, the AR model with 8 order is applied to outputs. Cepstrum method can be used to detect regular and periodic changes in the ictal period of the EEG signal. According to this feature, the Cepstrum coefficients of the data window are calculated and the first coefficient of each window is considered. By applying a median filter to the 12 outputs of the previous stage, the current period of the first channel is compared to the background period of the same channel and the second channel, and the same is done for the second channel. This method reduces artifact error and inter-attack discharges. Finally, the signal is averaged by the moving window and the positive envelope of the curve is calculated. Given that we will eventually have 12 outputs, 12 threshold values are obtained for a patient's training data, then these values are checked on the test data.

The proposed method was reviewed on a proposed model of adult epilepsy as well as 10 patients with long-term EEG data without artifact removal. Accuracy and average prediction time were 92% and 18.5 seconds, respectively. The algorithm performed better than other methods. Another advantage of the algorithm is the ability to reduce artifacts, while many studies have used short-term data without artifacts. Artifacts are located at different frequencies; which frequency analysis is performed by wavelet transform. Because two channel artifacts are unequal at the same time and in the same channel at different times, the artifacts are reduced by comparing the channels to each other. Algorithm testing on more patients is recommended to confirm the performance of the algorithm clinically.

Keywords: Epileptic Seizure Prediction, Temporal Lobe Epilepsy, Wavelet Transform, AR Model, Cepstrum, Median Filter, Positive Envelope of the Curve, Adult Epileptic Model.

۱-مقدمه

بیش از پنجاه میلیون نفر از مردم جهان درگیر بیماری صرع هستند. بیماری صرع اختلال مزمن و طغیان عملکرد مغزی است که به‌علت تخلیه الکتریکی نامتعارف و بیش‌ازحد یاخته‌های عصبی[1] مغز ایجاد شده و علائم آن حملات ناگهانی، بیهوشی موقت و تشنج متناوب است [1,2]. غیرقابل پیش‌بینی‌بودن وقوع تشنج‌ها منشأ مهمی از عوارض در بیماران مبتلا به صرع است. هدف اصلی درمان صرع رهایی از تشنج بدون اثرات نامطلوب بالینی است. این بیماران صدماتی را به‌دلیل ازدست‌رفتن هوشیاری یا تأخیر در واکنش هنگام شروع تشنج متحمل می‌شوند.

یکی از متدنخست‌ترین روش‌های درمان استفاده از داروهای ضد صرع[2] است، درحالی‌که برای ۳۰٪ بیماران

[1] Neuron

[2] Antiepileptic Drugs (AED)

[Downloaded from jsdp.rcisp.ac.ir on 2026-10-15]

[DOI: 10.61186/jsdp.19.4.149]

این روش ناکارآمد است و به‌ناچار از روش‌های جراحی مغزی و درمان‌های غیردارویی استفاده می‌کنند [3].

همچنین باید به عوارض جانبی و عدم کنترل رضایت‌بخش تشنج‌ها با روش‌های دارویی و جراحی توجه کرد.

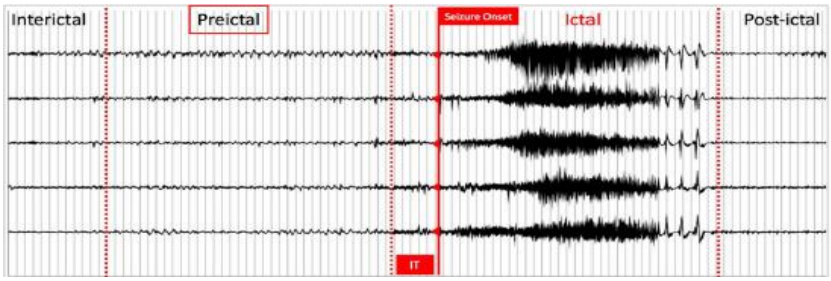

(شکل-۱): نمونه‌ای از پنج کانال نوار مغزی صرعی [3]

(Figure-1): An example of five epileptic EEG channels [3]

یک نظام[1] پیش‌بینی قابل‌اعتماد بر اساس داده نوار مغزی[2] می‌تواند امکان کنترل تشنج‌ها را به‌طور قابل‌توجهی افزایش داده و موجب بهبود زندگی و ایمنی بیماران شود [3]. یک دادهٔ نوار مغزی بیمار صرعی از پنج قسمت (شکل ۱) ایکتال[3] (دوره حمله)، اینترایکتال[4] (دوره بین دو حمله)، پری‌ایکتال[5] (دقیقه‌ها یا ساعت‌ها قبل از حمله)، پست ایکتال[6] (دوره بعد از حمله) و زمان مداخله[7] (چند ثانیه قبل از شروع ایکتال) تشکیل شده است.

در بیماری صرع علاوه بر پیش‌بینی حملات بحث تشخیص نیز مطرح می‌شود. هدف از تشخیص حمله با دادهٔ نوار مغزی، تشخیص حمله با دقت بیشتر و زمان کمتر در دوره ایکتال بوده و هدف از پیش‌بینی حمله، تشخیص دورهٔ پری‌ایکتال جهت ایجاد هشدارهایی برای اقدامات پزشکی است که درواقع ساعت‌ها یا دقیقه‌ها قبل از ایکتال مشخص می‌شود و لزوماً منظور، مشخص‌کردن زمان دقیق ایکتال نیست [4]. هدف بسیاری از مطالعات، شناسایی دوره پری‌ایکتال بر اساس داده نوار مغزی بوده است، بااین‌وجود مشکل پیش‌بینی قابل‌اعتماد تشنج صرعی تا حد زیادی غیرقابل‌حل باقی‌مانده است [5].

در روش‌های تشخیص و پیش‌بینی از دو نوع داده نوار مغزی سطحی و عمقی[8] استفاده می‌شود. ابتدا نحوه ثبت و نوع داده بر اساس کاربرد انتخاب‌شده که می‌توان آن‌ها از پایگاه‌های داده دریافت کرد. با توجه به اینکه مصنوعات[9] و نوفه[10] اثر بیشتری بر نوار مغزی سطحی نسبت به نوار مغزی عمیق دارند، در صورت وجود نوار مغزی عمیق، سعی به استفاده از آن شده است [6, 7]. روش‌های هشداردهنده تشنج که کاربرد بالینی دارند، به‌طورعمومی بر اساس استفاده از نوار مغزی سطحی هستند [8].

به‌طورکلی مصنوعات به دو دسته فیزیولوژیک[11] و غیر فیزیولوژیک تقسیم می‌شوند. مصنوعات فیزیولوژیکی به‌طورمعمول از منابع داخل بدن سرچشمه می‌گیرند و می‌تواند شامل موارد حرکات چشم، نوار قلب[12]، نوار عصب و عضله[13] و غیره شود و مصنوعات غیر فیزیولوژیکی از منابع مختلفی مانند مصنوعات ابزارهای رقمی[14](قطعات الکترونیکی، نوفه برق شهر و ...) و مصنوعات الکترودها و محیطی سرچشمه می‌گیرند. اغلب سیگنال‌های نوار مغزی حاوی اطلاعات عصبی زیر ۱۰۰ هرتز هستند برای مثال: امواج غیر صرعی بزرگ‌تر از ۳۰ هرتز را می‌توان با پالایه‌های پاسخ ضربه محدود[15] پایین‌گذر حذف کرد و برای حذف نوفه برق شهر می‌توان از پالایه پاسخ ضربه نامحدود[16] میان‌نگذر استفاده کرد. روش‌های مختلفی برای حذف مصنوعات از سیگنال نوار مغزی وجود دارد، به‌عنوان مثال می‌توان از روش تحلیل مؤلفه‌های مستقل[17] استفاده کرد [9]. مطالعات متعددی جهت تشخیص و پیش‌بینی تشنج انجام شده است. مرجع [4] الگوریتم‌های تشخیص را در سه دستهٔ:

۱) مسیر[18]

۲) پیش طبقه‌بندی[19]

۳) حالت[1] در نظر می‌گیرد.

[1] System
[2] Electroencephalogram (EEG)
[3] During Seizure States(Ictal)
[4] Gradual Transition Between Interictal (Interictal)
[5] Preictal
[6] Postictal
[7] Intervention Time (IT)
[8] Intracranial EEG (IEEG)
[9] Artifact
[10] Noise

[11] Physiologic
[12] Electrocardiogram (ECG)
[13] Electromyogram (EMG)
[14] Digital
[15] Finite impulse response (FIR)
[16] Infinite Impulse Response (IIR)
[17] Independent Component Analysis (ICA)
[18] Trending
[19] Pre_classification

[Downloaded from jsdp.rcisp.ac.ir on 2026-10-15]

[DOI: 10.61186/jsdp.19.4.149]

اساس الگوریتم‌های مسیر، مقایسه دوره‌ای از داده‌های جاری با داده‌های پیش‌زمینه[2] است. داده‌های پیش‌زمینه را به‌صورت یک پنجره داده قبل از داده‌های جاری در نظر می‌گیرند که با گذشت زمان نیز تغییر می‌کند. گاتمن چند روش برای این الگوریتم‌ها بر روی نوار مغزی سطحی و نوار مغزی عمیق پیشنهاد کرده است. یک دوره دوثانیه‌ای از داده جاری و شانزده ثانیه از داده پیش‌زمینه که با فاصله زمانی دوازده ثانیه قبل از داده جاری قرار گرفته در نظر می‌گیرد؛ سپس برای تشخیص تشنج، ویژگی‌های متوسط دامنه دوره نیم‌موج‌ها و ضرایب تغییرات دامنه مربوط به دوره جاری با دوره پیش‌زمینه مقایسه شده و با آستانه‌گذاری روی ویژگی‌ها تشخیص انجام می‌شود. در این الگوریتم دوره پیش‌زمینه به همراه دوره جاری تغییر کرده و روبه‌جلو حرکت می‌کنند [11 ,10]. در الگوریتم هاردینگ[3] از اختلاف اندازه مطلق، نمونه‌های متوالی استفاده شده است که می‌تواند وقایع دامنه و فرکانس بالا را تشخیص دهد [12].

الگوریتم‌های پیش‌طبقه‌بندی بر اساس داده نوار مغزی سطحی آموزشی که درقبل به دو دسته حمله و غیر حمله دسته‌بندی شده است عمل می‌کنند و داده نوار مغزی سطحی جدید را به این دو دسته طبقه‌بندی می‌کنند. به این صورت اطلاعات گذشته برای آموزش دسته‌بندهایی مانند شبکه عصبی، ماشین بردار پشتیبان و غیره، استفاده می‌شود. این الگوریتم‌ها، در دو جنبه متفاوت هستند:

الف) ویژگی‌های استخراج‌شده از نوار مغزی مانند ویژگی‌های آماری زمانی (دامنه مؤثر[4]،...) و واکاوی‌های[5] فرکانسی (تبدیل فوریه، تبدیل موجک و ...)

ب) روش دسته‌بندی نوار مغزی که به‌طورمعمول سه نوع هستند: شبکه‌های عصبی مصنوعی[6]، ماشین‌های بردار پشتیبان[7] و روش‌های بیزی.

الگوریتم‌های نوع سوم یک حالت را شناسایی می‌کنند. این نوع الگوریتم‌ها به تغییرات سیگنال بستگی ندارند، به‌علاوه حالت مطلق دوره جاری را، اندازه‌گیری کرده و با حالت غیر تشنج که درقبل تعریف شده یا از داده‌های پیشین به‌دست‌آمده مقایسه می‌کنند. حالات دوره‌ها بر اساس یک یا مجموعه‌ای از ویژگی‌های دوره به‌دست می‌آیند و با توجه به ویژگی‌های داده، غیر تشنجی یک آستانه کلی مشخص می‌شود. سپس داده جاری را با توجه به مقدار آستانه به‌دست‌آمده تفکیک می‌کند. این نوع الگوریتم می‌تواند چند ثانیه یا چند دقیقه قبل از شروع تشنج را تشخیص دهد بااین‌حال تمایز بین تشخیص و پیش‌بینی حمله صرع در این الگوریتم‌ها کمتر به چشم می‌آید [4].

روش‌های، پردازش اصلی سیگنال و استخراج ویژگی در دو مبحث تشخیص و پیش‌بینی یکسان هستند، اما تفاوت آن‌ها بدین‌صورت است که، در مبحث تشخیص، دوره‌های ایکتال و اینترایکتال مقایسه می‌شوند درحالی‌که در مبحث پیش‌بینی دوره‌های پری‌ایکتال و اینترایکتال مقایسه می‌شوند.

برخی از الگوریتم‌ها برای استخراج ویژگی از مدل‌سازی داده‌ها استفاده می‌کنند. مراجع [13, 14]، با تخمین‌گر کمترین مربعات[8] ضرایب مدل خود همبسته[9] داده نوار مغزی سطحی را به‌دست می‌آورد، سپس با دسته‌بندی ماشین بردار پشتیبان[10] دوتایی[11] ضرایب مدل، دسته‌بندی می‌شوند. مدل‌های متعددی برای سیگنال نوار مغزی ارائه شده است که آخرین آن‌ها بر اساس ویژگی غیرایستان آن است. باید به این نکته توجه داشت که بیشتر مطالعات انجام شده با فرض گوسی‌بودن نوار مغزی سطحی انجام شده‌اند. اما در [15] غیر گوسی بودن نوار مغزی سطحی را با استفاده از مدل میانگین متحرک خودهمبسته یکپارچه[12] در نظر گرفته است. در [16] و [17] به ترتیب پیش‌بینی بر اساس مدل دینامیکی با متغیر پنهان و مدل خود همبسته پراکنده لاگور- ولترا[13] انجام می‌شوند. همچنین معیارهای دیگری مانند میانگین همبستگی فاز [18-20]، شاخص تأخیر تطابق[14] برای مقایسه تطابق فاز بین نوسان‌های نامنظم [8 ,21]، طیف ویژه[15] ماتریس‌های همبستگی تأخیر فضا و هم‌وَردایی[16] [22]، بزرگ‌ترین نمای لیاپانوف[17] [23-25]، زمان ناهمبستگی، پارامترهای Hjorth مانند تحرک[18] و

[1] State
[2] Background
[3] Harding
[4] Root Mean Square (RMS)
[5] Analysis
[6] Artificial Neural Network (ANN)
[7] Support Vector Machin (SVM)

[8] Least squares
[9] Auto Regressive (AR)
[10] Support Vector Machine (SVM)
[11] Binary
[12] Autoregressive Integrated Moving Average (ARIMA)
[13] Sparse Laguerre-Volterra AutoRegressive
[14] Lag Synchronization Index
[15] Eigen Spectra
[16] Covariance
[17] Largest Lyapunov Exponent
[18] Mobility

[Downloaded from jsdp.rcisp.ac.ir on 2026-10-15]
[DOI: 10.61186/jsdp.19.4.149]

پیچیدگی[1]، طیف توان در باندهای فرکانسی، فرکانس لبه طیف[2]، چهارممان نخست‌آماری: میانگین، وَردایی[3]، کشیدگی[4]، چولگی[5] و معیارهایی بر اساس آنتروپی و احتمال وجود دارند [6, 29-26]. روش‌های تجزیه مد ذاتی[6] و تبدیل موجک نیز برای استخراج ویژگی استفاده شده‌اند [31, 30, 7, 2]. در [39] با استفاده از پالایه کالمن توسعه‌یافته و ارائه الگوی تولید صرع بر روی سیگنال‌های نوار مغزی عمقی به پیش‌بینی برخط و تک‌کاناله می‌پردازد. در [33, 32] از روش کپستروم روی چند کانال نوار مغزی سطحی و عمقی در حالات متفاوت بیمار به‌صورت جداگانه و کوتاه‌مدت[7] استفاده شده است. کپستروم برای استخراج تغییرات آرام و متناوب[8] در سیگنال‌های صوت استفاده می‌شود، که می‌توان در جداسازی دوره ایکتال از اینترایکتال استفاده کرد، همچنین برای خطی‌کردن نوار مغزی نیز استفاده شده است [34]. در [33] ابتدا ضرایب کپستروم چند کانال نوار مغزی سطحی را محاسبه کرده و ۹ ضریب نخست را در نظر می‌گیرد. سپس سرعت و شتاب ضرایب مدنظر را محاسبه کرده و با استفاده از شبکه عصبی به تشخیص حمله صرع می‌پردازد. روش این مقاله در سال ۲۰۱۴ تعمیم پیدا کرده است، بدین‌صورت که ابتدا انرژی سیگنال و ضرایب کپستروم محاسبه شده و سپس همان روند قبلی پیگیری می‌شود. مقادیر دقت سرعت ضرایب و دقت شتاب در این مطالعه به ترتیب ۸۹/۷٪_۹۸/۷٪ و ۹۸/۹٪ _۹۹/۹٪ به‌دست آمده است [32]. مطالعه [35]، با هدف پیش‌بینی کوتاه‌مدت یا پیش‌بینی شروع بالینی روی داده‌های نوار مغزی عمیق انجام شده است. ابتدا با روش مکان‌یابی پیشنهادی، کانال نزدیک به کانون تشنج مشخص می‌شود. سپس با پالایه میان‌گذر پیش‌پردازش شده و با استفاده از پالایه میانه‌روی سری‌های جاری و پیش‌زمینه مقایسه انجام می‌شود. درنهایت با تعیین مقادیر آستانه، ۹۲٪ از تشنج‌ها با متوسط زمان ۱۵/۵ ثانیه تشخیص داده می‌شوند.

طبق بررسی‌های انجام شده مطالعه [35]، تنها مطالعه‌ای است که تا سال ۲۰۱۸ تشنج را به‌صورت کوتاه‌مدت پیش‌بینی کرده است. در سال ۲۰۱۹ مطالعه‌ای وابسته به بیمار[9]، بر اساس پیداکردن الگوهای همگام‌سازی[10] جهت پیش‌بینی کوتاه‌مدت انجام شده است. درعمل، برای به‌دست‌آوردن تغییرات در همگام‌سازی و شناسایی پری‌ایکتال، توابعی را که به راحتی قابل محاسبه هستند، از یک مدل نمودار توسعه می‌دهد و از یک دسته‌بند استفاده می‌کند. دو الگوریتم دسته‌بندی پیشرفته و دسته‌بند سادهٔ مبتنی بر آستانه، با محاسبات کم را روی نوار مغزی سطحی مقایسه می‌کند. درنهایت، ۹۱ ثانیه قبل از تشنج را با کمک دسته‌بند سادهٔ مبتنی بر آستانه تشخیص می‌دهد [36]. مطالعه‌ای دیگر وابسته به بیمار، بر اساس یادگیری عمیق[11]، جهت پیش‌بینی بلندمدت[12] روی نوار مغزی سطحی انجام شده است. نوار مغزی خام، بدون هیچ‌گونه پیش‌پردازشی وارد الگوریتم می‌شود. فرایند دسته‌بندی و استخراج ویژگی با مدل‌های یادگیری عمیق انجام می‌شود. همچنین الگوریتم انتخاب کانال جهت دست‌یابی به کانال‌هایی با بیشترین ارتباط ارائه شده است. بیشترین مقدار دقت و کمترین مقدار نرخ مثبت کاذب به‌ترتیب ۹۹/۶ و ۰/۰۰۴ در ساعت به‌دست آمده‌اند [37].

در این مطالعه قصد داریم دوره زمان مداخله را در بیماران با صرع لوب تمپورال[13] که شایع‌ترین نوع صرع بوده شناسایی کنیم [38]. بدین منظور از دو کانال نوار مغزی سطحی با نظارت طولانی‌مدت[14] استفاده کرده‌ایم. ابتدا پردازش مقدماتی ازجمله نرمال‌سازی، حذف گرایش[15] خطی و پالایه‌کردن روی دو سیگنال دریافتی انجام می‌شود، سپس وارد بلوک پیش‌بینی می‌شویم. پیش‌بینی شامل پنج مرحله تبدیل موجک گسسته، مدل‌سازی خود همبسته، ضرایب کپستروم، پالایه میانه و مقایسه سری‌ها، متوسط‌گیری و پوش منحنی است.

ابتدا سیگنال با روش پنجره پیشرو و طول مناسب پنجره در نظر گرفته می‌شود. سیگنال موردنظر نرمال شده و گرایش خطی آن حذف می‌شود و پالایه میان‌گذر بر روی داده اعمال می‌شود.؛ سپس داده پالایه‌شده با استفاده از تبدیل موجک گسسته به امواج مغزی دلتا، تتا، آلفا، بتا و گاما تجزیه‌شده و مدل خود همبسته آن‌ها محاسبه می‌شود. می‌توان از روش کپستروم برای تشخیص تغییرات منظم و متناوب دوره ایکتال سیگنال نوار مغزی نسبت به

[1] Complexity
[2] Spectral Edge Frequency
[3] Variance
[4] Kurtosis
[5] Skewness
[6] Empirical Mode Decomposition (EMD)
[7] Short Term
[8] Periodic
[9] Patient-Specific
[10] Synchronization Patterns
[11] Deep Learning
[12] Long Term
[13] Temporal Lobe Epilepsy (TLE)
[14] Long Term Monitoring (LTM)
[15] Trend

[Downloaded from jsdp.rcisp.ac.ir on 2026-10-15]
[DOI: 10.61186/jsdp.19.4.149]

دوره اینترایکتال در این مرحله استفاده کرد. پالایه میانه نیز برای تشخیص دقیق لبه بین حمله و غیر حمله استفاده می‌شود؛ سپس دوره‌های جاری و پیش‌زمینه در نظر گرفته شده در این مرحله، مقایسه می‌شوند. در مرحله بعد مقدار متوسط هر پنجره داده محاسبه شده در پایان برای تشخیص دقیق‌تر شروع دوره زمان مداخله پوش بالای منحنی به‌دست می‌آید. برای انجام پیش‌بینی مقادیر آستانه را روی داده‌های آموزش به‌دست می‌آوریم؛ سپس روی داده آزمایش بررسی می‌کنیم.

ساختار مقاله به این صورت است که در بخش دو مفاهیم مورد نظر در پیش‌بینی حمله صرع را مورد بحث قرار می‌دهیم. در بخش ۳ راه‌کار پیشنهادی را بر اساس مراحلی که در بالا ذکر شد، توضیح داده و مورد تجزیه و تحلیل قرار می‌دهیم. بخش ۴ به نحوه تولید سیگنال مدل نوار مغزی پرداخته می‌شود و بخش ۵ روند الگوریتم پیشنهادی را روی داده حاصل از مدل نوار مغزی سطحی شبیه‌سازی کرده و درنهایت روی داده واقعی نتایج را به‌دست می‌آوریم.

۲- بیان مسئلهٔ پیش‌بینی حمله

یک الگوریتم پیش‌بینی حمله، باید قبل از رخدادن حمله آن را پیش‌بینی کند و به بیمار یا مراقبین بیمار هشدار دهد. این بدین معنی نیست که زمان رخداد حمله پیش‌بینی شود، بلکه مشخص می‌کند که حمله در یک بازه تعیین‌شده رخ می‌دهد. در [18]، این بازه را به‌عنوان بازه وقوع حمله[1] معرفی می‌کند. بازه وقوع حمله بازه‌ای است، که انتظار می‌رود حمله در آن رخ دهد. هدف از پیش‌بینی، ایجاد هشدار جهت عملیات درمانی است. در این‌جا عملیات درمانی شامل کاهش فرکانس‌های تشنج یا جلوگیری از وقوع تشنج به‌وسیله داروها یا تحریک‌های عصبی و یا جلوگیری از اتفاقات است، که موجب آسیب به بیمار می‌شود. به همین دلیل پیش‌بینی کوتاه‌مدت نیز می‌تواند ما را در این جهت یاری کند. در پیش‌بینی‌های بلندمدت به‌دلیل اینکه علائم بالینی ساعت‌ها و دقیقه‌ها قبل از حمله در بیشتر بیماران وجود ندارد، درنتیجه زمان مشخصی را نمی‌توان برای این دوره (پری ایکتال) در نظر گرفت. به همین صورت می‌توان دید مقالاتی که پیش‌بینی بلندمدت انجام می‌دهند، زمان‌های متفاوتی در نظر می‌گیرند. در این مطالعه هدف پیش‌بینی کوتاه‌مدت است، که مقدار زمان آن در حد عواکنش نشان‌دادن بیمار است؛ درواقع اگر بتوانیم پیش‌بینی را به‌اندازه کافی قبل از بروز علائم بالینی انجام دهیم موفق بوده‌ایم. زمان شروع بازه وقوع حمله هم‌زمان با هشدار است؛ یعنی از لحظه هشدار به بعد، احتمال رخ‌دادن حمله وجود دارد. که در این‌جا مقدار زمان پیش‌بینی الگوریتم اهمیت پیدا می‌کند. در قسمت قبل گفته شد که هر سیگنال نوار مغزی صرعی شامل پنج مرحله است؛ که در این‌جا دوره زمان مداخله اهمیت دارد. اگر هشدار در دوره زمان مداخله که توسط پزشک مشخص می‌شود، رخ دهد پیش‌بینی به‌درستی انجام شده‌است. به این معنی است که از این لحظه تا پایان بازه وقوع حمله تشنج رخ می‌دهد. زمان پیش‌بینی با توجه به مدت زمان واکنش بیمار در مقابل هشدار، بزرگ‌تر از ۱۰ ثانیه در نظر گرفته شده است. برای این‌که بتوان عملکرد الگوریتم را با دیگر مطالعات بررسی کنیم، از معیارهای حساسیت، اختصاص‌پذیری، دقت و نرخ مثبت کاذب[2] استفاده می‌کنیم، که به‌ترتیب از روابط (۱)، (۲)، (۳) و (۴) به‌دست می‌آیند.

$$(۱)\quad \text{حساسیت:}\quad \frac{\text{تعداد مثبت‌های صحیح}}{\text{تعداد مثبت‌های صحیح + تعداد منفی‌های کاذب}}$$

$$(۲)\quad \text{اختصاص پذیری:}\quad \frac{\text{تعداد منفی‌های صحیح}}{\text{تعداد منفی‌های صحیح + تعداد مثبت‌های کاذب}}$$

$$(۳)\quad \text{دقت:}\quad \frac{\text{تعداد مثبت‌های صحیح + تعداد منفی‌های صحیح}}{\text{تعداد منفی‌های صحیح + تعداد مثبت‌های کاذب + تعداد مثبت‌های صحیح + تعداد منفی‌های کاذب}}$$

$$(۴)\quad \text{نرخ مثبت کاذب:}\quad \frac{\text{تعداد مثبت‌های کاذب}}{\text{میزان کل ساعت‌های غیر تشنجی (ساعت)}}$$

تعداد مثبت‌های صحیح به معنی تعداد هشدارهایی که به‌درستی تشخیص داده شده‌اند، است. تعداد منفی کاذب، تعداد دوره‌های زمان مداخله که به‌اشتباه هشدار داده نشده‌اند و تعداد منفی‌های صحیح، تعداد دوره‌هایی از سیگنال که دوره زمان مداخله نبوده‌اند و به‌درستی تشخیص داده شده‌اند (هشداری هم داده نشده است). برای تعیین، تعدادها لازم است، سیگنال نوار مغزی به دوره‌هایی با اندازه مشخص تقسیم شود. در این مطالعه بازه وقوع حمله را طول متوسط حمله در نظر گرفته و

[1] Seizure Occurrence Period (SOP)

[2] False positive Rate (FPR)

[Downloaded from jsdp.rcisp.ac.ir on 2026-10-15]

[DOI: 10.61186/jsdp.19.4.149]

سیگنال نوار مغزی را به همین طول تقسیم کرده و به همین صورت تعداد منفی‌های صحیح را محاسبه می‌کنیم.

تعداد مثبت‌های کاذب تعداد دوره‌هایی است که دوره زمان مداخله نبوده و به‌اشتباه اخطار داده شده است.

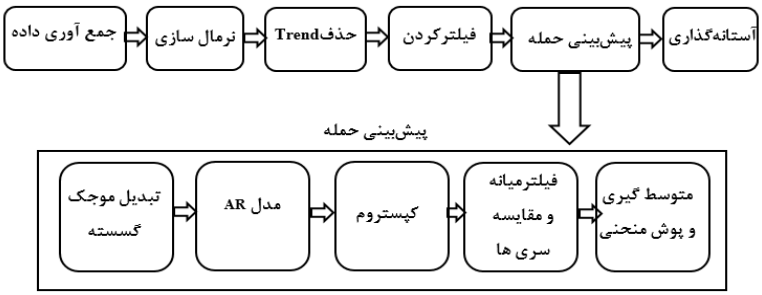

(شکل-۲): الگوریتم پیشنهادی پیش‌بینی حمله صرعی
(Figure-2): Proposed algorithm for predicting epileptic seizures

۳- روش پیشنهادی

نمودار جعبه‌ای روش پیشنهادی در شکل (۲)، آمده است. ابتدا از روش پنجره پیشرو با طول مناسب برای واکاوی سیگنال دو کانال استفاده می‌کنیم. داده‌های دو کانال نرمال شده و گرایش خطی آن‌ها حذف می‌شود. جهت استفاده از فرکانس‌های مؤثر صرعی سیگنال، از فیلتر پاسخ ضربه محدود میان‌گذراستفاده، سپس تبدیل موجک گسسته را بر سیگنال‌های دو کانال اعمال می‌کنیم. تبدیل موجک گسسته با فرایند تفکیک فرکانسی می‌تواند نوار مغزی را به امواج مغزی تشکیل دهنده آن تجزیه کند. این امر موجب کاهش خطاهای ناشی از مصنوعات و تخلیه‌های صرعی میان حمله‌ای می‌شود؛ سپس از مدل‌سازی خود همبسته جهت پارامتری‌کردن داده‌ها استفاده می‌کنیم [40]. از کپستروم برای تشخیص تغییرات آرام و متناوب استفاده شده است و دوره ایکتال سیگنال نوار مغزی نسبت به دوره اینترایکتال ریتم منظم و متناوب دارد، و می‌توان از ضریب نخست کپستروم برای تشخیص حمله بهره برد. فیلتر میانه در حفظ لبه برای ترمیم تصاویر خراب شده توسط نوفه استفاده می‌شود. با توجه به این ویژگی فیلتر میانه می‌تواند انتخاب مناسبی برای تشخیص دقیق لبه حمله باشد [35]. در این مرحله ابتدا داده‌های جاری و پیش زمینه به‌دست آورده شده و هم‌زمان فیلتر میانه روی آن‌ها اعمال، سپس تغییرات دوره جاری نسبت به پیش‌زمینه مقایسه می‌شود، که موجب بهبود فرایند تشخیص تشنج از مصنوعات، تخلیه‌های صرعی اینترایکتال و فعالیت‌های امواج آلفا می‌شود. مرحله بعد محاسبه مقدار متوسط هر پنجره داده است. با توجه به اینکه روش متوسط‌گیری می‌تواند تغییرات نخستیه دوره زمان مداخله را حذف کند، انتخاب طول پنجره مهم است. درنهایت برای تشخیص دقیق‌تر شروع دوره زمان مداخله، پوش بالای منحنی به‌دست می‌آید. برای انجام پیش‌بینی مقادیر آستانه را روی داده‌های آموزش به‌دست می‌آوریم سپس روی داده آزمایش بررسی می‌کنیم. انتخاب دو کانال نوار مغزی سطحی، با هدف کاهش پیچیدگی الگوریتم بوده و همچنین زمان حقیقی بودن آن در بیمارانی که امکان گرفتن نوار مغزی عمیق وجود ندارد. پس با استفاده از دو کانال نوار مغزی سطحی طولانی مدت، یک ضریب کپستروم و روش آستانه‌گذاری، در این الگوریتم به جای استفاده از چندین کانال نوار مغزی عمیق کوتاه‌مدت، چند ضریب کپستروم و دسته‌بندی‌ها، الگوریتم ساده‌تری خواهیم داشت. همچنین با توجه به مصنوعات به وجود آمده در نوار مغزی سطحی با نظارت طولانی‌مدت که ناشی از فعالیت‌های روزانه بیمار است می‌توان از این روش برای تشخیص در سیستم‌های کاشت[1] به‌صورت زمان حقیقی بهره برد. در ادامه به تشریح بلوک‌های روش پیشنهادی می‌پردازیم.

۳-۱- جمع‌آوری داده

داده‌های نوار مغزی سطحی استفاده شده در این مطالعه، از بیماران با صرع لوب تمپورال با نظارت طولانی‌مدت جمع‌آوری شده‌اند. داده‌ها توسط نویسندگان در بیمارستان، فقطجهت امور تشخیصی ثبت شده‌اند، که ما از این داده‌ها نیز در این مطالعه استفاده کردیم. در این مطالعه روی نوار مغزی سطحی ده بیمار، با سیستم چیدمان ۱۰-۲۰، ۲۶ الکترودی، با نرخ نمونه‌برداری ۲۵۶ هرتز، ۱۱ ساعت داده اینترایکتال و ۳۴ دقیقه داده ایکتال انجام شده است. بیماران مورد نظر بستری شده و داده‌ها در حالت بیدار و خواب جمع‌آوری شده‌اند. جزئیات نوار مغزی بیماران پیش‌بینی در جدول (۱) آمده است.

[1] Implant

[Downloaded from jsdp.rcisp.ac.ir on 2026-10-15]
[DOI: 10.61186/jsdp.19.4.149]

(جدول-۱): اطلاعات نوارهای مغزی بیماران پیش گویی از قبیل تعداد تشنج‌ها، میزان داده اینترایکتال و ایکتال آموزش و تست

(Table-1): EEG information of predictive patients such as number of seizures, amount of Inter-Ictal and Ictal data training and testing

بیماران	تعداد تشنج آموزش	میزان داده آموزش اینترایکتال (ثانیه)	میزان داده آموزش ایکتال (ثانیه)	تعداد تشنج آزمایش	میزان داده آزمایش اینترایکتال (ثانیه)	میزان داده آزمایش ایکتال (ثانیه)
بیمار نخست	۱	۶۷۷	۷۳	-	۸۰۰	-
بیمار دوم	۲	۱۷۴۴	۹۱	۴	۳۷۵۹	۱۸۲
بیمار سوم	۳	۲۶۵۷	۱۸۴	۲	۵۹۵۵	۱۹۲
بیمار چهارم	۱	۱۵۰۰	۱۳۰	۱	۳۷۰۷	۹۱
بیمار پنجم	۱	۱۴۳۵	۶۵	-	۲۱۹۵	-
بیمار ششم	۱	۷۴۰	۶۴	-	۱۲۰۰	-
بیمار هفتم	۱	۱۲۵۵	۷۲	۱	۳۳۵۰	۱۰۰
بیمار هشتم	۱	۲۶۴۱	۱۰۸	۳	۳۳۶۷	۳۰۸
بیمار نهم	۱	۲۱۰	۹۰	-	۳۵۰	-
بیمار دهم	۱	۱۹۰۰	۱۰۰	۲	۱۶۲۰	۲۰۰

برای هر بیمار چندین ثبت وجود دارد، که به صورت تصادفی تعدادی از آن‌ها به عنوان داده‌های آموزش در نظر گرفته می‌شوند. با توجه به تحقیقات انجام شده، دقت پیش‌بینی حملات صرع با چند کانال، بهتر از یک کانال است [3]. در اینجا از دو کانال استفاده شده است؛ یک کانال در محل کانون صرع و دیگری در طرف دیگر سر مقابل کانون انتخاب می‌شود. با توجه به طولانی مدت‌بودن داده‌ها، مصنوعات زیادی بر روی داده‌ها به‌علت فعالیت‌های روزانه بیمار وجود دارد. در الگوریتم پیشنهادی، بازه‌های دارای مصنوعات حذف نشده و داده‌ها به‌صورت کامل و پیوسته پردازش می‌شوند؛ و نتایج قابل قبولی به‌دست آمده است.

۲-۳- پیش پردازش

برای حذف گرایش، نرمال‌سازی و فیلتر کردن سیگنال به پنجره‌بندی نیاز داریم و انتخاب اندازه پنجره مناسب برای پیش‌بینی مهم است. اگر اندازه پنجره بزرگ باشد، هدف زمان حقیقی در نظر گرفته نخواهد شد و برخی اطلاعات از دست می‌روند. همچنین اگر پنجره کوچک باشد، موجب افزایش بی‌مورد محاسبات و اتلاف زمان می‌شود؛ بنابراین مرحله پنجره‌بندی در ابتدا بلوک پیش‌پردازش و بلوک روش پیش‌بینی انجام خواهد شد و جزئیات و اندازه‌های آن در بخش پیاده‌سازی ذکر خواهند شد. در ابتدا برای اینکه داده‌ها را به شکل قابل قیاس و نرمال تبدیل کنیم، مقدار میانگین و وَردایی آن‌ها را حذف می‌کنیم. برخی خطاها و مصنوعات در پیش‌پردازش کاهش داده می‌شوند. در شکل (۳)، خطای ناشی از جابه‌جاشدن الکترودها بر روی پوست سر مشاهده می‌شود. طبق شکل (۳)، این خطا در بازه زمانی صفر تا ۱۰ ثانیه وجود دارد. سیگنال در بازه ۱۰ تا ۲۰ ثانیه روند ثابتی دارد؛ درحالی‌که در ابتدای سری زمانی این ثبات دیده نمی‌شود، که می‌توان تا حدودی اثر آن را با حذف گرایش خطی از بین برد؛ اما همان‌طورکه در این شکل دیده می‌شود، خطا خطی نیست و اگر از حذف گرایش غیر خطی استفاده شود، اطلاعات مفیدی که در نوار مغزی صرعی وجود دارد نیز حذف می‌شود. طبق مطالعه کوین[1] ۲۰۰۵ مؤلفه‌های فرکانسی مؤثر سیگنال نوار مغزی صرعی، در فرکانس‌های بالاتر از ۳۰ هرتز وجود ندارند [41]، می‌توان برای حذف این مؤلفه‌ها از فیلترهای خطی استفاده کرد. جهت خطی‌بودن فاز فیلتر، فیلتر پاسخ ضربه محدود پنجره همینگ[2] میان‌گذر بین ۶ تا ۲۰ هرتز با درجه ۲۲۰ انتخاب می‌شود، دلیل انتخاب این بازه در بخش پیاده‌سازی گفته خواهد شد.

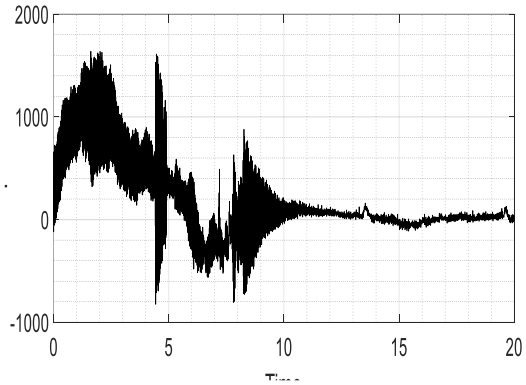

(شکل-۳): داده نوار مغزی پردازش نشده که شامل خطا ناشی از جابه‌جایی الکترودها بر روی پوست سر است.

(Figure-3): Unprocessed EEG data, which includes error due to the movement of electrodes on the scalp.

[1] Quyen
[2] Hamming

[Downloaded from jsdp.rcisp.ac.ir on 2026-10-15]
[DOI: 10.61186/jsdp.19.4.149]

۳-۳- تبدیل موجک گسسته

امواج مغزی بر اساس فرکانس به چند نوع تقسیم‌بندی می‌شوند، که عبارتند از: دلتا (۴-۰/۵ هرتز)، تتا (۸-۴ هرتز)، آلفا (۱۳-۸ هرتز)، بتا (۳۰-۱۳ هرتز) و گاما (۶۰-۳۰ هرتز). هر یک از امواج مغزی مسئول کنترل و اثرگذاری بر بخشی از عملکردهای ذهنی، هیجانی و رفتاری انسان هستند؛ درواقع اگر یکی از پنج موج مغزی از میزان نرمال خودش در نقاط مختلف مغز بیش از حد یا کمتر از میزان مناسب فعالیت نماید، می‌تواند نشان‌گر وجود مشکل در فرد باشد. بیماری صرع و فعالیت‌های مختلف بیمار در طول روز امواج خاصی در فرکانس‌های متفاوت را مکرراً در بر خواهد داشت. می‌توان با تجزیه نوار مغزی به امواج مغزی تشخیص و پیش‌بینی تشنج را بهتر و با خطای کمتری انجام داد. بدین صورت که وقتی نوار مغزی تجزیه می‌شود، در باندهای فرکانسی مختلف تجزیه شده شاهد پدیده‌های متفاوتی از قبیل مصنوعات و ایکتال هستیم که با مقایسه دوازده خروجی نهایی بلوک پیش‌بینی، برخی مصنوعات حذف و زمان شروع تشنج با تأخیر کمتری تشخیص داده می‌شود. برای تجزیه سیگنال گسسته به مؤلفه‌های فرکانسی می‌توان از تبدیل موجک گسسته[1] استفاده کرد. تبدیل موجک در مقابل تبدیل فوریه علاوه بر تفکیک فرکانسی، تفکیک زمانی نیز انجام می‌دهد و دقت تفکیک‌پذیری بهتری نسبت به تبدیل فوریه کوتاه‌مدت دارد. علت تفکیک‌پذیری بالاتر، استفاده از پنجره‌ها با طول‌های متغیر است. روش تبدیل موجک گسسته به این گونه است که سیگنال روی توابع سنجش[2] و موجک مادر تجزیه می‌شود، با این کار سیگنال در هر مرحله به دو بخش فرکانس پایین (سیگنال تقریب) و فرکانس بالا (سیگنال جزییات) تفکیک می‌شود. رابطه تبدیل موجک گسسته به این صورت است [42]:

$$x(t)=\sum_{k=0}^{2^{J_c}} c_{J_c,k}\phi_{J_c,k}(t)+\sum_{j=J_c}^{\infty}\sum_{k=0}^{2^j-1} d_{j,k}\psi_{j,k}(t) \quad (۵)$$

x(t) سیگنال زمانی، ψ تابع موجک مادر، ϕ تابع سنجش[3]، $d_{j,k}=\langle x,\psi_{j,k}\rangle$ ضرایب جزییات، $c_{J_c,k}=\langle x,\phi_{J_c,k}\rangle$ ضرایب تقریب و سیگنال روی این ضرایب تصویر می‌شود. در واقع تبدیل موجک گسسته، در هر مرحله ضریب تقریب از فیلترهای پایین‌گذر و بالا گذر عبور داده می‌شود (شکل ۴). ابتدا برای استفاده از تبدیل موجک گسسته، باید دو پارامتر موجک مادر و تعداد سطوح را مشخص کرد، سپس تبدیل موجک سیگنال‌های دو کانال محاسبه می‌شوند. از تبدیل موجک گسسته در مرجع [18] جهت تجزیه نوار مغزی به زیرباندهای آن استفاده شده است. در این مطالعه با استفاده از این روش ۱۲ خروجی به‌صورت همزمان با تفکیک‌پذیری زمانی و فرکانسی بالا خواهیم داشت.

۴-۳- مدل خود همبسته

مدل خود همبسته یک سیگنال تصادفی به‌صورت رابطه (۶) بیان می‌شود [43, 20]:

$$x_k=(\vec{\varphi}_k)^T\vec{a}_k+e_k \quad (۶)$$

که در آن $\varphi_k \square [x_{k-1},x_{k-2},...,x_{k-n}]'$ به‌عنوان رگرسورها شناخته می‌شوند. n مرتبه مدل، $a_j\ (j=1,2,\ldots,n)$ ضرایب خود همبسته، e_k سیگنال خطا نوفه سفید با میانگین صفر و x_k سری زمانی سیگنال نوار مغزی و $a \square [a_1,a_2,...,a_n]'$ بردارهای پارامتر ناشناخته هستند. می‌توان پارامترهای مجهول را به صورت برخط[4] و بُرون خط[5] محاسبه کرد. اما اینجا پارامترها با تخمین‌های برخط بازگشتی[6]، تخمین زده می‌شوند؛ تا روش پیشنهادی در سیستم‌های کاشت مغزی با زمان حقیقی قابل پیاده‌سازی باشد. در روش کمترین مربعات بازگشتی[7]، تخمین ضرایب خود همبسته به‌گونه‌ای است که معیار (J) کمترین مقدار شود:

$$J(\hat{a}_k)=\arg\min_{\hat{a}_k}\sum_{i=1}^{k}\lambda^{k-i}\in^2(i,a), \qquad 0<\lambda<1 \quad (۷)$$

که در آن $\hat{a}_k$ تخمین a_k، λ ضریب فراموشی و $\in(i,a)$ خطا پیش‌بینی که با رابطه (۸) به‌دست می‌آید:

$$\in(k,\hat{a})=x_k-(\vec{\varphi}_k)^T\vec{\hat{a}}_{k-1} \quad (۸)$$

و ضرایب a_k به‌صورت برگشت‌پذیر زیر بدین‌گونه تخمین زده می‌شوند:

$$\vec{\hat{a}}_k=\vec{\hat{a}}_{k-1}+\vec{K}_k\in_k \quad (۹)$$

در این‌جا $\hat{a}_k$ همان تخمین a_k، K_k مقدار بهره در نمونه k ام با ابعاد $n\times 1$ است؛

$$\vec{K}_k=\vec{p}_k\vec{\varphi}_k \quad (۱۰)$$

[1] Discrete Wavelet Transform (DWT)
[2] Scaling
[3] Scaling or Father wavelet

[4] Online
[5] Offline
[6] Recursive
[7] Recursive Least Square (RLS)

[Downloaded from jsdp.rcisp.ac.ir on 2026-10-15]
[DOI: 10.61186/jsdp.19.4.149]

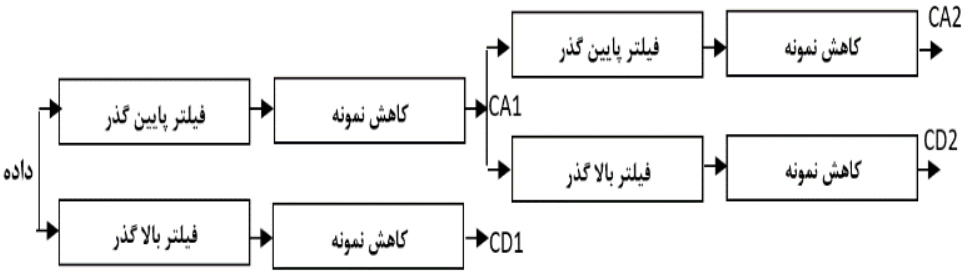

(شکل-۴): الگوریتم تبدیل موجک گسسته، CAs ضرایب تقریب و CDs ضرایب جزئیات

(Figure-4): Discrete wavelet transform, CAs approximation coefficients and CDs detail coefficients

و p_k معکوس ماتریس همبستگی ضرایب مدل با ابعاد $n \times n$ که با رابطه (۱۱) به‌دست می‌آید.

$$\vec{p}_k = (\vec{p}_{k-1} - \frac{\vec{p}_{k-1}\vec{\varphi}_k\vec{\varphi}_k^T\vec{p}_{k-1}}{\lambda + \vec{\varphi}_k^T\vec{p}_{k-1}\vec{\varphi}_k})\frac{1}{\lambda} \qquad (۱۱)$$

$\hat{x}_k$ یا تخمین x_k، از رابطه (۱۲) به‌دست می‌آید.

$$\hat{x}_k = (\vec{\varphi}_k)^T\vec{a}_{k-1} \qquad (۱۲)$$

به‌طورمعمول مقادیر نخستیه $p_0 = \delta I$ و بردار ضرایب $a_0 = 0$ در نظر گرفته می‌شوند که $0 < \delta < 1$ و I ماتریس همانی هستند. این مرحله با تعیین مقادیر مرتبه مدل و ضریب فراموشی انجام می‌شود. ابتدا می‌توان پارامترهای مدل خود همبسته هر پنجره داده را از رابطه (۹) محاسبه کرد و سپس مدل خود همبسته خروجی مرحله تبدیل موجک گسسته را از رابطه (۱۲) به‌دست آورد.

۵-۳- کپستروم

کپستروم، تبدیل فوریه معکوس، لگاریتم دامنه طیف سیگنال است. ابتدا تبدیل فوریه گسسته[1] سیگنال به‌دست آورده می‌شود [32].

$$X(k) = \frac{1}{N}\sum_{n=1}^{N} x(n)e^{-j(2\pi\frac{k}{N})n} \qquad (۱۳)$$

تعریف کپستروم سیگنال گسسته زمانی به‌صورت رابطه (۱۴) بیان می‌شود.

$$C(n) = \frac{1}{N}\sum_{k=1}^{N}\log(|X(k)|)e^{j(2\pi\frac{k}{N})n} \qquad (۱۴)$$

$\log(|X(k)|)$، لگاریتم اندازه تبدیل فوریه گسسته سیگنال و $C(n)$ ضرایب کپستروم هستند. مرجع [34] دلیل استفاده از کپستروم در امواج مغزی را این‌گونه بیان می‌کند.

دستگاه عصبی مرکزی شامل یاخته‌های عصبی و سلول‌های گلیال[2] است. نیمی از حجم دستگاه عصبی مرکزی را یاخته‌های عصبی و بقیه آن را گلیال‌ها تشکیل می‌دهند.

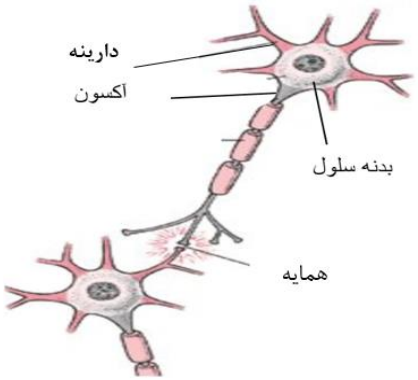

(شکل-۵): محل ارتباط دو یاخته یا همایه که پیام‌های عصبی را بین یاخته‌ها منتقل می‌کند.

(Figure-5): The junction of two neurons or synapses that transmit neural messages between neurons.

سلول‌های گلیال نقش پشتیبانی و محافظت از یاخته‌ها را بر عهده دارند و به‌عنوان سلول‌های حمایت‌کننده دستگاه عصبی شناخته می‌شوند. محل ارتباط دو یاخته یا یاخته و سلول ماهیچه‌ای[3] را همایه[4] گویند (شکل ۵). اگر چه رشته‌های عصبی عایق‌بندی شده‌اند اما ضرورت دارد که پیام‌های عصبی از یاخته به یاخته دیگر انتقال یابند به همین دلیل در سیناپس شاخه‌های انتهایی هر رشته عصبی با جسم سلولی یا دندریت یاخته عصبی دیگر تماس دارد. در محل همایه‌ها پایانه‌های اکسونی به دارینه‌ها[5] یا به جسم سلولی یاخته دیگر یا به سلول ماهیچه‌ای با فضای کوچکی به نام فضای همایه‌ای مرتبط می‌شوند. منظور از انتقال پیام عصبی انتقال پیام در محل همسایه‌ها است.

[1] Discrete Fourier Transform (DFT)

[2] Glial Cell
[3] Myosytus
[4] Synapse
[5] Dendrite

[Downloaded from jsdp.rcisp.ac.ir on 2026-10-15]
[DOI: 10.61186/jsdp.19.4.149]

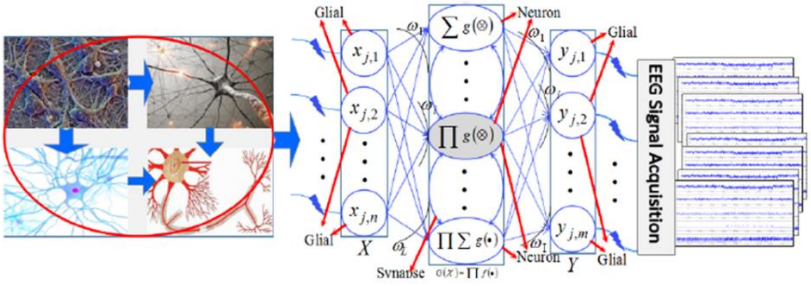

(الف) (ب) (ج)

(شکل-۶): الف) سلول‌های عصبی در مغز، ب) سیگنال‌های محرک وساختار سلول‌های مغز، ج) نوار مغزی [34]

(Figure-6): a) Nerve cells in the brain, b) Stimulus signals and structure of brain cells, c) EEG [34]

وقتی پیام عصبی به محل همایه می‌رسد از فاصله میکروسکوپی رشته‌ها جهیده و در یاخته دیگر حرکت می‌کند. اگر یاخته به هر دلیل تحریک شود، می‌توان رفتار آن را با سیگنال نوار مغزی دنبال کرد، درنتیجه می‌توان نوار مغزی را حاصل از سلول‌های گلیال، رفتار یاخته عصبی و ارتباط بین یاخته‌ها دانست و مدل کرد. باتوجه به شکل (۶)، ساختار تولید سیگنال نوار مغزی مؤثر از سلول‌های عصبی در مغز (شکل الف-۶)، ویژگی‌های الکتریکی سیگنال‌ها که مؤثر از سیگنال‌های محرک و ساختار سلول‌های مغز (شکل ب-۶) است. شکل (ب-۶) نحوه کار و سازوکار تولید نوار مغزی نشان می‌دهد، که به سه قسمت تقسیم می‌شود: سیگنال‌های محرک $x_{j,n}$ (مانند سیگنال‌های ناشی از کار سلول‌های گلیال)، رفتار یاخته‌ها g(.) و سیگنال‌های الکتریکی خروجی $y_{j,m}$. اصول کار یاخته‌ها g(.) بخش مهمی از کار است؛ از آنجایی که یاخته‌های عصبی با هم ارتباط دارند و عایق نیستند، این ارتباط با $\omega_{j,i}$ اعمال می‌شود و عملکرد تخلیه الکتریکی با دو یاخته جمع $\sum$. و یاخته ضرب $\prod$. بیان می‌شود. به‌طورمعمول یاخته جمع، به سیگنال‌هایی با توابع خطی اشاره دارد در حالی که یاخته ضرب سیگنال‌های جدید را تولید می‌کند، یا باعث افزایش انرژی سیگنال با الگوی غیرخطی می‌شود، که از غیرخطی‌بودن نوار مغزی سرچشمه می‌گیرد؛ می‌توان نتیجه گرفت سیگنال خروجی $y_{j,m}$ در رابطه (۱۵) است:

(۱۵)

$$y_{j,m} = \prod g(\omega_1.x_{1,n}) \oplus \prod g(\omega_2.x_{2,n}) \oplus \ldots \oplus \prod g(\omega_L.x_{j,n}) = \sum_{l=1}^{L} \prod g(\omega_l.x_{j,n})$$

طبق فرضیه این مرجع و رابطه فوق این تصور صحیح است که نوار مغزی در افراد مختلف به دلیل تفاوت در ساختار سلول‌های مغزی و ضرایب $\omega_{j,i}$ متفاوت است. این مرجع روش پیچیدگی‌زدایی[1] را برای جداسازی نوار مغزی از مؤلفه‌های مختلف پیشنهاد کرده‌است. می‌توان سیگنال‌های نوار مغزی را نتیجه پیچیدگی[2] دو تابع در نظر گرفت که در اثر سیگنال‌های محرک و ساختار سلول‌های مغز ایجاد شده است؛ بنابراین با اعمال کپستروم سیگنال پیچیده‌شده[3] به سیگنال خطی زمانی تبدیل می‌شود [34].

اکنون به برخی از ویژگی‌های ضرایب کپستروم و دلایل دیگر انتخاب این روش می‌پردازیم. کپستروم در تشخیص صدا از غیر صدا استفاده می‌شود. اگر تبدیل فوریه گسسته یک سیگنال صوت را در نظر بگیریم، انتظار می‌رود که در دوره‌های تناوب سیگنال، قله وجود داشته باشد.

بعد از لگاریتم‌گرفتن از طیف سیگنال، تغییرات آرام و متناوب نشان‌دهنده صدا بوده و فرکانس مربوط به قله‌های لگاریتم طیف، همان فرکانس تناوب سیگنال است (شکل ۷)، و قله‌ها در ضرایب کپستروم مربوط به بخش صدای سیگنال یا بخش متناوب سیگنال بوده است (شکل ۸). دوره ایکتال سیگنال نوار مغزی نسبت به دوره اینترایکتال ریتم منظم و متناوب دارد و می‌توان از کپستروم برای تشخیص ایکتال از اینترایکتال بهره برد. همچنین در سیگنال‌هایی مانند نوار مغزی که طول زیادی دارند می‌توان تعداد محدودی از ضرایب کپستروم را در نظر گرفت، زیرا ضرایب نهایی کپستروم به صفر نزدیک می‌شوند؛ درنتیجه تعداد ضرایب انتخاب شده به‌طول سیگنال بستگی ندارد. ضریب $c[0]$ لگاریتم انرژی یا مؤلفه جریان مستقیم[4] سیگنال است، که به‌عنوان ضریب کپستروم در نظر گرفته نمی‌شود [44].

[1] Deconvolution
[2] Convolution
[3] Convolved
[4] Direct current (DC)

[Downloaded from jsdp.rcisp.ac.ir on 2026-10-15]

[DOI: 10.61186/jsdp.19.4.149]

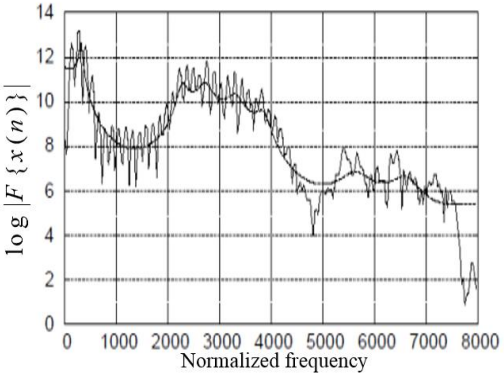

(شکل-۷): لگاریتم تبدیل فوریه گسسته یک نمونه سری زمانی [44]

(Figure-7): The logarithm of the DFT in time series [44]

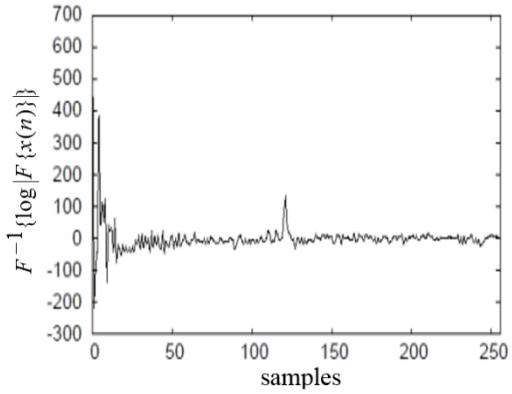

(شکل-۸): معکوس تبدیل فوریه گسسته، لگاریتم، تبدیل فوریه گسسته یک نمونه سری زمانی یا ضرایب کپستروم سری زمانی (IDFT سری زمانی به‌دست آمده از شکل (۷)) [44]

(Figure-8): IDFT, logarithm, DFT of time series or Cepstrum coefficients of time series (IDFT of Figure_7) [44]

۶-۳- فیلتر میانه و مقایسه سری پس‌زمینه با سری پیش‌زمینه

در این مرحله از فیلترهای میانه جهت بهبود فرایند تشخیص تشنج از مصنوعات، تخلیه‌های صرعی اینترایکتال و فعالیت‌های امواج آلفا استفاده می‌شود. فیلتر میانه قابلیت حذف نوفه تصادفی را دارد و می‌تواند تا حدودی جزئیات تصویر را حفظ کند. به‌علت توانایی آن در حفظ لبه برای ترمیم تصاویر خراب‌شده توسط نوفه، استفاده می‌شود. با توجه به این ویژگی، این فیلتر می‌تواند انتخاب مناسبی برای تشخیص دقیق لبه بین تشنج و غیر تشنج باشد. فیلترهای میانگین متحرک[1] به‌دلیل حذف جزئیات در تشخیص تشنج ضعیف‌تر عمل می‌کنند و فعالیت‌های صرعی کوتاه مدت اینترایکتال را حذف نمی‌کنند. سیگنال نوار مغزی شامل مقادیر مثبت و منفی است، که مقادیر اندازه سیگنال در دوره ایکتال نسبت به اینترایکتال بیشتر بوده است. همچنین برای افزایش تفاوت دو دوره ابتدا مربع آن به‌دست می‌آوریم سپس از فیلتر میانه با پنجره متحرک با طول مشخص عبور می‌دهیم. دوره پس زمینه اخیر (FG_k) از رابطه (۱۶) به‌دست می‌آید [35].

$$FG_k = median\left\{y_k^2, y_{k-1}^2, ..., y_{k-q+1}^2\right\} \qquad (۱۶)$$

اینجا q مرتبه فیلتر است. طول پنجره یا مرتبه فیلتر با توجه به نرخ نمونه‌برداری انتخاب و شاخص پس زمینه با شاخص مرجع (پیش زمینه) مقایسه می‌شود. درواقع تغییرات دوره پس‌زمینه نسبت به دوره پیش‌زمینه سنجیده می‌شوند. دوره پیش‌زمینه با عبور دوره پس زمینه از فیلتر میانه و تأثیر ضریب فراموشی (λ) به‌دست می‌آید. ضریب فراموشی موجب استفاده از اطلاعات پیش‌زمینه از ثانیه‌ها تا ساعت‌ها قبل، بدون افزایش محاسبات می‌شود. ترکیب فیلتر میانه و ضریب فراموشی موجب عدم حساسیت نسبت به تغییرات غیر تشنجی می‌شود و امکان نمایش دقیق اطلاعات گذشته و تطابق همزمان با تغییر وضعیت را داراست. دوره پیش زمینه از رابطه (۱۷) به‌دست می‌آید.

$$BG_k = \begin{cases} (1-\lambda)median\begin{Bmatrix} FG_k, FG_{k-s}, FG_{k-2s}, \\ ..., FG_{k-(q_2-1)s} \end{Bmatrix} + (\lambda)BG_{k-1} & \text{if k=ns} \\ BG_{k-1} & \text{if n(s-1)≤k<ns} \end{cases} \qquad (۱۷)$$

که $n = 0,1,2,...$ ، s نصف نرخ نمونه‌برداری، q_2 برابر با نرخ نمونه‌برداری و λ ضریب فراموشی است. نسبت‌های بدون بعد دوره اخیر هر کانال از رابطه (۱۸) محاسبه می‌شود.

$$r_k^{(i=1)} = \frac{FG_k^{(i=1)}}{BG_k^{(j)}} \qquad (۱۸)$$

که i, j شماره کانال که $1 \le j \le N$ و N تعداد کل کانال‌ها است. روش فیلتر میانه و تولید دوره پس‌زمینه روی داده یک بیمار آزمایش شده و توانایی شناسایی لبه‌های مربوط به تشنج‌ها و غیر تشنج‌ها مشاهده شده است؛ درنتیجه مقایسه دوره پس‌زمینه با دوره پیش‌زمینه موجب کاهش دامنه شبه‌تشنج‌ها می‌شود. همانطور که در مراحل قبل اشاره شد در پیش‌بینی از اطلاعات دو کانال استفاده می‌کنیم [35]. این مرحله طبق رابطه (۱۸) دو قسمت دارد؛ مورد نخست، نسبت کانال نخست به خودش و مورد دوم، نسبت کانال نخست به کانال دوم است.

[1] Moving Average Filter

[Downloaded from jsdp.rcisp.ac.ir on 2026-10-15]

[DOI: 10.61186/jsdp.19.4.149]

۷-۳- متوسط گیری و پوش منحنی

روش متوسط‌گیری همانند فیلتر پایین‌گذر تغییرات سریع یا فرکانس بالا را حذف می‌کند. همچنین می‌توان برای کاهش تعداد نمونه‌ها از این روش استفاده کرد. با توجه به اینکه روش متوسط‌گیری می‌تواند تغییرات نخستیه دوره زمان مداخله را حذف کند، اندازه پنجره داده را در حد چند ثانیه و با هم‌پوشانی در نظر می‌گیریم؛ درنتیجه با استفاده از روش پنجره پیشرو با اندازه و میزان همپوشانی مشخص سری زمانی تفکیک‌شده و متوسط‌گیری روی هر پنجره داده انجام می‌شود. نمودار ۲ در شکل (۹)، نمودار متوسط‌گیری شده است. زمان شروع دوره زمان مداخله در ثانیه ۳۶۰ رخ می‌دهد، که نمی‌توان با روش آستانه‌گذاری روی نمودار ۲، زمان شروع این دوره را مشخص کرد. اگر پوش نمودار ۲، را رسم کنیم نمودار ۱، را خواهیم داشت که به‌راحتی با پیداکردن مقدار آستانه زمان شروع دوره زمان مداخله مشخص می‌شود.

در اینجا لازم است به دلایل دیگر انتخاب هر بلوک اشاره شود. در شروع انجام پژوهش، ما به‌دنبال الگوریتمی بر اساس مدل خودهمبسته-کپستروم که جهت تشخیص تغییرات در سیگنال نوار مغزی در مرجع [40] استفاده شده است، بودیم؛ اما این روش به‌تنهایی جهت پیش‌بینی و تشخیص دوره زمان مداخله کافی نبود؛ درنتیجه ما برای افزایش دقت الگوریتم در تشخیص و کاهش خطاهای ناشی از مصنوعات و تخلیه‌های میان حمله‌ای به ریخت‌شناسی[1] سیگنال نوار مغزی مراجعه کردیم. با توجه به ریخت‌شناسی سیگنال در کانال‌های مختلف می‌توان پی برد که نوع، زمان و فرکانس رخ دادن مصنوعات، تشنج‌ها و تخلیه‌های میان حمله‌ای در کانال‌های مختلف متفاوت بوده است؛ بنابراین ما می‌توانیم با استفاده از روشی که، بتواند تجزیه زمان-فرکانسی را با دقت بالا انجام دهد، تشنج را از مصنوعات و تخلیه‌های میان حمله‌ای تفکیک و مشخص کنیم. جهت تجزیه زمان- فرکانسی از موجک گسسته استفاده شد؛ همان‌طور که مطالعه [18] نیز از موجک گسسته جهت تجزیه فرکانسی بهره برده است.

اگر زمان شروع تشنج را در کانال‌های نزدیک به هم بررسی کنیم، متوجه می‌شویم که، تشنج در برخی کانال‌ها زودتر رخ می‌دهد. همچنین همان‌طور که گفته شد، نوع و زمان رخ دادن تشنج‌ها با مصنوعات و تخلیه‌ها در کانال‌ها و سری‌های مختلف متفاوت است؛ بنابراین می‌توان با مقایسه سری‌های یک کانال نسبت به هم یا مقایسه یک سری‌های دو کانال، تشنج را زودتر تشخیص داد.

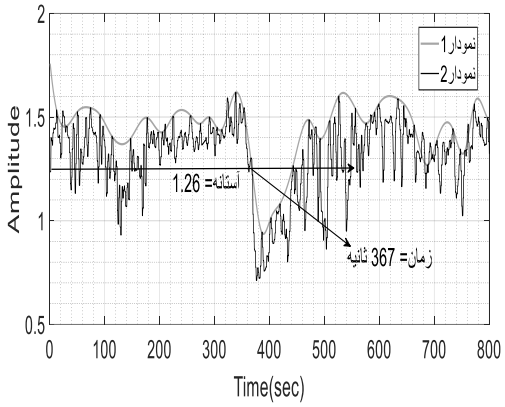

(شکل-۹): نمودار ۲ مقدار متوسط خروجی مرحله مقایسه سری‌ها با استفاده از پنجره پیشرو و نمودار ۱ پوش نمودار ۲ است.

(Figure-9): Diagram 2 is the average output of the series comparison stage using the leading window and the diagram 1 is envelope curve of the diagram 2.

با توجه به اینکه در بیماران با صرع لوب تمپورال، ابتدا تشنج از یک نقطه در یک طرف سر شروع شده و سپس به اطراف کانون تشنج منتشر می‌شود، بنابراین مقایسه سری‌ها و سیگنال کانال‌ها به پیش‌بینی تشنج در این بیماران، کمک می‌کند. جهت مقایسه کانال‌ها و سری‌ها، مطالعات مختلفی وجود دارد اما با توجه به هدف ما، مقایسه کانال‌ها و مقایسه سری‌ها مرجع [35] بررسی شد.

همان‌طور که تشنج یا دوره ایکتال نسبت به اینترایکتال همانند لبه عمل می‌کند، و فیلتر میانه توانایی تشخیص لبه را دارد، بنابراین می‌توان از فیلتر میانه جهت تشخیص تشنج بهره برد. ما فیلتر میانه را روی داده یک بیمار آزمایش کردیم و توانایی آن در تشخیص تشنج محرز شد.

بعد از این مراحل مشاهده شد که، زمان شروع تشنج واضح شده است، اما هنوز تأخیر در تشخیص وجود دارد. با توجه به ریخت‌شناسی سیگنال به‌دست آمده، بلوک‌های متوسط‌گیری و پوش بالای منحنی مورد نیاز بود.روش متوسط‌گیری کمک به کاهش دامنه مؤلفه‌های فرکانس بالا می‌کند و درنتیجه خطای ناشی از مصنوعات را می‌کاهد. در مرحله بعد، برای مشخص‌کردن راحت‌تر آستانه پوش بالای منحنی را به‌دست می‌آوریم.

[1] Morphology

[Downloaded from jsdp.rcisp.ac.ir on 2026-10-15]

[DOI: 10.61186/jsdp.19.4.149]

۸-۳- آستانه گذاری

با توجه به نتایج به‌دست‌آمده از خروجی نمودارهای پوش متوجه شده‌ایم که آستانه پیش‌بینی حمله هر بیمار متفاوت است؛ درنتیجه برای هر بیمار آستانه متفاوت در نظر گرفته می‌شود. با توجه به نتایج داده‌های آموزش، مقدار آستانه با کمترین خطا و مناسب‌ترین تأخیر از زمان شروع حمله انتخاب و در داده‌های آزمایش اعمال می‌شوند.

۴- مدل سیگنال مغز صرعی بزرگسال

مدل سلکا[1] برای تشخیص تشنج در نوزادان استفاده شده است. اساس ساختار این مدل قبلاً توسط روسگن[2] و لوپس داسیلوا[3] بر اساس ویژگی‌های غیر گوسی و غیر ایستان نوار مغزی پیشنهاد شده است [45-48]. در این مطالعه، مدل پیشنهادی برگرفته از مدل سلکا و داده‌های واقعی بزرگسال است که شامل دوره‌های ایکتال، اینترایکتال و دوره زمان مداخله است. مدل سلکا دو شاخه موازی غیرخطی وینر دارد که شاخه بالا نوار مغزی زمینه و شاخه پایین تشنج را تولید می‌کند. با فرض استقلال نوار مغزی زمینه و تشنج، شاخه بالا یک فیلتر خود همبسته میانگین- متحرک[4] (G_p) است که با نوفه سفید گوسی تحریک می‌شود؛ سپس از تابع شکل‌دهی غیر خطی g_p عبور می‌کند (شکل ۱۰).

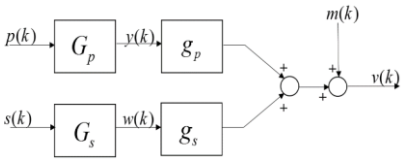

(شکل-۱۰): مدل غیرایستان و غیرخطی نوار مغزی صرعی مطالعه سلکا

(Figure-10): Non_Stationary and nonlinear EEG model of epileptic Celka study

شاخه پایین فیلتر خود همبستهٔ میانگین- متحرک (G_s) با سیگنال دندان اره‌ای سوار شده[5]، فرکانسی خطی تکه‌ای[6] تحریک می‌شود، سپس از تابع شکل‌دهی غیرخطی g_s عبور می‌کند. سوارسازی[7] فرکانسی خطی تکه‌ای، رفتار غیر ایستان تشنج‌ها را مدل می‌کند. مدل پیشنهادی سلکا برگرفته از نوارهای مغزی صرعی نوزادان است؛ به‌صورتی‌که محدوده فرکانسی بخش زمینه ۰/۵ تا ۱۰ هرتز و بخش تشنج ۱/۵ هرتز است. درحالی‌که محدوده فرکانسی بخش زمینه بزرگسالان ۰/۵ تا ۵۰ هرتز است و فرکانس بخش تشنج نیز به یک مقدار محدود نمی‌شود. تاکنون مدل نوار مغزی صرعی بزرگسالان که مناسب هدف پیش‌بینی باشد، ارائه نشده است. برای اینکه تفاوت‌های نوار مغزی نوزاد و بزرگسال را تا حدودی پوشش دهیم، با تغییر فرکانس‌ها، تعیین ضرایب فیلترهای مورد استفاده در این مدل و همچنین استفاده از داده‌های واقعی بزرگسال موجود، اعمال می‌کنیم. برای این کار ابتدا دوره اینترایکتال سیگنال بزرگسال داده‌های موجود را از تابع شکل‌دهی g_p^{-1} عبور می‌دهیم و سیگنال خروجی (y(k)) به‌دست می‌آید. حال باید مدل G_p تخمین زده شود که با دستور armax این تخمین انجام می‌شود. اگر تبدیل Z فیلتر G_p به این صورت باشد:

$$G_p(z) = \frac{H_1(z)}{H_2(z)} \qquad (۱۹)$$

فیلتر G_s مربوط به شاخه پایین این رابطه خواهد بود:

$$G_s(z) = \frac{1}{H_2(z)} \qquad (۲۰)$$

با ورودی نوفه سفید و خروجی y(k)، فیلتر $G_p(z) = \frac{Y(z)}{E(z)}$ با p=q=2، تخمین زده می‌شود. طیف سیگنال y(k) یا طیف پاسخ نوفه سفید فیلتر G_p در شکل (۱۱) آمده است. همچنین طیف پاسخ ضربه فیلتر $\hat{G}_p$ نیز همانند شکل (۱۱) بوده است. طیف بُد فیلتر $\hat{G}_p$ که طبق ضرایب فیلتر رسم‌شده در شکل (۱۲)، آمده است. شکل‌های (۱۱) و (۱۲) تقریباً یکسان هستند و تخمین به‌خوبی انجام شده است. بعد از پیداکردن $H_1(z)$، $H_2(z)$، G_p و G_s می‌توان بخش تشنج را به‌دست آورد. در رابطه $S(k)$ مقدار $f_m = 1.5Hz$ است. نمونه‌ای از اینترایکتال و ایکتال به‌دست‌آمده، به‌ترتیب در شکل‌های (۱۳) و (۱۴) آمده است. دوره زمان مداخله دامنه و فرکانس کمتری نسبت به ایکتال دارد. برای تولید این دوره همانند تولید دوره ایکتال عمل می‌کنیم؛ درحالی‌که فرکانس f_m را برابر یک هرتز و دامنه کمتری قرار می‌دهیم، می‌توان دوره زمان مداخله تولیدشده از مدل صرعی بزرگسال را در شکل (۱۵) مشاهده کرد.

[1] Celka
[2] Roessgen
[3] Lopesdasilva
[4] Autoregressive Moving-Average (ARMA)
[5] Modulated
[6] Piecewise Linear Frequency Modulated
[7] Modulation

[Downloaded from jsdp.rcisp.ac.ir on 2026-10-15]
[DOI: 10.61186/jsdp.19.4.149]

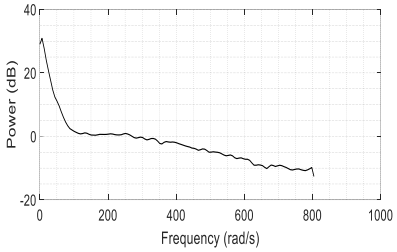

(شکل-۱۱): شکل طیف سیگنال y(k) یا شکل طیف پاسخ نوفه سفید فیلتر G_p

(Figure-11): The spectrum signal of y (k) or the white noise response of the filter G_p

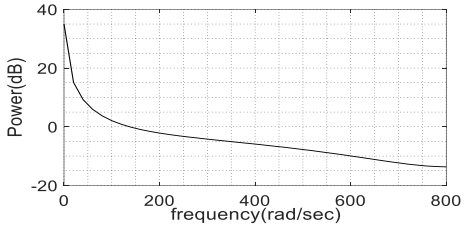

(شکل-۱۲): طیف بد فیلتر $\hat{G}_p$ که طبق ضرایب فیلتر رسم شده است.

(Figure-12): Bode filter of $\hat{G}_p$ drawn according to filter coefficients

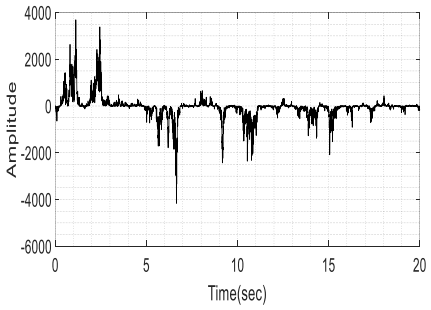

(شکل-۱۳): دوره اینترایکتال نوار مغزی به‌دست آمده از مدل صرعی بزرگسال

(Figure-13): Inter_ictal period EEG obtained from the adult epileptic model

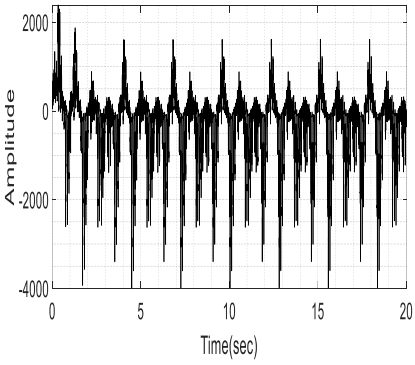

(شکل-۱۴): دوره ایکتال نوار مغزی به‌دست آمده از مدل صرعی بزرگسال

(Figure-14): Ictal period EEG obtained from adult epileptic model

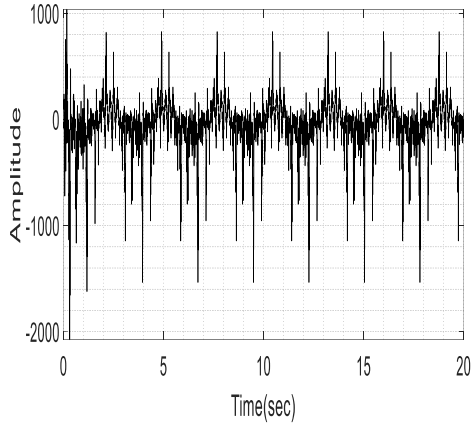

(شکل-۱۵): دوره زمان مداخله به‌دست‌آمده از مدل صرعی بزرگسال

(Figure-15): IT period obtained from the adult epileptic model

۵- شبیه‌سازی و بیان نتایج

۵-۱- جمع‌آوری داده

داده‌ها آموزش و آزمایش طبق جدول (۱) تعیین می‌شوند. برای داشتن بهترین نتیجه، بایستی مناسب‌ترین کانال‌ها بر اساس تجربه پزشک انتخاب شوند که برای هر بیمار متفاوت است. با توجه به بیماران با صرع لوب تمپورال، دو کانال از نواحی لوب‌های تمپورال و فرونتال انتخاب می‌شوند. کانال اصلی همان کانون تشنج است و کانال دوم طرف مقابل کانون انتخاب می‌شود. لازم به ذکر است که هدف این مطالعه، مکان‌یابی کانون تشنج نیست و انتخاب کانال به‌صورت غیر خودکار انجام می‌شود. همچنین کانال انتخاب‌شده در ثبت‌های مختلف ثابت است. اعمال مراحل پیش‌بینی حمله صرعی، روی داده کانال‌های مورد نظر با نرم افزار متلب[1] انجام می‌شوند.

۵-۲- پیش‌پردازش

مراحل پیش‌پردازش عبارتند از:

پنجره‌بندی با طول پنج ثانیه با همپوشانی ۸۰٪، حذف میانگین و وَردایی، حذف گرایش خطی و اعمال فیلتر میان‌گذر است. برای پیش پردازش ابتدا داده با پنجره پیشرو در نظر گرفته می‌شود و سپس برای مشخص‌کردن طول مناسب پنجره، طول‌های مختلفی را بررسی می‌کنیم؛ به این صورت که ابتدا طول پنجره را به‌ترتیب ۲، ۵ و ۱۳ ثانیه در نظر گرفته و سپس مراحل حذف

[1] Matlab

[Downloaded from jsdp.rcisp.ac.ir on 2026-10-15]

[DOI: 10.61186/jsdp.19.4.149]

میانگین، وَردایی و گرایش خطی انجام می‌شود. طبق نتایج به‌دست‌آمده از نمودارها که به‌علت گستردگی، از آوردن آن‌ها صرف نظر کردیم، دقت حذف خطا با طول پنجره دو ثانیه (۵۰۰ نمونه) زیاد است. این مقدار دقت با حذف گرایش در این مرحله لازم نیست؛ زیرا این میزان تغییرات در مراحل بعد با فیلتر پاسخ ضربه محدود حذف می‌شوند. اگر طول پنجره کمتر از دو ثانیه باشد، امکان حذف اطلاعات حمله وجود دارد. این در صورتی است که طول پنجره پنج ثانیه به نسبت سیزده ثانیه با دقت بهتری عمل کرده‌است؛ درنتیجه طول پنج ثانیه (۱۳۷۵ نمونه)، را انتخاب کردیم. برای اعمال فیلتر میان‌گذر انتخاب بازه فیلتر و مرتبه آن حائز اهمیت است؛ برای تعیین مرتبه فیلتر، مراتب ۸۰، ۲۲۰ و ۵۰۰ با بازه ۶ تا ۲۰ هرتز را مورد بررسی قرار می‌دهیم. فیلتر با مرتبه ۸۰ نسبت به مرتبه ۵۰۰، فرکانس‌های پایین را کمتر تضعیف کرده است. با توجه به نرخ نمونه‌برداری ۲۵۶ هرتز، فیلتر با درجه ۲۲۰ انتخاب می‌شود. این فیلتر تضعیف مناسب‌تری نسبت به مرتبه هشتاد دارد و در این بازه فاز آن خطی و تعداد عناصر[1] کمتری نسبت به مرتبه پانصد دارد. برای پیداکردن باند عبور فیلتر از خروجی مرحله کپستروم در پیش‌بینی (ضریب نخست کپستروم) استفاده می‌کنیم. شکل (۱۶)، ضریب نخست کپستروم بیمار نخست با فیلتر ۶ تا ۲۰ هرتز را نمایش می‌دهد. شکل (۱۷)، همان بیمار با فیلتر ۳ تا ۱۵ هرتز بوده و حمله صرعی در ثانیه ۳۶۰ رخ داده است. همانطور که مشاهده می‌کنیم تفاوت و تشخیص تشنج با فیلتر ۶ تا ۲۰ هرتز آسان‌تر است. برای نمونه دامنه دوره ایکتال در شکل (۱۶) تقریباً عدد ۸، اینترایکتال نزدیک به ۱۵ و مصنوعات نزدیک ۱۱ هستند در حالی که در شکل (۱۷) دوره ایکتال به‌طورتقریبی روی عدد ۹، اینترایکتال نزدیک به ۱۴ و مصنوعات نزدیک ۱۱ قرارگرفته‌اند. تفاوت مقدار ایکتال و اینترایکتال در شکل (۱۶) بیشتر بوده و تشخیص راحت‌تر صورت می‌گیرد. باندهای فرکانسی ۳ تا ۱۰ هرتز و ۶ تا ۱۵ هرتز نیز بررسی شده‌اند. در نهایت بازه ۶ تا ۲۰ را انتخاب می‌کنیم. بعد از انتخاب پارامترها ابتدا پنج ثانیه داده دریافت شده، سپس داده به‌صورت یک‌ثانیه‌ای (پنجره پنج ثانیه با هم‌پوشانی ٪۸۰) دریافت می‌شود. در واقع هدف ما از ذکرکردن نحوه به‌دست‌آوردن پارامترها، فهم عمیق‌تر و دید بهتر خواننده نسبت به تأثیر این نوع پارامترها است. مقادیر به‌دست‌آمده پارامترها، برای همه داده‌های موجود در این مطالعه، مناسب است و وابسته به بیمار نیست.

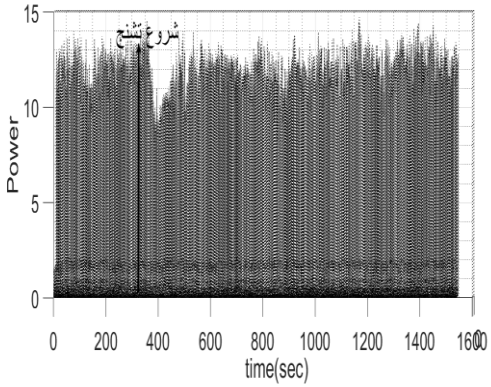

(شکل-۱۶): ضریب نخست کپستروم بیمار نخست با فیلتر ۶ تا ۲۰ هرتز (حمله در ثانیه ۳۶۰)

(Figure-16): The first Cepstrum coefficient of the first patient with a filter6_20 Hz (seizure in360 secs)

۳-۵- پیش‌بینی حمله صرعی

مراحل پیش‌بینی کوتاه‌مدت حمله صرعی عبارتند از: تبدیل موجک گسسته، مدل خود همبسته، کپستروم، فیلتر میانه و مقایسه سری‌ها و متوسط‌گیری و پوش منحنی. خروجی بلوک پیش‌پردازش، دو سیگنال زمانی به‌دست‌آمده از دو کانال است. به‌عنوان مثال دو سیگنال زمانی ۲۵ دقیقه‌ای داریم، در این مرحله این دو سیگنال با روش تبدیل موجک گسسته تجزیه می‌شوند که می‌توان از دستور wavedec در متلب استفاده کرد. با استفاده از موجک مادر دابیچی چهار سیگنال به شش سطح جزئی D1-D6 و یک سطح تقریب نهایی A6 تفکیک می‌شوند. با توجه به دو ورودی مرحله موجک، خروجی آن‌ها دوازده سیگنال سطح جزئی خواهیم داشت. مرحله بعد مدل‌سازی خود همبسته است که بر روی دوازده سیگنال سطح جزئی به‌دست‌آمده از بلوک موجک، با پنجره‌بندی اعمال می‌شوند.

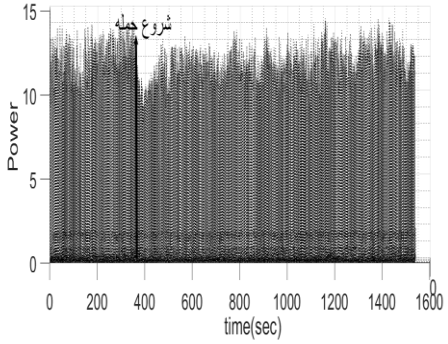

(شکل-۱۷): ضریب نخست کپستروم بیمار نخست با فیلتر ۳ تا ۱۵ هرتز (حمله در ثانیه ۳۶۰)

(Figure-17): The first Cepstrum coefficient of the first patient with a filter3_15 Hz (seizure in360 secs)

[1] Element

[Downloaded from jsdp.rcisp.ac.ir on 2026-10-15]

[DOI: 10.61186/jsdp.19.4.149]

همان‌طور که گفته شد این مرحله با روش پنجره پیشرو انجام می‌شود، به‌دلیل اینکه طول دوره زمان مداخله حداقل چند ثانیه است؛ برای انجام پیش‌بینی، طول پنجره پانصد نمونه (یک تا دو ثانیه) با هم‌پوشانی ۷۵ درصد در نظر گرفته می‌شود. برای پیداکردن مدل خودهمبسته از روابط بازگشتی (۶) و (۹) استفاده کرده و یا از دستور RecursiveAR در نرم‌افزار متلب استفاده می‌شود. مقدار ضریب فراموشی در رابطه (۷) را ۰/۹۹ قرار داده و جهت پیداکردن مرتبه مناسب مدل خود همبسته از معیارهای تخمین مرتبه مدل، معیار اطلاعات Akaike [1]، خطای پیش‌بینی نهایی[2] و تابع هزینه[3] که در [49] آمده‌است استفاده می‌شود. با توجه به سه معیاری که درقبل اشاره کردیم، مناسب‌ترین مرتبه برای مدل خود همبسته، هشت است. مرتبه هشت به این معنی است که به‌ازای هر نمونه یک بردار هشت‌تایی خواهیم داشت، درنتیجه تخمین سیگنال با هشت ضریب مدل خودهمبسته ساخته می‌شود. به این صورت که تخمین مدل خودهمبسته هر کدام از پنجره‌های داده به‌ترتیب محاسبه شده و درنتیجه ۱۲ سیگنال ۲۵ دقیقه‌ای تخمین زده شده، خواهیم داشت که به بلوک بعد وارد می‌شوند. این مرحله نیز ابتدا خروجی‌های مرحله قبل با پنجره‌هایی با طول پانصد نمونه و هم‌پوشانی ۷۵ درصد پنجره‌بندی، سپس ضرایب کپستروم هر پنجره محاسبه می‌شوند. به‌ازای هر پنجره پانصدنمونه‌ای ۵۰۱ ضریب کپستروم به‌دست می‌آید. ضرایب کپستروم از رابطه (۱۴) یا دستور rceps متلب، محاسبه می‌شوند. شکل (۱۸) ضریب نخست، شکل (۱۹) ضریب دوم و شکل (۲۰) ضریب ۱۲۹ کپستروم کانال اصلی بیمار نخست است. همان‌طورکه مشاهده می‌شود، ضریب نخست می‌تواند دوره ایکتال را تشخیص دهد و لزومی به استفاده از دیگر ضرایب وجود ندارد. البته اگر در بلوک نهایی از روش‌های دسته‌بندی استفاده شود، استفاده از چندین ضریب موجب بهبود نتایج خواهد شد. اما در الگوریتم پیشنهادی روش آستانه‌گذاری استفاده شده است؛ درنتیجه همانند مرحله قبل، ضریب نخست کپستروم هر کدام از پنجره‌های داده به‌ترتیب محاسبه شده و درنتیجه ۱۲ سیگنال ۲۵ دقیقه‌ای به‌دست‌آمده از ضریب نخست کپستروم خواهیم داشت.

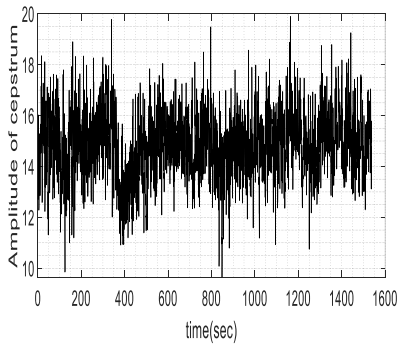

(شکل-۱۸): ضریب نخست کپستروم (حمله در ثانیه ۳۶۰)

(Figure-18): The first Cepstrum coefficient (seizure in360 secs)

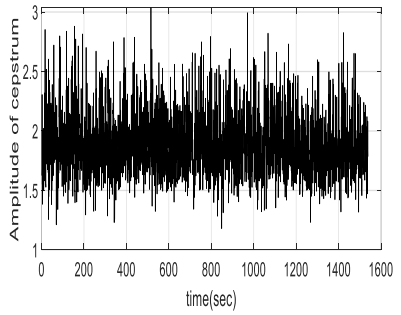

(شکل-۱۹): ضریب دوم کپستروم (حمله در ثانیه ۳۶۰)

(Figure-19): The second Cepstrum coefficient (seizure in360 secs)

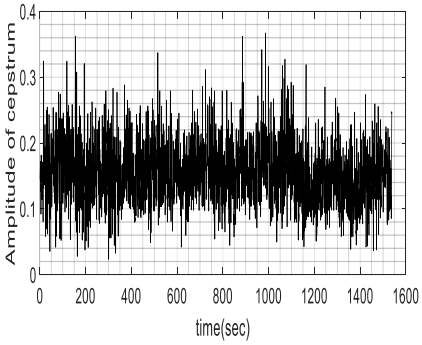

(شکل-۲۰): ضریب ۱۲۹ کپستروم (حمله در ثانیه ۳۶۰)

(Figure-20): The 129th Cepstrum coefficient (seizure in360 secs)

درواقع شش سیگنال نخست مربوط به ضریب نخست کپستروم کانال اصلی و شش سیگنال دوم مربوط به ضریب نخست کپستروم کانال مقابل است. مرحله بعد فیلتر میانه و مقایسه سری پس‌زمینه نسبت به سری پیش‌زمینه است. دوره پس‌زمینه با استفاده از شش سیگنال نخست ناشی از کانال اصلی به‌دست می‌آید. هر نمونه در دوره پس‌زمینه (FG_k) با رابطه (۱۶) محاسبه می‌شود طبق این رابطه ابتدا نمونه‌ها مربع می‌شوند، سپس از فیلتر میانه عبور می‌کنند. در رابطه (۱۶)، q برابر یک ثانیه که همان طول پنجره است. حال شاخص پس‌زمینه را با شاخص مرجع (پیش‌زمینه) مقایسه می‌کنیم، درواقع تغییرات دوره پس‌زمینه نسبت به دوره پیش‌زمینه سنجیده می‌شود. دوره پیش‌زمینه از هر دو

[1] Akaike Information Criterion (AIC)
[2] Final Prediction Error (FPE)
[3] Cost Function

[Downloaded from jsdp.rcisp.ac.ir on 2026-10-15]
[DOI: 10.61186/jsdp.19.4.149]

کانال اصلی و مقابل طبق رابطه (۱۷) به‌دست می‌آید. در رابطه (۱۷) $n = 0,1,2,...$ ، $s = 0.5$ ثانیه، q_2 برابر یک ثانیه و $\lambda = 0.99$ است. FG_k و $BG_k^{(1)}$ مربوط به کانال نخست و $BG_k^{(2)}$ مربوط به کانال دوم هستند و هر کدام دارای ۶ سیگنال خواهند بود. نسبت‌ها از رابطه (۱۸) به‌دست می‌آیند. در رابطه (۱۸) $i = 1, j = 1,2$ شماره کانال و $1 \le j \le 2$ است. خروجی $r_k^{(i=1)}$ دارای ۱۲ سیگنال ۲۵ دقیقه‌ای خواهد بود. هر کدام از سیگنال‌ها با پنجره‌هایی به‌طول دو ثانیه و هم‌پوشانی یک ثانیه تفکیک شده و متوسط هر پنجره محاسبه می‌شود و ۱۲ سیگنال ۲۵ دقیقه‌ای متوسط‌گیری شده خواهیم داشت. مرحله آخر به‌دست‌آوردن پوش بالا منحنی است که روی خروجی‌های مرحله متوسط‌گیری انجام می‌شود. می‌توان از دستور envelope در متلب استفاده کرد. متغیری که در این دستور باید مشخص شود، تعداد نمونه‌های بین دو قله نمودار است و در اینجا مقدار ۳۰ مناسب بوده است.

۴-۵- آستانه‌گذاری و ارزیابی عملکرد روش پیشنهادی

مقدار آستانه با کمترین خطا و مناسب‌ترین تاخیر از زمان شروع تشنج در داده‌های آموزش مشخص شده و روی داده‌های آزمایش اعمال می‌شود. به این صورت که اگر یکی از سیگنال‌های خروجی یک بیمار که شامل: دوره‌های اینترایکتال، زمان مداخله و ایکتال است؛ مقدار دامنه سیگنال در دوره زمان مداخله نسبت به دوره اینترایکتال تعیین کننده مقدار آستانه است. دوره‌های ایکتال یا حمله از ۳۰ ثانیه تا ۱۸۰ ثانیه هستند. اگر دوره ایکتال به طور متوسط ۱۰۰ ثانیه فرض شود، می‌توان داده‌های اینترایکتال را به بازه‌های ۱۰۰ ثانیه‌ای تقسیم کرد که همان بازه وقوع حمله است. نحوه آستانه‌گذاری در پیش‌بینی با توجه به ۱۲ سیگنال خروجی انجام می‌شود. ابتدا طبق داده آموزش آستانه‌ها برای هر سیگنال مشخص می‌شود. که ممکن است در برخی از سیگنال‌ها آستانه‌ای برای پیش‌بینی با خطای کم وجود نداشته باشد درنتیجه از این سیگنال برای آموزش استفاده نمی‌شود. آستانه‌های مشخص‌شده در داده‌های آزمایش اعمال می‌شوند. با توجه به تعداد آستانه مشخص‌شده از داده‌های آموزش، در صورتی که بیش از نیمی از دامنهٔ داده‌های آزمایشی، از آستانه عبور کنند دوره زمان مداخله در نظر گرفته می‌شود. برای نمونه اگر در دادهٔ آموزشی از ۱۲ سیگنال، ۷ سیگنال دارای آستانه تأیید شده داشته باشیم باید دامنه ۴ سیگنال از آستانه‌ها عبور کنند. برای هر بیمار این روند طی می‌شود. برای نمونه نتایج پیش‌بینی یک بیمار را آورده‌ایم. شکل (۲۱) سیگنال نوار مغزی سطحی پردازش نشده است که دوره زمان مداخله در ثانیه ۳۶۰ رخ می‌دهد. همان‌طورکه گفته شد ۱۲ خروجی خواهیم داشت. شکل (۲۲) خروجی نخست که از مقایسه کانال نخست نسبت به خودش و ناشی از ضریب جزئی نخست در مرحله موجک است. که نمودار ۱ همان پوش منحنی ۲ است و مقدار آستانه برپایهٔ نمودار ۱ مشخص می‌شود. مقدار آستانه برای اینکه خطا نداشته باشیم ۱/۲۲ در نظر گرفته می‌شود و زمان پیش‌بینی ثانیه ۳۷۰ است. شکل (۲۳) خروجی هفتم که از مقایسه کانال نخست نسبت به کانال دوم و ناشی از ضریب جزئی نخست در مرحله موجک است و نمودار ۱ همان پوش منحنی ۲ است. با توجه به شکل می‌توان دریافت که این خروجی دوره زمان مداخله را تشخیص نداده است. درنتیجه از این خروجی در این بیمار برای داده آزمایش استفاده نمی‌شود. مقادیر آستانه برای ۱۲ خروجی داده آموزش به همین صورت مشخص شده و در داده آزمایش بررسی می‌شوند. طبق موارد گفته شده معیارهای حساسیت، اختصاص‌پذیری، دقت و نرخ مثبت کاذب برای پیش‌بینی محاسبه شده و در جدول (۲) آمده است.

(جدول-۲): نتایج به‌دست آمده از روش پیشنهادی پیش گویی

(Table-2): Results obtained from the proposed prediction method

بیماران	حساسیت٪	اختصاص‌پذیری٪	دقت ٪	FPR	متوسط زمان پیش‌بینی (ثانیه)
بیمار نخست	-	۱۰۰	-	۰	-
بیمار دوم	۷۵	۸۸/۳	۸۶/۹	۴/۱۹	۴۱
بیمار سوم	۱۰۰	۹۸/۴	٪۹۸/۵	۰/۵	۵
بیمار چهارم	۱۰۰	۱۰۰	۱۰۰	۰	۲۰
بیمار پنجم	-	۱۰۰	-	۰	-
بیمار ششم	-	۱۰۰	-	۰	-
بیمار هفتم	۱۰۰	۱۰۰	۱۰۰	۰	۲۷

[Downloaded from jsdp.rcisp.ac.ir on 2026-10-15]

[DOI: 10.61186/jsdp.19.4.149]

بیمار هشتم	۵۰	۸۸/۴	۸۶/۳	۳/۹	۲
بیمار نهم	-	۱۰۰	-	۰	-
بیمار دهم	۱۰۰	۸۱/۴	۸۴/۳	۶/۶	۱۰
نتایج نهایی	**۸۷/۵**	**۹۵/۶**	**۹۲/۶**	**۱/۵۰**	**۱۸/۵**

۵-۵- ارزیابی عملکرد روش پیشنهادی با مدل سیگنال صرعی بزرگسال

با توجه به روابط بخش ۴ داده بزرگسال تولید می‌شود. جزئیات داده‌هایی که در تولید مدل استفاده شده‌اند، در جدول (۳) آورده شده‌است. مدل شامل دوره‌های ایکتال اینترایکتال و زمان مداخله است. می‌توان روش پیشنهادی را با این داده مدل آزمایش کرد. برای نمونه نتایج پیش‌بینی روش پیشنهادی در شکل (۲۴) آمده‌است که قادر به پیش‌بینی بوده است.

(جدول_۳) اطلاعات مدل نوار مغزی از قبیل تعداد تشنج ها، میزان داده اینترایکتال و ایکتال آموزش و تست
(Table_3) EEG model information such as number of seizures, amount of Inter_Ictal and Ictal data training and testing

	تعداد تشنج آموزش	میزان داده آموزش اینترایکتال (ثانیه)	میزان داده آموزش ایکتال (ثانیه)	تعداد تشنج آزمایش	میزان داده آزمایش اینترایکتال (ثانیه)	میزان داده آزمایش ایکتال (ثانیه)
مدل EEG	۲	۵۷۸۰	۲۰۰	۳	۲۰۱۵	۶۰۰

۵-۶- مقایسه با روش های دیگر

مطالعات بسیار کمی در زمینه پیش‌بینی کوتاه‌مدت حمله صرع انجام شده‌است. روش‌های [35] و [36] بر روی داده‌های نوار مغزی موجود اعمال شده و متوسط نتایج مقایسه با روش پیشنهادی در جدول (۷) آمده است. نتایج روش [35] که درقبل توضیح داده شد، در جدول (۴) نشان داده شده است. علت تفاوت نتایج [35] و نتایج به‌دست‌آمده از این مرجع، داده‌های متفاوت است.

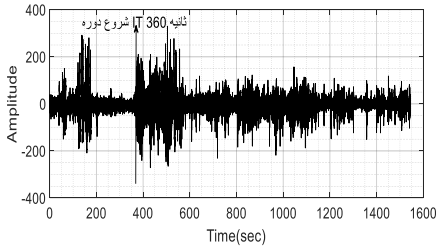

(شکل-۲۱): سیگنال یک بیمار بدون پردازش، شروع دوره زمان مداخله ثانیه ۳۶۰
(Figure-21): Signal of a patient without processing, start of IT period in 360

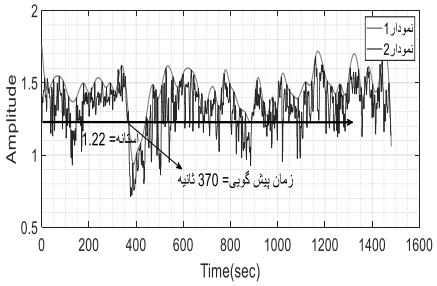

(شکل-۲۲): نمودار ۱ خروجی نخست که از مقایسه کانال نخست نسبت به خودش و ناشی از ضریب جزئی نخست در مرحله موجک بوده و نمودار ۱ پوش منحنی ۲ است، مقدار آستانه ۱/۲۲ و زمان پیش بینی ثانیه ۳۷۰ به‌دست آمده است.
(Figure-22): The diagram 1 of the first output, which is the result of comparing the first channel to itself and resulting from the first partial coefficient in the wavelet and the diagram 1 is envelope curve of the diagram 2, threshold value is 1.22 and a prediction time in 370 secs.

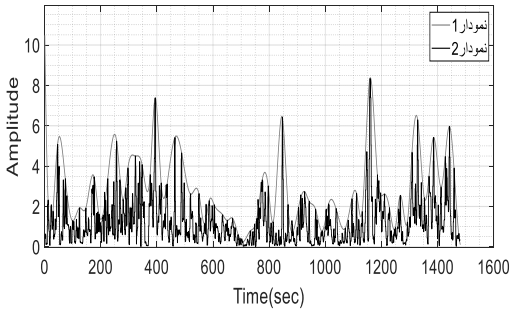

(شکل-۲۳): نمودار ۱ خروجی هفتم که از مقایسه کانال نخست نسبت به کانال دوم و ناشی از ضریب جزئی نخست در مرحله موجک بوده و نمودار ۱ پوش منحنی ۲ است، قادر به تشخیص دوره زمان مداخله نبوده و در نظر گرفته نمی‌شود.
(Figure-23): The diagram 1 of the seventh output, which is from the comparison of the first channel with the second channel and resulting from the first partial coefficient in the wavelet and the diagram 1 is envelope curve of the diagram 2, is not able to recognize the IT period and is not considered.

[Downloaded from jsdp.rcisp.ac.ir on 2026-10-15]
[DOI: 10.61186/jsdp.19.4.149]

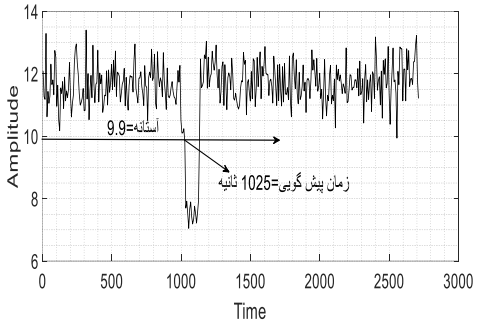

(شکل-۲۴): خروجی بلوک پیش بینی با روش پیشنهادی روی مدل صرعی بزرگسال (شروع دوره زمان مداخله در ثانیه ۱۰۰۰ و شروع دوره ایکتال در ثانیه ۱۰۳۰)

(Figure-24): Prediction block output with the proposed method on the adult epileptic model (start of IT period in 1000 secs and start of ictal period in 1030 secs)

داده مورد استفاده در این مطالعه نوار مغزی سطحی واقعی طولانی‌مدت با مصنوعات بوده و داده [35]، نوار مغزی عمیق بدون مصنوعات است. همان‌طورکه در بخش‌های قبل اشاره شد، مرجع [36] سه الگوریتم طبقه‌بندی ارائه کرده است که ما روش خود را با طبقه‌بندی مبتنی بر آستانه سنجیده‌ایم. به‌دلیل محدودیت طول مجموعه داده موجود، طول پست ایکتال را ۱۵۰ ثانیه در نظر گرفته‌ایم، در حالی که در [36] ۱۰۰۰ ثانیه است. ۶۰٪ از حجم داده هر بیمار جهت آموزش و ۵۰٪ از تشنج‌ها با انتخاب تصادفی، تشنج‌های آموزشی آن بیمار در نظر گرفته شده است، بنابراین چهار بیمار از مجموعه داده حذف می شوند، جزئیات نوار مغزی بیماران در جدول (۵) آورده شده است. از آن‌جایی که دو ویژگی شاخص تأخیر فاز[1] و شاخص تأخیر فاز وزن‌دار[2] در سه طول مختلف ۱۵۰، ۲۰۰ و ۳۰۰ ثانیه بررسی شده‌اند، متوسط دوره ایکتال ۷۰ ثانیه و درنتیجه طول بازه وقوع حمله به‌ترتیب ۳۷۰، ۴۲۰ و ۵۲۰ به‌دست می‌آیند (برای طول ۱۵۰: متوسط طول ایکتال + ۱۵۰+ پست ایکتال = ۳۷۰). ویژگی و طولی که بهترین متوسط نتایج را در طول اجراها برای هر بیمار داشته است در جدول (۶) آورده‌ایم. با توجه به نتایج جدول (۷) می‌توان دریافت که حساسیت، اختصاص‌پذیری، دقت و نرخ مثبت کاذب روش پیشنهادی بر روش‌های [35] و [36] برتری دارد. دقت، نرخ مثبت کاذب و زمان پیش‌بینی روش پیشنهادی به‌ترتیب ۹۲/۶، ۱/۵ و ۱۸/۵ ثانیه هستند. زمان پیش‌بینی ما جهت مدیریت نخستیه حملات صرع و کاهش رویدادهای تهدید کننده مناسب است و کمترین نرخ مثبت کاذب را دارد.

[1] Phase Lag Index (PLI)
[2] Weighted PLI (WPLI)

۶- بحث و نتیجه‌گیری

در این مطالعه، یک الگوریتم پیش‌بینی کوتاه‌مدت تشنج دربیماران با لوب تمپورال ارائه شد. ما در این روش، تغییرات رفتار ناحیه کانون صرع را در دوکانال ثبت مقابل در حوزه زمان ردیابی کردیم. ابتدا با استفاده از تبدیل موجک گسسته، داده را به امواج نوار مغزی تجزیه کردیم، سپس تغییرات مربوط به دوره زمان مداخله را با مدل خود همبسته و کپستروم تشخیص دادیم. برای بهبود نتایج پیش‌بینی و افزایش دقت، از روش‌های فیلتر میانه، متوسط‌گیری و پوش منحنی استفاده شد. جهت ساده‌سازی الگوریتم، استفاده از دو کانال، ضریب نخست کپستروم به‌عنوان مؤثرترین ضریب و روش آستانه‌گذاری به جای دسته‌بندی در نظر گرفته شد. مزیت دیگر الگوریتم توانایی کاهش مصنوعات است. مصنوعات در فرکانس‌های مختلف قرار دارند که با تبدیل موجک، جداسازی فرکانس انجام می‌شود. با توجه به اینکه مصنوعات دو کانال در زمان‌های یکسان و در یک کانال در زمان‌های متفاوت نابرابر هستند، مصنوعات با مقایسه کانال‌ها نسبت به خود و دیگری کاهش می‌یابند. در این مطالعه نتایج پیش‌بینی با مقادیر حساسیت ۸۷/۵٪، اختصاص‌پذیری ۹۵/۶٪، دقت ۹۲/۶٪ و نرخ مثبت کاذب ۱/۵۰ با متوسط زمان پیش‌بینی ۱۸/۵ ثانیه به‌دست آمده‌اند. اگر زمان پیش‌بینی بزرگتر از ۱۰ ثانیه در نظرگرفته شود، مقادیر حساسیت، اختصاص‌پذیری، دقت و نرخ مثبت کاذب به‌ترتیب ۶۳/۸٪ ۹۵/۶٪، ۹۰٪ و ۱/۵۰ به‌دست می‌آیند. نتایج تجربی ما و مقایسه با سایر روش‌ها نشان می‌دهد که روش پیشنهادی کارآمد، قابل اعتماد و مناسب برای پیش‌بینی کوتاه‌مدت تشنج است. این امر با دستیابی به دقت بالاتر از روش های دیگر و زمان پیش‌بینی مناسب برای ایجاد هشدار جهت عملیات درمانی است. برای اطمینان بیشتر، عملکرد الگوریتم بر روی مدل نوار مغزی صرعی بزرگسال بررسی شد و نتایج قابل قبولی به‌دست آورد. آزمایش الگوریتم روی تعداد بیماران بیشتر، جهت تأیید عملکرد آن به صورت بالینی پیشنهاد می‌شود.

سپاس و قدردانی

بر خود لازم می‌دانیم از خانم مهندس نازنین کلانتری‌نژاد، آقایان مهندس حسین الهامی مجد، مهندس نیما افضلی‌پور و دکتر جواد شیخ‌پور جهت مطالعه مقاله و کمک در ویراستاری و نگارش آن، سپاس‌گزاری کنیم.

[Downloaded from jsdp.rcisp.ac.ir on 2026-10-15]

[DOI: 10.61186/jsdp.19.4.149]

(جدول-۴): نتایج به‌دست‌آمده از روش مرجع[35]

(Table-4): Results obtained from the reference method [35]

بیماران	حساسیت ٪	اختصاص‌پذیری٪	دقت ٪	FPR	متوسط زمان پیش‌بینی (ثانیه)
بیمار نخست	۴۰/۴	-	-	۲۱/۲	-
بیمار دوم	۱۰۰	۷۶/۵	۷۸/۷	۸/۴۳	۳۸
بیمار سوم	۱۰۰	۹۳/۳	۹۳/۵	۲/۴	۲
بیمار چهارم	۱۰۰	۷۰	۷۱	۱۰/۷	۵۰/۵
بیمار پنجم	-	۹۰/۸	-	۳/۲	-
بیمار ششم	-	۱۰۰	-	۰	-
بیمار هفتم	۱۰۰	۲۸/۹	۳۱	۱۰/۴	۳۶/۵
بیمار هشتم	۰	۱۰۰	۹۲/۴	۰	
بیمار نهم	-	۴۲/۸	-	۲۰/۵	-
بیمار دهم	۵۰	۵۳/۸	۵۳/۳	۱۶/۶	۱/۵
نتایج نهایی	**۷۵**	**۶۹/۷**	**۷۰**	**۹/۳**	**۲۶/۲**

(جدول-۵): اطلاعات نوارهای مغزی بیماران پیش گویی از قبیل تعداد تشنج ها، میزان داده اینترایکتال و ایکتال آموزش و تست، استفاده شده در [36]

(Table-5): EEG model information such as number of seizures, amount of Inter_Ictal and Ictal data training and testing, used in [36]

بیماران	تعداد تشنج آموزش	تعداد تشنج آزمایش	میزان داده اینترایکتال (ثانیه)	میزان داده ایکتال (ثانیه)	تعداد اجراها
بیمار دوم	۳	۳	۵۵۰۳	۲۷۳	۵
بیمار سوم	۳	۲	۸۶۱۲	۳۷۶	۵
بیمار چهارم	۱	۱	۵۲۰۷	۲۲۱	۲
بیمار هفتم	۱	۱	۴۶۰۵	۱۷۲	۲
بیمار هشتم	۲	۲	۶۰۰۸	۴۱۶	۵
بیمار دهم	۲	۱	۳۵۲۰	۳۰۰	۳

(جدول-۶): نتایج به‌دست‌آمده از روش مرجع[36]

(Table-6): The best results obtained from the reference method [36]

بیماران	بهترین نتایج	حساسیت٪	اختصاص‌پذیری٪	دقت ٪	FPR	متوسط زمان پیش‌بینی (ثانیه)
بیمار دوم	شاخص تاخیر فاز-طول ۳۰۰	۶۹/۶	۴۴/۳	۵۱/۴۱	۳/۷۲	۱۹۹
بیمار سوم	شاخص تاخیر فاز وزن دار-طول ۲۰۰	۹۶/۳	۱۹/۶	۴۰/۴	۶/۱	۶۱/۷
بیمار چهارم	شاخص تاخیر فاز وزن دار-طول ۱۵۰، شاخص تاخیر فاز-طول ۱۵۰	۵۰	۷۷	۷۷	۱/۷۵	۸۲
بیمار هفتم	شاخص تاخیر فاز وزن دار-طول ۳۰۰، شاخص تاخیر فاز-طول ۳۰۰	۱۰۰	۶۴	۶۹	۲/۷۱	۲۶۴
بیمار هشتم	شاخص تاخیر فاز-طول ۳۰۰	۳۵/۳	۲۶/۳	۲۳/۷	۴/۹	۲۰۹
بیمار دهم	شاخص تاخیر فاز وزن دار-طول ۱۵۰	۰	۱۰۰	۷۴/۵	۰	-
متوسط نتایج [36]		۵۸/۵	۵۵	۵۶	۳/۱۹	۱۶۳

[Downloaded from jsdp.rcisp.ac.ir on 2026-10-15]

[DOI: 10.61186/jsdp.19.4.149]

(جدول-۷): مقایسه با سایر روش‌های پیش‌بینی تشنج که در مجموعه داده‌های موجود ما اعمال شده اند.

(Table-7): Comparison with other seizure prediction methods applied to our existed dataset

	حساسیت٪	اختصاص‌پذیری٪	دقت٪	FPR	متوسط زمان پیش‌بینی (ثانیه)
متوسط نتایج [35]	۷۵	۶۹/۷	۷۰	۹/۳	۲۶/۲
متوسط بهترین نتایج [36]	۵۸/۵	۵۵	۵۶	۳/۱۹	**۱۷۳/۸**
متوسط نتایج روش پیشنهادی	**۸۷/۵**	**۹۵/۶**	**۹۲/۶**	**۱/۵۰**	۱۸/۵۲

۷- مراجع 7- References

[1] S. Engelborghs, R. D'hooge, and P. De Deyn, "*Pathophysiology of epilepsy*," Acta neurologica belgica, vol.100, pp. 201-213, .2000

[2] E. Alickovic, J. Kevric, and A. Subasi, "*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, vol. 39, pp. 94-102, .2018

[3] E. B. Assi, D. K. Nguyen, S. Rihana, and M. Sawan, "*Towards accurate prediction of epileptic seizures: A review*," Biomedical Signal Processing and Control, vol. 34, pp. 144-157, .2017

[4] H. O. Luders, "*Textbook of epilepsy surgery: CRC Press*", 2008

[5] A. S. Zandi, R. Tafreshi, M. Javidan, and G. A. Dumont, "*Predicting epileptic seizures in scalp EEG based on a variational Bayesian Gaussian mixture model of zero-crossing intervals*," IEEE Transactions on Biomedical Engineering, vol. 60, pp. 1401-1413, 2013.

[6] C. Teixeira, B. Direito, H. Feldwisch-Drentrup, M. Valderrama, R. Costa, C. Alvarado-Rojas, et al., "*EPILAB: A software package for studies on the prediction of epileptic seizures*," Journal of Neuroscience Methods, vol. 200, pp. 257-271, .2011

[7] H. G. Daoud, A. M. Abdelhameed, and M. Bayoumi, "*Automatic epileptic seizure detection based on empirical mode decomposition and deep neural network*," in 2018 IEEE 14th International Colloquium on Signal Processing &Its Applications (CSPA), pp. 182-186, 2018

[8] M. Winterhalder, B. Schelter, T. Maiwald, A. Brandt, A. Schad, A. Schulze-Bonhage, et al., "*Spatio-temporal patient–individual assessment of synchronization changes for epileptic seizure prediction*," Clinical neurophysiology, vol. 117, pp. 2399-2413, .2006

[9] C. Guerrero-Mosquera, A. M. Trigueros, and A. Navia-Vazquez, "*EEG signal processing for epilepsy*," in Epilepsy-Histological, electroencephalographic and psychological aspects, ed: IntechOpen, .2012

[10] J. Gotman and P. Gloor, "*Automatic recognition and quantification of interictal epileptic activity in the human scalp EEG*," Electroencephalography and clinical neurophysiology, vol. 41, pp. 513-529, .1976

[11] J. Gotman, "*Automatic recognition of epileptic seizures in the EEG*," Electroencephalography and clinical Neurophysiology, vol. 54, pp. 530-540, .1982

[12] G. Harding, "An automated seizure monitoring system for patients with indwelling recording electrodes," *Electroencephalography and clinical Neurophysiology*, vol. 86, pp. 428-437, .1993

[13] S. Mousavi, M. Niknazar, and B. V. Vahdat, "*Epileptic seizure detection using AR model on EEG signals*," in 2008 Cairo International Biomedical Engineering Conference, 2008, pp. 1-4

[14] L. Chisci, A. Mavino, G. Perferi, M. Sciandrone, C. Anile, G. Colicchio, et al., "*Real-time epileptic seizure prediction using AR models and support vector machines*," IEEE Transactions on Biomedical Engineering, vol. 57, pp. 1124-1132, .2010

[15] S. Mohamadi, H. Amindavar, and S. A. T. Hosseini, "*ARIMA-GARCH modeling for epileptic seizure prediction*," in 2017 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), 2017, pp. .994-998

[16] M. Bozek-Juzmicki, D. Colella, and G. M. Jacyna, "*Feature-based epileptic seizure detection and prediction from ECoG recordings*," in Proceedings of IEEE-SP International Symposium on Time-Frequency and Time-Scale Analysis, 1994, pp. 564-567

[17] P.-N. Yu, S. A. Naiini, C. N. Heck, C. Y. Liu, D. Song, and T. W. Berger, "*A sparse Laguerre-Volterra autoregressive model for seizure prediction in temporal lobe epilepsy*," in 2016 38 th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), pp. .1664-1667, 2016

[Downloaded from jsdp.rcisp.ac.ir on 2026-10-15]

[DOI: 10.61186/jsdp.19.4.149]

[۱۸] س. نسائی، ا. شرافت، "پیش بینی وقوع حمله صرع با استفاده از در حوزه زمان فاز تطابق تحلیل فرکانس،" اردیبهشت ۱۳۹۰.

[18] S. Nesaei, AR. Sharafat, " *Epileptic seizure prediction based on phase synchronization analysis in time-frequency domain*," in 2011 19th Iranian Conference on Electric Engineering (ICEE), pp. 3364-3369, 2011

[19] F. Mormann, K. Lehnertz, P. David, and C. E. Elger, "*Mean phase coherence as a measure for phase synchronization and its application to the EEG of epilepsy patients*," Physica D: Nonlinear Phenomena, vol. 144, pp. 358-369, .2000

[20] M. Le Van Quyen, J. Soss, V. Navarro, R. Robertson, M. Chavez, M. Baulac, et al., "*Preictal state identification by synchronization changes in long-term intracranial EEG recordings*," Clinical Neurophysiology, vol. 116, pp. 559-568, .2005

[21] B. Schelter, M. Winterhalder, T. Maiwald, A. Brandt, A. Schad, A. Schulze-Bonhage, et al., "*Testing statistical significance of multivariate time series analysis techniques for epileptic seizure prediction*," Chaos: An Interdisciplinary Journal of Nonlinear Science, vol. 16, p. 013108, .2006

[22] J. R. Williamson, D. W. Bliss, D. W. Browne, and J. T. Narayanan, "*Seizure prediction using EEG spatiotemporal correlation structure*," Epilepsy & Behavior, vol. 25, pp. 230-238, .2012

[23] X. Huang, W. Wang, X. Sun, Y. Chen, L. Li, Y. Deng, et al., "*Model research for epileptic prediction based on improved chaos operator of Lyapunov*," in 2009 3rd International Conference on Bioinformatics and Biomedical Engineering, pp. .1-4, 2009

[24] L. Tong, W. Wang, N. Zhao, and X. Huang, "*The method evaluation for preictal prediction of epilepsy with strong-noise EEG and simulation of automatic drug release system*," in 2010 3rd International Conference on Biomedical Engineering and Informatics, pp. .1054-1058, 2010

[25] S. Wang, W. A. Chaovalitwongse, and S. Wong, "*A novel reinforcement learning framework for online adaptive seizure prediction*," in 2010 IEEE International Conference on Bioinformatics and Biomedicine (BIBM), pp. 499, 2010

[26] C. A. Teixeira, B. Direito, M. Bandarabadi, M. Le Van Quyen, M. Valderrama, B. Schelter, et al., "*Epileptic seizure predictors based on computational intelligence techniques: A comparative study with ۲۷۸patients*,"

Computer methods and programs in biomedicine, vol. 114, pp. 324-336 , 2014

[27] B. Hjorth, "*EEG analysis based on time domain properties*," Electroencephalography and clinical neurophysiology, vol. 29, pp. 306-310, .504, 1970

[28] C. Sudalaimani, S. Asha, K. Parvathy, T. E. Thomas, P. Devanand, P. Sasi, et al., "*Use of electrographic seizures and interictal epileptiform discharges for improving performance in seizure prediction*," in 2015 IEEE Recent Advances in Intelligent Computational Systems (RAICS), 2015, pp. .229-234

[29] M. A. F. Harrison, I. Osorio, M. G. Frei, S. Asuri, and Y.-C. Lai, "*Correlation dimension and integral do not predict epileptic seizures*," Chaos: An Interdisciplinary Journal of Nonlinear Science, vol. 15, p. 033106, .2005

[30] L. Boubchir and B. Boashash, "*Wavelet denoising based on the MAP estimation using the BKF prior with application to images and EEG signals*," IEEE Transactions on signal processing, vol. 61, pp. 1880-1894, .2013

[31] A. K. Tafreshi, A. M. Nasrabadi, and A. H. Omidvarnia, "*Empirical mode decomposition in epileptic seizure prediction*," in 2008 IEEE International Symposium on Signal Processing and Information Technology, pp. .275-280, 2008

[32] C. Kamath, "*Automatic seizure detection based on Teager Energy Cepstrum and pattern recognition neural networks*," QScience Connect, vol. 2014, p. 1, .2014

[33] C. Kamath, "*Comparison of baseline cepstral vector and composite vectors in the automatic seizure detection using probabilistic neural networks*," ISRN Biomedical engineering, vol. 2013, .2013

[34] H. Ren, J. Qu, Y. Chai, L. Huang, and Q. Tang, "*Cepstrum Coefficient Analysis from Low-Frequency to High-Frequency Applied to Automatic Epileptic Seizure Detection with Bio-Electrical Signals*," Applied Sciences, vol. 8, p. 1528, .2018

[35] I. Osorio, M. G. Frei, and S. B. Wilkinson, "*Real-time automated detection and quantitative analysis of seizures and short-term prediction of clinical onset*," Epilepsia, vol. 39, pp. 615-627, .1998

[36] P. Detti, G. Z. M. de Lara, R. Bruni, M. Pranzo, F. Sarnari, and G. Vatti, "*A patient-specific approach for short-term epileptic seizures prediction through the analysis of EEG synchronization*," *IEEE Transactions on Biomedical Engineering*, vol. 66, pp. 1494-1504, 2018.

[37] H. Daoud and M. A. Bayoumi, "*Efficient epileptic seizure prediction based on deep*

[Downloaded from jsdp.rcisp.ac.ir on 2026-10-15]

[DOI: 10.61186/jsdp.19.4.149]

learning," IEEE transactions on biomedical circuits and systems, vol. 13, pp. 804-813, 2019.

[38] C. Panayiotopoulos, "*Epileptic syndromes and their treatment*," Neonatal Seizures, pp. 185-206, .2007

[۳۹] ف. شایق، ف. قاسمی، ر. امیر فتاحی، س. صدری، ک. انصاری اصل، "پیش‌گویی برخط و تک‌کاناله وقوع حمله‌های صرعی با ارائه الگوی تولید صرع بر روی سیگنال‌های depth-EEG با استفاده از فیلتر کالمن توسعه‌یافته،" فصل‌نامه علمی پژوهشی پردازش علائم و داده‌ها، شماره ۱، پیاپی ۳۵، ۱۳۹۷

[39] F. Shayegh, F. Ghasemi, R. Amirfattahi, S. Sadri, K. Ansariasl, " *Online single-channel seizure prediction, based on seizure gensis model of depth-EEG signals using extended Kalman filter*," JSDP, pp. 3-27, 2019

[40] L. Hao, R. Ghodadra, and N. V. Thakor, "*Quantification of brain injury by EEG cepstral distance during transient global ischemia*," in Proceedings of the 19th Annual International Conference of the IEEE Engineering in Medicine and Biology Society.'Magnificent Milestones and Emerging Opportunities in Medical Engineering'(Cat. No. 97CH36136), pp. .1205-1206, 1997

[41] M. Le Van Quyen, "*Anticipating epileptic seizures: from mathematics to clinical applications*," Comptes rendus biologies, vol. 328, pp. 187-198, .2005

[42] P. Ong, Z. Zainuddin, and K. H. Lai, "*A novel selection of optimal statistical features in the DWPT domain for discrimination of ictal and seizure-free electroencephalography signals*," Pattern Analysis and Applications, vol. 21, pp. 515-527, .2018

[43] S. Haykin, "*Adaptive filter theory*," .2015

[44] L. R. Rabiner and R. W. Schafer, "*Introduction to digital speech processing*," Foundations and Trends® in Signal Processing, vol. 1, pp. 1-194, 2007.

[45] M. Roessgen, A. M. Zoubir, and B. Boashash, "*Modeling of newborn EEG data for seizure detection*," in Advanced Signal Processing Algorithms, pp. .101-112, 1995

[46] P. Celka and P. Colditz, "*Nonlinear nonstationary Wiener model of infant EEG seizures*," IEEE Transactions on Biomedical Engineering, vol. 49, pp. 556-564, .2002

[47] M. Roessgen, A. M. Zoubir, and B. Boashash, "*Seizure detection of newborn EEG using a model-based approach*," IEEE Transactions on Biomedical Engineering, vol. 45, pp. 673-685, .1998

[48] d. S. F. Lopes, A. Hoeks, H. Smits, and L. Zetterberg, "*Model of brain rhythmic activity. The alpha-rhythm of the thalamus*," Kybernetik, vol. 15, p. 27, .1974

[49] T. Söderström and P. Stoica, "*system identification*," .2001

بهار تاج‌الدینی مدارک کارشناسی و کارشناسی ارشد خود را به‌ترتیب در مهندسی برق-مخابرات و مخابرات-سیستم در سال‌های ۱۳۹۴ و ۱۳۹۸ هر دو از دانشگاه شهید باهنر کرمان دریافت کرد. زمینه‌های پژوهشی مورد علاقه ایشان پردازش سیگنال و تحلیل سیگنال‌های مغزی است.
نشانی رایانه ایشان عبارت است از:
tajadinibahar@yahoo.com

سعیدرضا صیدنژاد در حال حاضر دانشیار دانشکده مهندسی برق دانشگاه شهید باهنر کرمان است. زمینه‌های پژوهشی مورد علاقه ایشان پردازش سیگنال و مهندسی پزشکی است.
نشانی رایانه ایشان عبارت است از:
sseydnejad@uk.ac.ir

سهیلا رضاخانی مدرک پزشکی عمومی خود را در سال ۱۳۷۹ از دانشگاه علوم پزشکی شیراز دریافت کرد. ایشان تخصص مغز و اعصاب و فلوشیپ صرع-تشنج و الکتروانسفالوگرافی خود را در سال‌های ۱۳۹۰ و ۱۳۹۴ دریافت کرد. زمینه‌های پژوهشی مورد علاقه ایشان درمان بیماران با صرع مقاوم به دارو، بررسی سیگنال‌های مغزی و نیز انواع کاربردهای بالینی تحریک الکتریکی مغز است.
نشانی رایانه ایشان عبارت است از:
drrezakhani@gmail.com

[Downloaded from jsdp.rcisp.ac.ir on 2026-10-15]

[DOI: 10.61186/jsdp.19.4.149]