

# پیش‌بینی حملات صرعی در بیماران با صرع

## لوب تمپورال (TLE) بر اساس آنالیز

## کپستروم و مدل AR تعمیم‌یافته سیگنال

### EEG

بهار تاج‌الدینی<sup>۱\*</sup>، سعیدرضا سعیدنژاد<sup>۲</sup> و سهیلا رضاخانی<sup>۳</sup>

<sup>۱</sup> و <sup>۲</sup> بخش مهندسی برق، دانشکده فنی، دانشگاه شهید باهنر، کرمان، ایران

<sup>۳</sup> 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، به دلیل 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 به دلیل متناوب بودن 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؛ در نهایت 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، به ترتیب ۰.۹۲٪، ۱۸/۵ ثانیه به دست 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<sup>1\*</sup>, SaeidReza Seydnejad<sup>2</sup> & Soheila Rezakhani<sup>3</sup>

<sup>1,2</sup>Department of Electrical Engineering, Technical Faculty, Shahid Bahonar University, Kerman, Iran

<sup>3</sup>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].

\* Corresponding author

\* نویسنده عهده‌دار مکاتبات

سال ۱۴۰۱ شماره ۴ پایانی ۵۴

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



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.

از عوارض در بیماران مبتلا به صرع است. هدف اصلی درمان صرع رهایی از تشنج بدون اثرات نامطلوب بالینی است. این بیماران صدماتی را به دلیل ازدست رفتن هوشیاری یا تأخیر در واکنش هنگام شروع تشنج متحمل می‌شوند.

یکی از متدنخست‌ترین روش‌های درمان استفاده از داروهای ضد صرع<sup>۲</sup> است، درحالی‌که برای ۳۰٪ بیماران

<sup>2</sup> Antiepileptic Drugs (AED)

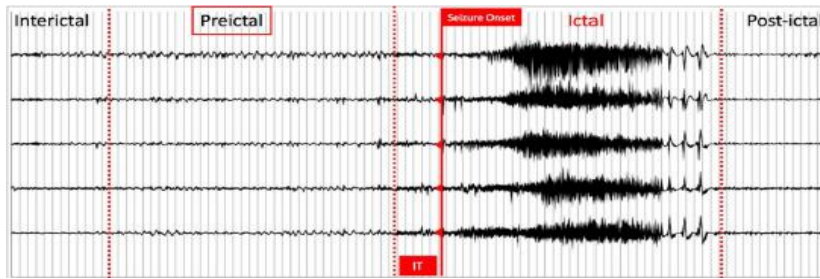
## ۱-مقدمه

بیش از پنجاه میلیون نفر از مردم جهان درگیر بیماری صرع هستند. بیماری صرع اختلال مزمن و طغیان عملکرد مغزی است که به علت تخلیه الکتریکی نامتعارف و بیش‌ازحد یاخته‌های عصبی<sup>۱</sup> مغز ایجاد شده و علائم آن حملات ناگهانی، بیهوشی موقت و تشنج متناوب است [1,2]. غیرقابل پیش‌بینی بودن وقوع تشنج‌ها منشأ مهمی

<sup>1</sup> Neuron

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

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



(شکل-1): نمونه‌ای از پنج کانال نوار مغزی صرعی [3]  
(Figure-1): An example of five epileptic EEG channels [3]

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].

به‌طور کلی مصنوعات به دو دسته فیزیولوژیک<sup>۱۱</sup> و غیر فیزیولوژیک تقسیم می‌شوند. مصنوعات فیزیولوژیکی به‌طور معمول از منابع داخل بدن سرچشمه می‌گیرند و می‌تواند شامل موارد حرکات چشم، نوار قلب<sup>۱۲</sup>، نوار عصب و عضله<sup>۱۳</sup> و غیره شود و مصنوعات غیر فیزیولوژیکی از منابع مختلفی مانند مصنوعات ابزارهای رقمی<sup>۱۴</sup> (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<sup>۱۵</sup> پایین‌گذر حذف کرد و برای حذف نوفه برق شهر می‌توان از پالایه پاسخ ضربه نامحدود<sup>۱۶</sup> میان‌گذر استفاده کرد. روش‌های مختلفی برای حذف مصنوعات از سیگنال نوار مغزی وجود دارد، به‌عنوان مثال می‌توان از روش تحلیل مؤلفه‌های مستقل<sup>۱۷</sup> استفاده کرد [9]. مطالعات متعددی جهت تشخیص و پیش‌بینی تشنج انجام شده است. مرجع [4] الگوریتم‌های تشخیص را در سه دسته:

- (۱) مسیر<sup>۱۸</sup>
- (۲) پیش طبقه‌بندی<sup>۱۹</sup>
- (۳) حالت<sup>۱</sup> در نظر می‌گیرد.

یک نظام<sup>۱</sup> پیش‌بینی قابل‌اعتماد بر اساس داده نوار مغزی<sup>۲</sup> می‌تواند امکان کنترل تشنج‌ها را به‌طور قابل‌توجهی افزایش داده و موجب بهبود زندگی و ایمنی بیماران شود [3]. یک داده نوار مغزی بیمار صرعی از پنج قسمت (شکل ۱) ایکتال<sup>۳</sup> (دوره حمله)، اینترایکتال<sup>۴</sup> (دوره بین دو حمله)، پری‌ایکتال<sup>۵</sup> (دقیقه‌ها یا ساعت‌ها قبل از حمله)، پست ایکتال<sup>۶</sup> (دوره بعد از حمله) و زمان مداخله<sup>۷</sup> (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 داده نوار مغزی، تشخیص حمله با دقت بیشتر و زمان کمتر در دوره ایکتال بوده و هدف از پیش‌بینی حمله، تشخیص دوره پری‌ایکتال جهت ایجاد هشدارهایی برای اقدامات پزشکی است که در واقع ساعت‌ها یا دقیقه‌ها قبل از ایکتال مشخص می‌شود و لزوماً منظور، مشخص کردن زمان دقیق ایکتال نیست [4]. هدف بسیاری از مطالعات، شناسایی دوره پری‌ایکتال بر اساس داده نوار مغزی بوده است، با این‌وجود 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<sup>۸</sup> 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<sup>۹</sup> و نوفه<sup>۱۰</sup> اثر بیشتری بر نوار مغزی سطحی نسبت به نوار مغزی عمیق دارند، در صورت وجود نوار

<sup>11</sup> Physiologic  
<sup>12</sup> Electrocardiogram (ECG)  
<sup>13</sup> Electromyogram (EMG)  
<sup>14</sup> Digital  
<sup>15</sup> Finite impulse response (FIR)  
<sup>16</sup> Infinite Impulse Response (IIR)  
<sup>17</sup> Independent Component Analysis (ICA)  
<sup>18</sup> Trending  
<sup>19</sup> Pre\_classification

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

اساس الگوریتم‌های مسیر، مقایسه دوره‌ای از داده‌های جاری با داده‌های پیش‌زمینه<sup>۲</sup> است. داده‌های پیش‌زمینه را به صورت 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 دو ثانیه‌ای 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 [10, 11]. در الگوریتم هاردینگ<sup>۳</sup> 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 در قبل 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 دسته‌بندی‌مانند 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<sup>۴</sup>،...) و واکاوی‌های<sup>۵</sup> فرکانسی (تبدیل فوریه، تبدیل موجک و...)

ب) روش دسته‌بندی نوار مغزی که به‌طور معمول سه نوع هستند: شبکه‌های عصبی مصنوعی<sup>۶</sup>، ماشین‌های بردار پشتیبان<sup>۷</sup> 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 در قبل 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 با این حال تمایز بین تشخیص و پیش‌بینی حمله صرع در این الگوریتم‌ها کمتر به چشم می‌آید [4].

روش‌های، پردازش اصلی سیگنال و استخراج ویژگی در دو محث تشخیص و پیش‌بینی یکسان هستند، اما تفاوت آن‌ها بدین صورت است که، در محث تشخیص، دوره‌های ایکتال و اینترایکتال مقایسه می‌شوند در حالی که در محث 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<sup>۸</sup> ضرایب مدل خود همبسته<sup>۹</sup> داده نوار مغزی سطحی را به‌دست می‌آورد، سپس با دسته‌بندی ماشین بردار پشتیبان<sup>۱۰</sup> دوتایی<sup>۱۱</sup> ضرایب مدل، دسته‌بندی می‌شوند. مدل‌های متعددی برای سیگنال نوار مغزی ارائه شده است که آخرین آن‌ها بر اساس ویژگی غیرایستاد آن است. باید به این نکته توجه داشت که بیشتر مطالعات انجام شده با فرض گوسی بودن نوار مغزی سطحی انجام شده‌اند. اما در [15] غیر گوسی بودن نوار مغزی سطحی را با استفاده از مدل میانگین متحرک خودهمبسته یکپارچه<sup>۱۲</sup> 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<sup>۱۳</sup> انجام می‌شوند. همچنین معیارهای دیگری مانند میانگین همبستگی فاز [18-20]، شاخص تأخیر تطابق<sup>۱۴</sup> برای مقایسه تطابق فاز بین نوسان‌های نامنظم [8, 21]، طیف ویژه<sup>۱۵</sup> ماتریس‌های همبستگی تأخیر فضا و هم‌وردایی<sup>۱۶</sup> [22]، بزرگ‌ترین نمای لیاپانوف<sup>۱۷</sup> [23-25]، زمان ناهمبستگی، پارامترهای Hjorth مانند تحرک<sup>۱۸</sup> و

<sup>8</sup> Least squares

<sup>9</sup> Auto Regressive (AR)

<sup>10</sup> Support Vector Machine (SVM)

<sup>11</sup> Binary

<sup>12</sup> Autoregressive Integrated Moving Average (ARIMA)

<sup>13</sup> Sparse Laguerre-Volterra AutoRegressive

<sup>14</sup> Lag Synchronization Index

<sup>15</sup> Eigen Spectra

<sup>16</sup> Covariance

<sup>17</sup> Largest Lyapunov Exponent

<sup>18</sup> Mobility

<sup>1</sup> State

<sup>2</sup> Background

<sup>3</sup> Harding

<sup>4</sup> Root Mean Square (RMS)

<sup>5</sup> Analysis

<sup>6</sup> Artificial Neural Network (ANN)

<sup>7</sup> Support Vector Machin (SVM)

همگام‌سازی<sup>۱۰</sup> جهت پیش‌بینی کوتاه‌مدت انجام شده است. در عمل، 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 ساده مبتنی بر آستانه، با محاسبات کم را روی نوار مغزی سطحی مقایسه می‌کند. در نهایت، ۹۱ ثانیه قبل از تشنج را با کمک دسته‌بند ساده مبتنی بر آستانه تشخیص می‌دهد [36]. مطالعه‌ای دیگر وابسته به بیمار، بر اساس یادگیری عمیق<sup>۱۱</sup>، جهت پیش‌بینی بلندمدت<sup>۱۲</sup> 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 به ترتیب 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<sup>۱۳</sup> که شایع‌ترین نوع صرع بوده شناسایی کنیم [38]. بدین منظور از دو کانال نوار مغزی سطحی با نظارت طولانی‌مدت<sup>۱۴</sup> استفاده کرده‌ایم. ابتدا پردازش مقدماتی از جمله نرمال‌سازی، حذف گرایش<sup>۱۵</sup> 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

پیش‌بینی<sup>۱</sup>، طیف توان در باندهای فرکانسی، فرکانس لبه طیف<sup>۲</sup>، چهارممان نخست‌آماری: میانگین، وِردایی<sup>۳</sup>، کشیدگی<sup>۴</sup>، چولگی<sup>۵</sup> و معیارهایی بر اساس آنتروپی و احتمال وجود دارند [26-29, 6]. روش‌های تجزیه مد ذاتی<sup>۶</sup> و تبدیل موجک نیز برای استخراج ویژگی استفاده شده‌اند [2, 7, 30, 31]. 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 [32, 33] از روش کپستروم روی چند کانال نوار مغزی سطحی و عمقی در حالات متفاوت بیمار به‌صورت جداگانه و کوتاه‌مدت<sup>۷</sup> استفاده شده است. کپستروم برای استخراج تغییرات آرام و متناوب<sup>۸</sup> 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  $0.987/0.897$  و  $0.98/0.99/0.99$  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. در نهایت 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<sup>۹</sup>، بر اساس پیدا کردن الگوهای

<sup>1</sup> Complexity

<sup>2</sup> Spectral Edge Frequency

<sup>3</sup> Variance

<sup>4</sup> Kurtosis

<sup>5</sup> Skewness

<sup>6</sup> Empirical Mode Decomposition (EMD)

<sup>7</sup> Short Term

<sup>8</sup> Periodic

<sup>9</sup> Patient-Specific

<sup>10</sup> Synchronization Patterns

<sup>11</sup> Deep Learning

<sup>12</sup> Long Term

<sup>13</sup> Temporal Lobe Epilepsy (TLE)

<sup>14</sup> Long Term Monitoring (LTM)

<sup>15</sup> Trend

دوره اینترایکتال در این مرحله استفاده کرد. پالایه میانه نیز برای تشخیص دقیق لیه 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 به دست می‌آید. برای انجام پیش‌بینی مقادیر آستانه را روی داده‌های آموزش به دست 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 مراحل 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 در نهایت روی داده واقعی نتایج را به دست می‌آوریم.

## ۲- بیان مسئله پیش‌بینی حمله

یک الگوریتم پیش‌بینی حمله، باید قبل از رخ دادن 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 تعیین شده رخ می‌دهد. در [18]، این بازه را به‌عنوان بازه وقوع حمله<sup>۱</sup> 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 به دلیل اینکه علائم بالینی ساعت‌ها و دقیقه‌ها قبل از حمله در بیشتر بیماران وجود ندارد، در نتیجه 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 نشان دادن بیمار است؛ در واقع اگر بتوانیم پیش‌بینی را به اندازه 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 رخ دادن 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<sup>۲</sup> استفاده می‌کنیم، که به ترتیب از روابط (۱)، (۲)، (۳) و (۴) به دست می‌آیند.

(۱) حساسیت:

تعداد مثبت‌های صحیح

تعداد مثبت‌های صحیح + تعداد منفی‌های کاذب

(۲) اختصاص‌پذیری:

تعداد منفی‌های صحیح

تعداد منفی‌های صحیح + تعداد مثبت‌های کاذب

(۳) دقت:

تعداد مثبت‌های صحیح + تعداد منفی‌های صحیح

تعداد منفی‌های صحیح + تعداد مثبت‌های کاذب + تعداد

مثبت‌های صحیح + تعداد منفی‌های کاذب

(۴) نرخ مثبت کاذب:

تعداد مثبت‌های کاذب

میزان کل ساعت‌های غیر تشنجی (ساعت)

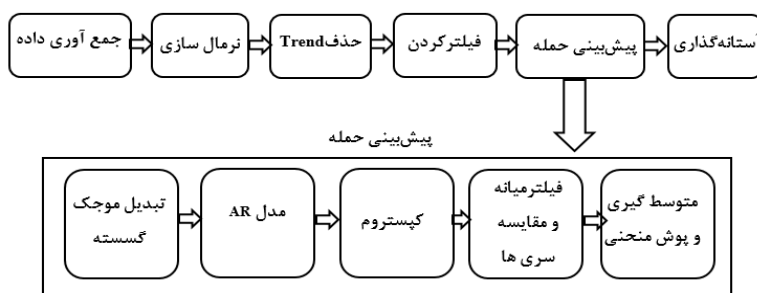
تعداد مثبت‌های صحیح به معنی تعداد هشدارهایی که به‌درستی تشخیص داده شده‌اند، است. تعداد منفی کاذب، تعداد دوره‌های زمان مداخله که به اشتباه هشدار داده نشده‌اند و تعداد منفی‌های صحیح، تعداد دوره‌هایی از سیگنال که دوره زمان مداخله نبوده‌اند و به‌درستی تشخیص داده شده‌اند (هشدار هم داده نشده است). برای تعیین، 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

<sup>2</sup> False positive Rate (FPR)

<sup>1</sup> Seizure Occurrence Period (SOP)

تعداد مثبت‌های کاذب تعداد دوره‌هایی است که دوره زمان مداخله نبوده و به اشتباه خاطر داده شده است.

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



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

بالای منحنی به دست می‌آید. برای انجام پیش‌بینی مقادیر آستانه را روی داده‌های آموزش به دست 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 کوتاه مدت، چند ضریب کپستروم و دسته‌بندی‌ها، الگوریتم ساده‌تری خواهیم داشت. همچنین با توجه به مصنوعات به وجود آمده در نوار مغزی سطحی با نظارت طولانی مدت که ناشی از فعالیت‌های روزانه بیمار است می‌توان از این روش برای تشخیص در سیستم‌های کاشت<sup>۱</sup> به صورت زمان حقیقی بهره برد. در ادامه به تشریح بلوک‌های روش پیشنهادی می‌پردازیم.

### ۱-۳- جمع آوری داده

داده‌های نوار مغزی سطحی استفاده شده در این مطالعه، از بیماران با صرع لوب تمپورال با نظارت طولانی مدت جمع‌آوری شده‌اند. داده‌ها توسط نویسندگان در بیمارستان، فقط جهت 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.

### 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 میان‌گذرا استفاده، 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 پارامتری کردن 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 پیش‌زمینه به دست 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. در نهایت برای تشخیص دقیق‌تر شروع دوره زمان مداخله، پوش

<sup>1</sup> Implant



### ۳-۳- تبدیل موجک گسسته

امواج مغزی بر اساس فرکانس به چند نوع تقسیم‌بندی می‌شوند، که عبارتند از: دلتا (۴-۵ 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<sup>۱</sup> استفاده کرد. تبدیل موجک در مقابل تبدیل فوری علاوه بر تفکیک فرکانسی، تفکیک زمانی نیز انجام می‌دهد و دقت تفکیک‌پذیری بهتری نسبت به تبدیل فوری 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<sup>۲</sup> و موجک مادر تجزیه می‌شود، با این کار سیگنال در هر مرحله به دو بخش فرکانس پایین (سیگنال تقریب) و فرکانس بالا (سیگنال جزئیات) تفکیک می‌شود. رابطه تبدیل موجک گسسته به این صورت است [42]:

$$x(t) = \sum_{k=0}^{2^l c} c_{J_c, k} \phi_{J_c, k}(t) + \sum_{j=J_c}^{\infty} \sum_{k=0}^{2^j - 1} d_{j, k} \psi_{j, k}(t) \quad (5)$$

$x(t)$  سیگنال زمانی،  $\psi$  تابع موجک مادر،  $\phi$  تابع سنجش<sup>۳</sup>،  $d_{j, k} = \langle x, \psi_{j, k} \rangle$  ضرایب جزئیات،  $c_{J_c, k} = \langle x, \phi_{J_c, k} \rangle$  ضرایب تقریب و سیگنال روی این ضرایب تصویر می‌شود. در واقع تبدیل موجک گسسته، در هر مرحله ضریب تقریب از فیلترهای پایین‌گذر و بالا‌گذر عبور داده می‌شود (شکل ۴). ابتدا برای استفاده از تبدیل موجک گسسته، باید دو پارامتر موجک مادر و تعداد

<sup>1</sup> Discrete Wavelet Transform (DWT)

<sup>2</sup> Scaling

<sup>3</sup> Scaling or Father wavelet

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.

### ۳-۴- مدل خود همبسته

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

$$x_k = (\bar{\varphi}_k)^T \bar{a}_k + e_k \quad (6)$$

که در آن  $[x_{k-1}, x_{k-2}, \dots, x_{k-n}]'$  به‌عنوان رگرورها شناخته می‌شوند.  $n$  مرتبه مدل،  $a_j$  ( $j=1, 2, \dots, n$ ) ضرایب خود همبسته،  $e_k$  سیگنال خطا نوفه سفید با میانگین صفر و  $x_k$  سری زمانی سیگنال نوار مغزی و  $a = [a_1, a_2, \dots, a_n]'$  بردارهای پارامتر ناشناخته هستند. می‌توان پارامترهای مجهول را به صورت برخط<sup>۴</sup> و برون خط<sup>۵</sup> محاسبه کرد. اما اینجا پارامترها با تخمین‌های برخط بازگشتی<sup>۶</sup>، تخمین زده می‌شوند؛ تا روش پیشنهادی در سیستم‌های کاشت مغزی با زمان حقیقی قابل پیاده‌سازی باشد. در روش کمترین مربعات بازگشتی<sup>۷</sup>، تخمین ضرایب خود همبسته به‌گونه‌ای است که معیار ( $J$ ) کمترین مقدار شود:

$$J(\hat{a}_k) = \arg \min_{\hat{a}_k} \sum_{i=1}^k \lambda^{k-i} \epsilon^2(i, a), \quad 0 < \lambda < 1 \quad (7)$$

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

$$\epsilon(k, \hat{a}) = x_k - (\bar{\varphi}_k)^T \bar{a}_{k-1} \quad (8)$$

و ضرایب  $a_k$  به‌صورت برگشت‌پذیر زیر بدین گونه تخمین زده می‌شوند:

$$\bar{a}_k = \bar{a}_{k-1} + \bar{K}_k \epsilon_k \quad (9)$$

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

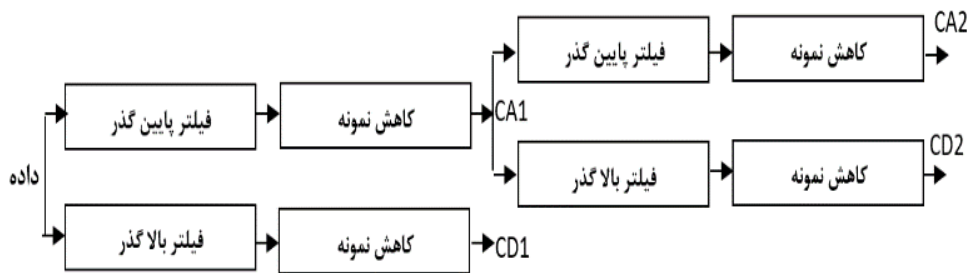
$$\bar{K}_k = \bar{p}_k \bar{\varphi}_k \quad (10)$$

<sup>4</sup> Online

<sup>5</sup> Offline

<sup>6</sup> Recursive

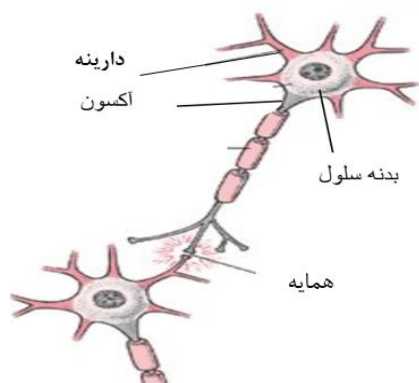
<sup>7</sup> Recursive Least Square (RLS)



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

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

دستگاه عصبی مرکزی شامل یاخته‌های عصبی و سلول‌های گلیال<sup>۲</sup> 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<sup>۳</sup> را همایه<sup>۴</sup> 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<sup>۵</sup> 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.

<sup>2</sup> Glial Cell

<sup>3</sup> Myosytus

<sup>4</sup> Synapse

<sup>5</sup> Dendrite

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

$$\vec{p}_k = (\vec{p}_{k-1} - \frac{\vec{p}_{k-1} \vec{\varphi}_k^T \vec{\varphi}_k \vec{p}_{k-1}}{\lambda + \vec{\varphi}_k^T \vec{p}_{k-1} \vec{\varphi}_k}) \frac{1}{\lambda} \quad (11)$$

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

$$\hat{x}_k = (\vec{\varphi}_k)^T \vec{a}_{k-1} \quad (12)$$

به‌طور معمول مقادیر نخستیه  $p_0 = \delta I$  و بردار ضرایب  $a_0 = 0$  در نظر گرفته می‌شوند که  $0 < \delta < 1$  و 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<sup>۱</sup> سیگنال به‌دست آورده می‌شود [32].

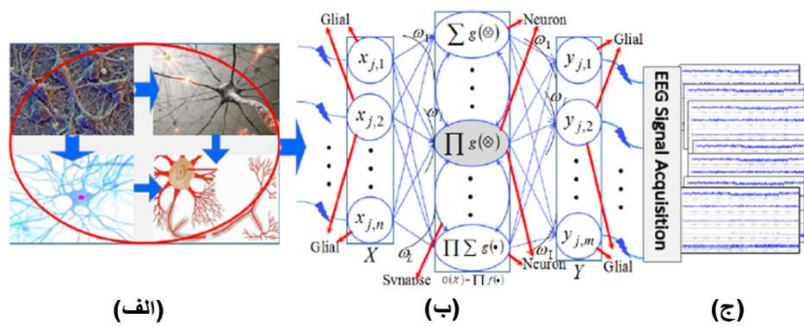
$$X(k) = \frac{1}{N} \sum_{n=1}^N x(n) e^{-j(2\pi \frac{k}{N})n} \quad (13)$$

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

$$C(n) = \frac{1}{N} \sum_{k=1}^N \log(|X(k)|) e^{j(2\pi \frac{k}{N})n} \quad (14)$$

$\log(|X(k)|)$ ، 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.

<sup>1</sup> Discrete Fourier Transform (DFT)



(شکل-۶): الف) سلول‌های عصبی در مغز، ب) سیگنال‌های محرک و ساختار 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]

ساختار سلول‌های مغزی و ضرایب  $\omega_{j,i}$  متفاوت است. این مرجع روش پیچیدگی‌زادایی<sup>۱</sup> را برای جداسازی نوار مغزی از مؤلفه‌های مختلف پیشنهاد کرده‌است. می‌توان سیگنال‌های نوار مغزی را نتیجه پیچیدگی<sup>۲</sup> دو تابع در نظر گرفت که در اثر سیگنال‌های محرک و ساختار سلول‌های مغز ایجاد شده است؛ بنابراین با اعمال کپستروم سیگنال پیچیده‌شده<sup>۳</sup> 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 لگاریتم گرفتن 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؛ در نتیجه تعداد ضرایب انتخاب شده به طول سیگنال بستگی ندارد. ضریب  $c[0]$  لگاریتم انرژی یا مؤلفه جریان مستقیم<sup>۴</sup> سیگنال است، که به‌عنوان ضریب کپستروم در نظر گرفته نمی‌شود [44].

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، در نتیجه 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  $g(\cdot)$  و سیگنال‌های الکتریکی خروجی  $y_{j,m}$ . اصول کار یاخته‌ها  $g(\cdot)$  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. به‌طور معمول 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 غیرخطی بودن نوار مغزی سرچشمه می‌گیرد؛ می‌توان نتیجه گرفت سیگنال خروجی  $y_{j,m}$  در رابطه (۱۵) است:

$$(15) \quad y_{j,m} = \prod g(\omega_1 \cdot x_{1,n}) \oplus \prod g(\omega_2 \cdot x_{2,n}) \oplus \dots \\ \oplus \prod g(\omega_L \cdot x_{j,n}) = \sum_{l=1}^L \prod g(\omega_l \cdot x_{j,n})$$

طبق فرضیه این مرجع و رابطه فوق این تصور صحیح است که نوار مغزی در افراد مختلف به دلیل تفاوت در

<sup>1</sup> Deconvolution  
<sup>2</sup> Convolution  
<sup>3</sup> Convolved  
<sup>4</sup> Direct current (DC)

افزایش تفاوت دو دوره ابتدا مربع آن به دست می‌آوریم سپس از فیلتر میانه با پنجره متحرک با طول مشخص عبور می‌دهیم. دوره پس زمینه اخیر ( $FG_k$ ) از رابطه (۱۶) به دست می‌آید [35].

$$FG_k = \text{median}\{y_k^2, y_{k-1}^2, \dots, y_{k-q+1}^2\} \quad (16)$$


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. در واقع تغییرات دوره پس زمینه نسبت به دوره پیش زمینه سنجیده می‌شوند. دوره پیش زمینه با عبور دوره پس زمینه از فیلتر میانه و تأثیر ضریب فراموشی ( $\lambda$ ) به دست می‌آید. ضریب فراموشی موجب استفاده از اطلاعات پیش زمینه 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) به دست می‌آید.

$$BG_k = \begin{cases} (1-\lambda)\text{median}\left\{FG_k, FG_{k-s}, FG_{k-2s}, \dots, FG_{k-(q_2-1)s}\right\} + (\lambda)BG_{k-1} & \text{if } k=ns \\ BG_{k-1} & \text{if } n(s-1) \leq k < ns \end{cases} \quad (17)$$

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

$$r_k^{(i=1)} = \frac{FG_k^{(i=1)}}{BG_k^{(j)}} \quad (18)$$


که  $i, j$  شماره کانال که  $1 \leq j \leq N$  و  $N$  تعداد کل کانال‌ها است. روش فیلتر میانه و تولید دوره پس زمینه روی داده یک بیمار آزمایش شده و توانایی شناسایی لبه‌های مربوط به تشنج‌ها و غیر تشنج‌ها مشاهده شده است؛ در نتیجه مقایسه دوره پس زمینه با دوره پیش زمینه موجب کاهش دامنه شبه تشنج‌ها 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.



(شکل-۷): لگاریتم تبدیل فوری به گسسته یک نمونه

سری زمانی [44]

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



(شکل-۸): معکوس تبدیل فوری به گسسته، لگاریتم، تبدیل

فوری به گسسته یک نمونه سری زمانی یا ضرایب کپستروم

سری زمانی IDFT سری زمانی به دست آمده

از شکل (۷) [44]

(Figure-8): IDFT, logarithm, DFT of time series or Cepstrum coefficients of time series (IDFT of Figure\_7) [44]

## ۳-۶- فیلتر میانه و مقایسه سری


### پس زمینه با سری پیش زمینه

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. به علت توانایی آن در حفظ لبه برای ترمیم تصاویر خراب شده 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<sup>۱</sup> به دلیل 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

<sup>1</sup> Moving Average Filter

## ۷-۳- متوسط‌گیری 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؛ در نتیجه 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 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 به راحتی با پیدا کردن مقدار آستانه زمان شروع دوره زمان مداخله مشخص می‌شود.



(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.

در اینجا لازم است به دلایل دیگر انتخاب هر بلوک اشاره شود. در شروع انجام پژوهش، ما به دنبال الگوریتمی بر اساس مدل خودهمبسته-کپستروم که جهت تشخیص تغییرات در سیگنال نوار مغزی در مرجع [40] استفاده شده است، بودیم؛ اما این روش به تنهایی جهت پیش‌بینی و تشخیص دوره زمان مداخله کافی نبود؛ در نتیجه ما برای افزایش دقت الگوریتم در تشخیص و کاهش خطاهای ناشی از مصنوعات و تخلیه‌های میان حمله‌ای به ریخت‌شناسی<sup>۱</sup> 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

<sup>1</sup> Morphology

با توجه به اینکه در بیماران با سرعت 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 ایکنال نسبت به اینترایکنال 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 به دست آمده، بلوک‌های متوسط‌گیری و پوش بالای منحنی مورد نیاز بود. روش متوسط‌گیری کمک به کاهش دامنه مؤلفه‌های فرکانس بالا می‌کند و در نتیجه خطای ناشی از مصنوعات را می‌کاهد. در مرحله بعد، برای مشخص کردن راحت‌تر آستانه پوش بالای منحنی را به دست می‌آوریم.

با توجه به نتایج به دست آمده از خروجی نمودارهای پوش متوجه شده ایم که آستانه پیش بینی حمله هر بیمار متفاوت است؛ در نتیجه برای هر بیمار آستانه متفاوت در نظر گرفته می شود. با توجه به نتایج داده های آموزش، مقدار آستانه با کمترین خطا و مناسب ترین تأخیر از زمان شروع حمله انتخاب و در داده های آزمایش اعمال می شوند.

#### ۴- مدل سیگنال مغز صرعی بزرگسال

مدل سلکا<sup>۱</sup> برای تشخیص تشنج در نوزادان استفاده شده است. اساس ساختار این مدل قبلاً توسط روسگن<sup>۲</sup> و لوپس داسیلوا<sup>۳</sup> بر اساس ویژگی های غیر گوسی و غیر ایستان نوار مغزی پیشنهاد شده است [45-48]. در این مطالعه، مدل پیشنهادی برگرفته از مدل سلکا و داده های واقعی بزرگسال است که شامل دوره های 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 می کند. با فرض استقلال نوار مغزی زمینه و تشنج، شاخه بالا یک فیلتر خود همبسته<sup>۴</sup> میانگین-متحرک<sup>۴</sup> ( $G_p$ ) است که با نوفه سفید گوسی تحریک می شود؛ سپس از تابع شکل دهی غیر خطی  $g_p$  عبور می کند (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 همبسته میانگین-متحرک ( $G_s$ ) با سیگنال دندان اره ای سوار شده<sup>۵</sup>، فرکانسی خطی تکه ای<sup>۶</sup> تحریک می شود، سپس از تابع شکل دهی غیرخطی  $g_s$  عبور می کند. سوارسازی<sup>۷</sup> فرکانسی خطی تکه ای، رفتار غیر ایستان تشنج ها را مدل

می کند. مدل پیشنهادی سلکا برگرفته از نوارهای مغزی صرعی نوزادان است؛ به صورتی که محدوده فرکانسی بخش زمینه ۰/۵ تا ۱۰ هرتز و بخش تشنج ۱/۵ هرتز است. در حالی که محدوده فرکانسی بخش زمینه بزرگسالان ۰/۵ تا ۵۰ هرتز است و فرکانس بخش تشنج نیز به یک مقدار محدود نمی شود. تاکنون مدل نوار مغزی صرعی بزرگسالان که مناسب هدف پیش بینی باشد، ارائه نشده است. برای اینکه تفاوت های نوار مغزی نوزاد و بزرگسال را تا حدودی پوشش دهیم، با تغییر فرکانس ها، تعیین ضرایب فیلترهای مورد استفاده در این مدل و همچنین استفاده از داده های واقعی بزرگسال موجود، اعمال می کنیم. برای این کار ابتدا دوره اینترایکتال سیگنال بزرگسال داده های موجود را از تابع شکل دهی  $g_p^{-1}$  عبور می دهیم و سیگنال خروجی ( $y(k)$ ) به دست می آید. حال باید مدل  $G_p$  تخمین زده شود که با دستور  $\text{arimax}$  این تخمین انجام می شود. اگر تبدیل Z فیلتر  $G_p$  به این صورت باشد:

$$G_p(z) = \frac{H_1(z)}{H_2(z)} \quad (19)$$

فیلتر  $G_s$  مربوط به شاخه پایین این رابطه خواهد بود:

$$G_s(z) = \frac{1}{H_2(z)} \quad (20)$$

با ورودی نوفه سفید و خروجی  $y(k)$ ، فیلتر  $G_p(z) = \frac{Y(z)}{E(z)}$  با  $p=q=2$  تخمین زده می شود. 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 رسم شده در شکل (۱۲)، آمده است. شکل های (۱۱) و (۱۲) تقریباً یکسان هستند و تخمین به خوبی انجام شده است. بعد از پیدا کردن  $G_p$  و  $G_s$ ، می توان بخش تشنج را به دست آورد. در رابطه  $S(k)$  مقدار  $f_m = 1.5Hz$  است. نمونه ای از اینترایکتال و ایکتال به دست آمده، به ترتیب در شکل های (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 می کنیم؛ در حالی که فرکانس  $f_m$  را برابر یک هرتز و دامنه کمتری قرار می دهیم، می توان دوره زمان مداخله تولید شده از مدل صرعی بزرگسال را در شکل (۱۵) مشاهده کرد.

<sup>1</sup> Celka

<sup>2</sup> Roessgen


<sup>3</sup> Lopesdasilva

<sup>4</sup> Autoregressive Moving-Average (ARMA)

<sup>5</sup> Modulated

<sup>6</sup> Piecewise Linear Frequency Modulated

<sup>7</sup> Modulation



(شکل-۱۵): دوره زمان مداخله به دست آمده 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 به صورت غیر خودکار انجام می‌شود. همچنین کانال انتخاب شده در ثبت‌های مختلف ثابت است. اعمال مراحل پیش‌بینی حمله صرعی، روی داده کانال‌های مورد نظر با نرم افزار متلب<sup>۱</sup> انجام می‌شوند.

### ۵-۲- پیش‌پردازش

مراحل پیش‌پردازش عبارتند از: پنجره‌بندی با طول پنج ثانیه با همپوشانی ۰٫۸۰، حذف میانگین و وردایی، حذف گرایش خطی و اعمال فیلتر میان‌گذر است. برای پیش‌پردازش ابتدا داده با پنجره پیشرو در نظر گرفته می‌شود و سپس برای مشخص کردن طول مناسب پنجره، طول‌های مختلفی را بررسی می‌کنیم؛ به این صورت که ابتدا طول پنجره را به ترتیب ۲، ۵ و ۱۳ ثانیه در نظر گرفته و سپس مراحل حذف

<sup>۱</sup> Matlab

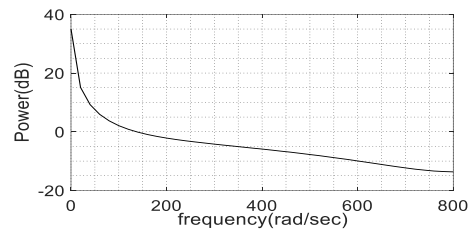


(شکل-۱۱):

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)

(۱۳): دوره اینترایکتال نوار مغزی به دست آمده از مدل صرعی بزرگسال

(Figure-13): Inter\_ictal period EEG obtained from the adult epileptic model

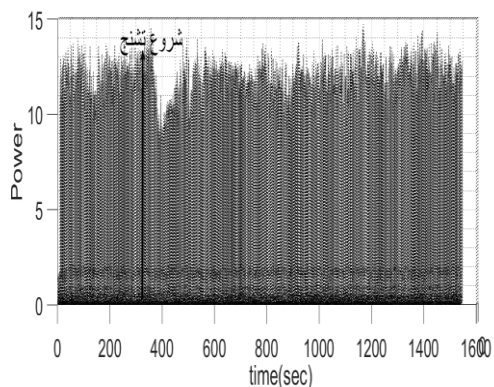


(شکل-۱۴)

(۱۴): دوره ایکتال نوار مغزی به دست آمده از مدل صرعی بزرگسال

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

نسبت به تأثیر این نوع پارامترها است. مقادیر به دست آمده پارامترها، برای همه داده‌های موجود در این مطالعه، مناسب است و وابسته به بیمار نیست.



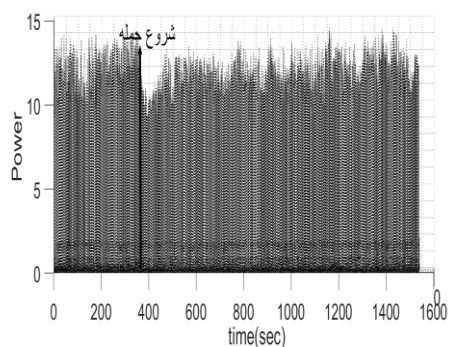
(شکل-۱۶): ضریب نخست کپستروم بیمار نخست با فیلتر ۶

تا ۲۰ هرتز (حمله در ثانیه ۳۶۰)

(Figure-16): The first Cepstrum coefficient of the first patient with a filter6\_20 Hz (seizure in 360 secs)

### ۳-۵- پیش‌بینی حمله صرعی

مرحل 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 به دست آمده از دو کانال است. به عنوان 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 دابچی 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 به دست آمده 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 in 360 secs)

میانگین، وردایی و گرایش خطی انجام می‌شود. طبق نتایج به دست آمده از نمودارها که به علت 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؛ در نتیجه 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 هشتماد دارد و در این بازه فاز آن خطی و تعداد عناصر<sup>۱</sup> کمتری نسبت به مرتبه پانصد دارد. برای پیدا کردن 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 به‌طور تقریبی روی عدد ۹، اینترایکتال نزدیک به ۱۴ و مصنوعات نزدیک ۱۱ قرار گرفته‌اند. 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 به صورت یک‌ثانیه‌ای (پنجره پنج ثانیه با هم‌پوشانی ۸۰٪) دریافت می‌شود. در واقع هدف ما از ذکر کردن نحوه به دست آوردن پارامترها، فهم عمیق‌تر و دید بهتر خواننده


<sup>۱</sup> Element



(شکل-۱۸): ضریب نخست کیستروم (حمله در ثانیه ۳۶۰)  
(Figure-18): The first Cepstrum coefficient (seizure in 360 secs)



(شکل-۱۹): ضریب دوم کیستروم (حمله در ثانیه ۳۶۰)  
(Figure-19): The second Cepstrum coefficient (seizure in 360 secs)



(شکل-۲۰): ضریب ۱۲۹ کیستروم (حمله در ثانیه ۳۶۰)  
(Figure-20): The 129th Cepstrum coefficient (seizure in 360 secs)

درواقع شش سیگنال نخست مربوط به ضریب نخست کیستروم کانال اصلی و شش سیگنال دوم مربوط به ضریب نخست کیستروم 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

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 پیدا کردن 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  $0.99$  قرار داده و جهت پیدا کردن مرتبه مناسب مدل خود همبسته از معیارهای تخمین مرتبه مدل، معیار اطلاعات Akaike<sup>۱</sup>، خطای پیش‌بینی نهایی<sup>۲</sup> و تابع هزینه<sup>۳</sup> که در [49] آمده‌است استفاده می‌شود. با توجه به سه معیاری که در قبل 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 کیستروم هر پنجره محاسبه می‌شوند. به‌ازای هر پنجره پانصدنمونه‌ای  $501$  ضریب کیستروم به‌دست می‌آید. ضرایب کیستروم از رابطه (۱۴) یا دستور rceps متلب، محاسبه می‌شوند. شکل (۱۸) ضریب نخست، شکل (۱۹) ضریب دوم و شکل (۲۰) ضریب ۱۲۹ کیستروم کانال اصلی بیمار نخست است. همان‌طور که 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 کیستروم هر کدام از پنجره‌های داده به‌ترتیب محاسبه شده و درنتیجه ۱۲ سیگنال ۲۵ دقیقه‌ای به‌دست‌آمده از ضریب نخست کیستروم خواهیم داشت.

<sup>1</sup> Akaike Information Criterion (AIC)

<sup>2</sup> Final Prediction Error (FPE)

<sup>3</sup> Cost Function

کانال اصلی و مقابل طبق رابطه (۱۷) به دست می آید. در رابطه (۱۷)  $s=0.5$ ,  $n=0,1,2,\dots$  برابر یک ثانیه و  $\lambda=0.99$  است.  $BG_k^{(1)}$  و  $FG_k$  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) به دست می آیند. در رابطه (۱۸)  $i=1, j=1,2$  شماره کانال و  $1 \leq j \leq 2$  است. خروجی  $r_k^{(i=1)}$  دارای ۱۲ سیگنال ۲۵ دقیقه ای خواهد بود. هر کدام از سیگنالها با پنجرههایی به طول دو ثانیه و هم پوشانی یک ثانیه تفکیک شده و متوسط هر پنجره محاسبه می شود و ۱۲ سیگنال ۲۵ دقیقه ای متوسط گیری شده خواهیم داشت. مرحله آخر به دست آوردن پوش بالا منحنی است که روی خروجی های مرحله متوسط گیری انجام می شود. می توان از دستور envelope در متلب استفاده کرد. متغیری که در این دستور باید مشخص شود، تعداد نمونه های بین دو قله نمودار است و در اینجا مقدار ۳۰ مناسب بوده است.

#### ۴-۵- آستانه گذاری و ارزیابی عملکرد روش پیشنهادی

مقدار آستانه با کمترین خطا و مناسب ترین تاخیر از زمان شروع تشنج در داده های آموزش مشخص شده و روی داده های آزمایش اعمال می شود. به این صورت که اگر یکی از سیگنال های خروجی یک بیمار که شامل: دوره های اینتریکتال، زمان مداخله و ایکتال است؛ مقدار دامنه سیگنال در دوره زمان مداخله نسبت به دوره اینتریکتال تعیین کننده مقدار آستانه است. دوره های ایکتال یا حمله از ۳۰ ثانیه تا ۱۸۰ ثانیه هستند. اگر دوره ایکتال به طور متوسط ۱۰۰ ثانیه فرض شود، می توان داده های اینتریکتال را به بازه های ۱۰۰ ثانیه ای تقسیم کرد که همان بازه وقوع حمله است. نحوه آستانه گذاری در پیش بینی با توجه به ۱۲ سیگنال خروجی انجام می شود. ابتدا طبق داده آموزش آستانه ها برای هر

سیگنال مشخص می شود. که ممکن است در برخی از سیگنالها آستانه ای برای پیش بینی با خطای کم وجود نداشته باشد در نتیجه از این سیگنال برای آموزش استفاده نمی شود. آستانه های مشخص شده در داده های آزمایش اعمال می شوند. با توجه به تعداد آستانه مشخص شده از داده های آموزش، در صورتی که بیش از نیمی از دامنه داده های آزمایشی، از آستانه عبور کنند دوره زمان مداخله در نظر گرفته می شود. برای نمونه اگر در داده آموزشی از ۱۲ سیگنال، ۷ سیگنال دارای آستانه تأیید شده داشته باشیم باید دامنه ۴ سیگنال از آستانه ها عبور کنند. برای هر بیمار این روند طی می شود. برای نمونه نتایج پیش بینی یک بیمار را آورده ایم. شکل (۲۱) سیگنال نوار مغزی سطحی پردازش نشده است که دوره زمان مداخله در ثانیه ۳۶۰ رخ می دهد. همان طور که 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 بر پایه نمودار ۱ مشخص می شود. مقدار آستانه برای اینکه خطا نداشته باشیم ۱/۲۲ در نظر گرفته می شود و زمان پیش بینی 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 می توان دریافت که این خروجی دوره زمان مداخله را تشخیص نداده است. در نتیجه از این خروجی در این بیمار برای داده آزمایش استفاده نمی شود. مقادیر آستانه برای ۱۲ خروجی داده آموزش به همین صورت مشخص شده و در داده آزمایش بررسی می شوند. طبق موارد گفته شده معیارهای حساسیت، اختصاص پذیری، دقت و نرخ مثبت کاذب برای پیش بینی محاسبه شده و در جدول (۲) آمده است.

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

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

بیماران	حساسیت %	اختصاص پذیری %	دقت %	FPR	متوسط زمان پیش بینی (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

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

اینترایکتال و زمان مداخله است. می‌توان روش پیشنهادی را با این داده مدل آزمایش کرد. برای نمونه نتایج پیش‌بینی روش پیشنهادی در شکل (۲۴) آمده است که قادر به پیش‌بینی بوده است.

## 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 شده است. مدل شامل دوره‌های ایکتال

(جدول ۳-۲) اطلاعات مدل نوار مغزی از قبیل تعداد تشنج‌ها، 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

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

(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 پیش‌بینی 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.

## ۵-۶- مقایسه با روش‌های دیگر

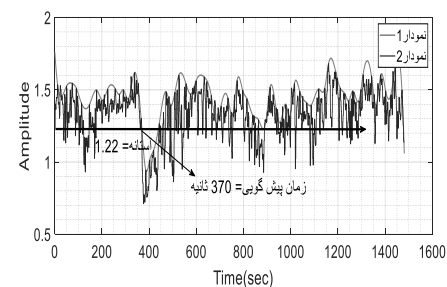
مطالعات بسیار کمی در زمینه پیش‌بینی کوتاه‌مدت حمله صرع انجام شده است. روش‌های [35] و [36] بر روی داده‌های نوار مغزی موجود اعمال شده و متوسط نتایج مقایسه با روش پیشنهادی در جدول (۷) آمده است. نتایج روش [35] که درقبل توضیح داده شد، در جدول (۴) نشان داده شده است. علت تفاوت نتایج [35] و نتایج به‌دست‌آمده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




## ۶- بحث و نتیجه گیری

در این مطالعه، یک الگوریتم پیش‌بینی کوتاه‌مدت تشنج در بیماران با لوب تمپورال ارائه شد. ما در این روش، تغییرات رفتار ناحیه کانون صرع را در دو کانال 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  $0.87/5$ ، اختصاص‌پذیری  $0.95/6$ ، دقت  $0.92/6$  و نرخ مثبت کاذب  $0.1/50$  با متوسط زمان پیش‌بینی  $18/5$  ثانیه به‌دست آمده‌اند. اگر زمان پیش‌بینی بزرگتر از  $10$  ثانیه در نظر گرفته شود، مقادیر حساسیت، اختصاص‌پذیری، دقت و نرخ مثبت کاذب به ترتیب  $0.63/8$ ،  $0.95/6$ ،  $0.90$  و  $0.1/50$  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 روش‌های 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 افضل‌پور و دکتر جواد شیخ‌پور جهت مطالعه مقاله و کمک در ویراستاری و نگارش آن، سپاس‌گزاری کنیم.



(شکل-۲۴): خروجی بلوک پیش‌بینی 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. همان‌طور که در بخش‌های قبل اشاره شد، مرجع [36] سه الگوریتم طبقه‌بندی ارائه کرده است که ما روش خود را با طبقه‌بندی مبتنی بر آستانه سنجیده‌ایم. به دلیل محدودیت طول مجموعه داده موجود، طول پست ایکتال را  $150$  ثانیه در نظر گرفته‌ایم، در حالی که در [36]  $1000$  ثانیه است.  $60\%$  از حجم داده هر بیمار جهت آموزش و  $50\%$  از تشنج‌ها با انتخاب تصادفی، تشنج‌های آموزشی آن بیمار در نظر گرفته شده است، بنابراین چهار بیمار از مجموعه داده حذف می‌شوند، جزئیات نوار مغزی بیماران در جدول (۵) آورده شده است. از آنجایی که دو ویژگی شاخص تأخیر فاز ۱ و شاخص تأخیر فاز ۲ در سه طول مختلف  $150$ ،  $200$  و  $300$  ثانیه بررسی شده‌اند، متوسط دوره ایکتال  $70$  ثانیه و در نتیجه طول بازه وقوع حمله به ترتیب  $370$ ،  $420$  و  $520$  به‌دست می‌آیند (برای طول  $150$ : متوسط طول ایکتال  $+150$  پست ایکتال =  $370$ ). 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 به ترتیب  $0.92/6$ ،  $0.95/6$  و  $0.18/5$  ثانیه هستند. زمان پیش‌بینی ما جهت مدیریت نخستیه حملات صرع و کاهش رویدادهای تهدید کننده مناسب است و کمترین نرخ مثبت کاذب را دارد.

<sup>1</sup> Phase Lag Index (PLI)

<sup>2</sup> Weighted PLI (WPLI)

(جدول-۴): نتایج به دست آمده از روش مرجع [35]  
(Table-4): Results obtained from the reference method [35]

بیماران	حساسیت %	اختصاص پذیری %	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 پیش‌گویی از قبیل تعداد تشنج‌ها، 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 به دست آمده از روش مرجع [36]

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

بیماران	بهترین نتایج	حساسیت %	اختصاص پذیری %	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

(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

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

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

## 7- References

## ۷- مراجع

- [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*,

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
- [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  $\gamma$  patients,"



- [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](mailto: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](mailto: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](mailto:drrezakhani@gmail.com)

"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 genesis 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 biologiques*, 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