

طبقه‌بندی و استخراج ویژگی الکتروانسفالوگرام صرعی با استفاده از روش‌های SVM و DWT، EMD، ICA، PCA

جواد ابراهیم نژاد^(۱) - مهکام کاهکش^(۲) - علیرضا نقش^(۳)

(۱) مرکز تحقیقات پردازش دیجیتال و بینایی ماشین - دانشگاه آزاد اسلامی واحد نجف‌آباد

دانشجوی دکتری مهندسی برق مخابرات - دانشکده مهندسی برق، واحد نجف‌آباد، دانشگاه آزاد اسلامی، نجف‌آباد، اصفهان، ایران

(۲) مرکز تحقیقات پردازش دیجیتال و بینایی ماشین - دانشگاه آزاد اسلامی واحد نجف‌آباد

دانشجوی دکتری مهندسی برق کنترل - دانشکده مهندسی برق، واحد نجف‌آباد، دانشگاه آزاد اسلامی، نجف‌آباد، اصفهان، ایران

(۳) مرکز تحقیقات پردازش دیجیتال و بینایی ماشین - دانشگاه آزاد اسلامی واحد نجف‌آباد

استادیار - دانشکده مهندسی برق، واحد نجف‌آباد، دانشگاه آزاد اسلامی، نجف‌آباد، اصفهان، ایران

تاریخ دریافت: ۱۳۹۷/۲/۳۱ تاریخ پذیرش: ۱۳۹۷/۶/۲۱

خلاصه: هدف این مقاله طبقه‌بندی سیگنال‌های الکتروانسفالوگرام به دو دسته صرعی و سالم می‌باشد. برای دستیابی به بالاترین دقت، از تکنیک‌های مختلف استفاده شده است. روش‌های تبدیل موجک و تجزیه حالت تجربی برای استخراج ویژگی‌های مورد نظر از این سیگنال‌ها به کار رفته است. این دو روش از لحاظ تاثیر در فرآیند طبقه‌بندی با یکدیگر مقایسه شده‌اند. جهت کاهش ابعاد فضای ویژگی، روش‌های تحلیل اجزای مستقل و اصلی مورد استفاده قرار گرفته‌اند. سپس به منظور کاهش اثر نویز بر تحلیل سیگنال الکتروانسفالوگرام، روش نرم کردن اعمال گردید. در نهایت، به کمک طبقه‌بندی کننده ماشین بردار پشتیبان، داده‌های موجود طبقه‌بندی شدند. این مراحل برای مجموعه داده موجود، شامل ۵ گروه از سیگنال‌های الکتروانسفالوگرام تک کانال، آزمایش شد. نتایج، کارایی و دقت بالای روش تجزیه حالت تجربی در استخراج ویژگی و طبقه‌بندی سیگنال‌ها را نشان می‌دهد. بر این اساس، دقت و حساسیت به دست آمده از روش تجزیه حالت تجربی ۱۰۰٪ می‌باشد. خروجی این سیستم در کنترل و درمان بیماری کاربرد دارد.

کلمات کلیدی: الکتروانسفالوگرام، صرعی، تبدیل موجک، تحلیل اجزای مستقل، تحلیل اجزای اصلی، تجزیه حالت تجربی، ماشین بردار پشتیبان.

Classification and Feature Extraction of Electroencephalogram Signals for Epilepsy Using PCA, ICA, DWT and SVM Methods

Javad Ebrahimnejad⁽¹⁾ - Mahkam Kahkesh⁽¹⁾ - Alireza Naghsh⁽²⁾

(1) Digital Processing and Machine Vision Research Center, Najafabad Branch, Islamic Azad University, Najafabad, Iran

PhD Student of Telecommunication Engineering- Dept. of Electrical Engineering, Najafabad Branch, Islamic Azad University, Najafabad, Isfahan, Iran
javad_esh@yahoo.com

(2) Digital Processing and Machine Vision Research center, Najafabad Branch, Islamic Azad University, Najafabad, Iran

PhD Student of Control Engineering- Dept. of Electrical Engineering, Najafabad Branch, Islamic Azad University, Najafabad, Isfahan, Iran
mahkamkakhkesh@gmail.com

(3) Digital Processing and Machine Vision Research center, Najafabad Branch, Islamic Azad University, Najafabad, Iran

Assistant Professor - Dept. of Electrical Engineering, Najafabad Branch, Islamic Azad University, Najafabad, Isfahan, Iran
naghsh_a@yahoo.com

Abstract: The purpose of this article is to classify electroencephalogram signals into two types of epilepsy and healthy. To achieve the highest accuracy, various techniques have been used. The desired characteristics of these signals can be extracted by Wavelet Transform and Empirical Mode Decomposition methods. These two methods are compared in terms of impact in the classification process. To reduce the dimensions of the feature space, Independent and Principal Component Analysis methods can be used. Then, in order to reduce the effect of noise on electroencephalogram signal analysis, a smoothing method can be applied. Finally, by using Support Vector machine classifier, the existing data classified. These steps were tested for an existing data set, including 5 groups of single channel electroencephalogram signals. Results show that the empirical decomposition method has high efficiency and accuracy to extract the characteristics and classification of signals. Accordingly, the accuracy and sensitivity of both combinations of "empirical mode decomposition - independent component analysis" and "empirical mode decomposition - principal component analysis", after data smoothing, as a new approach to extraction and classification of features are 100%. The output of this system is used to control and treat the disease.

Index Terms: EEG, Epilepsy, ICA, PCA, EMD.

۱- مقدمه

مطابق آمار، یک درصد از مردم دنیا دچار صرع و تشنج هستند [۱]. ریشه واژه صرع در واقع به معنای از دست دادن آگاهی^۱ است. تشنج، ناشی از تخلیه الکتریکی ناگهانی، معمولاً کوتاه و بیش از حد در یک گروه از سلول‌های مغزی^۲ است و در بخش‌های مختلفی از مغز می‌تواند رخ دهد. مجموعه‌ای از علائم گذرا مانند از دست دادن آگاهی، سوزش و یا اختلالاتی در حرکت، احساس و یا عملکرد ذهنی می‌تواند در اثر حمله صرعی رخ دهند. صرع در بسیاری موارد درمان شده و تا به امروز مهم‌ترین درمان آن، روش دارویی است. در مواردی که بیمار به این درمان مقاومت نشان دهد، روش جراحی پیشنهاد می‌شود. هر دو روش درمانی عوارض جانبی خواهند داشت [۲].

برای بهبود کیفیت زندگی، کنترل صرع ضروری است. یک رویکرد برای جلوگیری از آسیب دیدن بیمار در اثر تشنج، پیش‌بینی اولیه است تا به بیمار از طریق دارو و یا برخی عوامل خواص کمک کند و یا حتی از شخص دیگری درخواست کمک شود [۳].

امروزه از سه روش معمول برای کمک به تشخیص تشنج استفاده می‌شود: MEG^۳، EEG^۴ و fMRI^۵. سیگنال الکتروانسفالوگرام، نوار مغز، شایع‌ترین ابزار مورد استفاده در این گونه مطالعات است [۲]. برای رسیدن به سیستم تشخیص اتوماتیک، تعیین ویژگی‌های سیگنال الکتروانسفالوگرام در مراحل مختلف تشنج ضروری است. الکتروانسفالوگرام در واقع یک الگوی الکتریکی از عملکرد مغز می‌باشد. در مغز انسان زیرسیستم‌هایی وجود دارند که موقعیت‌های مغزی را از طریق فعالیت‌های خود مشخص می‌کنند. بنابراین نوار مغز یکی از مهم‌ترین سیگنال‌های حیاتی برای تشخیص الگوهای مغز است و برای استخراج ناهنجاری‌های این الگوها یک عنصر کلیدی به شمار می‌رود [۳]. ویژگی‌های مورد نیاز سیگنال می‌توانند دامنه، شدت و مدت زمان موج سیگنال، انرژی آن و تغییرات فرکانس و غیره باشد.

طبقه‌بندی داده‌های نوار مغزی به دو دسته صرعی و سالم نیاز به ابزاری مناسب دارد؛ به ویژه در وضعیت‌های مختلف و با توجه به اطلاعات مورد تقاضا اهمیت این ابزار بیشتر مشخص می‌شود. برای طبقه‌بندی و شناسایی ویژگی‌ها مراحل ذیل انجام می‌شود: پیش پردازش، استخراج ویژگی‌ها و کاهش ابعاد.

۲- مروری بر کارهای گذشته

با توجه به اهمیت استخراج و طبقه‌بندی ویژگی‌ها در سیگنال‌های الکتروانسفالوگرام، به منظور تشخیص و یا پیشگیری حمله صرعی، روش‌های پردازشی متفاوتی طی سال‌های اخیر صورت گرفته است. استخراج ویژگی در حوزه زمان و فرکانس برای افزایش کارایی این روش‌ها انجام شده است. به منظور غلبه بر محدودیت تبدیل فوری، تبدیل کوتاه مدت فوری با یک پنجره متحرک با عرض ثابت و تبدیل موجک گسسته^۶ مورد استفاده قرار گرفته است. روش‌های کاهش ابعاد برای تضمین مقاوم بودن سیستم و کاهش بار پردازشی استفاده شده است [۳].

در سال ۲۰۰۵، Chow و Huang نشان دادند که آموزش طبقه‌بندی کننده با مجموعه داده‌های با ابعاد بالا، کارایی طبقه‌بندی را کاهش می‌دهد. تحلیل اجزای اصلی^۷، تحلیل اجزای اصلی و تحلیل جداکننده خطی تکنیک‌های رایج برای استخراج ویژگی‌ها هستند. تجزیه و تحلیل اجزاء مستقل^۸ جهت افزایش استقلال آماری متغیرهای تصادفی اعمال شده است. این روش نقاط ضعفی مشابه با تحلیل اجزای اصلی دارد [۲]، [۳].

طبقه‌بندی کننده KNN، که توسط طبقه‌بندی کننده Bayes ارائه شده است، بهترین عملکرد ممکن طبقه‌بندی را ارائه می‌دهد. طبقه‌بندی سری‌های زمانی مربوط به ویژگی‌های سیستم واسط مغز رایانه، توسط مدل مخفی مارکوف انجام شده است [۳].

تعریف و شناسایی حالت پیش از حمله، با استفاده از سیگنال ECoG^۹ پیوسته در سگ‌های مبتلا به صرع، با یک الگوریتم بردار پشتیبانی انجام شده است [۴]. این مساله بعداً توسط Zhang و همکاران در سال ۲۰۱۶ با استفاده از نسبت توان طیفی داده‌های ECoG و پردازش از طریق فیلتر مرتبه دوم کالمن و در نهایت به عنوان ورودی به یک طبقه‌بندی کننده ماشین بردار پشتیبان خطی، توضیح داده شده است [۵]. یک روش انتخاب ویژگی مبتنی بر حذف، توسط Wang و همکاران در سال ۲۰۱۵ برای افزایش اثربخشی استفاده شده است. این کار از طریق کاهش افزونگی و در نتیجه کاهش زمان پردازش به انجام رسیده است [۶]. یک الگوریتم یادگیری سریع برای شبکه عصبی فازی خود سازماندهی شده^{۱۰} توسط Coyle و همکاران (۲۰۰۹) ارائه شد. این روش، سیستم واسط مغز رایانه^{۱۱} مبتنی بر الکتروانسفالوگرام برای پیش‌بینی سری‌های زمانی-عصبی را تسریع می‌کند [۷].


از روش یادگیری عمیق بهینه شده برای داده‌های عظیم^{۱۲} سیگنال EEG و ECoG، در پیش‌بینی حمله صرعی مبتنی بر واسط مغز-رایانه از طریق اینترنرت اشیاء^{۱۳} استفاده شده است. برای حل مشکل ذخیره سازی و پردازش بلادرنگ داده‌ها و ویژگی‌های استخراج شده از سیگنال‌های مورد بررسی، روش داده‌های عظیم و پردازش ابری به کار رفته است. سپس از روش‌های SAE^{۱۴} و شبکه عصبی پیچشی^{۱۵} بر مبنای PCA، JCA و الگوریتم جستجوی تفاضلی^{۱۶} برای پردازش بهینه و استخراج ویژگی‌های مورد نیاز استفاده شده است که دقت طبقه‌بندی این روش ۹۶٪ بوده و در مقایسه با روش‌های مشابه عملکرد مناسب‌تری دارد. مزیت اصلی آن، تحلیل و یادگیری سریع حجم زیادی از داده‌های بدون نظارت بوده که باعث جلوگیری از وقوع صرع در مراحل اولیه می‌گردد. تخمین واریانس EEG می‌تواند به عنوان بازخورد تحریک عصبی پاسخگو در ارائه سیستم محاسباتی اتوماتیک جهت تشخیص حمله صرعی در آینده به کار رود [۱]. در یکی دیگر از روش‌های پیشنهادی به منظور دسته‌بندی سیگنال‌های صرعی، اطلاعات مربوط به مولفه‌های مد ذاتی^{۱۷} سیگنال EEG برای ردیابی دامنه محلی و فرکانس سیگنال، استخراج شده اند. این روش با استفاده از EMD^{۱۸} چند متغیره به دقت ۸۰٪ رسیده است و دارای مزایایی همچون سرعت و دقت مناسب و حساسیت و ویژه بودن قابل قبول در مقایسه با روش‌های قبلی می‌باشد [۱۴].

استفاده می‌کند. فیلترهای بالاگذر و پایین‌گذر برای تجزیه فرکانس‌های بالا و پایین به کار می‌روند. تفکیک‌پذیری سیگنال، توسط فیلتر کردن و مقیاس‌بندی تغییر می‌کند [۲]، [۳]. به این ترتیب، سیگنال به ضرایب تقریب و جزئیات براساس روابط ۲ و ۳ تجزیه می‌شود [۲].

$$y_{high}[k] = \sum_n x[n] \cdot g[2k - n] \quad (2)$$

$$y_{low}[k] = \sum_n x[n] \cdot h[2k - n] \quad (3)$$

در اینجا y_{low} ، y_{high} به ترتیب خروجی‌های فیلتر بالاگذر و فیلتر پایین‌گذر به ترتیب پس از کاهش نمونه‌ها^{۲۱} است. این روش تجزیه، تفکیک زمانی را به نصف کاهش می‌دهد، وضوح فرکانس را دو برابر می‌کند [۲]. در هر سطح تجزیه، نیمی از نمونه‌ها و باند فرکانس‌ها با فیلتر کردن و کمینه شدن در نظر گرفته می‌شوند [۲]. الگوریتم تبدیل موجک گسسته با روش بانک فیلتر در شکل (۱) نشان داده شده است.



شکل (۱): روش بانک فیلتر در تبدیل موجک گسسته [۲].

Fig. (1): DWT with Filter bank method [2].

۳-۲- تجزیه حالت تجربی

روش مناسب برای تجزیه و تحلیل سری‌های غیرخطی و غیرثابت از زمان، استفاده از تجزیه حالت تجربی است. تجزیه حالت تجربی^{۲۲} بر روی یک ایده اولیه استوار می‌باشد؛ "سیگنال چند مودی برابر است با نوسانات زیاد بر روی نوسانات آرام‌تر." برای حل مشکل تبدیل موجک در پیدا کردن فرکانس مرکزی، از روش تجزیه حالت تجربی، تبدیل هیلبرت-هوانگ^{۲۳} و ویژگی‌ها و فرکانس مرکزی سیگنال استفاده می‌شود. سیگنال را می‌توان به برخی از اجزای نوسانی به عنوان توابع حالت ذاتی تجزیه کرد. توابع حالت ذاتی از طریق غربالگری الگوریتم فرآیند، از سیگنال اولیه استخراج می‌شوند [۹].

بنابراین سیگنال اصلی را می‌توان به صورت مجموعه‌ای از مؤلفه‌های مد ذاتی به علاوه باقیمانده سیگنال به صورت رابطه ۴ در نظر گرفت.

$$x(t) = r + \sum_{n=1}^N h_n \quad (4)$$

مؤلفه مود ذاتی دارای شرایط و ویژگی‌های ذیل می‌باشد:

- (الف) تعداد اکستریم‌های آن برابر است با تعداد نقاط صفر آن و یا در نهایت یک عدد بیشتر از آن؛
- (ب) انتگرال آن در بازه زمانی تعریف شده مساوی صفر است (پوش سیگنال متقارن است).

الگوریتم تجزیه حالت تجربه، طی چندین مرحله و با شرایط توقف و ادامه خاصی، انجام می‌شود که این مراحل عبارتند از:

- ۱- تعیین نقاط ماکسیمم و مینیمم محلی سیگنال ورودی؛

در طبقه‌بندی ارائه شده مبتنی بر تبدیل موجک برای سیگنال‌های EEG صرعی، از DWT برای تجزیه سیگنال در چندین زیر باند استفاده شده و پنج ویژگی از ضرایب تبدیل موجک استخراج گردید. این ویژگی‌ها برای آموزش یک طبقه‌بندی کننده SVM^{۱۹} به کار رفته‌اند. دقت کلی به دست آمده از این روش به ۸۷٪ رسیده است [۱۵].

یکی دیگر از روش‌های شناسایی صرع بر پایه آمارگان نقشه تبدیل موجک و روش EMD برای آنالیز طیفی هیلبرت - هوانگ در باند فرکانسی گاما سیگنال‌های EEG می‌باشد [۱۷].

با توجه به کارهای قبلی عنوان شده، به منظور استخراج ویژگی‌ها و طبقه‌بندی آن‌ها روش‌های مورد استفاده در این مقاله معرفی می‌گردد.

۳- مبانی نظری تحقیق

به منظور استخراج ویژگی‌های مورد نیاز جهت تشخیص صرع در سیگنال الکتروانسفالوگرام، ابتدا این ویژگی‌های آماری تعریف شده و سپس با استفاده از روش‌های تبدیل موجک گسسته و تجزیه حالت تجربی به استخراج این ویژگی‌ها پرداخته و به این ترتیب فضای ویژگی ایجاد می‌گردد. با توجه به این که پردازش ویژگی‌ها در فضایی با ابعاد بزرگ، مستلزم صرف زمان زیاد می‌باشد لذا از روش‌هایی همچون تحلیل اجزای مستقل و تحلیل اجزای اصلی جهت کاهش ابعاد فضای ویژگی و افزایش سرعت پردازش استفاده شده و نتایج حاصله با یکدیگر مقایسه می‌گردد. در این مقاله، ویژگی‌های آماری با استفاده از تبدیل موجک گسسته و تجزیه حالت تجربی استخراج و سپس طبقه‌بندی انجام شده و با یکدیگر مقایسه شده است.

ویژگی‌های آماری استخراج شده توسط تبدیل موجک گسسته و تجزیه حالت تجربی عبارتند از:

- ۱) متوسط مقادیر مطلق تابع مود ذاتی^{۲۰} و ضرایب تبدیل موجک گسسته.
- ۲) توان متوسط (از روش ولج) مؤلفه مود ذاتی یا ضرایب تبدیل موجک گسسته.
- ۳) انحراف معیار تابع مود ذاتی یا ضرایب تبدیل موجک گسسته در هر حالت.
- ۴) متوسط انحراف مطلق حالت‌های مجاور.

۳-۱- تبدیل موجک گسسته

به منظور رفع مشکل تفکیک‌پذیری زمان و فرکانس، از روش‌های تحلیل چندرزولوشنی استفاده می‌شود که یکی از این روش‌ها، تبدیل موجک می‌باشد.

تبدیل موجک، روش رایجی برای محلی‌سازی اجزای سیگنال در حوزه زمان-فرکانس بوده و به دو صورت تبدیل موجک پیوسته و گسسته به کار می‌رود. در حالت پیوسته، سیگنال اصلی در تابع موجک ضرب شده (همانند پنجره در تبدیل فوریه زمان کوتاه) و به صورت زیر تعریف می‌شود [۲]، [۳]:

$$\Psi(\tau, s) = \frac{1}{\sqrt{s}} \int x(t) \psi^*\left(\frac{t-\tau}{s}\right) dt \quad (1)$$

تبدیل موجک گسسته، برای پردازش سیگنال‌های دیجیتال مناسب بوده و از روش‌های فیلتر دیجیتال برای نمایش زمان - مقیاس سیگنال

نظر گرفته می شود. علاوه بر این، A به عنوان یک ماتریس مرکب با ابعاد $n \times i$ با ستون هایی حاوی دوره های زمانی مربوط به اجزای n است. این مساله به عنوان یک مساله جداسازی کور منبع مطرح می باشد که می تواند با یک مدل خطی با رابطه ۸ نمایش داده شود [۳].

$$X = AS \quad (۸)$$

همچنین تابعی با فرمول ۹ در نظر گرفته می شود:

$$Y = WX \quad (۹)$$

بنابراین هدف الگوریتم تحلیل اجزای مستقل، برآورد ماتریس غیرمرکب $W_{i \times j}$ است، به طوری که Y تقریب خوبی از منابع سیگنال باشد. الگوریتم های تحلیل اجزای مستقل از روش های آماری مرتبه بالا برای حل اجزای مستقل استفاده می کنند.

با اعمال ماتریس معکوس روی سیگنال دریافتی، جداسازی صورت می گیرد. لذا لازم است ماتریس معکوس طی روابط ۱۰ تا ۱۳ بدست آید:

$$X(t) = AS(t) + n(t) \quad (۱۰)$$

$$W^T = \tilde{A} \quad (۱۱)$$

$$\hat{S}(t) = Y(t) \quad (۱۲)$$

$$Y(t) = W^T X(t) \quad (۱۳)$$

برای تخمین زدن سیگنال مورد نظر سه حالت وجود دارد [۱]، [۳]:

الف) تعداد منابع از تعداد دریافت کننده ها کمتر باشد که در مسائل فیلترینگ، بهبود، همبستگی و شناسایی کاربرد دارد.

ب) تعداد منابع برابر با تعداد دریافت کننده ها باشد.

ج) تعداد منابع بیشتر از تعداد دریافت کننده ها باشد که در مسائل برون یابی کاربرد دارد.

در حالات الف و ب، بدست آوردن تخمین و معکوس ساده تر است. در حالت ج می توان به تعداد سیگنال دریافتی، منابع اول را تخمین زد و مابقی منابع را از خصوصیات آماری مرتبه دوم به دست آورد.

برای استفاده از تحلیل اجزای مستقل مجموعه ای از شرایط بدین شرح مورد نیاز است: استقلال سیگنال های منبع، نداشتن توزیع گوسی (حداقل یکی از منابع گوسی نباشد)، داشتن میانگین صفر و واریانس یک در سیگنال های منبع. علاوه بر این در تحلیل اجزاء مستقل، نمی توان ترتیب مؤلفه های مستقل را حفظ کرد.

در تحلیل اجزاء مستقل، فرضیات ذیل در نظر گرفته می شوند:

- ۱- همه سیگنال های منبع، بایستی مستقل از هم باشند.
 - ۲- تعداد سیگنال های مرکب از تعداد منابع بیشتر یا برابر آن ها باشند.
 - ۳- ماتریسی که با ضرب آن در سیگنال منبع، سیگنال ترکیبی به دست می آید (ماتریس A) از مرتبه کامل باشد.
 - ۴- بردارهای X و S ، میانگین صفر داشته باشند.
 - ۵- حداقل یکی از سیگنال های منبع توزیع گوسی داشته باشد.
- پیش پردازش در تحلیل اجزاء مستقل به معنی سفیدسازی است. واریانس مشاهدات در این تحلیل، یک بوده و سیگنال ها نسبت به هم ناهمبسته اند. با فیلتر سفیدسازی، ماتریس مرکب به فاکتورهای متعامد یا واحد تبدیل

۲- ایجاد منحنی پوش بالا از طریق برازش منحنی درجه ۳ بر نقاط ماکسیمم محلی؛

۳- ایجاد منحنی پوش از طریق برازش منحنی درجه ۳ بر نقاط مینیمم محلی؛

۴- میانگین گیری از منحنی های پوش بالا و پایین؛

۵- تفریق میانگین منحنی پوش بالا و پایین از سیگنال ورودی، مطابق رابطه ۵ که منجر به حذف مولفه فرکانس پایین از سیگنال اصلی خواهد شد.

$$h_1(t) = x(t) - m_1(t) \quad (۵)$$

۶- بررسی شرایط مؤلفه مود ذاتی و معیار توقف بر اساس رابطه ۶:

$$D_k = \frac{\sum_{t=0}^T |h_1^{k-1}(t) - h_1^k(t)|^2}{\sum_{t=0}^T |h_1^{k-1}(t)|^2} \quad (۶)$$

۷- در صورت نبودن شرط ۶، جایگذاری سیگنال از مرحله ۵ به جای سیگنال اصلی و ادامه از مرحله اول؛

۸- اگر شرط ۶ برقرار بود، فرآیند غربال پایان یافته و h_1^k ؛

۹- اگر باقیمانده h_1^k ، شرایط مولفه مود ذاتی را ارضا کند یک مولفه مود ذاتی محسوب می شود و در غیر این صورت اگر شرط (الف) را داشته باشد، به عنوان سیگنال اولیه، فرض شده و گام های ۱ تا ۵ تکرار می شود تا مولفه مود ذاتی به دست آید؛ اگر شرط الف برقرار نباشد، به فرم رابطه ۷ و به عنوان باقیمانده تلقی می شود.

$$r_1 = x(t) - C_1^k \quad (۷)$$

شرایط معیار توقف به صورت ذیل بوده و ترتیب استخراج مودها، از فرکانس بالا به پایین است [۹]، [۱۰].

الف) سیگنال بیش از حد غربال نشود.

ب) سیگنال کمتر از حد غربال نشده و اختلاط مود بوجود نیاید.

ج) زمان اجرای برنامه زیاد نشود.

۳-۳- آنالیز اجزای مستقل

علت استفاده از این روش، نبودن اطلاعات کافی از چگونگی تولید سیگنال های منبع و همچنین نحوه ترکیب آنها با یکدیگر است. هدف این روش رسیدن به سیگنال های منبع نامعلوم از طریق سیگنال های دریافتی و در حضور نویز می باشد. به عنوان نمونه، در پژوهش های انجام شده و در سال ۲۰۱۳ جهت تفکیک سیگنال های مغزی در کاربردهای واسط مغز رایانه بر اساس تصور حرکت دست راست و چپ، طبقه بندی کننده های مختلفی بررسی شد. در این میان تفکیک کننده های جداسازی خطی با ۱۲/۴٪ خطا، دارای بهترین بازدهی جهت تفکیک سیگنال های تصور می باشد.

یکی از متداول ترین روش های جداسازی کور منابع، آنالیز اجزای مستقل نام دارد. در این روش سیگنال ها به اجزای تشکیل دهنده آن با منابع مستقل از هم تجزیه می شوند. الگوریتم های متعددی برای تحلیل اجزای مستقل معرفی شده اند که یکی از پرکاربردترین آنها fastICA می باشد [۸].

ابتدا ماتریس $Z \times i$ ساخته می شود که در آن i تعداد اسکن ها در یک مطالعه و Z تعداد وکسل ها از اسکن های پیش پردازش شده است. سپس یک ماتریس $n \times Z$ ، که n تعداد عنصر مستقل مورد انتظار می باشد، در

$$T = \begin{bmatrix} \Phi_1 \\ \Phi_2 \\ \vdots \\ \Phi_d \\ \vdots \\ \Phi_i \end{bmatrix} \cdot \begin{bmatrix} \lambda_1 \\ \lambda_2 \\ \vdots \\ \lambda_d \\ \vdots \\ \lambda_i \end{bmatrix} \quad (17)$$

$$\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_d \geq \dots \geq \lambda_i$$

این بردارهای ویژه، اجزای اصلی نامیده می‌شوند. به منظور کاهش ابعاد، تنها ردیف اول ماتریس T انتخاب می‌شود (بر اساس d عدد از مهمترین بردارهای ویژه).

نگاشت بردار X_k (یا هر ماتریس تصادفی Z با همان نوع و بعد X_k) به یک فضای جدید و محاسبه اجزای اصلی آن می‌تواند با ماتریس T انجام شود. این ماتریس‌ها از روابط ۱۸ و ۱۹ به دست می‌آیند.

$$Y = T \cdot (Z - \mu_Z) \quad (18)$$

$$Y_i = \Phi_i^T (Z_i - \mu_{Z_i}) \quad (19)$$

خطای کاهش ابعاد می‌تواند با استفاده از روش حداقل میانگین مربعات^{۲۷} محاسبه شود. روش تحلیل اجزاء اصلی وضعیت خاصی از روش تجزیه مقادیر منفرد است. نامساوی ۲۰ باید برای تعیین تعداد ویژگی‌های جدید در دامنه (d) روش تحلیل اجزاء اصلی برقرار باشد [۳]، [۱۱].

$$\frac{\sum_{i=1}^d \lambda_i}{\sum_{i=1}^n \lambda_i} \geq 0.99 \quad (20)$$

برای آماده‌سازی ماتریس ورودی به طبقه‌بندی کننده و ایجاد بهترین عملکرد، ابعاد ویژگی‌های استخراج شده با کمک روش تحلیل اجزاء اصلی، کاهش یافت. تحلیل اجزای اصلی و سپس نرم کردن به صورت ابتکاری، به عنوان مرحله پیش‌پردازش طبقه‌بندی مورد استفاده قرار گرفت.

۳-۵- نرم کردن

روند کردن^{۲۸} و نرم کردن^{۲۹} پارامترها، به ویژه زمانی که از داده‌هایی مانند سیگنال الکتروانسفالوگرام استفاده می‌شود، مفید می‌باشد. در این مقاله از روش نرم کردن، برای دستکاری و کاهش نویز اطلاعات بانک داده استفاده شده تا یک تقریب از سیگنال اصلی به دست آید. بنابراین از این تقریب، نقاط مهم سیگنال استخراج می‌شود [۱۲].

در نرم کردن، کلیه نقاط سیگنال بررسی می‌شوند تا نقاط منفردی که به علت نویز، بالاتر یا پایین‌تر از نقاط اصلی سیگنال هستند تعدیل گردند. این عملیات به طور طبیعی منجر به سیگنال نرم خواهد شد. اگر سیگنال اصلی نرم باشد، در اثر نرم کردن تغییر خاصی نخواهد کرد، اما نویز فرکانس بالا کاهش خواهد یافت. از لحاظ اجزای فرکانسی، عملیات نرم کردن به عنوان یک فیلتر پایین‌گذر عمل می‌کند، اجزای فرکانس بالا را کاهش می‌دهد و اجزای فرکانس پایین را با تغییرات کمی عبور می‌دهد. ساده‌ترین الگوریتم نرم کردن، جعبه مستطیلی و یا پنجره لغزنده بدون وزن، روی میانگین داده‌ها است [۱۲].

۳-۶- ماشین‌های بردار پشتیبان

ماشین‌های بردار پشتیبان^{۳۰} یک روش طبقه‌بندی معمول خطی و با نظارت است. اگر گروه‌ها بتوانند به طور خطی جدا شوند، ممکن است ابر

می‌شود. هدف از سفیدسازی، افزایش زاویه بین مشاهدات به ۹۰ درجه و ایجاد استقلال است.

یکی از کاربردهای مهم تحلیل اجزای مستقل، آنالیز سیگنال‌های بیولوژیکی (مانند الکتروانسفالوگرام) است. با توجه به این که سنسورهای که جهت دریافت سیگنال به مغز متصل می‌شوند ترکیبی از سیگنال‌های منابع مختلف را دریافت می‌کنند، لذا جداسازی سیگنال هدف و حذف سیگنال‌های مزاحم از آن موضوع بسیار مهمی در مرحله پیش‌پردازش سیگنال‌های حیاتی به شمار می‌رود [۲].

۳-۴- تحلیل اجزاء اصلی

تحلیل اجزاء اصلی یک روش مفید برای استخراج ویژگی‌ها و کاهش ابعاد است، به طوری که حداقل داده‌ها از بین می‌روند. اجزای اصلی یک ماتریس، بردارهای ویژه ماتریس کوواریانس خود هستند. متغیرهای تعیین شده، ناهمبسته هستند. تحلیل اجزاء اصلی، متغیرهای همبسته را به صورتی تغییر می‌دهد که مستقل خطی شوند. این متغیرها به وسیله یک تبدیل مستطیلی به نام مؤلفه اصلی نامگذاری می‌شوند. تحلیل اجزاء اصلی، یک تحلیل خطی و غیرپارامتری است. بعضی از روش‌های تحلیل اجزاء اصلی مانند هسته تحلیل اجزاء اصلی^{۲۵}، تحلیل اجزاء اصلی چندخطی^{۲۶} و تحلیل اجزاء مستقل برای مجموعه داده‌های غیرخطی استفاده می‌شوند [۳]، [۱۱].

ابتدا یک بردار n بعدی (X_i) از ویژگی‌ها فرض می‌شود. روش تحلیل اجزاء اصلی، ابعاد این بردار را از n به d ($d \ll n$) کاهش می‌دهد. برای رسیدن به این هدف، بردار X_i با ماتریس تبدیل و از رابطه ۱۴ به دست می‌آید.

$$Y_i = T \cdot X_i \quad (14)$$

برای به دست آوردن ماتریس تبدیل تحلیل اجزای اصلی، مراحل زیر باید انجام شود:

- ۱) محاسبه میانگین بردارهای ویژگی M
- ۲) تمرکز تمام ویژگی‌ها: تفریق میانگین ویژگی از همان ویژگی
- ۳) محاسبه ماتریس همبستگی فرمول ۱۵ و از ویژگی‌های متمرکز (یعنی ماتریس کوواریانس از ویژگی‌های اولیه)

$$C_x = \frac{1}{M} \sum_{k=1}^M [(\bar{X}_k)(\bar{X}_k)^T] \quad (15)$$

۴) محاسبه بردارهای ویژه (Φ_i) و مقادیر ویژه (λ_i) ماتریس کوواریانس C_x از رابطه ۱۶:


$$C_x \Phi_i = \lambda_i \Phi_i \quad (16)$$

تعداد بردارهای ویژه و مقادیر ویژه برابر با بعد بردارهای ویژگی می‌باشد. بزرگ‌ترین مقدار ویژه از بردار ویژه، جزء اصلی مجموعه داده را ارائه می‌دهد.

۵) با استفاده از بردارهای ویژه و مقادیر ویژه، ماتریس تبدیل، به فرم ماتریس ۱۷، تولید می‌شود.

باز و مجموعه B در موقعیت چشم بسته قرار داشتند [۳]. مجموعه‌های C، D و E در طی عمل جراحی ثبت شدند. مجموعه E، فقط برای فعالیت‌های تشنجی است. داده‌های الکتروانسفالوگرام از پنج نفر بیمار تشنجی انتخاب شده‌اند [۳].

تمام سیگنال‌های الکتروانسفالوگرام با یک سیستم ۱۲۸ کاناله با استفاده از یک مرجع معمول مشترک ثبت شدند. نرخ نمونه‌برداری برابر با ۱۷۳/۶۱ نمونه در هر ثانیه با دقت ۱۲ بیتی می‌باشد. در مطالعه حاضر مجموعه‌های A و E مورد استفاده قرار گرفته‌اند [۳]. یک پنجره از سیگنال‌های A و E در شکل ۲ نشان داده شده است، بنابراین می‌توان سیگنال‌های به دست آمده را با یکدیگر مقایسه کرد.



شکل (۲): سیگنال‌های عادی و صرعی؛ دامنه پایین‌تر مربوط به یک فرد سالم.
Fig. (2): Normal & epileptic signals, the lower amplitude related to non-patient person.

از روش‌های تبدیل موجک گسسته و تجزیه حالت تجربی برای استخراج ویژگی‌های تصادفی مورد نظر از سیگنال الکتروانسفالوگرام استفاده و مطابق نتایج، ماشین بردار پشتیبان می‌تواند یک راه‌حل مناسب برای طبقه‌بندی سیگنال‌های الکتروانسفالوگرام باشد. همچنین کاهش ابعاد تاثیر مثبتی بر عملکرد آن دارد. استفاده از ترکیب‌های چهارگانه DWT و EMD به همراه روش‌های ICA و PCA جهت کاهش ابعاد فضای ویژگی و سپس نرم کردن داده‌های ورودی به SVM و مقایسه این روش‌ها با یکدیگر به عنوان رویکردهای جدید در طبقه‌بندی ویژگی‌های استخراج شده از سیگنال‌های EEG صرعی در نظر گرفته شده است.

اثر دو روش EMD و DWT در فرآیند طبقه‌بندی با یکدیگر مقایسه شده و نشان می‌دهد که ویژگی‌های استخراج شده توسط EMD، باعث افزایش دقت طبقه‌بندی نسبت به روش DWT شده است. در ادامه، به منظور کاهش ابعاد فضای ویژگی، روش‌های تحلیل اجزای مستقل و تحلیل اجزای اصلی مورد استفاده قرار گرفت. سپس برای کاهش اثر نویز بر روی سیگنال الکتروانسفالوگرام، از روش‌های نرم کردن استفاده شد. در نهایت، به کمک طبقه‌بندی کننده ماشین بردار پشتیبان، داده‌های موجود به دو دسته سالم و صرعی طبقه‌بندی گردید. نتایج با الگوهای طبیعی تشنج مقایسه می‌شود. روش مورد استفاده، در فلوچارت شکل ۳ نشان داده شده است.

در فرآیند تجزیه سیگنال با تابع تبدیل موجک، با توجه به شباهت سیگنال EEG به شکل ویولت مادر دابچیز، از db4 استفاده شده است که تعداد

صفحه‌ها با حداکثر حاشیه‌ای برای تمایز بین آنها وجود داشته باشد. در غیر این صورت، اگر داده‌ها به صورت خطی قابل جدا شدن نباشند، می‌توان برای جداسازی آن‌ها به صورت خطی، آنها را به یک فضای با ابعاد بزرگ‌تر (یعنی فضای ویژگی) نگاشت کرد. این تبدیل، تابع کرنل^{۳۱} (هسته) نامیده می‌شود. هسته‌ها برای حل مشکل کار با ابعاد بزرگ فضای ویژگی و صرفه‌جویی در زمان اجرا مورد استفاده قرار می‌گیرند. برخی از هسته‌ها مانند چند جمله‌ای درجه m ، پایه‌های شعاعی و شبکه عصبی وجود دارند [۳]، [۱۳].

هدف ماشین بردار پشتیبان پیدا کردن بهترین خط یا ابرصفحه، برای تمایز دادن بین گروه‌ها است. به طور کلی، معادله خطی برای n بعد، به صورت زیر است:

$$\vec{W}^T \cdot \vec{X} + b = 0 \quad (21)$$

بهترین جداکننده، دارای حداکثر فاصله تا صفحات حاشیه‌ای است. برای کاهش خطای تعمیم، حاشیه داده‌های آموزشی باید حداکثر باشد.

اندازه‌گیری عملکرد ماشین بردار پشتیبان می‌تواند با اندازه‌گیری دقت^{۳۲}، حساسیت^{۳۳} و ویژگی^{۳۴}، که با استفاده از معیارهای خطای مثبت^{۳۵}، منفی کاذب^{۳۶}، درست مثبت^{۳۷} و درست منفی^{۳۸} تعریف شده است، انجام می‌شود [۳]، [۱۳]. روابط ۲۲ تا ۲۴ روش محاسبه این معیارها را نشان می‌دهد.

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (22)$$

$$Specificity = \frac{TN}{TN+FP} \quad (23)$$

$$Sensitivity = \frac{TP}{TP+FN} \quad (24)$$

در این کار، از کرنل RBF^{۳۹} که پارامتر مقیاس آن به صورت اتوماتیک تنظیم می‌گردد، استفاده شده و ماتریس بردارهای پشتیبان با ابعاد 20×9 تشکیل شده است. شبکه‌های RBF به واسطه آموزش سریع و فراگیر و نیز تنها با داشتن یک لایه مخفی دارای خاصیت طبقه‌بندی مناسب الگوها با فضای غیرخطی بوده و نرخ طبقه‌بندی آن نسبت به سایر روش‌ها از جمله MLP بالاتر است [۱۸].

۴- روش پیشنهادی و نتایج تجربی

استفاده از روش‌های استخراج ویژگی و تجزیه و تحلیل سیگنال الکتروانسفالوگرام می‌تواند نیاز به ملاقات حضوری بیمار را کاهش داده و از این طریق بر روی کیفیت زندگی بیمار تاثیر مثبت داشته باشد. به منظور ارزیابی کارایی و دقت روش‌های استخراج ویژگی و طبقه‌بندی این ویژگی‌ها، لازم است روش‌های پیشنهادی فوق بر روی مجموعه داده موجود بررسی شده و نتایج حاصله با یکدیگر مقایسه گردند.

مجموعه داده مورد استفاده در این مقاله، از دانشگاه Bonn و مربوطه به Andrzejak در سال ۲۰۰۱ بوده که شامل پنج مجموعه A تا E می‌باشد. هر یک از آنها دارای ۱۰۰ قسمت از سیگنال‌های الکتروانسفالوگرام تک کانال است. مجموعه‌های A و B، شامل الکتروانسفالوگرام سطحی از پنج کاندیدای سالم هستند. الکترودهای استاندارد در این کار استفاده شدند. کاندیداها در حالت آگاهی بودند. مجموعه A در وضعیت چشم

Table (1): Performance comparison of applied methods.

جدول (۱): مقایسه عملکرد روش‌های به کار رفته.

ویژه بودن	حساسیت	دقت	معیار روش
100	94.4	97.5	DWT, PCA, SVM
100	97.1	98.3	DWT, ICA, SVM
100	100	100	EMD, ICA, SVM
100	100	100	EMD, PCA, SVM

Table (2): Results comparison with and without smoothing method.

جدول (۲): مقایسه نتایج با استفاده از روش نرم کردن داده و بدون آن.

نتیجه کلی %	TN%	FN%	FP%	TP%	معیار روش
97.5	65.5	2.5	0	32.5	EMD
100	63.3	0	0	36.7	EMD with Smoothing

Table (2): Results comparison of some previous works.

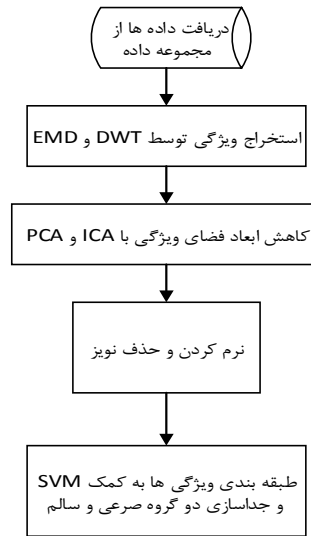
جدول (۳): مقایسه نتایج تعدادی از کارهای قبلی.

ویژه بودن	حساسیت	دقت	معیار روش
98.5	99	98.75	PCA, DWT [۳]
99	100	99.5	ICA, DWT [۳]
96.44	87	87	DWT, SVM [۱۵]
80	81	80	Multi variable EMD [۱۴]
-	-	98.8	RBF+MLP [۱۶]

۵- نتیجه‌گیری

با توجه به ایستا نبودن سیگنال الکتروانسفالوگرام و با در نظر گرفتن محدوده کاربرد آن، روش‌های متفاوتی به منظور تحلیل و پردازش آنها وجود دارد. جهت تعیین صریح بودن یا نبودن، لازم است روش‌های دقیق و قابل اطمینانی برای تمایز شرایط نرمال از حالت تشنجی به کار گرفته شود. استفاده از تجزیه حالت تجربی به همراه تحلیل مؤلفه‌های اصلی، تحلیل مؤلفه‌های مستقل و ماشین بردار پشتیبان به عنوان رهیافتی جدید و قابل اعتماد جهت استخراج ویژگی‌ها و طبقه‌بندی سیگنال‌های مغزی پیشنهاد می‌گردد که منجر به نتایج قابل قبولی در تشخیص صرع خواهد شد. در مرحله استخراج ویژگی و با استفاده از روش تجزیه حالت تجربی، ویژگی‌های مورد نظر به طور کامل بدست آمده و نتایج حاصل از طبقه‌بندی این ویژگی‌ها نسبت به روش تبدیل موجک، دارای بهبود قابل توجهی بوده و به دقت ۱۰۰٪ رسید. همچنین این امر می‌تواند یکی از اقدامات مؤثر در رویارویی با بیماری صرع باشد. خروجی طبقه‌بندی کننده را می‌توان به یک مدار کنترلی اعمال نموده و یا از راه دور، جهت رسیدگی به وضعیت بیمار، به پزشک اطلاع رسانی نمود. چالش زمان پاسخ در استخراج ویژگی‌ها را می‌توان با اعمال روش‌های پیش پردازش داده‌های ورودی به بلوک تجزیه بهبود بخشید. در نهایت، استفاده از این تکنیک‌ها بر روی مجموعه داده‌های متفاوت پیشنهاد می‌گردد تا فراگیر بودن و زمان پاسخ مساله تضمین گردد.

سطوح تجزیه آن براساس تعداد نمونه‌های سیگنال در حوزه زمان، ۵ سطح می‌باشد. تعیین توابع مد ذاتی براساس الگوریتم شرح داد شده در بخش ۲-۳ مقاله و با توجه به معیار توقف با پارامترهای سطح آستانه ۱ و ۲ و همچنین پارامتر تیلرانس، تعیین می‌گردد. محاسبه سطوح آستانه ۱ و ۲ براساس مقادیر حداقل، حداکثر و میانگین دامنه منحنی‌های پوش سیگنال به دست می‌آید. همچنین تعداد تکرار در روش تجزیه حالت تجربی برای ICA، ۲۰ بار و برای PCA، ۱۵ بار در نظر گرفته شده است. اعمال تبدیل موجک گسسته با فیلتر db4 و در ۵ سطح، باعث استخراج ۵ عدد از ضرایب جزییات و یک ضریب از تقریب گردید که این ضرایب منطبق بر سطوح فرکانسی ۰ تا ۸/۸ هرتز می‌باشند. همچنین براساس معیار توقف، تعداد ۶ مؤلفه مد ذاتی در نظر گرفته می‌شود. فضای ویژگی‌ها با توجه به پایگاه داده معرفی شده و ویژگی‌های تعریف شده در بخش ۳، تشکیل شده است. براساس زیر باندهای مختلف سیگنال، ماتریس ویژگی‌ها با ابعاد ۲۴×۲۰ ایجاد می‌شود که پس از اعمال روش‌های کاهش بعد فضای ویژگی، ابعاد ماتریس به ۹×۲۰ کاهش یافته است. بنابراین زمان مورد نیاز برای طبقه‌بندی ویژگی‌ها با استفاده از SVM، حداقل می‌گردد. همچنین استفاده از تابع کرنل RBF در طبقه‌بندی ویژگی‌ها، موجب جداسازی داده‌های غیرخطی و افزایش کارایی و امکان تعمیم روش پیشنهادی شده است.



شکل (۳): فلوجارت روش پیشنهادی.

Fig. (3): Flowchart of the proposed method.

علاوه بر این، نتایج به دست آمده نشان‌دهنده کارایی و دقت بیشتر روش تجزیه حالت تجربی در استخراج ویژگی‌ها و در نتیجه طبقه‌بندی سیگنال‌ها می‌باشد. جدول ۱ نشان‌دهنده نتایج اعمال روش‌های عنوان شده و مقایسه عملکرد آن‌ها می‌باشد:

پیش از طبقه‌بندی نهایی داده‌ها، روش نرم کردن انتخاب شده و نتایج آن با حالت معمولی مقایسه شده و اثر آن روی متغیرهای مورد بررسی در جدول ۲ ارایه شده است؛ همچنین جدول ۳ نشان‌دهنده مقایسه‌ای بین نتایج تعدادی از کارهای قبلی می‌باشد.

- | | |
|--|---------------------------------------|
| 1. Apasmara | 21. Down-sampling |
| 2. Neuron | 22. EMD: Empirical mode decomposition |
| 3. MagnetoEncephaloGraphy | 23. HHT: Hilbert-Houang Transform |
| 4. ElectroEcephaloGraphy | 24. Residue (r) |
| 5. Functional Magnetic Resonance Imaging | 25. Kernel PCA |
| 6. DWT: Discrete Wavelet Transform | 26. Multilinear PCA |
| 7. PCA: Principle Component Analysis | 27. LMS: Least Mean Square |
| 8. ICA: Independent Component Analysis | 28. Rounding |
| 9. ElectroCorticoGraphy | 29. Smoothing |
| 10. SOFNN: Self Organized Fuzzy Neural Network | 30. SVM: Support Vector Machine |
| 11. BCI: Brain Computer Interface | 31. Kernel |
| 12. Big Data | 32. Accuracy |
| 13. IoT: Internet of Things | 33. Sensitivity |
| 14. Stacked Auto-Encoder | 34. Specificity |
| 15. Convolutional Neural Network(CNN) | 35. FP: False Positive |
| 16. Differential Search Algorithm | 36. FN: False Negative |
| 17. IMF: Intrinsic Mode Function | 37. TP: True Positive |
| 18. Empirical Mode Decomposition | 38. TN: True Negative |
| 19. Support Vector Machine | 39. RBF: Radial Basis Function |
| 20. IMF: Intrinsic Mode Function | |

References

- [1] M.P. Hosseini, D. Pompili, K. Elisevich, H. Soltanian-Zadeh, "Optimized deep learning for EEG big data and seizure prediction BCI via internet of things", *IEEE Trans. on Big Data*, Vol. 3, No. 4, pp.392-404, Dec. 2017.
- [2] J.A. Chambers, S. Sanei, "EEG signal processing", Vol. 1, No. 1, pp.1-215, Center of Digital Signal Processing Cardiff University, UK: John Wiley & Sons Ltd., 2007.
- [3] A. Subasi, M.I. Gursay, "EEG signal classification using PCA, ICA, LDA and support vector machines", *Expert Systems with Applications*, Vol. 37, No. 12, pp.8659-8666, Dec. 2010.
- [4] B.H. Brinkmann et al., "Forecasting seizures using intracranial EEG measures and SVM in naturally occurring canine epilepsy", *PloS one*, Vol. 10, No. 8, pp.1-12, Aug. 2015, Available: <https://doi.org/10.1371/journal.pone.0133900>
- [5] Z. Zhang, K.K. Parhi, "Low-complexity seizure prediction from iEEG/sEEG using spectral power and ratios of spectral power", *IEEE transactions on biomedical circuits and systems*, Vol. 10, No. 3, pp.693-706, Jun. 2016.
- [6] N. Wang, M.R. Lyu, "Extracting and selecting distinctive EEG features for efficient epileptic seizure prediction", *IEEE Journal of Biomedical and Health Informatics*, Vol. 19, No. 5, pp.1648-1659, Sep. 2015.
- [7] D. Coyle, G. Prasad, T.M. McGinnity, "Faster self-organizing fuzzy neural network training and a hyperparameter analysis for a brain-computer interface", *IEEE Trans. on Systems, Man, and Cybernetics, Part B (Cybernetics)*, Vol. 39, No. 6, pp.1458-1471, Dec. 2009.
- [8] M. Bagheri et al., "A study on the performance of classifiers and extracted features in discriminating EEG patterns of mental activities related to four main directions", *Journal of Arak University of Medical Sciences*, Vol. 18, No. 12, pp.11-23, Dec. 2016.
- [9] A. McDonald et al., "Empirical Mode Decomposition of the atmospheric wave field", *Annales Geophysicae*, Vol. 25, No. 2, pp.375-384, Mar. 2007.
- [10] J.C. Nunes, E. Deléchelle, "Empirical mode decomposition: Applications on signal and image processing", *Advances in Adaptive Data Analysis*, Vol. 1, No. 1, pp.125-175, Jan. 2009.
- [11] A. Bouzalmat, J. Kharroubi, A. Zarghili, "Comparative study of PCA, ICA, LDA using SVM classifier", *Journal of Emerging Technologies in Web Intelligence*, Vol. 6, No. 1, pp.64-68, Feb. 2014.
- [12] R.E. Kass, V. Ventura, C. Cai, "Statistical smoothing of neuronal data", *Network Computation in Neural Systems*, Vol. 14, No. 1, pp.5-16, Feb. 2003.
- [13] K.P. Bennett, C. Campbell, "Support vector machines: hype or hallelujah?", *Acm Sigkdd Explorations Newsletter*, Vol. 2, No. 2, pp.1-13, Dec. 2000.
- [14] R.J. Oweis, E.W. Abdulhay, "Seizure classification in EEG signals utilizing Hilbert-Huang transform", *Biomedical engineering online*, Vol. 10, No. 1, pp.38, Dec. 2011.
- [15] K.D. Tzimirta, L.G. Astrakas, M.G. Tsipouras, "Wavelet based classification of epileptic seizures in EEG signals", *IEEE 30th International Symposium on Computer-Based Medical Systems (CBMS)*, pp.35-39, 2017.
- [16] H. LotfaliNejad, R. Keshvari, S. Shabroo, H. Moghaddas, "Comparison of MLP and RBF Neural Network Trends in Diagnosis of Epilepsy", *National Conference on Electrical Engineering and Sustainable Development*, Mashhad, Khavaran Higher Education Institute, 2013 .
- [17] M. Behnam, H. Pourghasem, "Epileptic seizure detection based on wavelet transform statistics map and EMD method for hilbert-huang spectral analyzing in gamma frequency band of EEG signals", *Journal of Intelligent Procedures in Electrical Technology*, Vol. 6, No. 22, pp.23-36, Jan. 2015.
- [18] M. Hajian, A. Akbari Foroud, H. Norouzian, "Static voltage stability analysis by using svm and neural network", *Journal of Intelligent Procedures in Electrical Technology*, Vol. 4, No. 13, pp.3-14, Apr. 2013.