

شناسایی تشنج صرعی بر پایه‌ی آمارگان نقشه تبدیل موجک و روش EMD برای آنالیز طیفی هیلبرت - هوانگ در باند فرکانسی گاما سیگنال‌های EEG

مرتضی به نام^(۱) - حسین پورقاسم^(۲)

(۱) کارشناس ارشد - دانشکده مهندسی برق، واحد نجف آباد، دانشگاه آزاد اسلامی، نجف آباد، اصفهان، ایران

(۲) دانشیار - دانشکده مهندسی برق، واحد نجف آباد، دانشگاه آزاد اسلامی، نجف آباد، اصفهان، ایران

تاریخ دریافت: ۱۳۹۴/۳/۳۰ تاریخ پذیرش: ۱۳۹۴/۵/۸

خلاصه: تشخیص بیماری تشنج با استفاده از آنالیز سیگنال‌های مغزی (EEG) از جمله روش‌های کلینیکی کارآمد در درمان دارویی و تصمیمات پیش از جراحی مغزی می‌باشد. در این مقاله، پس از آماده‌سازی سیگنال‌ها با استفاده از یک فیلترینگ مناسب، باند فرکانسی گاما استخراج شده است و سایر ریتم‌های مغزی، مقادیر نوبز محیطی و سیگنال‌های حیاتی دیگر حذف می‌شوند. سپس، تبدیل موجک سیگنال‌های مغزی و نقشه موزائیکی تبدیل موجک در چند سطح محاسبه می‌شود. با تقسیم مناسب نقشه‌ی رنگی به بخش‌بندی‌های^۲ مختلف، هیستوگرام هر زیر- تصویر محاسبه شده و آمارگان آن بر پایه‌ی مقدار ممان‌های آماری^۳ و آنتروپی منفی^۴ محاسبه می‌شود. بردار ویژگی آماری با استفاده از تحلیل مولفه‌های اصلی (PCA)^۵ به یک بعد کاهش می‌یابد. با استفاده از الگوریتم EMD^۶ و پروسه غربالگری در تحلیل داده‌ها به وسیله‌ی توابع حالت ذاتی (IMF)^۷ و مقدار مانده‌ی سیگنال‌ها و با استفاده از طیف تبدیل هیلبرت و تشکیل طیف هیلبرت - هوانگ یک ویژگی مکانی بر پایه‌ی فاصله اقلیدسی برای طبقه‌بندی سیگنال‌های مغزی محاسبه می‌شود. بوسیله‌ی طبقه‌بند K- نزدیک‌ترین همسایه (KNN)^۸ و با در نظر گرفتن پارامتر همسایگی بهینه، سیگنال‌های مغزی به دو کلاس دارای تشنج و سیگنال‌های سالم با میزان صحت ۷۶/۵۴٪ و واریانس خطای ۰/۳۶۸۵ در آزمایش‌های مختلف طبقه‌بندی می‌شوند.

کلمات کلیدی: بیماری صرعی، تبدیل موجک، تبدیل

هیلبرت - هوانگ، ریتم‌های مغزی، طبقه‌بند K- نزدیک‌ترین همسایه (KNN).

Epileptic Seizure Detection based on Wavelet Transform Statistics Map and EMD Method for Hilbert-Huang Spectral Analyzing in Gamma Frequency Band of EEG Signals

Morteza Behnam⁽¹⁾ - Hossein Pourghasem⁽²⁾

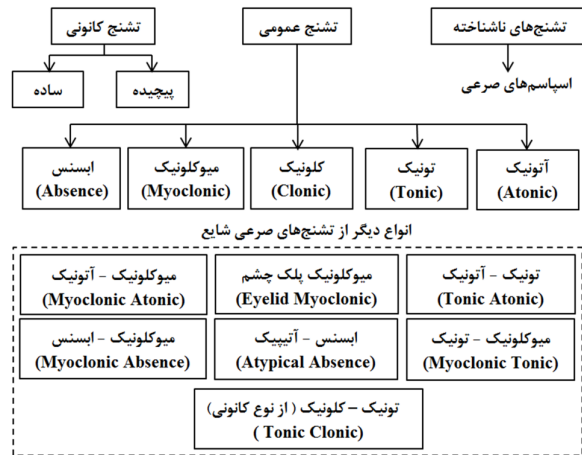
(1) MSc Student - Department of Electrical Engineering, Najafabad Branch, Islamic Azad University, Najafabad, Isfahan, Iran
morteza.behnam@sel.iaun.ac.ir

(2) Associate Professor - Department of Electrical Engineering, Najafabad Branch, Islamic Azad University, Najafabad, Isfahan, Iran
h_pourghasem@iaun.ac.ir

Seizure detection using brain signal (EEG) analysis is the important clinical methods in drug therapy and the decisions before brain surgery. In this paper, after signal conditioning using suitable filtering, the Gamma frequency band has been extracted and the other brain rhythms, ambient noises and the other bio-signal are canceled. Then, the wavelet transform of brain signal and the map of wavelet transform in multi levels are computed. By dividing the color map to different epochs, the histogram of each sub-image is obtained and the statistics of it based on statistical momentums and Negentropy values are calculated. Statistical feature vector using Principle Component Analysis (PCA) is reduced to one dimension. By EMD algorithm and sifting procedure for analyzing the data by Intrinsic Mode Function (IMF) and computing the residues of brain signal using spectrum of Hilbert transform and Hilbert - Huang spectrum forming, one spatial feature based on the Euclidian distance for signal classification is obtained. By K-Nearest Neighbor (KNN) classifier and by considering the optimal neighbor parameter, EEG signals are classified in two classes, seizure and non-seizure signal, with the rate of accuracy 76.54% and with variance of error 0.3685 in the different tests.

Index Terms: Epilepsy, wavelet transform, hilbert-huang transform, brain rhythms, K-nearest neighbor (KNN).

نویسنده مسئول: حسین پورقاسم، دانشکده مهندسی برق، واحد نجف آباد، دانشگاه آزاد اسلامی، نجف آباد، اصفهان، ایران، h_pourghasem@iaun.ac.ir



شکل (۱): طبقه‌بندی انواع تشنج‌های رایج بر اساس حوزه عملکرد آن‌ها در مغز [۴-۱]

Fig. (1): Classifying the common types of seizure based on their performances in the areas of brain [1-4]

در بخش سوم، حمله بروز کرده و نشانه‌های کلینیکی بیماری نیز بروز می‌نماید، لذا سیگنال‌های مغزی نمایش داده شده در شکل (۴) از نمونه ۱۵۰۰ به بعد رفتاری آشوبناک و پرفرکانس را آغاز می‌نمایند. در سال‌های اخیر، پژوهش‌های متفاوتی در زمینه تشخیص بروز حمله صرع و همچنین پیش‌بینی وقوع تشنج در سراسر دنیا انجام شده است [۷]. بطور کلی و با بررسی سیستم‌های پردازش سیگنال می‌توان همواره یک مدل کلی برای پردازش سیگنال‌های مغزی از ابتدا که شامل ثبت سیگنال می‌شود، تا انتها که تشخیص را به همراه دارد در نظر گرفت. در پژوهش‌های انجام شده در این زمینه همواره نوآوری را می‌توان در بخش استخراج ویژگی مشاهده نمود [۸]. از جمله این ویژگی‌ها می‌توان به بررسی مولفه‌های زمان - فرکانس [۹]، آنالیز طیفی [۱۰]، نمای لیاپانوف و بعد همبستگی [۱۱]، و مواردی از این دست اشاره نمود. همچنین استفاده از پردازش‌هایی با در نظر گرفتن چندین کانال از سیگنال‌های مغزی و انجام یک عمل سوئیچینگ بین کانال‌هایی با محتوای مناسب در بین پژوهش‌ها مشاهده می‌شود.

از جمله اولین تحقیقات در زمینه تشنج در سال ۱۹۹۰ با معرفی الگوریتمی برای آشکارسازی وقوع تشنج ارائه شده است [۱۲]. این الگوریتم فعالیت‌های ریتمیک هماهنگ را از میان سیگنال‌های EEG به عنوان علامتی از وقوع تشنج جستجو می‌کند. این مدل، فعالیت دنباله‌دار مغزی را در محدوده‌ی فرکانسی بین ۳ تا ۳۰ هرتز با چگالی توان بیشینه و همچنین دامنه‌ی کمتر از سه برابر بزرگترین پنجره زمینه را جستجو می‌کند و با در نظر گرفتن مدت زمان حضور یک ریتم در حدود ۴ ثانیه اعلام تشنج می‌نماید. در کل این الگوریتم ۵۰٪ از تشنج‌های آزمایش شده را با خطایی حدود ۰/۵ تشخیص داد [۱۲].

پس از آن تحقیقات به سمت فعالیت‌های دوره‌ای در سیگنال‌های مغزی حرکت کرد [۱۳]. از این موارد می‌توان به آشکارساز معرفی شده در [۱۴] اشاره نمود، که با در نظر گرفتن بخش‌هایی مشخص در


۱- مقدمه

سیگنال‌های حیاتی، اطلاعات بیوالکتریک مفیدی را در مورد عملکرد ناحیه‌ی تحت ثبت برای بررسی‌های کلینیکی در اختیار محققین قرار می‌دهند. از جمله‌ی این سیگنال‌ها می‌توان به سیگنال مغزی یا الکتروانسفالوگرام (EEG) اشاره نمود، که یکی از پرکاربردترین سیگنال‌ها در زمینه‌های تحقیقاتی و عصب‌شناختی می‌باشد [۱]. سیگنال EEG که ناشی از فعالیت الکتریکی نرون‌ها و سلول‌های عصبی است، تحت سیستم‌های مختلف ثبت سیگنال، مانند سیستم بین‌المللی ۱۰-۲۰ با قرارگیری الکترودهایی در نقاط مشخص از جمجمه و بر روی پوست سر ثبت شده و جهت کاربردهای دیگر با در نظر گرفتن فرکانس نمونه‌برداری مناسب ذخیره می‌شوند [۱]. سیگنال‌های EEG جنبه‌های مختلفی از عملکرد مغز انسان را نمایش می‌دهند. از جمله این موارد می‌توان به موضوع تشنج^۱ مغزی و همچنین بیماران مبتلا به حمله‌ی صرع^{۱۰} اشاره نمود [۲]. صرع به عنوان یک پدیده‌ی رایج که حدود ۱٪ از مردم جهان به آن مبتلا هستند [۳]، همواره موضوعی برای پژوهش بوده است. تشنج و بیماری صرع دارای انواع متفاوتی هستند که به صورت خلاصه و در یک دسته‌بندی کلی در شکل (۱) آورده شده است [۴]. سیگنال‌های EEG از لحاظ فرکانسی همواره دارای یک پهنای باند مشخص هستند. نکته قابل ملاحظه این است که تمامی رخدادهای موجود در مغز، خود را به عنوان مولفه‌هایی در همین پهنای باند نشان می‌دهند. تشنج مغزی، اختلالات خواب مانند دوک‌های خواب و پتانسیل‌های تحریک (ERP)^{۱۱} امواجی هستند که نهفته در سیگنال‌های EEG بوده و خارج از باند فرکانسی آن نیستند [۵]. بنابراین نیاز به الگوریتمی مقاوم و با قابلیت تعمیم بالا برای تشخیص بیماری صرع احساس می‌شود. الگوریتمی که توان تفکیک بین سیگنال‌های شامل تشنج و دیگر امواج را داشته باشد. سیگنال‌های مغزی به عنوان فرآیندهای تصادفی، دارای مشخصات آماری گاهاً متغیر با زمان هستند [۶]. شروع حمله تشنج همراه با نوسانات شدید در امواج مغزی بوده و این نوسانات علاوه بر ماهیت تصادفی خود، دارای یک ریتم تکرار شونده نیز هستند که در انتهای اثر حمله تشنج از بین می‌روند. به عنوان نمونه می‌توان شکل (۲) را در نظر گرفت. این شکل، ۱۶ کانال از سیگنال‌های مغزی مربوط به یک کودک مبتلا به بیماری صرع را نشان می‌دهد که هیچ‌گونه عارضه‌ای در آن‌ها مشاهده نمی‌شود. همچنین شکل (۳) نیز نمایشی از سیگنال‌های EEG فرد بیمار در هنگام وقوع تشنج و حمله صرع را نشان می‌دهد. همانطور که مشاهده می‌شود، رخداد حمله صرع یک فرآیند عمومی بوده و تمام ناحیه سر را درگیر می‌نماید. در واقع اثرات تشنج در هر ۱۶ کانال مغزی قابل مشاهده هستند. می‌توان هر ۱۶ کانال را به ۳ قسمت مطابق شکل (۴) تقسیم نموده و بیان کرد که، در قسمت اول، ما شاهد یک سیگنال و فعالیت مغزی سالم می‌باشیم. در قسمت دوم و با گذشت زمان نوسانات فرکانس بالای سیگنال‌های EEG بیشتر شده و نشانه‌های حمله صرع آشکار می‌شود.


در حالت کلی می‌توان پردازش برون خط را به عنوان یکی از بخش‌های مهم در پردازش درون خط در نظر گرفت. لازم به ذکر است که هر یک از این پردازش‌ها دارای کاربردهای کلینیکی خاص خود هستند. برای مثال، در هنگام مداخله و جراحی مغزی، اطمینان از وقوع حمله تشنج در مقابل سایر پدیده‌های عصب‌شناختی مانند آنچه در ابتدای مقدمه ذکر شده بود، نیازمند الگوریتمی صرفاً برای تشخیص رخداد تشنج و بررسی ناحیه‌ی وقوع تشنج هستیم. این پردازش‌ها که با نام پردازش‌های برون خط از آن یاد می‌شود، علاوه بر کاربردهای مزبور، در فرآیند تشخیص بلادرنگ و درون خط هم از بخش‌های اساسی هستند. پردازش‌های بلادرنگ با پیش‌بینی زمان وقوع حمله تشنج در امر پیش‌گیری، مراقبت‌های دارویی و مانیتورینگ بیماران مبتلا به صرع کمک می‌نمایند [۱ و ۵].

پنجره‌های طیف فرکانسی و با استفاده از شبکه‌های عصبی به منظور طبقه‌بندی ویژگی‌های استخراجی، در نهایت توانست به صحتی از تشخیص در حدود ۷۶٪ دست یابد. با در نظر گرفتن این موضوع که این آشکارسازی بطور خاص برای هر بیمار طراحی شده و دارای تعمیم‌پذیری^{۱۲} کمی نیز بود، ولی در عمل با خطایی ۰/۳۴ همراه شده بود [۱۴]. در یک پژوهش دیگر محققین در [۱۵]، با استخراج ویژگی‌های مبتنی بر طیف تبدیل موجک از سیگنال‌های مغزی و کاهش ابعاد بردار ویژگی‌ها توسط روش PCA و الگوریتم بهینه شده از دحام ذرات، سیگنال‌های EEG را در دو کلاس سیگنال‌های دارای علائم تشنج و سیگنال‌های سالم با نرخ صحت ۷۲/۲۴٪ طبقه‌بندی نموده‌اند.

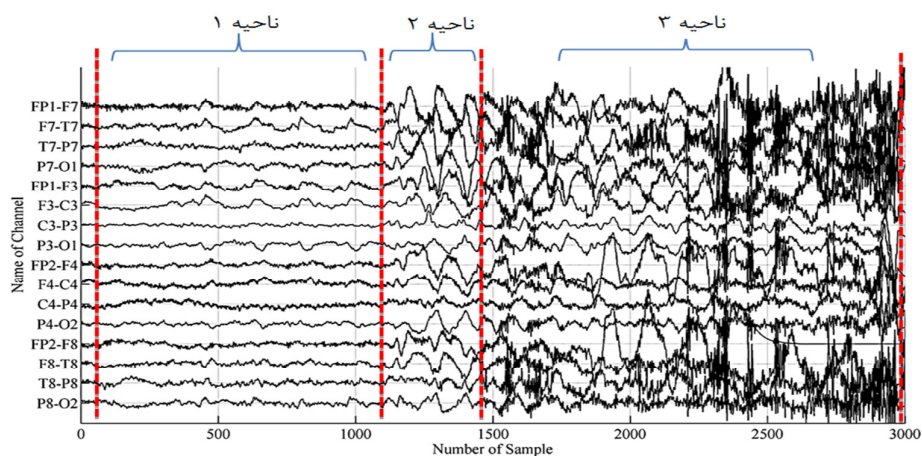
الگوریتم‌های تشخیص و آشکارسازی بیماری تشنج صرعی، دارای دسته‌بندی‌های متفاوتی هستند. تشخیص برون خط^{۱۳} حمله‌ی تشنج و همچنین تشخیص درون خط^{۱۴} آن از جمله‌ی این دسته‌بندی‌ها هستند.



شکل (۲): نمایش ۱۶ کانال از سیگنال‌های EEG فرد بیمار در حالت عادی با استفاده از سیگنال‌های موجود در پایگاه داده [۱۶]
Fig. (2): 16 channels of EEG signals of the patient in the normal mode using the signals in the dataset [16]



شکل (۳): نمایش سیگنال‌های EEG در ۱۶ کانال مغزی در هنگام وقوع حمله صرع با استفاده از سیگنال‌های موجود در پایگاه داده [۱۶]
Fig. (3): 16 channels of EEG signals of the patient with seizure attack using the signals in the dataset [16]



شکل (۴): تقسیم‌بندی سیگنال‌های مغزی و مشاهده ۳ حالت گذرا در سیگنال‌ها از زمان آرامش تا وقوع حمله تشنج صرعی [۱۶]
 Fig. (4): EEG signals partitioning and demonstrating 3 transient states in the signals from the rest time to epileptic seizure attack [16]

۲- روش پیشنهادی شناسایی تشنج صرعی

در این مقاله یک الگوریتم جدید، جهت تشخیص برون‌خط بیماری صرع از طریق پردازش سیگنال‌های مغزی ارائه شده است. با توجه به شکل (۵)، در الگوریتم پیشنهادی ابتدا سیگنال‌های مغزی کودکان مبتلا به بیماری صرع مقاوم نسبت به درمان (موجود در پایگاه داده) به بخش‌های ۳۰ ثانیه‌ای تقسیم شده است. هر قسمت از سیگنال‌ها به منظور پردازش‌های بعدی توسط یک فیلتر میانگذر به گونه‌ای فیلتر می‌شود، که علاوه بر نویزهای محیطی، تنها باند گاما از هر سیگنال مغزی باقی می‌ماند. از سیگنال حاصل، ویژگی‌های مبتنی بر تبدیل موجک استخراج می‌شوند. برای این منظور با تشکیل نقشه موزائیکی تبدیل موجک در چند سطح و تقسیم تصویر حاصل به چند زیر-تصویر، هیستوگرام هر بخش محاسبه شده و آمارگان آن که شامل مقدار آنتروپی منفی می‌باشد، به عنوان ویژگی محاسبه می‌شود. این بردار ویژگی آماری با استفاده از ابزار کاهش بعد PCA به صورت یک ویژگی مستخرج از نقشه تبدیل موجک تبدیل می‌شود. همچنین با استفاده از الگوریتم EMD و پروسه غربالگری مربوطه در محاسبه داده‌های IMF و مقدار مانده سیگنال‌های مغزی^{۱۵}، با استفاده از طیف تبدیل هیلبرت مشخصه‌ای تحت عنوان طیف هیلبرت-هوانگ ایجاد شده است که با استفاده از محاسبه‌ی فاصله اقلیدسی بین بیشینه و کمینه مقدار آن، ویژگی دیگری نیز از هر سیگنال محاسبه می‌شود. سپس بردار ویژگی نهایی که متشکل از دو مولفه می‌باشد توسط طبقه‌بند KNN، سیگنال‌های مغزی را در دو کلاس، سیگنال‌های دارای تشنج صرعی و سیگنال‌های بدون تشنج و سالم طبقه‌بندی می‌نماید.

۲-۱- پیش پردازش سیگنال‌های EEG

به منظور آماده‌سازی سیگنال‌های EEG ثبت شده و موجود در پایگاه داده، دو مجموعه عملیات بر روی آن‌ها صورت می‌پذیرد. ابتدا نیاز است تا پایگاه داده‌ای متناسب با روال کلی پردازش در این تحقیق آماده‌سازی شود و پس از آن فیلترینگ مناسب بر روی داده‌ها صورت

در حالت کلی و با توجه به تحقیقات انجام شده در زمینه پردازش سیگنال‌های مغزی برای تشخیص و پیش‌بینی تشنج، می‌توان یک نمای کلی از این الگوریتم‌ها را ارائه نمود. در تشخیص تشنج (پردازش برون‌خط)، پس از آماده‌سازی و فیلترینگ سیگنال‌های مغزی، ویژگی‌هایی متناسب با رفتار دینامیکی سیگنال‌ها در هنگام حمله استخراج می‌شوند [۵] و [۶]. در مرحله‌ی بعد نیازمند استفاده از ابزارهای بهینه‌سازی جهت انتخاب ویژگی‌های بهینه مانند مدل ترکیبی یک شبکه عصبی یا یک طبقه‌بند آماری با یک الگوریتم تکاملی و همچنین استفاده از الگوریتم‌های یادگیری ماشین و یا استفاده از ابزارهای آماری به منظور کاهش ابعاد بردار ویژگی‌ها هستیم. با تعیین ویژگی‌های بهینه و یا کاهش یافته نوبت به طبقه‌بندی سیگنال‌های مغزی با استفاده از ابزارهای طبقه‌بندی است. لازم به ذکر است که عملکرد هر طبقه‌بند وابسته به پارامترهای تنظیمی خود و همچنین وابسته به نوع داده‌های ورودی قابل تنظیم و بهینه‌سازی می‌باشد. در بحث پیش‌بینی و پردازش بلادرنگ (الگوریتم‌های درون‌خط)، با استفاده از ویژگی‌های بهینه‌ی به دست آمده در مدل برون‌خط و همچنین با استفاده از طبقه‌بند آموزش دیده می‌توان الگوریتم پیش‌بینی را تکمیل نمود [۱۵]. در الگوریتم‌های بلادرنگ، تنها تخمین نمونه‌های آینده‌ی سیگنال نسبت به تشخیص برون‌خط اضافه شده است [۱]. با پیش‌بینی مقادیر آینده‌ی سیگنال‌های مغزی و استفاده از ویژگی‌های مناسب که در قسمت پردازش برون‌خط به دست آمده است، می‌توان فرآیند پیش‌بینی را نیز تکمیل نمود. لذا، استخراج ویژگی‌های مناسب و آموزش ابزار طبقه‌بندی، علاوه بر اینکه در کاربرد تشخیص اهمیت بسیاری دارد، در زمینه پیش‌بینی نیز از جمله بخش‌های کلیدی می‌باشد.

در این مقاله، هدف ارائه‌ی الگوریتمی جهت تشخیص برون‌خط بیماری تشنج صرعی در کودکان مبتلا می‌باشد. همچنین تلاش شده است تا ویژگی‌های استخراجی از سیگنال‌های مغزی به‌گونه‌ای انتخاب شوند که حجم محاسباتی مناسبی برای استفاده در پروسه‌های بلادرنگ داشته باشند.

این منظور از روش پنجره گذاری در طراحی فیلترهای FIR^{۱۹} استفاده شده است. لذا با انتخاب یک پنجره کیزر - بسل و تنظیم پارامترهای آن، فیلتری با فرکانس قطع پایین و بالای $\omega_{c1} = 22 \text{ Hz}$ و $\omega_{c2} = 30\text{Hz}$ و همچنین باند انتقالی در فرکانسهای ω_{p1} که به ترتیب برابر است با 0.5 و 30.1 هرتز و با لحاظ کردن مقدار ریپل مجاز در محدوده نوسانات $\delta_1 = \delta_3 = 0.1$ برای باند توقف و $\delta_2 = 0.5$ در باند عبور، فیلتراسیون سیگنالهای EEG صورت می‌پذیرد [۱۸]. به عنوان یک قیاس کلی شکل (۶)، نمایشی از ۲۰۰ نمونه از یک سیگنال مغزی فیلتر نشده، شامل نویز تصادفی و همچنین تمام باند فرکانسی مغزی می‌باشد. در مقابل شکل (۷) ریتم گاما را نمایش می‌دهد. لازم به ذکر است که در این مقاله تمامی پردازش‌ها بر روی این ریتم صورت می‌پذیرد.

۳- استخراج ویژگی‌ها

جهت طبقه‌بندی سیگنال‌های مغزی با نشانه‌های حمله صرع و همچنین سیگنال‌های بدون تشنج و سالم نیاز به فرآیندی تحت عنوان استخراج ویژگی می‌باشد. لذا با در نظر گرفتن سیگنال‌های EEG به عنوان یک فرآیند تصادفی ایستادن (W.S.S.)^{۲۰} و همچنین فرض میانگین - ارگودیک (M.E.)^{۲۱} بودن ریتم گاما، می‌توان هر بردار مشاهده را به صورت $\underline{x} = [x(0)x(1)\dots x(L)]^T$ در نظر گرفت، که در اینجا L معادل با تعداد نمونه‌های هر سیگنال می‌باشد. با در نظر گرفتن ریتم‌های گاما به صورت بردار \underline{x} با طول L می‌توان ویژگی‌های مورد نظر را از آن استخراج نمود.

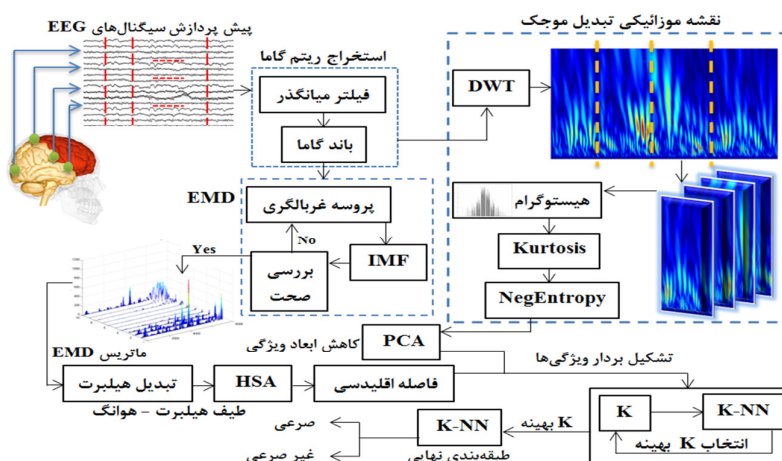
پذیرد تا علاوه بر نویزهای تصادفی موجود در محیط، که می‌تواند شامل نویز حاصل از سیگنال‌های حیاتی دیگر نظیر؛ سیگنال الکتروکاردیوگرام (ECG)^{۱۶}، سیگنال الکترواکولوگرام (EOG)^{۱۷} و همچنین نویزهایی نظیر پلک زدن و تعرق، حذف شوند و باند فرکانسی مورد پردازش نیز به طور خاص استخراج شود.

۲-۲- مشخصات پایگاه داده

پایگاه داده به کار گرفته شده در این تحقیق، از بیمارستان کودکان بوستون (CHB-MIT)، جمع آوری شده است [۱۶]. افراد و بیماران مورد آزمایش تا چند روز پس از خروج داروهای ضد تشنج برای مداخله و عمل جراحی تحت نظر و مراقبت ویژه قرار گرفته‌اند. در این پژوهش، از ۱۰۴ ساعت از سیگنال‌های مغزی موجود در این پایگاه داده استفاده شده است. هر سیگنال به $N=120$ بخش مجزا تقسیم بندی شده است و هر بخش دارای طول زمانی ۳۰ ثانیه می‌باشد. لذا در کل ۱۲۴۸۰ سیگنال وجود دارد که تماماً دارای فرکانس نمونه برداری ۲۵۶ هرتز و همچنین رزولوشن ۱۶ بیت هستند. در میان سیگنال‌های استفاده شده در این پژوهش ۲۰۴۰ سیگنال که برابر با ۱۶/۳۵٪ از کل داده‌های مورد آزمایش هستند، دارای نشانه‌های حمله تشنج و بیماری صرع هستند [۱۶].

۲-۳- فیلترینگ باند فرکانسی گاما

سیگنال‌های مغزی به طور کلی و در حالت عادی دارای ۵ باند فرکانسی و ریتم مغزی هستند. با توجه به محتوای فرکانسی باند گاما که یک ریتم غالب در محدوده فرکانسی ۲۲ تا ۳۰ هرتز است و همچنین مشاهدات سیگنال‌های دارای تشنج [۱۷ و ۱۸]، هر سیگنال EEG موجود در پایگاه داده توسط یک فیلتر میانگذر (BPF)^{۱۸} فیلتر شده و تنها مولفه‌های فرکانسی باند گاما از آن استخراج می‌شود. برای



شکل (۵): بلوک دیاگرام الگوریتم پیشنهادی تشخیص بیماری صرع در کودکان مقاوم نسبت به درمان.

Fig. (5): Block diagram of proposed algorithm for epileptic seizure detection in the treatment-resistant pediatric patients.

۳-۱- نقشه تبدیل موجک^{۲۲}

با در نظر گرفتن یک پنجره به صورت $\psi\left(\frac{n-b}{a}\right)$ که تابع Ψ را موجک مادر، پارامتر a را پارامتر مقیاس یا ضریب کش آمدن و همچنین b را مقدار جابجایی تعریف می‌نماییم [۱۹]، پنجره طوری نرمالیزه می‌شود که نرم آن برابر واحد باشد. لذا با در نظر گرفتن ضریب $\frac{1}{\sqrt{a}}$ برای نرمالیزه کردن پنجره تبدیل موجک سیگنال \underline{x} به صورت رابطه (۱) و (۲) به دست می‌آید:

$$w_{\psi}x(a, b) = \left\langle \underline{x}(n), \frac{1}{\sqrt{a}} \psi\left(\frac{n-b}{a}\right) \right\rangle, a \in \mathbb{R}^+, b \in \mathbb{R} \quad (1)$$

$$w_{\psi}x(a, b) = \int_{-\infty}^{+\infty} \underline{x}(n) \cdot \frac{1}{\sqrt{a}} \psi\left(\frac{n-b}{a}\right) dn = \underline{x}(\tau) * \frac{\psi\left(\frac{-\tau}{a}\right)}{\sqrt{a}} \quad (2)$$

که در این روابط مجموعه $\left\{ \frac{1}{\sqrt{a}} \psi\left(\frac{n-b}{a}\right) \right\}$ یک پایه برای بردار \underline{x} در فضای هیلبرتی $L^2(\mathbb{R})$ هستند.

لذا با توجه به افزودگی ناشی ضرایب پیوسته a و b و با در نظر گرفتن مقادیر گسسته $b = \alpha b_0 a_0^m$ تابع پنجره به صورت $\psi(a_0^{-m} n - \alpha b_0)$ تبدیل خواهد شد و به دنبال آن، مقدار ضرب داخلی موجود در رابطه (۱) و (۲) تغییر خواهد نمود. در این مسئله انتخاب پنجره مورد نظر، بسیار حائز اهمیت می‌باشد. با فرض این‌که بردار \underline{x} در محدوده‌ای متناهی m بار مشتق‌پذیر باشد [۲۰]، می‌بایست m ممان اولیه آن صفر باشند و بسته به مرتبه مشتق‌پذیری تعریف شوند.

با تعمیم این قضیه و بسط تیلور برای بردار Ψ در لحظه $t = v$ می‌توانیم تعریف لپشیتز و میزان رگولاسیون را بیان نماییم [۲۰]. بردار Ψ را $\alpha - \text{Lip}$ گوئیم هرگاه به ازای $k > 0$ چند جمله‌ای $p_v(n)$ از مرتبه m وجود داشته باشد که $m = \lfloor \alpha \rfloor$ باشد، به طوری که $|\psi(n) - p_v(n)| < k |n - v|^{\alpha}$ باشد و این تعریفی دقیق از میزان درجه مشتق‌پذیری تابع موجک مادر است. هر چه تعداد ممان‌های صفر شونده Ψ بیشتر باشد، تعداد خطوط مربوط به ماژول - بیشینگی^{۲۳} (که جهت تشخیص لبه و نقاط تکینی با استفاده از درجه میرایی Ψ محاسبه می‌شود) در صفحه زمان - مقیاس بیشتر می‌شود [۲۱]. لذا در یک نقشه زمان مقیاس خطوط پررنگ‌تر مبین نقاط تکینی شدیدتر در سیگنال هستند. بنابراین براساس ساختار این نقشه می‌توان ویژگی لازم برای طبقه‌بندی را استخراج نمود [۱۹ و ۲۰]. با در نظر گرفتن یک موجک دابچی^{۲۴} مرتبه $N=4$ ، $(db4)$ ، که در آن ضرایب بسط برابر است با:

$$P(y) = \sum_{k=0}^{N-1} \binom{N-1+k}{k} y^k \quad (3)$$

که در این رابطه عبارت ترکیب، ضرایب بسط دوجمله‌ای هستند. همچنین تعداد ممان‌های صفر شونده برابر با N می‌باشد. با رسم نقشه زمان - مقیاس با نام نمایش مخروطی^{۲۵} که ۴ ممان صفر شونده نیز بیان شده است، با توجه به رابطه (۳) خواهیم داشت:

$$\log_2 |w_{a,b}x(n)| < \log_2 A + \left(\alpha + \frac{1}{2} \right) \log_2 a \quad (4)$$

که در آن $a=2^j$ و $Aa^{\alpha+\frac{1}{2}} > |w_{a,b}x(n)|$ می‌باشد. با تغییر مقدار j می‌توان تعداد سطوح نقشه را معین نمود [۲۱]. شکل (۸) نمونه‌ای از نقشه تبدیل موجک سیگنال‌های EEG در باند گاما را به ازای $j=1024$ نمایش می‌دهد.

۳-۱-۱- استخراج آمارگان نقشه موزائیکی

با تقسیم نمودن بردار زمان طیف تبدیل موجک، که آن را با نام نقشه موزائیکی می‌شناسیم، این نقشه به ۴ تصویر با ابعاد یکسان شکسته می‌شود. هر قسمت در واقع یک تصویر رنگی می‌باشد. نقاط با تکینی بالا و نوسانات شدید، دارای تفاوت زیادی با سایر نمونه‌های با شدت کم هستند [۲۲]. از این‌رو برای محاسبه آمارگان مورد نظر ابتدا بردار هیستوگرام به ازای هر زیرتصویر محاسبه می‌شود. برای این منظور از رابطه زیر استفاده شده است:

$$y = P(r_k) = \frac{r_k}{MN} \quad (5)$$

که در این رابطه M و N به ترتیب طول و عرض هر بخش از نقشه تبدیل موجک می‌باشد. همچنین مقدار $P(r_k)$ میزان احتمال وقوع شدت روشنایی r در هر تصویر به ازای $k=0,1,2,\dots,L-1$ است. پس از محاسبه هیستوگرام مربوط به تمام زیر ماتریس‌های نقشه موجک، از ممان چهارم یعنی کورتوزیس به عنوان معیاری از غیرگوسین بودن هیستوگرام‌ها استفاده می‌شود [۲۳].

برای این منظور و با در نظر گرفتن دو پیش فرض به صورت $E\{y\}=0$ و همچنین $E\{y^2\}=1$ ، مقدار کورتوزیس به صورت زیر به دست می‌آید:

$$\text{Kurt}(y) = E\{y^4\} - 3E\{y^2\}^2 \quad (6)$$

که در این رابطه برای تمام متغیرهای تصادفی گوسین مقدار $\text{Kurt}(y)$ برابر صفر است. این امر در حالی است که اگر $\text{Kurt}(y) < 0$ آنگاه y متغیر تصادفی زیر-گوسی^{۲۶} یا پلاتوکورتیک^{۲۷} است و اگر $\text{Kurt}(y) > 0$ آنگاه y متغیر تصادفی فوق-گوسی^{۲۸} یا لپتوکورتیک^{۲۹} است [۲۳ و ۲۴]. لذا با استفاده از $\text{Kurt}(y)$ می‌توان میزان گوسین بودن PDF استخراجی از هر بخش را محاسبه نمود. به ازای یک متغیر تصادفی مانند H می‌توان میزان آنتروپی طیفی را به صورت رابطه زیر محاسبه نمود:


$$A_n = \sum_i P(H = h_i) \cdot \log P(H = h_i) \quad (7)$$

که h_i مقدار احتمالی H می‌باشد. بنابراین میزان آنتروپی منفی حاصل از هیستوگرام به صورت عبارت زیر به دست خواهد آمد:

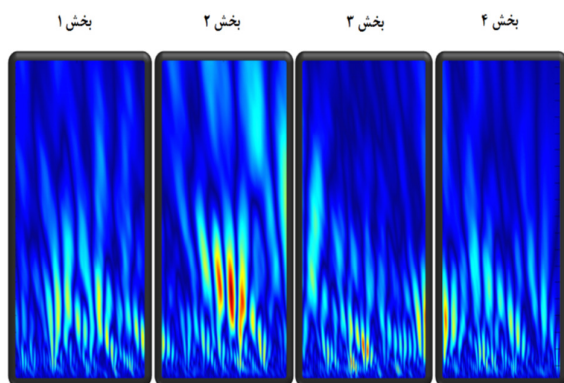
با آن، نگاهت بردار ورودی در فضای متعامد جدید به دست می‌آید [۱۵]. با توجه به میزان همبستگی بین ۴ مؤلفه بردار مزبور با استفاده از PCA، ابعاد بردار ApNeg به ۱ بعد کاهش می‌یابد. این روش دارای ۳ تاثیر مهم در این بردار است. ابتدا مؤلفه‌های بردار ورودی ناهمبسته می‌شوند و متعامد خواهند شد. سپس اجزای متعامد حاصل به ترتیب بیشترین فاصله از مقدار میانگین، مرتب شده و اجزای دارای کمترین تاثیر حذف می‌شوند [۱۵]. لذا در نهایت به ازای هر سیگنال مغزی یک ویژگی آماری محاسبه شده، که در مراحل بعدی می‌توان از آن به عنوان معیاری برای طبقه‌بندی سیگنال‌ها استفاده نمود. ما در این مقاله، این ویژگی را ویژگی آماری نقشه موجک (SFWM) ^{۳۰} می‌نامیم.

۳-۲- آنالیز تطبیقی طیف هیلبرت - هوانگ

ویژگی مستخرج از طیف تبدیل هیلبرت - هوانگ (HHT) ^{۳۱} را می‌توان در کنار SFWM به عنوان یک ویژگی مهم در زمینه تشخیص بیماری صرع در نظر گرفت. بنابراین برای ایجاد طیف ناشی از HHT از روش EMD استفاده می‌شود.



شکل (۸): نمایشی از نقشه موزائیکی تبدیل موجک در حوزه‌ی زمان و مقیاس.
Fig. (8): The map of DWT in some levels in Time-Scale domain




شکل (۹): نمایش تقسیم‌بندی نقشه موزائیکی تبدیل موجک در ۴ بخش
Fig. (9): Dividing the map of DWT in 4 parts


$$\text{Neg}(y) = \text{An}(y_{\text{Gaussian}}) - \text{An}(y) \quad (۸)$$

که y_{Gaussian} یک بردار تصادفی گوسی بوده و y_{Gaussian} و y هر دو دارای یک ماتریس کوواریانس یکسان هستند [۲۴]. با تقریبی از رابطه (۸) می‌توان به تخمینی از مقدار واقعی آنتروپی منفی رسید که خود یک ممان مرتبه بالا بر پایه‌ی کورتوزیس می‌باشد. این مقدار عبارت است از [۲۵]:

$$\text{ApNeg}(y) \approx \frac{1}{12} E\{y^3\}^2 + \frac{1}{48} \text{Kurt}(y)^2 \quad (۹)$$



شکل (۶): سیگنال EEG اصلی همراه با نویز تصادفی
Fig. (6): Original EEG signal with stochastic noise



شکل (۷): باند گامای نمونه‌ای از سیگنال EEG فیلتر شده
Fig. (7): The Gamma band of prototype filtered EEG signal

که y متغیری با میانگین صفر و واریانس واحد در نظر گرفته می‌شود [۲۵]. در نهایت، به ازای هر سیگنال EEG برداری از مقادیر ApNegها وجود خواهد داشت که شامل ۴ ویژگی آماری از نقشه موجک می‌باشد و می‌توان آن را به فرم برداری $\text{ApNeg} = [w(0) \ w(1) \ w(2) \ w(3)]^T$ نمایش داد.

۳-۱-۲- کاهش ابعاد ویژگی‌های آماری توسط الگوریتم PCA

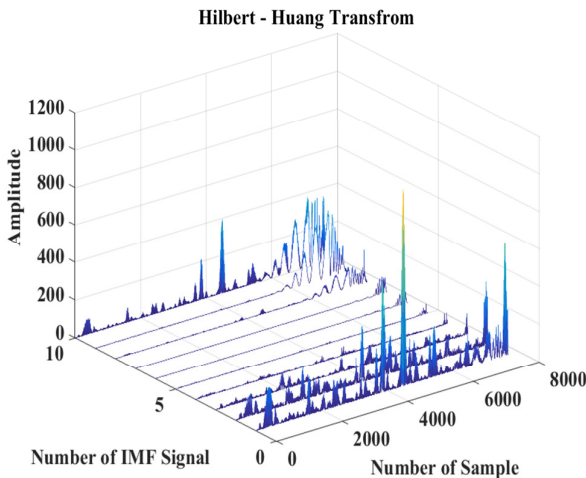
الگوریتم تحلیل مولفه‌های اصلی یا PCA از جمله روش‌های جبری در تحلیل داده‌های آماری می‌باشد. در الگوریتم PCA، در ابتدا میانگین داده‌ها محاسبه شده و تمامی داده‌ها به متغیرهای مرکزی تبدیل می‌شوند. سپس ماتریس کوواریانس برای هر بردار محاسبه می‌شود. بعد از این مرحله، مقادیر ویژه و بردارهای ویژه برای ماتریس کوواریانس محاسبه می‌شوند. با انتخاب بزرگ‌ترین مقدار ویژه و بردار ویژه متناظر

تبدیل هیلبرت که به ازای تمام توابع ذاتی محاسبه می‌شود خواهیم داشت [۲۸]:

$$\underline{IMF}_H(k) = \sum_{j=1}^L a_j(n) e^{i2\pi \int \underline{IMF}(k) dk} \quad (15)$$

$$HT(\underline{IMF}(k)) = \frac{1}{\pi} P.V / \int_{-\infty}^{+\infty} \frac{\underline{IMF}_H(k')}{k - k'} dk \quad (16)$$

که P.V مقدار ضرایب اصلی رابطه کوشی برای تعیین و محاسبه چنین انتگرالی می‌باشد که به اختصار CPV^{۳۵} نامیده می‌شوند [۲۸]. سپس با محاسبه طیف تبدیل هیلبرت، ماتریسی از ضرایب طیف تبدیل هیلبرت خواهیم داشت. ترکیب EMD و طیف تبدیل هیلبرت (HSA) را اصطلاحاً تبدیل و تحلیل هیلبرت - هوانگ می‌نامند [۲۹]. با استخراج HT(IMF(k)) از هر سیگنال مغزی نوبت به استخراج ویژگی مناسب از آن جهت طبقه‌بندی و تشخیص بیماری صرع است. توجه به ماهیت مختلط ضرایب طیف HT(IMF(k))، مقدار اندازه



شکل (۱۰): نمایش آبریخت طیف هیلبرت - هوانگ از سیگنال‌های EEG
Fig. (10): The water-fall plotting for Hilbert-Huang spectral of EEG signals

آن محاسبه شده و فاصله اقلیدسی بین ماکزیمم و مینیمم مطلق آن به دست می‌آید. یک نمونه از نمایش اندازه HT(IMF(k)) به صورت شکل (۹) که یک نمایش آبریخت^{۳۶} به ازای ۱۰ تکرار در محاسبه IMF می‌باشد، به دست آمده است. نمایش آبریخت در حقیقت برای رسم نمودارهای مورد نظر به صورت مجزا و برای جلوگیری از نمایش همزمان آن‌ها به شکل رویه استفاده می‌شود. لذا ویژگی جدیدی که در این مرحله به آن دست یافته می‌شود، یک عدد حقیقی به عنوان فاصله بین دو نقطه خاص از طیف است. لذا با محاسبه اندازه $|\text{HT}(\underline{IMF}(k))|^2$ و با فرض یک مختصات ۳ بعدی برای طیف، نقاط اکسترمم مطلق نیز به صورت زیر بیان می‌شوند:

$$\text{Max} \left(|\text{HT}(\underline{IMF}(k))|^2 \right) = (x_1, y_1, z_1) \quad (17)$$

۳-۲-۱- تجزیه تطبیقی سیگنال‌ها به روش EMD

در الگوریتم EMD، سیگنال‌ها که به صورت بردار \underline{x} نمایش داده شده‌اند، به یک تابع با شرایط ذاتی که شامل محتوای نیم باند فرکانس بالای بردار ورودی اصلی، در هر تکرار می‌باشد با عنوان IMF، (که به صورت $c_i(n)$ به ازای $i=0,1,2,\dots,m$ نمایش داده می‌شوند) و همچنین به مقدار $r(n)$ که مانده محاسبات است، تجزیه می‌شوند [۲۶]. لذا خواهیم داشت:

$$\underline{x}(n) = \sum_{i=1}^m c_i(n) + r(n) \quad (10)$$

که مقدار m میانگین تعداد توابع IMF می‌باشد. مقدار مانده $r(n)$ در حقیقت میانگینی از تمایل سیگنال اصلی و مولفه‌های حیاتی آن می‌باشد. توابع IMF در کل پایگاه داده همواره دارای دو شرط و ویژگی اساسی هستند: ۱- تعداد اکسترمم‌های نسبی سیگنال‌های مغزی (مینیمم‌ها و ماکزیمم‌ها) و مقدار عبور از صفر سیگنال‌ها باید دارای مقداری برابر یا حداکثر با اختلاف یک واحد باشد. ۲- نمونه‌هایی که توسط ماکزیمم یا مینیمم‌های محلی تعریف می‌شوند، صفر است [۲۶] و [۲۷].

۳-۲-۲- الگوریتم غربالگری^{۳۲}

در یک الگوریتم غربالگری جهت استخراج توابع IMF در ابتدا گلبرگ بالایی $E_u(n)$ توسط ماکزیمم محلی و گلبرگ پایینی $E_l(n)$ توسط مینیمم محلی در سیگنال باند گاما \underline{x} ایجاد می‌شوند [۲۶]. سپس میانگین مقادیر گلبرگ‌های بالایی و پایینی با نام $m_1(n)$ محاسبه خواهد شد:

$$m_1(n) = \frac{E_u(n) + E_l(n)}{2} \quad (11)$$

سپس با حذف این مقدار از سیگنال اصلی خواهیم داشت:

$$h_1(n) = \underline{x}(n) - m_1(n) \quad (12)$$

که h_1 شرایط IMF بودن را ارضا می‌نماید. با تکرار k مرتبه از آزمون محاسبه در نهایت خواهیم داشت:

$$c_1(n) = h_{1k}(n) - m_{1(k-1)}(n) \quad (13)$$

که مقدار مانده هم به صورت $r_1(n) = \underline{x}(n) - c_1(n)$ محاسبه می‌شود. لذا با تکرار الگوریتم مقادیر مانده r_1, r_2, \dots, r_k به صورت توابع یکنوا^{۳۳} هستند. در نهایت با تکرار الگوریتم پس از k مرتبه، رابطه (۱۳) به عنوان تخمینی از تبدیل موجک و نمونه‌ای از تجزیه EMD به دست خواهد آمد [۲۷].

۳-۲-۴- ویژگی HSA^{۳۴} و فاصله اقلیدسی

پس از محاسبه توابع IMF، به ازای هر سیگنال مغزی برداری از توابع IMF به صورت:

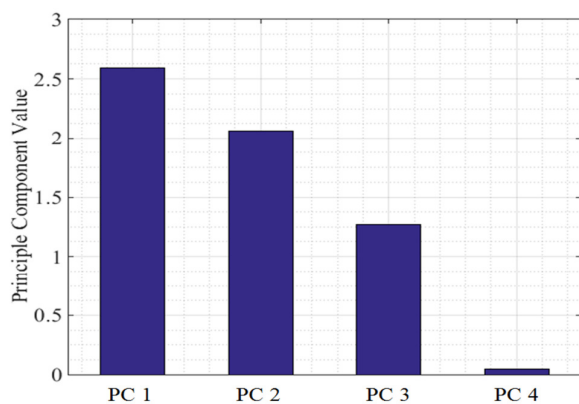
$$\underline{IMF}(k) = [\text{IMF}(0) \text{IMF}(1) \dots \text{IMF}(L) T] \quad (14)$$

بیان می‌شود، که L طول سیگنال اصلی می‌باشد و مقدار k تعداد تکرار و همچنین تعداد توابع IMF را مشخص می‌نماید. با استفاده از رابطه

۴-۲- طبقه‌بندی با روش KNN

روش‌های تخمین تابع چگالی احتمال را می‌توان در دو دسته‌بندی عمده قرار داد که عبارتند از: تخمین پارامتری و تخمین غیرپارامتری. الگوریتم KNN به عنوان یک روش تخمین غیرپارامتری در تعیین تابع چگالی احتمال یک بردار یا فرآیند تصادفی است. اما می‌توان از آن به عنوان یک طبقه‌بند ساده نیز استفاده نمود. روش KNN با انتخاب یک پارامتر K مناسب به عنوان تقریبی از طبقه‌بند بی‌زین، در صفحه‌ی ویژگی‌ها دایره‌هایی (ابر کره در ابعاد بالاتر) را به مرکز بردار ویژگی ورودی جدید و یا بردار آزمون رسم می‌نماید، به گونه‌ای که K مورد از نمونه‌های موجود در فضای ویژگی در داخل دایره قرار گیرند [۳۰]. برای کلاس ω_i و با داشتن بردار ویژگی‌های x ، با استفاده از رابطه احتمالاتی زیر:

$$P(\omega_i | x) = \frac{K_i}{K_n} \quad (20)$$



شکل (۱۱): نمایش مرتب شده از مقادیر مولفه‌های اصلی پس از اعمال PCA بر روی مقادیر آن‌تروپی منفی.

Fig. (11): The sorted diagram for principle values after applying the PCA on the Negentropy values.

که K_i تعداد نمونه‌های کلاس ω_i و K_n تعداد کل نمونه‌های موجود در ناحیه مورد نظر می‌باشد، عمل طبقه‌بندی صورت می‌پذیرد [۳۰ و ۳۱]. لذا با محاسبه این مقدار احتمال برای هر نمونه جدید از مجموعه‌ی داده‌های آزمون، می‌توان عمل طبقه‌بندی با استفاده از استخراج دو ویژگی ارائه شده برای سیگنال‌های حاوی علائم تشنج و سیگنال‌های سالم انجام داد.

۴-۳- نتایج طبقه‌بندی سیگنال‌ها

مسئله‌ی اساسی برای طبقه‌بندی داده‌ها با استفاده از KNN انتخاب مناسب K می‌باشد [۳۱]. برای این منظور و به موجب بهینه‌سازی الگوریتم و همچنین با توجه به تراکم که داده‌ها به دلیل نزدیکی مقادیر ویژگی به یکدیگر دارند، چهار مقدار فرد متفاوت از همسایگی اختیار شده است و نتایج طبقه‌بندی با استفاده از آن‌ها بیان می‌شوند.

$$\text{Min} \left(\left| \text{HT}(\text{IMF}(k)) \right|^2 \right) = (x_2, y_2, z_2) \quad (18)$$

لذا فاصله اقلیدسی در ۳ بعد بین نقاط ماکزیمم و مینیمم مطلق به صورت زیر محاسبه می‌شود:

$$(19)$$

$$d(\text{Min}, \text{Max}) = \sqrt{(x_1 - x_2)^2 + (y_1 - y_2)^2 + (z_1 - z_2)^2}$$

در این مقاله، این ویژگی جدید که برای طبقه‌بندی سیگنال‌های مغزی مورد استفاده قرار خواهد گرفت ویژگی فاصله طیفی (DSF) نامیده می‌شود.


۴-۴- نتایج آزمایش و تنظیم پارامترها

به منظور طبقه‌بندی سیگنال‌های EEG به دو کلاس دارای تشنج و بدون تشنج، از ویژگی‌های SFWM و DSF معرفی شده در این مقاله استفاده می‌شود. با استخراج این ویژگی‌ها از تمامی سیگنال‌های موجود در پایگاه داده، در نهایت طبقه‌بندی سیگنال‌ها با استفاده از طبقه‌بند K- نزدیک‌ترین همسایه صورت می‌پذیرد.

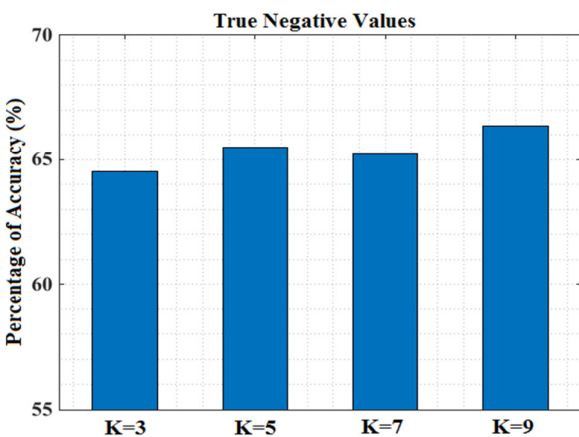
۴-۱- انتخاب مولفه‌ی اصلی در الگوریتم PCA

در الگوریتم ارائه شده در این مقاله، پس از تقسیم‌بندی نقشه‌ی تبدیل موجک، هیستوگرام هر زیر- تصویر محاسبه شده و معیار آن‌تروپی منفی به عنوان یک ابزار در محاسبه‌ی میزان غیرگوسی بودن تابع توزیع استفاده شده است. لذا هر سیگنال مغزی شامل چهار مقدار از آن‌تروپی منفی می‌باشد، که معرف چهار ویژگی استخراجی از طیف موجک هر سیگنال است. با استفاده از الگوریتم PCA این چهار مقدار به فضای متعامد جدید نگاشت پیدا می‌کنند. در این فضای چهار بعدی، چهار بردار ویژه متعامد نقش پایه‌های فضا را ایفا می‌کنند [۱۵]. چهار مقدار ویژه متناظر نیز میزان انرژی و قدرت هر بردار ویژه را در توصیف و نگاشت ویژگی‌ها در فضای جدید بیان می‌کنند. شکل (۱۱) مقدار مولفه‌های اصلی یا در واقع مقادیر ویژه را به ازای هر چهار مقدار آن‌تروپی منفی در کل پایگاه داده نمایش می‌دهد. لازم به ذکر است که PC 1 مربوط به مقدار ویژه بخش اول، PC 2 مربوط به مقدار ویژه بخش چهارم، PC 3 مربوط به مقدار ویژه بخش سوم و PC 4 نیز مربوط به مقدار ویژه بخش دوم هستند که به ترتیب نزولی در شکل (۱۱) نمایش داده شده‌اند.

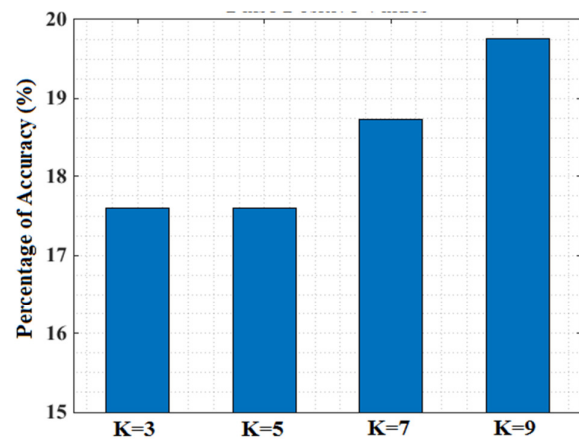
می‌توان مشاهده نمود که مقدار ویژه‌ی بخش اول از نقشه تبدیل موجک سیگنال‌های EEG دارای بیشینه مقدار انرژی است. لذا اینگونه برداشت می‌شود که سیگنال‌های دارای تشنج و بدون تشنج در ربع اول از نقشه موزائیکی تبدیل موجک خود دارای توزیع گوسی با کمی انحراف هستند. لذا انرژی موجود در این مولفه‌ی اصلی بیش از سایر مولفه‌ها است. با انتخاب این مقدار ویژه و بردار ویژه متناظر با آن، ویژگی آن‌تروپی منفی استخراج شده از بخش اول تحت نگاشت قرار گرفته و به صورت یک ویژگی نگاشت شده در قسمت طبقه‌بندی مورد استفاده قرار می‌گیرد.



شکل (۱۳): مقدار TP به ازای مقادیر مختلف K.
Fig. (13): TP values for different K.



شکل (۱۴): مقدار TN به ازای مقادیر مختلف K.
Fig. (14): TN values for different K




شکل (۱۵): مقدار FP به ازای مقادیر مختلف K.
Fig. (15): FP values for different K.

جدول (۱) شامل نتایج آزمایش طبقه‌بندی سیگنال‌های مغزی می‌باشد. نتایج آزمایش بر اساس مقدار صحت طبقه‌بندی برای داده‌های آزمایش و همچنین چهار معیار اساسی طبقه‌بندی می‌باشد. این معیارها به ترتیب بیانگر پذیرش مورد صحیح (TP)^{۳۸}، رد مورد صحیح (TN)^{۳۹}، پذیرش مورد نادرست (FP)^{۴۰} و رد مورد نادرست (FN)^{۴۱} می‌باشد. با استفاده از نرخ صحت کل برای طبقه‌بندی داده‌ها، منحنی خطا در قسمت بعد برای تعمیم پارامتر همسایگی درونیایی خواهد شد.

۴-۳-۱- درونیایی منحنی خطا برای پارامتر همسایگی

انتخاب یک پارامتر همسایگی زوج، گاهی موجب بروز خطا در محاسبه و عملیات طبقه‌بندی با استفاده از الگوریتم KNN می‌شود. با استفاده از یک شبکه عصبی جلوسو با یک لایه‌ی پنهان، همچنین استفاده از قاعده‌ی آموزش لونبرگ، داده‌های مربوط به خطای طبقه‌بندی موجود در جدول (۱) برآزش می‌شوند [۹]. پس از آموزش شبکه عصبی منحنی شکل (۱۲) به عنوان مدلی درونیایی شده از مقدار خطا برای پارامتر همسایگی K به دست خواهد آمد.

به منظور یک درک شهودی از تاثیر مقدار K در میزان صحت طبقه‌بندی، می‌توان نمودار میله‌ای شکل (۱۳) تا شکل (۱۷) را با توجه به داده‌های موجود در جدول (۱) رسم نمود. همانطور که مشاهده می‌شود، طبقه‌بند KNN به ازای K=5 بهترین طبقه‌بندی خود را با میزان صحت عملکرد ۷۶/۵۳۷۹٪ نشان می‌دهد. به گونه‌ای که برای مقادیر همسایگی‌های بیشتر یا کمتر از ۵ مقدار صحت عملکرد طبقه‌بندی کاهش می‌یابد.



شکل (۱۲): منحنی درونیایی شده‌ی خطا به ازای پارامترهای همسایگی مختلف.

Fig. (12): Interpolated curve of error values for different neighborhood parameters.

Table (1): Performance of seizure and non-seizure signals classification.

جدول (۱): میزان عملکرد طبقه‌بندی سیگنال‌های دارای تشنج و بدون تشنج.


صحت عملکرد طبقه‌بند KNN (%)							داده‌های آزمایش
خطای کل	صحت کل	FN	FP	TN	TP	K	
24.4635	75.5365	6.8670	17.5966	64.5207	11.0157	3	مجموعه داده ۱
23.4621	76.5379	5.8655	17.5966	65.5222	11.0157	5	مجموعه داده ۲
24.8927	75.1073	6.1516	18.7411	65.2361	9.8712	7	مجموعه داده ۳
24.4635	75.5365	5.0072	19.4564	66.3805	9.1559	9	مجموعه داده ۴
نتایج نهایی		پایگاه داده					
میانگین خطا	درصد بهینه	داده‌های سالم	داده‌های صرعی	کل داده‌ها	نسبت داده‌ها		
24.3208	76.5379	10440	2040	12480	تعداد سیگنال‌ها		
واریانس خطا	بهینه K	دقیقه ۵۲۲۰	دقیقه ۱۰۲۰	۶۲۴۰ دقیقه	زمان سیگنال‌ها		
0.3685	5	83.7%	16.3%	100%	درصد سیگنال‌ها		

۴-۳-۲- دیاگرام ورونویی - تسلیشن^{۴۲}

با توجه به نتایج به دست آمده برای پارامتر همسایگی K، مشاهده می‌شود که به ازای $K = 5$ بهترین نتایج در طبقه‌بندی سیگنال‌های مغزی به دست می‌آید. با وجود دو ویژگی ارائه شده در این مقاله، فضای ویژگی، یک فضای دو بعدی است. این دو ویژگی به عنوان دو مولفه‌ی افقی و عمودی در صفحه مختصات (صفحه ویژگی‌ها) برای تمامی سیگنال‌ها محاسبه می‌شوند [۳۰]. لازم به ذکر است که در این پژوهش ۷۰٪ داده‌ها برای آموزش طبقه‌بند و ۳۰٪ آن‌ها به منظور آزمون در نظر گرفته شده است. هر زوج ویژگی معرف یک کلاس از سیگنال‌های EEG است. نقاط قرمز رنگ موجود در شکل (۱۸)، زوج ویژگی‌های محاسبه شده برای ۳۰ نمونه از سیگنال‌های EEG هستند. فاصله اقلیدسی به ازای تمامی نقاط ویژگی تا نقاط موجود در صفحه ویژگی‌ها محاسبه می‌شود. با در نظر گرفتن پارامتر همسایگی ۵ و محاسبه احتمال موجود در رابطه (۲۰)، صفحه ویژگی‌ها مطابق شکل (۱۸) ناحیه‌بندی می‌شود. این شکل را اصطلاحاً دیاگرام ورونویی - تسلیشن می‌گویند [۳۰ و ۳۱]. کلاس سیگنال‌های دارای تشنج و سیگنال‌های بدون تشنج نیز با استفاده از رنگ خاکستری از یکدیگر جدا شده است. مشاهده می‌شود که مرز تصمیم ناحیه‌ای مشابه با خطوط قرمز رسم شده در شکل (۱۸) می‌باشد و صفحه ویژگی‌ها به ۳ ناحیه تقسیم‌بندی شده است. حال با مشاهده‌ی یک سیگنال جدید و استخراج ویژگی‌های ارائه شده از آن، می‌توان بررسی نمود که این ویژگی‌ها در چه ناحیه‌ای قرار می‌گیرند. لذا تصمیم‌گیری برای وجود یا عدم وجود تشنج در یک سیگنال به آسانی قابل انجام است.

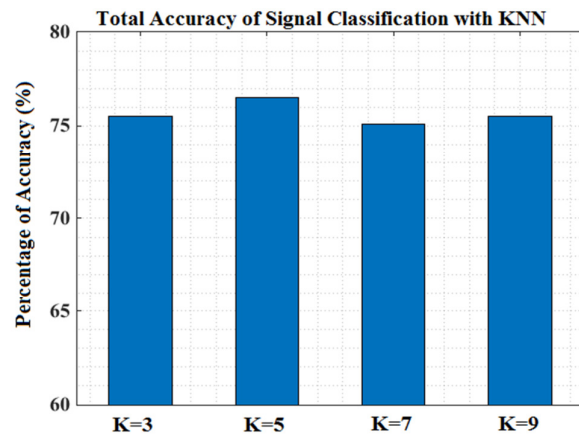
۵- بحث و نتیجه‌گیری

آنالیز سیگنال‌های EEG به عنوان یک ابزار کارآمد در تشخیص بیماری تشنج صرعی است. با توجه به باند فرکانسی موجود در ریتم‌های مغزی و



شکل (۱۶): مقدار FN به ازای مقادیر مختلف K.

Fig. (16): FN values for different K.



شکل (۱۷): مقدار صحت کل به ازای مقادیر مختلف K در تشخیص تشنج به وسیله الگوریتم KNN.

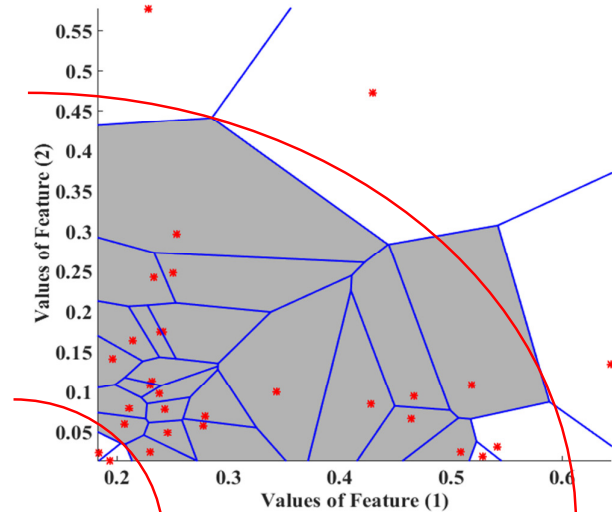
Fig. (17): Total accuracy for different K in seizure detection by KNN algorithm.

داده‌هایی با تراکم و پیچیدگی بیش از اندازه را دارا می‌باشد. هرچند ویژگی‌های موجود در این مقاله از تفکیک‌پذیری مناسبی برخوردار هستند، ولی پیاده‌سازی آسان و هزینه محاسباتی پایین این روش، استفاده از آن را همچنان توجیه می‌نماید. لذا با بررسی و انتخاب پارامتر همسایگی مناسب، بهترین طبقه‌بندی با بیشترین نرخ صحت در تشخیص سیگنال دارای تشنج به دست می‌آید. در یک نگاه کلی می‌توان اینگونه برداشت نمود که استخراج ویژگی‌های آماری از الگوهای مبتنی بر تبدیل در باند فرکانسی گاما، اطلاعات مفیدی را از رفتار سیگنال‌های EEG در هنگام حمله تشنج نشان می‌دهد. این ویژگی‌ها با استفاده از طبقه‌بند آماری KNN و با صحت و واریانس خطای قابل قبولی بیماری تشنج صرعی را تشخیص می‌دهد.

پی‌نوشت:

- 1- Electroencephalogram
- 2- Epoch
- 3- Kurtosis
- 4- NegEntropy
- 5- Principle Component Analysis
- 6- Empirical Mode Decomposition
- 7- Intrinsic Mode Function
- 8- K-Nearest Neighbor
- 9- Seizure
- 10- Epilepsy
- 11- Evoke Related Potential
- 12- Generalizability
- 13- Offline
- 14- Online
- 15- Residue
- 16- Electrocardiogram
- 17- Electrooculogram
- 18- Band Pass Filter
- 19- Finite Impulse Response
- 20- Wide Sense Stationary
- 21- Mean - Ergodic
- 22- Map of Wavelet Transform
- 23- Modulus-Maximas
- 24- Daubechies
- 25- Cone of Influence
- 26- Sub-Gaussian
- 27- Platykurtic
- 28- Super-Gaussian
- 29- Leptokurtic
- 30- Statistical Feature of Wavelet Map
- 31- Hilbert – Huang Transform
- 32- Sifting Process
- 33- Monotonic
- 34- Hilbert Spectral Analysis
- 35- Cauchy Principal Value
- 36- Water-Fall
- 37- Distance Spectral Feature
- 38- True Positive
- 39- True Negative
- 40- False Positive
- 41- False Negative
- 42- Voronoi – Tessellation Diagram

همچنین رفتار آشوبناک و پرفرکانس حمله‌ی تشنج، می‌توان ریتم مغزی گاما را برای پردازش‌های مورد نظر در زمینه‌ی تشخیص تشنج مناسب دانست. استخراج ویژگی‌هایی که نشان دهنده‌ی تمام جنبه‌های سیگنال‌های مورد آزمایش هستند، بسیار حائز اهمیت است. لذا در این پژوهش تلاش شده است تا ویژگی‌های استخراج شده صفات کلی از رفتار دینامیکی و استاتیکی سیگنال‌ها را پوشش دهند. از طرفی با توجه به کاربرد الگوریتم تشخیص تشنج ارائه شده در زمینه پیش‌بینی، سعی شده است تا ویژگی‌هایی با ارزش کلینیکی بالا و مرتبه محاسباتی پایین‌تری ارائه شوند. برای این منظور از ویژگی‌های آماری و ویژگی‌هایی مبتنی بر تبدیل‌های زمان-فرکانس استفاده شده است. ارائه‌ی نقشه‌ی تبدیل موجک برای ریتم مغزی گاما می‌تواند معیار بسیار مناسبی برای نمایش نقاط تکین موجود در سیگنال‌های EEG باشد. تقسیم‌بندی و استخراج ویژگی‌های آماری از PDF هر زیر- تصویر از نقشه موجک اطلاعات مفیدی را در زمینه توزیع نقاط تکین در اختیار می‌گذارد.



شکل (۱۸): دیاگرام ورونوی - تسلیشن برای ۳۰ نمونه از سیگنال‌های مغزی.
Fig. (18): Voronoi-Tessellation diagram for 30 sample of EEG signals

استفاده از روش PCA در انتخاب ویژگی آماری با انرژی بیشتر، می‌تواند صحت و نرخ تشخیص بیماری را افزایش دهد. استفاده از الگوریتم EMD و آنالیز طیفی هیلبرت - هوانگ به عنوان یک روش تجربی و مبتنی بر تبدیل، می‌تواند جنبه‌ای دیگر از رفتار فرکانسی و توابع سازنده‌ی سیگنال گاما باشد. لذا با ارائه‌ی دو ویژگی DSF و SFWM در این مقاله، تلاش شده است تا توصیفی کامل از سیگنال‌های دارای تشنج و سالم معرفی شود. پس از استخراج ویژگی‌ها، برای طبقه‌بندی داده‌های آزمایش و ارائه‌ی یک طبقه‌بند آموزش دیده برای تشخیص نمونه‌های جدید از الگوریتم طبقه‌بندی K- نزدیک‌ترین همسایه استفاده شده است. این روش به عنوان تقریبی از طبقه‌بند بی‌زین به ازای یک پارامتر همسایگی محدود، قابلیت استفاده برای طبقه‌بندی

References

- [1] S. Nasehi, H. Pourghassem, "Seizure detection algorithms based on analysis of EEG and ECG signals: A survey", *Neurophysiology*, Vol. 44, No. 2, pp. 174-186, June 2012.
- [2] S. Nasehi, H. Pourghassem, "Epileptic seizure onset detection algorithm using dynamic cascade feed-forward neural networks", *International Conference on Intelligent Computation and Bio-Medical Instrumentation (ICBMI)*, China, pp.196-199, Dec. 2011.
- [3] M. Behnam, H. Pourghassem, "Epilepsy detection based on optimization of fused Hartley transform feature with hybrid model of MLP and GA using Memetic learning strategy", *Tabriz Journal of Electrical Engineering*, Vol. 45, No. 4, pp. 51-67, Winter 2015 (In Persian).
- [4] S. Nasehi, H. Pourghassem, "Real-time seizure detection based on EEG and ECG fused features using Gabor functions", *International Conference on Intelligent Computation and Bio-Medical Instrumentation (ICBMI)*, China, pp. 204-207, Dec. 2011.
- [5] S. Nasehi, H. Pourghassem, "A novel fast epileptic seizure onset detection algorithm using general tensor discriminant analysis", *Journal of Clinical Neurophysiology*, Vol. 30, No. 4, pp. 362-370, Aug. 2013.
- [6] S. Nasehi, H. Pourghassem, "A new feature dimensionally reduction approach based on general tensor discriminant analysis in EEG signal classification", *International Conference on Intelligent Computation and Bio-Medical Instrumentation (ICBMI)*, China, pp. 188-191, Dec. 2011.
- [7] A. Aarabi, R. Grebe, F. Wallois, "A multistage knowledge-based system for EEG seizure detection in newborn infants", *Clinical Neurophysiology*, Vol. 118, No. 12, pp. 2781-2797, Dec. 2007.
- [8] S. Nasehi, H. Pourghassem, "Automatic prediction of epileptic seizure using kernel fisher discriminant classifiers", *International Conference on Intelligent Computation and Bio-Medical Instrumentation (ICBMI)*, China, pp. 200-203, Dec. 2011.
- [9] E. Ubeyli, I. Guler, "Detection of electrocardiographic changes in partial epileptic patients using Lyapunov exponents with multilayer perceptron neural networks", *Engineering Applications of Artificial Intelligence*, Vol. 17, No. 6, pp. 567-576, Sep. 2004.
- [10] N. Kannathal, M. Choo, U. Acharya, P. Sadasivan, "Entropies for detection of epilepsy in EEG", *Computer Methods and Programs in Biomedicine*, Vol. 80, No. 3, pp. 187-194, Dec. 2005.
- [11] Y. Lee, G.M. Yeon, Y.M. Kim, S.O. Nam, "Relationship between initial electroencephalographic characteristics and seizure outcomes in children with non-lesional West syndrome", *Epilepsy Research*, Vol. 110, pp. 49-54, Feb. 2015.
- [12] J. Gotman, "Automatic seizure detection: improvements and evaluation", *Electroencephalography and Clinical Neurophysiology*, Vol. 76, No. 4, pp. 317-324, Oct. 1990.
- [13] S.B. Wilson, M.L. Scheuer, C. Plummer, B. Young, S. Pacia, "Seizure detection: correlation of human experts", *Clinical Neurophysiology*, Vol. 114, No. 11, pp. 2156-2164, Nov. 2003.
- [14] S.B. Wilson, M.L. Scheuer, R.G. Emerson, A.J. Gabor, "Seizure detection: evaluation of the Reveal algorithm," *Clinical Neurophysiology*, Vol. 115, No. 10, pp. 2280-2291, Oct. 2004.
- [15] S. Nasehi, H. Pourghassem, "Patient-specific epileptic seizure onset detection algorithm based on spectral features and IPSONN classifier", *International Conference on Communication Systems and Network Technologies (CSNT)*, pp. 186-190, April 2013.
- [16] EEG Database, <http://www.physionet.org/pn6/chbmit>.
- [17] M. Behnam, H. Pourghassem, "Periodogram pattern feature-based seizure detection algorithm using optimized hybrid model of MLP and Ant colony", *Iranian Conference on Electrical Engineering (ICEE 2015)*, Tehran, Iran, pp. 32-37, May 2015.
- [18] O. Faust, U.R. Acharya, H. Adeli, A. Adeli, "Wavelet-based EEG processing for computer-aided seizure detection and epilepsy diagnosis", *Seizure*, Vol. 26, pp. 56-64, Mar. 2015.
- [19] S. Nasehi, H. Pourghassem, "An optimal EEG-based emotion recognition algorithm using Gabor features", *WSEAS TRANSACTIONS on SIGNAL PROCESSING*, Vol. 8, No. 3, pp. 87-99, July 2012.
- [20] S. Momeni, H. Pourghassem, "An automatic fuzzy-based multi-temporal brain digital subtraction angiography image fusion algorithm using Curvelet transform and content selection strategy", *Journal of Medical Systems*, Vol. 38, No. 8, pp. 1-16, Aug. 2014.
- [21] S. Nasehi, H. Pourghassem, "A novel effective feature selection algorithm based on S-PCA and wavelet transform features in EEG signal", *IEEE 3rd International Conference on Communication Software and Networks (ICCSN)*, pp.114-117, May 2011.
- [22] A. Samadi, H. Pourghassem, "Children detection algorithm based on statistical models and LDA in human face images", *International Conference on Communication Systems and Network Technologies (CSNT 2013)*, pp. 206-209, Gwalior, India, 6-8 April 2013.
- [23] H. Pourghassem, S. Daneshvar, "A framework for medical image retrieval using merging-based classification with dependency probability-based relevance feedback", *Turkish Journal of Electrical Engineering and Computer Science*, Vol. 21, No. 3, pp.882-896, 2013.

- [24] M. Hashemian, H. Pourghassem, "Diagnosing autism spectrum disorders based on EEG analysis: A Survey", *Neurophysiology*, Vol. 46, No. 2, pp. 183-195, April 2014.
- [25] S. Nasehi, H. Pourghassem, "Online mental task classification based on DWT-PCA features and probabilistic neural network", *International Journal of Imaging and Robotics*, Vol. 7, No. 1, pp. 110-118, Jan. 2012.
- [26] X. Guanlei, W. Xiaotong, X. Xiaogang, "Improved bi-dimensional EMD and Hilbert spectrum for the analysis of textures", *Pattern Recognition*, Vol. 42, No. 5, pp. 718-734, May 2009.
- [27] Ch.C. Peter, Ch. Fan, N. Huang, "Derivative-optimized empirical mode decomposition for the Hilbert-Huang Transform", *Journal of Computational and Applied Mathematics*, Vol. 259, No. 1, pp. 57-64, Mar. 2014.
- [28] J. Yan, L. Lu, "Improved Hilbert-Huang transform based weak signal detection methodology and its application on incipient fault diagnosis and ECG signal analysis", *Signal Processing*, Vol. 98, pp. 74-87, May 2014.
- [29] S. Carbajo, Esther, R.S. Carbajo, C. Mc Goldrick, B. Basu, "ASDAH: An automated structural change detection algorithm based on the Hilbert-Huang transform", *Mechanical Systems and Signal Processing*, Vol. 47, No. 1, pp. 78-93, Aug. 2014.
- [30] P. Ghaderyan, A. Abbasi, M.H. Sedaaghi, "An efficient seizure prediction method using KNN-based under sampling and linear frequency measures", *Journal of neuroscience methods*, Vol. 232, pp. 134-142, July 2014.
- [31] I. Saini, D. Singh, A. Khosla, "QRS detection using K-Nearest Neighbor algorithm (KNN) and evaluation on standard ECG databases", *Journal of Advanced Research*, Vol. 4, No. 4, pp. 331-344, July 2013.