

تشخیص صرع در سیگنال‌های الکتروانسفالوگرافی (EEG) بر اساس ویژگی طیف کلی موجک (GWS) با استفاده ماشین بردار پشتیبان

فریبا حسن‌زاده^۱، دانشجوی کارشناسی ارشد؛ سعید مشگینی^۲، استادیار

۱- گروه مهندسی پزشکی - دانشکده مهندسی برق و کامپیوتر - دانشگاه تبریز - تبریز - ایران - f.hasanzadeh96@ms.tabrizu.ac.ir

۲- گروه مهندسی پزشکی - دانشکده مهندسی برق و کامپیوتر - دانشگاه تبریز - تبریز - ایران - meshgini@tabrizu.ac.ir

چکیده: در حدود یک درصد از مردم دنیا از صرع^۱ رنج می‌برند. اولین مرحله از درمان صرع، تشخیص به موقع و صحیح آن است. یکی از راه‌های تشخیص صرع، تجزیه و تحلیل دقیق سیگنال الکتروانسفالوگرافی^۲ (EEG) است. ویژگی‌های مختلفی جهت تشخیص این بیماری از روی سیگنال مانند دامنه سیگنال^۳ وجود دارد. در این مقاله، با بررسی اطلاعات زمان-فرکانسی سیگنال EEG در افراد مبتلا به سندرم صرع بدون تشنج و افراد سالم، روش جدیدی برای تشخیص صرع ارائه شده است. در ابتدا ویژگی طیف کلی موجک^۴ (GWS) برای سیگنال EEG افراد سالم و افراد مبتلا به سندرم صرع استخراج شده است. برای بررسی این طیف در باندهای فرکانسی، سیگنال EEG با استفاده از تبدیل موجک به ۵ زیرباند تجزیه می‌گردد. سپس با اعمال این ویژگی به طبقه‌بند مبتنی بر ماشین بردار پشتیبان^۵ به تشخیص صرع پرداخته شده است. نتایج تجزیه و تحلیل، تفاوت قابل ملاحظه‌ای، جهت تفکیک کردن فرد بر اساس سیگنال EEG فراهم می‌کند. روش پیشنهادی در مقایسه با روش‌های قبلی، سیگنال‌های سالم و صرعی را با دقت ۱۰۰٪ طبقه‌بندی کرده است. همچنین، مشاهده شد که مقادیر غالب GWS برای سیگنال‌های انتخاب شده از بیماران مبتلا به سندرم صرعی در باند فرکانسی دلتا و تتا یافت می‌شوند.

واژه‌های کلیدی: صرع، الکتروانسفالوگرافی، تبدیل موجک، طیف کلی موجک، ماشین بردار پشتیبان.

Detection of Epilepsy in Electroencephalographic (EEG) Signals Based on Global Wavelet Spectrum (GWS) Using Support Vector Machine (SVM)

F. Hasanzadeh¹, MSc Student; S. Meshgini², Assistant Professor

1- Department of Biomedical Engineering, Faculty of Electrical and Computer Engineering, University of Tabriz, Tabriz, Iran, Email: f.hasanzadeh96@ms.tabrizu.ac.ir

2- Department of Biomedical Engineering, Faculty of Electrical and Computer Engineering, University of Tabriz, Tabriz, Iran, Email: meshgini@tabrizu.ac.ir

Abstract: Approximately one percent of the world's population suffers from epilepsy. The first stage of epilepsy treatment is timely and correct diagnosis. One of the ways to diagnose epilepsy is to accurately analyze EEG signals. There are various features to diagnose the disease from a signal such as the signal amplitude. In this paper, a new method for the diagnosis of epilepsy is presented by examining the time-frequency information of the EEG signal in people with seizure-free seizure syndrome and healthy people. Initially, the Global Wavelet Spectrum (GWS) feature of the EEG signal was extracted. To interpret this Spectrum in frequency bands, EEG signals decompose to five levels by continuous wavelet transform. Then, by applying this feature, a Support vector machine-based classifier was used to diagnose epilepsy. The results of the analysis provided a significant difference in the separation of the individual based on the brain signal. The proposed method compared to the previous methods, can classify epilepsy and intact signals with 100% accuracy. It was also observed that the dominant (GWS) values for the signals selected from patients with epilepsy in the delta and theta frequency band are discussed.

Keywords: Epilepsy, electroencephalography, wavelet transform, global wavelet spectrum, support vector machine.

تاریخ ارسال مقاله: ۱۳۹۷/۱۱/۲۳

تاریخ اصلاح مقاله: ۱۳۹۸/۰۲/۰۸

تاریخ پذیرش مقاله: ۱۳۹۸/۰۳/۱۴

نام نویسنده مسئول: سعید مشگینی

نشانی نویسنده مسئول: ایران - تبریز - بلوار ۲۹ بهمن - دانشگاه تبریز - دانشکده مهندسی برق و کامپیوتر.

۱- مقدمه

صرع، پس از ضربه مغزی دومین عارضه رایج مغزی در جهان است. حدود یک درصد از جمعیت جهان دچار این بیماری هستند. بیماری صرع در واقع نوعی اختلال عصبی گذرای مغزی می‌باشد که به علت فعالیت بیش از حد و ناگهانی سلول‌های عصبی در مغز ایجاد شده، می‌تواند منجر به حمله شود.

تاکنون روش‌های مختلفی جهت تشخیص خودکار صرع به وسیله سیگنال EEG ارائه شده است. زیرا سیگنال‌های EEG حاوی اطلاعات عظیمی از اطلاعات مفید است. متخصصین مغز و اعصاب با بررسی بصری سیگنال‌های EEG می‌توانند بیماری صرع را تشخیص دهند.

Yamaguchi در سال ۲۰۰۲ [۱]، به بررسی قطعات سیگنال EEG سالم و صرعی با استفاده از تبدیل فوریه و تبدیل موجک می‌پردازد و در نهایت بیان می‌نماید که ریتم آلفا در تبدیل فوریه قطعات سیگنال EEG سالم واضح‌تر از قطعات سیگنال EEG صرعی می‌باشد. به عبارتی تأیید می‌کند که تبدیل فوریه قطعات سیگنال EEG سالم از صرعی تفکیک‌پذیر می‌باشد. Nigam و Graupe در سال ۲۰۰۴ [۲]، با استفاده از استخراج ویژگی‌های مختلف و شبکه عصبی مصنوعی دقت طبقه‌بندی این مدل را ۹۷/۲٪ به دست آورد. در نهایت بیان می‌نماید که شبکه عصبی مصنوعی کارایی بالایی در طبقه‌بندی سیگنال‌های سالم و صرع عمومی دارد. در سال ۲۰۰۵، Srinivasan و همکاران [۳]، روش تشخیص صرع بر پایه شبکه‌های عصبی را بهبود دادند و از ویژگی‌های سیگنال در حوزه زمان و فرکانس برای تشخیص صرع استفاده کردند. در همین سال Kannathal و همکاران [۴]، برای تشخیص صرع، ویژگی آنتروپی را در سیگنال‌های EEG به کار بردند. در سال ۲۰۰۷، Gunes و Palat [۵]، طبقه‌بندی بیماری صرع را بر پایه درخت تصمیم و تبدیل فوریه سریع انجام دادند. در همین سال Subasi [۶]، با کمک استخراج ویژگی تبدیل موجک گسسته از یک ترکیب مدل خیره شبکه عصبی مصنوعی (MENN) که از سه شبکه خیره (سه شبکه عصبی مصنوعی MLP) و یک شبکه گیتینگ (یک شبکه عصبی مصنوعی MLP) تشکیل شده بود و یک شبکه عصبی مصنوعی MLP تنها استفاده کرد و دقت طبقه‌بندی را برای MENN ۹۴/۵٪ و برای MLPNN تنها ۹۳/۲٪ بیان نمود. در سال ۲۰۱۰، Guo و همکاران [۷]، یک سیستم تشخیص صرع با استفاده از تبدیلات موجک و تقریب‌های آنتروپی و شبکه‌های عصبی ارائه کرد. در همین سال Mashakbeh [۸]، با کمک تبدیل موجک گسسته و با استفاده از معیار انحراف معیار ضرایب موجک در سطوح تجزیه توانست ۲۰ قطعه سیگنال (۱۰ قطعه سالم و ۱۰ قطعه صرع عمومی) را با ۱۰۰٪ دقت تفکیک نماید. در حقیقت طبقه‌بندی پیشنهادی توسط مشکیه یک آستانه بود و او معتقد بوده که اگر انحراف معیار ضرایب موجک در سطوح تجزیه بزرگ‌تر از ۱۴۰ باشد، قطعه سیگنال مربوط به کلاس صرع عمومی خواهد بود. در سال ۲۰۱۲، Nicolaou [۹]، با استفاده از آنتروپی جایگشت و ماشین بردار پشتیبان روشی را برای طبقه‌بندی سیگنال‌های EEG ارائه کرد. در همین سال Kumar

و همکاران [۱۰]، تشخیص بیماری صرع را با استفاده از تبدیل موجک گسسته، آنتروپی تقریبی و ماشین بردار پشتیبان انجام دادند. Weng و Khorasani [۱۱]، از ویژگی‌هایی همچون دامنه متوسط EEG، ضریب پراکندگی و طیف توان متوسط را به عنوان ورودی شبکه عصبی وقفی استفاده کردند. Tzallas و همکاران [۱۲]، نیز با استفاده از توزیع‌های مختلف زمان فرکانس و اعمال ویژگی‌های استخراج‌شده به یک شبکه عصبی مصنوعی سیگنال‌های صرعی و سالم را جداسازی کرده اند. Saini و Dhiman [۱۳]، از روش تعمیم‌یافته تبدیل موجک و الگوریتم ژنتیک^۸ و طبقه‌بند ماشین بردار پشتیبان جهت تشخیص صرع بهره گرفته‌اند.

در این مقاله برای نشان دادن تفاوت بین سیگنال سالم و صرعی یک ویژگی جدید به عنوان طیف کلی موجک از سیگنال‌های EEG با استفاده از تبدیل موجک استخراج می‌شود. تفاوتی که این روش با روش‌های موجود در زمینه تشخیص صرع دارد، در این است که این روش به داده‌های کمتری نیاز دارد و همچنین تغییرات سیگنال‌ها به راحتی تشخیص داده می‌شوند. برای بالا بردن دقت طبقه‌بندی نیز از ماشین بردار پشتیبان استفاده شده است.

یکربندی این مقاله بدین صورت است که در بخش ۲ مبانی و روش‌های استفاده‌شده برای تشخیص صرع آورده شده است. در بخش ۳ روش پیشنهادی بر مبنای استخراج ویژگی طیف کلی موجک با استفاده از تبدیل موجک بیان شده است. همچنین در این بخش ویژگی‌های آماری میانگین و مد برای ویژگی استخراج‌شده محاسبه می‌گردد. در بخش ۴ نتایج روش پیشنهادی و مقایسه روش پیشنهادی با روش‌های قبلی آورده شده است. نتیجه‌گیری نهایی روش پیشنهادی در بخش ۵ بیان شده است.

۲- مبانی و روش‌ها

در کارهای انجام‌شده قبلی، با استفاده از روش‌هایی مانند فیلترهای پیش‌پردازش غیر خطی، خصوصیات حوزه زمان، خصوصیات حوزه فرکانس، تحلیل فرکانس زمان، ویژگی‌های آنتروپی و تبدیل موجک، ویژگی‌های مختلفی از سیگنال EEG برای تشخیص صرع استخراج شده است. در به کارگیری الگوریتم‌های به کار گرفته‌شده نوآوری و تکنیک‌های ریاضی زیادی به کار گرفته شده است. مطالعات نشان می‌دهد که تبدیل موجک موفق‌ترین روش برای استخراج ویژگی‌های سیگنال EEG است. در بعضی پژوهش‌ها ویژگی‌های استخراج‌شده از سیگنال EEG توسط روش‌های تشخیص خودکار مانند شبکه عصبی، درخت تصمیم و ماشین بردار پشتیبان طبقه‌بندی شده‌اند. در این بخش توضیحاتی در مورد روش‌های استفاده‌شده در این مقاله آورده می‌شود.

۲-۱- تبدیل موجک

برای تحلیل سیگنال‌ها مبدل‌های ریاضی مورد استفاده قرار می‌گیرد تا بتوان اطلاعاتی را که از سیگنال‌های خام به آسانی قابل دسترس نیست به دست آورد. تبدیل موجک یکی از تبدیل‌های ریاضی کارآمد در

ابرفرصه و b بایاس آن می‌باشد که فاصله بین ابرصفحه تصمیم‌گیری و مبدا فضای ویژگی را نمایش می‌دهد. در جداسازی داده‌های غیرخطی جداناپذیر، ویژگی اصلی آن‌ها انتقال داده‌ها به فضایی با ابعاد بیشتر می‌باشد که داده‌ها در آن فضا به صورت خطی بیشترین تفکیک‌پذیری را داشته باشند. این عمل بر مبنای توابع کرنل صورت می‌گیرد که از امتیازات منحصر به فرد این طبقه‌بند است. هدف اصلی در فاز آموزشی SVMها حل یک مساله بهینه‌سازی است جهت ماکزیمم کردن حاشیه در عین مینیمم کردن تعداد نمونه‌های آموزشی قرار گرفته درون حاشیه، در صورت استفاده از توابع کرنل تابع تصمیم‌گیری یک SVM بر پایه کرنل به شکل رابطه (۳) تبدیل می‌گردد.


$$g(x) = \text{sign}\left(\sum_{i=1}^{N_s} \alpha_i y_i k(x_i, x) + b\right) \quad (3)$$

N_s تعداد نمونه‌های آموزشی است که دارای ضریب صفر می‌باشند.

α_i و y_i از حل مساله بهینه‌سازی به دست می‌آیند. نمونه‌هایی که دقیقاً روی ابرصفحه قرار گرفته‌اند، به این نمونه‌ها اصطلاحاً بردارهای پشتیبان (SV) گفته می‌شوند که مهم‌ترین داده‌های آموزشی هستند چرا که SVها به تنهایی برای تعریف حاشیه تفکیک‌پذیری کفایت می‌کنند. در شکل ۱ تصویری از یک مجموعه داده متعلق به دو کلاس نشان داده شده که روش ماشین بردار پشتیبان بهترین ابرسطح را برای جداسازی آن‌ها انتخاب می‌کند.

نکته قابل توجه این است که اگر داده‌های تعلیمی به صورت خطی تفکیک‌پذیر باشند، می‌توان دو ابرسطح مرزی را به گونه‌ای انتخاب کرد که هیچ داده‌ای بین آن‌ها نباشد و سپس فاصله بین این دو ابرسطح موازی را به حداکثر رساند. با به کارگیری قضایای هندسی، فاصله این دو

ابرسطح عبارت است از، $\frac{2}{\|w\|}$ پس باید $|w|$ را به حداقل رساند.



شکل ۱: ابرسطح با حداکثر حاشیه جداکننده به همراه مرزهای جداکننده برای طبقه‌بندی نمونه داده‌های مربوط به دو طبقه متفاوت

[۱۵]

زمینه پردازش سیگنال است تبدیل موجک تبدیلی است که سیگنال را به یک مجموعه از توابع اساسی سیگنال تجزیه می‌کند. در حقیقت یک مجموعه تابع اساسی، از تأخیر و تغییر در مقیاس موجک مادر به دست می‌آید. یک واقعیت مهم در مورد توابع موجک این است که خود تبدیل هیچ محدودیتی در مورد شکل آن‌ها ایجاد نمی‌کند و این تفاوت عمده تبدیل موجک با سایر تبدیل‌ها است. مزیت مهم تبدیل موجکی این است که اطلاعات زمان و فرکانس را به طور موثری از سیگنال متغیر در زمان استخراج می‌کند. تابع موجک ψ موجک مادر نامیده می‌شود که دارای سه مشخصه تعداد نوسان محدود، بازگشت سریع به صفر در هر دو جهت مثبت و منفی در دامنه خود و میانگین صفر است (این سه ویژگی شرط لازم برای این است که تابعی بتواند به عنوان تبدیل موجکی عمل کند) که شرط مقبولیت نامیده می‌شود [۱۴]. به صورت رابطه (۱) بیان می‌شود:

$$\int_{-\infty}^{\infty} \frac{|\psi(\omega)|^2}{\omega} d\omega < \infty \quad (1)$$

که در آن $\psi(\omega)$ تبدیل فوریه $\psi(t)$ است.

۲-۲- طبقه‌بندی توسط ماشین بردار پشتیبان (SVM)

در این بخش مفاهیم و روابط ریاضی مربوط به طبقه‌بند ماشین بردار پشتیبان آورده شده است. هدف از طبقه‌بندی پیدا کردن تابعی است که داده‌ها را از هم جدا کند. این تابع با استفاده از نمونه‌های آموزشی موجود به دست می‌آید. در واقع هدف ایجاد تابعی است که بتوان آن را به نمونه‌های دیگر تعمیم داد.

ایده ماشین بردار پشتیبان، اولین بار توسط Boser و همکاران [۱۵] در سال ۱۹۹۲ معرفی شد. SVM، یکی از ابزارهای طبقه‌بندی دارای نظارت است. هدف اصلی در SVM فراهم کردن یک تابع $f(x)$ است که مرز تصمیم‌گیری با ابرصفحه بهینه را مشخص می‌کند. این ابرصفحه داده‌های ورودی را به دو کلاس تقسیم می‌کند، در واقع نکته مهم SVM یافتن دو ابرصفحه موازی است که دارای بیشترین فاصله نسبت به یکدیگر باشند که در بین این دو صفحه کم‌ترین تعداد نمونه آموزشی قرار گیرد که به این فاصله اصطلاحاً حاشیه^۱ می‌گویند. مجموعه ابرصفحه‌های موازی و حاشیه تعیین شده بین آن‌ها مرز تصمیم‌گیری جهت تفکیک بین دو دسته را می‌دهد. برای محاسبه مرز تصمیم‌گیری دو کلاس کاملاً جدا از هم، از روش حاشیه بهینه استفاده می‌شود [۱۶].

در SVM داده‌ها می‌توانند به دو صورت تفکیک شوند: خطی و غیر خطی و در کل می‌توان آن را به عنوان دسته‌های از ابزارهای طبقه‌بندی خطی در نظر گرفت. برای داده‌های جداپذیر به صورت خطی تابع تفکیک‌کنندگی به صورت رابطه (۲) نمایش داده می‌شود.

$$g(x) = \text{sign}(x(\omega, \theta) + b) \quad (2)$$

که علامت مثبت تعلق به دسته اول و علامت منفی تعلق به دسته دوم را نمایش می‌دهد، x بردار نمونه‌های آموزشی ویژگی‌ها، ω بردار

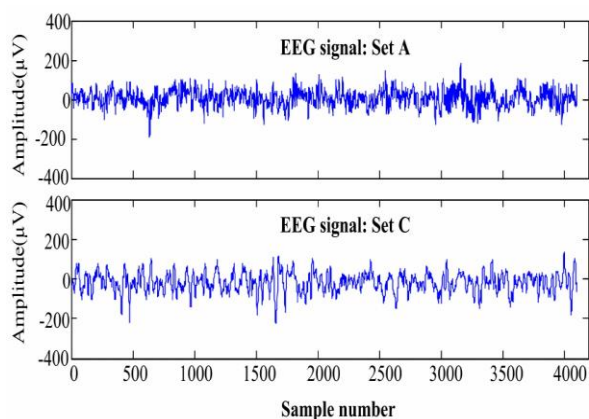
۳- روش پیشنهادی

و با چشمان باز و بسته قرار گرفته‌اند. سه مجموعه آخر (C, D, E) و نیز از پنج بیمار صرعی به صورت الکتروگذاری عمقی ثبت شده‌اند. دو مجموعه D و C هنگام عدم حمله صرع و به ترتیب فرد بیمار با در نظر گرفتن صرع ژنتیکی و ثبت در نیمکره مخالف مغز است. مجموعه E در خلال تشنج ثبت شده است. در کل، این داده‌ها شامل سه دسته مختلف حالت طبیعی بیمار، مرحله قبل از تشنج (صرع جزئی) و تشنج (صرع عمومی) هستند. همه سیگنال‌های EEG با سیستم ۱۲۸ کاناله و نرخ نمونه‌برداری ۱۷۳/۶۱ هرتز و به کمک میدل آنالوگ به دیجیتال ۱۲ بیتی گرفته شده‌اند. در جدول ۱ خلاصه‌ای از داده‌های به دست آمده از دانشگاه بن آلمان آورده شده است.

جدول ۱: خلاصه‌ای از داده‌های دانشگاه بن آلمان

موضوع	مجموعه A	مجموعه B	مجموعه C	مجموعه D	مجموعه E
وضعیت بیمار	هوشیار با چشمان باز	هوشیار با چشمان بسته	صرع جزئی (بدون تشنج)	صرع جزئی (بدون تشنج)	صرع عمومی (با تشنج)
تعداد نمونه	۱۰۰	۱۰۰	۱۰۰	۱۰۰	۱۰۰
طول نمونه	۲۳/۶	۲۳/۶	۲۳/۶	۲۳/۶	۲۳/۶

روش پیشنهادی این مقاله یک روش ساده است و به مجموعه داده‌های نسبتاً کوچکی نیاز دارد. بنابراین در این مقاله از دو دسته داده A (افراد سالم با چشم‌های باز) و دسته C (افراد بیمار مبتلا به سندرم صرع بدون تشنج) جهت تست الگوریتم پردازش استفاده شده است. شکل ۳ یک کانال از این دو دسته سیگنال را نمایش می‌دهد.

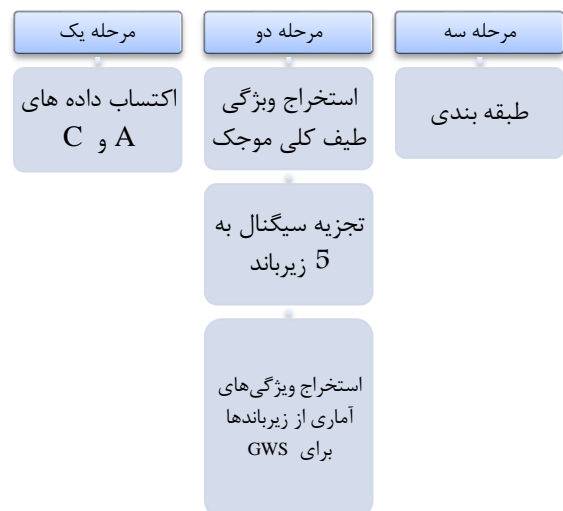


شکل ۳: نمونه‌هایی از سیگنال EEG از دو مجموعه داده (A, C)

۳-۲- استخراج ویژگی طیف کلی موجک (GWS)

روش مورد استفاده در این مقاله توسط تورنس و کومپو توسعه و معرفی شده است [۱۹]. موجک مورلت به‌عنوان تابع موجک مادر ۱/۲ در این مقاله انتخاب شده است. یکی از دلایل مهم برای انتخاب آن شکل موجک مورلت است. شکل موجک مورلت برای استخراج مؤلفه‌های دوره

در این مقاله، به بررسی اطلاعات زمان-فرکانسی سیگنال EEG در افراد بیمار مبتلا به سندرم صرع و افراد سالم پرداخته شده است. برای تفکیک سیگنال‌های صرعی از سیگنال‌های سالم یک ویژگی جدید از سیگنال‌های EEG با استفاده از تبدیل موجک پیوسته^{۱۰} استخراج می‌شود. این ویژگی جدید به عنوان طیف کلی موجک (GWS) شناخته می‌شود. این طیف معیاری مناسب جهت سنجش طیف توانی واقعی یک سری زمانی را ایجاد می‌کند و توسط آن تغییرات یک سیگنال به راحتی تشخیص داده می‌شود. سیگنال‌های EEG با استفاده از تبدیل موجک پیوسته به پنج سطح تجزیه می‌شوند. چون GWS مجموعه‌ای از مقادیر را برای مؤلفه خاصی از سیگنال EEG در محدوده فرکانس‌های مختلف ارائه می‌دهد و مقدار GWS در باندهای فرکانسی دلتا و تتا دارای ظرفیتی برای نشان دادن تفاوت بین EEG سالم و صرعی است. همچنین با استفاده از این زیرباندها، اطلاعات آماری میانگین و حالت مد دامنه GWS هر یک از افراد را در باندهای فرکانسی خاصی مشخص می‌شود. در نهایت، GWS سیگنال‌های EEG توسط طبقه‌بند ماشین بردار پشتیبان طبقه‌بندی می‌شوند. شکل ۲ الگوریتم روش پیشنهادی را نشان می‌دهد.



شکل ۲: الگوریتم پیشنهادی

در ادامه هر بخش توضیح داده می‌شود.

۳-۱- دادگان

داده‌های EEG استفاده شده در این مقاله از دانشگاه بن آلمان به صورت آنلاین بر روی سایت تهیه شده است، گرفته شده‌اند. [۱۷ و ۱۸] این داده‌ها شامل پنج مجموعه از A تا E هستند که هر کدام شامل ۱۰۰ عدد سیگنال به طول ۲۳/۶ ثانیه است، مجموعه اول و دوم (A, B) از پنج نفر انسان سالم با استفاده از شیوه الکتروگذاری سطحی با استاندارد ۲۰-۱۰ جمع‌آوری شده‌اند. این افراد در حالت کاملاً هوشیار

را جهت اندازه‌گیری و تشخیص واریانس سری زمانی در فرکانس‌ها و زمان‌های مختلف در اختیار قرار می‌دهد.

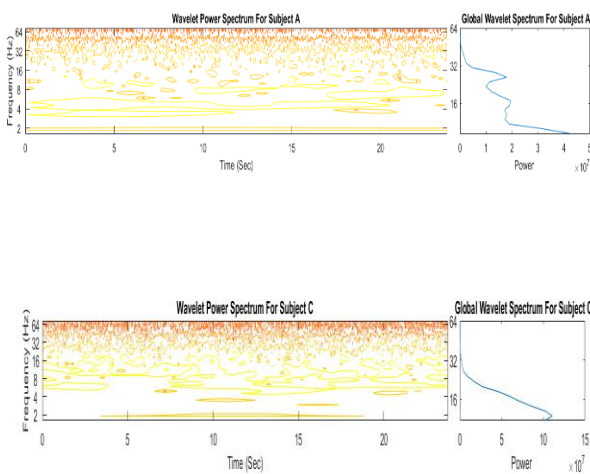
طیف کلی موجک (GWS) به صورت میانگین زمانی طیف توانی موجک تعریف می‌شود.

پس از محاسبه ضرایب تبدیل موجک (رابطه (۵))، با استفاده از رابطه (۶) طیف کلی موجک (GWS) محاسبه می‌شود:

$$\bar{W}^2(s) = \frac{1}{N} \sum_{n=0}^N |W(s)|^2 \quad (6)$$

طیف توان موجک به عنوان $|W(s)|^2$ تعریف شده است.

طیف توان موجک و GWS از سیگنال EEG به ازای فرد سالم و بیمار در اولین کانال ثبتی، به صورت شکل ۵ می‌توان مقایسه کرد.



شکل ۵: طیف توان موجک و GWS از سیگنال EEG به ازای فرد سالم و بیمار در اولین کانال ثبتی

برای تفسیر نتایج به دست آمده از شکل ۵ باندهای فرکانسی تقسیم شده است. که هر کدام نام خاصی و هر قسمت خصوصیات خاصی دارد و شامل اطلاعات مفیدی در مورد فعالیت‌های عصبی است و می‌تواند اطلاعات ارزشمندی را در اختیار ما قرار دهد.

از شکل ۵ واضح است که تفاوت در مقدار سیگنال EEG اولین سیگنال مجموعه C در محدوده فرکانسی تا ۶ هرگز نسبت به همان مؤلفه سیگنال EEG اولین سیگنال مجموعه A بسیار قابل توجه است. همانطور نتایج یک کانال نشان داد که توان سیگنال افراد بیمار در فرکانس‌های پایین بسیار بیشتر از افراد سالم است.

۳-۲-۱- تجزیه سیگنال EEG به پنج زیرباند

نتایج طیف کلی موجک (GWS) سیگنال را برای ۱۰۰ کانال فرد سالم و ۱۰۰ کانال فرد بیمار در شکل ۶ مشاهده می‌کنید. اولین ۱۰۰ سیگنال GWS (۱۰۰-۰) مربوط به سیگنال‌های مجموعه A و ۱۰۰

ای یک سری زمانی بسیار مناسب است و تأثیر اثرات حاشیه‌ای^{۱۱} در آن به دقت بررسی شده است. عملکرد موجک مورلت^{۱۲} به صورت رابطه (۴) تعریف می‌شود:

$$\psi(\eta) = \pi^{1/4} e^{i\omega_0 \eta} e^{-\eta^2/2} \quad (4)$$


که در آن در این رابطه ω_0 فرکانس مرکز (center frequency) است و وظیفه آن ایجاد انطباق (همنویایی) بین زمان و فرکانس است و η زمان بدون بعد را نشان می‌دهد.

برای استخراج ویژگی از تبدیل موجک از رابطه (۵) استفاده شده است:

$$W(s) = \frac{\delta_t}{\sqrt{s}} \sum_{n=0}^{N-1} EEG_n \psi^* \left[\frac{(n-m)\delta_t}{s} \right] \quad (5)$$

$$m = 0, 1, \dots, N-1$$

که در آن $W(s)$ ضریب موجک پیوسته و علامت \times نشان‌دهنده مزدوج مختلط^{۱۳} تابع مورلت است. N تعداد نقاط در سری زمانی است. ψ تابع موجک مورلت در مقیاس S (تعیین‌کننده فرکانس یا طول موج تابع موجک است) و شیفت زمانی m است. شکل موج، موجک مادر استفاده شده (تابع مورلت) به صورت شکل ۴ می‌باشد.



شکل ۴: تابع مورلت

فرایند محاسبه به صورت زیر است:

- موجک در آغاز سیگنال قرار می‌گیرد و $s = 1$ قرار داده می‌شود. (موجک پایه، اصلی).

- تابع موجک در مقیاس ۱ در سیگنال ضرب می‌شود و طی همه زمان‌ها از آن انتگرال گرفته می‌شود سپس در متغیری از S ضرب می‌شود.

- موجک به $t = \tau$ منتقل می‌شود و مقدار انتقال $t = \tau$ فرایند را تا زمانی که موجک به انتهای سیگنال برسد ادامه دهید؛

مقیاس S به اندازه یک مقدار داده شده افزایش می‌یابد؛ فرایند بالا برای همه S ها تکرار شود.

هر محاسبه برای مقدار داده شده S یک سطر از صفحه زمان - مقیاس را پر می‌کند؛ اگر همه مقادیر S محاسبه شده باشند، تبدیل موجک به دست آمده است.

طیف توان موجک را می‌توان به صورت توان دوم ضرایب تبدیل موجک پیوسته در نظر گرفت ($|W(s)|^2$). این طیف ابزار بسیار مفیدی

۲-۲-۳- استخراج ویژگی‌های آماری از زیرباند‌ها برای GWS

سیگنال با دامنه فرکانسی پایین قابل چشم‌پوشی است و در نظر گرفته نمی‌شود و تجزیه و تحلیل بیشتر متوجه دامنه فرکانسی بالای ۹ Hz می‌شود که شامل باند فرکانسی دلتا و تتا است. همچنین برای اندازه‌گیری تفاوت بین سیگنال‌های EEG صرع و سالم ویژگی‌های آماری زیر از دامنه GWS محاسبه شده است. جدول ۲ اطلاعات آماری هر یک از افراد را در باندهای فرکانسی خاصی مشخص می‌کند. استخراج یک مشخصه آماری انسان را قادر می‌کند تا اختلافات و اختلالات را به راحتی و به صورت عینی درک کند. از طرف دیگر این کار باعث می‌شود طبقه‌بندی این حالات و اختلالات را تفکیک و طبقه‌بندی کنند.

جدول ۲: ویژگی‌های آماری استخراج شده از دامنه GWS

باند فرکانسی	ویژگی	مجموعه A	مجموعه C
دلتا ۴-۰ Hz	میانگین	۱۶۳۶۵/۵۵	۵۶۵۳۰/۲۷
دلتا ۴-۰ Hz	مد	۹۰۸۷/۴۳	۳۷۱۸۲/۳۳
تتا ۸-۴ Hz	میانگین	۸۸۲۰/۲۲	۳۱۸۳۶/۸۷
تتا ۸-۴ Hz	مد	۸۱۹۰/۴۸	۹۸۴۶/۵۷
آلفا ۱۶-۸ Hz	میانگین	۵۹۲۳/۲۶	۱۱۵۸۶/۲۴
آلفا ۱۶-۸ Hz	مد	۱۰۶۰۹/۰۷	۲۴۹۶/۹۲

از جدول ۲ قابل مشاهده است که برای EEG صرعی GWS مقادیر در باند فرکانس دلتا و تتا در مقایسه با EEG سالم زیاد است.

۳-۳- طبقه‌بندی

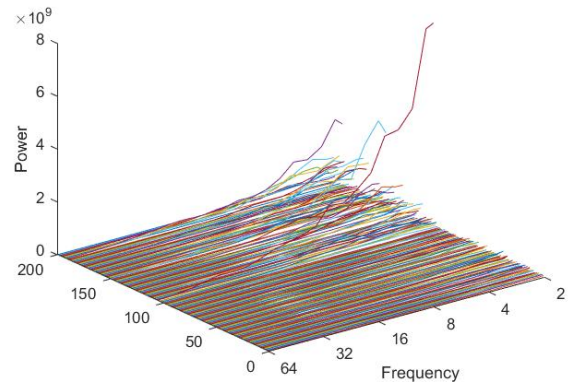
ماشین بردار پشتیبان یکی از جدیدترین روشها جهت طبقه‌بندی داده‌ها می‌باشد که نسبت به روشهای قدیمی‌تر مانند شبکه عصبی کارایی بهتری دارد. این تکنیک، یک روش یادگیری supervised و جزو شاخه Kernel Methods در یادگیری ماشین محسوب می‌شود. از SVM هم جهت شناسایی الگو و هم جهت طبقه‌بندی استفاده می‌شود.

SVM با فرض این که دسته‌ها به صورت خطی جداپذیر باشند، ابرصفحه‌هایی با حداکثر حاشیه^{۱۴} به دست می‌آورد تا دسته‌ها را جدا کند. سپس با در نظر گرفتن این ابرصفحه‌ها، داده‌ها را به دو کلاس مجزا تقسیم می‌کند که جواب کلاس اول در معادله صفحه مثبت و دیگری در معادله صفحه منفی است. البته این روش تا زمانی پاسخگو است که داده‌ها به صورت خطی تفکیک پذیر باشند اما در مسایلی که داده‌ها به صورت خطی جداپذیر نباشند؛ داده‌ها به فضایی با ابعاد بیشتر نگاشت داده می‌شود تا در همین فضا، آن‌ها را توسط تابعی (به نام کرنل) جایگزین کرد تا بتوان آن‌ها را به صورت خطی جدا نمود.

علت استفاده از طبقه‌بند ماشین بردار پشتیبان نسبت به طبقه‌بندی دیگر مانند شبکه‌های عصبی و درخت تصمیم این است که:

- آموزش ماشین بردار پشتیبان نسبتاً ساده است.
- نسبت به شبکه‌های عصبی تئوری قوی‌تری دارد.


سیگنال دوم (۱۰۰-۲۰۰) مربوط به سیگنال‌های مجموعه C است. همچنین برای تکمیل نتایج ضروری است که سیگنال EEG به زیرباند‌های تجزیه گردد. چون درک ویژگی‌های باندهای فرکانسی EEG اطلاعات ارزشمندی را ارائه می‌دهد.



شکل ۶: طیف توان عمومی (GWS) سیگنال برای ۱۰۰ کانال فرد سالم و ۱۰۰ کانال فرد بیمار

در شکل ۶ برای اولین ۱۰۰ سیگنال EEG، یک مؤلفه غالب می‌تواند حدود ۱۰ Hz شناسایی شود، که نشان دهنده ریتم آلفا است. همانطور که انتظار می‌رفت، توان سیگنال در افراد بیمار در فرکانس‌های کم، بیشتر از توان در افراد سالم می‌باشد.

برای به دست آوردن اطلاعات دقیق‌تر از سیگنال EEG، سیگنال را به ۵ زیر باند تجزیه می‌کنند. همچنین برای تجزیه سیگنال EEG از روش تبدیل موجکی استفاده شده است، چون با توجه به ماهیت غیر ایستادن اغلب سیگنال‌های حیاتی شرط ایستایی که از شروط لازم در بیشتر پردازش‌های معمول حوزه فرکانس (از جمله تحلیل طیفی) است، معمولاً برقرار نیست. بنابراین برای بررسی محتوای فرکانسی سیگنال EEG و تغییرات زمانی آن از روش‌های زمان فرکانس استفاده می‌شود. پنج زیر باند طیف گسترده سیگنال EEG که عموماً در کلینیک‌ها استفاده می‌شود: موج‌های دلتا (۴-۰) Hz، تتا (۸-۴) Hz، آلفا (۱۶-۸) Hz، بتا (۱۶-۳۲) Hz، گاما (۳۲-۶۴) Hz فرکانس‌های بالاتر برای حالت‌های غیر عادی مغز از جمله صرع به کار می‌روند [۲۰]. شکل ۷ تجزیه سیگنال EEG به زیرباند‌هایش را نشان می‌دهد.



شکل ۷: امواج سیگنال EEG

۴-۱- نتایج طبقه‌بندی

به‌منظور ارزیابی نتایج معمولاً از معیارهای ارزیابی استاندارد استفاده می‌شود. مشهورترین و عمومی‌ترین معیار برای تعیین کارایی یک الگوریتم طبقه‌بند دقت است. عملکرد سیستم طبقه‌بندی کننده برای آشکارسازی خودکار سیگنال‌های صرعی با استفاده از معیار حساسیت^{۱۵} طبق رابطه (۷) ارزیابی می‌شوند.

$$\text{Sensitivity} = \frac{TP}{TP + FN} \times 100\% \quad (7)$$

حساسیت معیار توانایی طبقه‌بندی کننده در آشکارسازی Spikeها است.

مهم‌ترین معیار برای تعیین کارایی یک الگوریتم طبقه‌بندی دقت طبقه‌بندی است. که این معیار دقت کل یک طبقه بند را محاسبه می‌کند. میزان دقت^{۱۶} طبقه‌بندی به‌صورت رابطه (۸) است:

$$\text{Accuracy} = \frac{TN + TP}{TN + FP + TP + FN} \times 100\% \quad (8)$$

معیار خطای طبقه‌بندی^{۱۷} دقیقاً برعکس معیار دقت طبقه‌بندی است. کمترین مقدار آن، برابر صفر است زمانی که بیشترین کارایی را طبقه‌بند دارد و به‌طور مشابه بیشترین مقدار آن، یک است زمانی که طبقه بند کمترین کارایی را دارد. معیار خطای طبقه‌بندی به‌صورت رابطه (۹) محاسبه می‌شود:

$$\text{Error_Rate} = \frac{FN + FP}{TN + FP + TP + FN} \times 100\% \quad (9)$$

در روابط بالا،

TP^{18} تعداد Spikeهای صرعی که توسط سیستم طبقه‌بندی کننده به درستی آشکار شده است؛

TN^{19} تعداد Spikeهای غیر صرعی که توسط سیستم به درستی آشکار شده است؛

FP^{20} ، تعداد Spikeهای غیر صرعی که به اشتباه توسط سیستم به عنوان Spike صرعی طبقه‌بندی شده است؛

FN^{21} ، تعداد Spikeهای صرعی که به اشتباه توسط سیستم به عنوان spike غیر صرعی طبقه‌بندی شده است.

جهت به‌دست آوردن دقت روش پیشنهادی در طبقه‌بندی سیگنال‌های الکتروانسفالوگرافی، قسمتی از داده‌ها به عنوان داده‌های آموزشی جهت آموزش الگوریتم و مابقی آن‌ها به عنوان داده‌های آزمایشی به کار گرفته شده‌اند. بدین منظور دو حالت مختلف در نظر گرفته شده است:

✓ در حالت اول ۸۰ درصد داده‌ها به‌صورت تصادفی به عنوان داده‌های آموزشی در نظر گرفته شده و ۲۰ درصد داده‌های باقی‌مانده (۴۰ داده) جهت آزمایش به کار برده شده‌اند. (شکل ۸)

✓ حالت دوم نیز ۹۰ درصد داده‌ها را به‌صورت تصادفی به عنوان داده‌های آموزشی و ۱۰ درصد (۲۰ داده) دیگر را جهت آزمایش روش پیشنهادی استفاده می‌کند. (شکل ۹)

• برخلاف شبکه‌های عصبی در ماکزیم‌های محلی گیر نمی‌افتد.

• برای داده‌های با ابعاد بالاتر خوب جواب می‌دهد در حالی که در روش درخت تصمیم اگر درخت بزرگ باشد امکان است خطاها از سطحی به سطح دیگر جمع شوند (انباشته شدن خطاها بر روی یک‌دیگر).

• برای ذخیره مدل پیش‌بینی به فضای کمتری نیاز دارد. به نتایج خواناتر و یک تفسیر هندسی دست پیدا می‌کند ولی در درخت تصمیم احتمال تولید روابط نادرست وجود دارد.

ابرفصحه یک مفهوم در هندسه و تعمیمی از یک صفحه در تعداد متفاوتی از ابعاد است. در SVM اگر داده‌ها دارای n بعد باشند. صفحه جداساز دارای $n-1$ بعد است. اما جهت جداسازی داده‌ها چندین صفحه جداساز وجود دارد. زیرا مفهوم آموزشی که اشیاء بتوانند به‌عنوان نقاط در یک فضای با ابعاد بالا طبقه‌بندی شوند و پیدا کردن خطی که آن‌ها را جدا کند؛ منحصر به فرد نیست. برای انتخاب صفحه مناسب‌تر منظور از مناسب‌تر بودن داشتن حداکثر فاصله با داده‌های دو کلاس و حداقل خطا می‌باشد. آنچه که SVM را از سایر طبقه‌بندها متمایز می‌کند، به‌کارگیری همین شیوه در انتخاب صفحه جداساز است. به همین دلیل، SVM به‌راحتی می‌تواند برای طبقه‌بندی داده‌ها در دو کلاس یا بیشتر استفاده شود. در SVM بیشینه کردن حاشیه بین دو کلاس، مدنظر است. بنابراین، ابرفصحه‌ای را انتخاب می‌کند که فاصله آن از نزدیک‌ترین داده‌ها در هر دو طرف جداکننده خطی، بیشینه باشد. اگر چنین ابرفصحه‌ای وجود داشته باشد؛ به‌عنوان ابرفصحه با حاشیه بیشینه شناخته می‌شود.

این الگوریتم، قدرت تعمیم خوبی خواهد داشت. علیرغم ابعاد زیاد از سرریز شدن پرهیز می‌کند. همچنین به جای استفاده از کل داده‌ها، فقط از بردارهای پشتیبان استفاده می‌کند. یک جداکننده اغلب به‌صورت یک تابع نشان داده می‌شود.

اگر داده‌های آموزشی را بتوان به‌صورت خطی جدا کرد، می‌توان دو صفحه جداکننده را طوری انتخاب کرد که هیچ داده‌ای بین آن‌ها نباشد و سپس سعی می‌شود فاصله آن‌ها را بیشینه کرد. با استفاده از هندسه، فاصله بین این دو ابرفصحه (پهنای حاشیه) را پیدا می‌کند که برابر است؛ بنابراین، کمینه می‌شود.

۴- نتایج شبیه‌سازی

تجزیه و تحلیل ۲۰۰ سیگنال EEG گواه این حقیقت است که روش پیشنهادی ما، روشی ساده در تشخیص بیماری صرع است. نتایج نشان دهنده این است که مؤلفه‌های سیگنال EEG در انسان سالم و انسان مبتلا به بیمار صرع فرق می‌کند. پس طیف کلی موجک (GWS) توانایی تولید پارامترها برای طبقه‌بندی EEG سالم یا صرعی را دارد.

جدول ۳: مقایسه روش پیشنهادی با روش‌های قبلی

دقت (%)	روش‌ها	پژوهشگران
۹۷/۲	فیلترهای پیش‌پردازش غیر خطی، شبکه عصبی	Nigam and Graupe [۲]
۹۹/۶	ویژگی‌های حوزه زمان-فرکانس، شبکه عصبی	Srinivasan et al. [۳]
۹۲/۲۲	معیارهای آنتروپی، سیستم استنتاج فازی	Kannathal et al. [۴]
۹۸/۷۲	تبدیل فوریه سریع، درخت تصمیم	Polat and Gunes [۵]
۹۵	تبدیل موجک گسسته و ترکیبی از مدل‌های خبره	Subasi [۶]
۹۹/۸۵	تبدیلات موجک چندگانه، ویژگی آنتروپی تقریبی، شبکه عصبی پرسپترون چند لایه	Ling Guo et al. [۷]
۸۸	روش آنتروپی جایگشت و ماشین بردار پشتیبان	Nicoletta Nicolaou [۹]
۱۰۰	تبدیل موجک گسسته، آنتروپی تقریبی، شبکه عصبی، ماشین بردار پشتیبان	Yatindra Kumar et al. [۱۰]
۱۰۰	طیف کلی موجک، ماشین بردار پشتیبان	روش پیشنهادی مقاله

۵- نتیجه‌گیری


در این مقاله، از ویژگی، طیف توان محلی موجک (GWS) جهت تشخیص حملات صرع به‌کار گرفته شده است. مقایسه نتایج حاصل از دو مجموعه تحلیل شده، روشن است که GWS تمایز روشنی بین سیگنال‌های EEG افراد سالم و بیماران مبتلا به سندرم صرع را فراهم می‌کند. همچنین GWS به عنوان مجموعه‌ای از مقادیر برای مؤلفه خاصی از سیگنال EEG را در محدوده فرکانس‌های مختلف ارائه می‌دهد. مقادیر GWS به‌عنوان داده‌های ورودی برای طبقه‌بندی ماشین بردار پشتیبان استفاده شده است. نتایج شبیه‌سازی به‌صورت جدول ۴ است.

جدول ۴: نتایج شبیه‌سازی


ماشین بردار پشتیبان (%)	دقت
۱۰۰	دقت
۱۰۰	حساسیت
۰	خطای طبقه‌بندی

نتایج این مقاله گواه آن است که سیستم ماشین بردار پشتیبان می‌تواند داده‌ها را با دقت ۱۰۰٪ طبقه‌بندی کند. نظر به اینکه این سیستم دارای حجم محاسباتی کمتر و دقت خیلی خوب می‌باشد و می‌تواند به عنوان یکی از بهترین سیستم‌های تشخیص صرع به‌کار رود.

در هر دو حالت طبقه‌بندی، دقت طبقه‌بندی ۱۰۰٪ به دست آمد. شکل‌های ۸ و ۹ نتایج حاصل از طبقه‌بندی را نشان می‌دهند. در شکل ۸ عدد ۲۰ سطر اول ماتریس نشان‌دهنده داده‌های TP است. این مربوط به ۵۰٪ از تمام ۴۰ داده‌ها است. عدد ۲۰ سطر دوم نشان‌دهنده داده‌های TN است. به‌طور مشابه، این مربوط به ۵۰٪ از تمام ۴۰ داده‌ها است. عدد صفر سطر اول مربوط به داده‌های FP است. همچنین عدد صفر سطر دوم مربوط به داده‌های FN است. عدد ۱۰۰٪ سطر اول دقت طبقه‌بندی داده‌های TP و FP، عدد ۱۰۰٪ سطر دوم دقت طبقه‌بندی داده‌های FN و TN، عدد ۱۰۰٪ ستون اول دقت طبقه‌بندی داده‌های TP و FN، عدد ۱۰۰٪ ستون دوم دقت طبقه‌بندی داده‌های FP و TN و عدد ۱۰۰٪ قطر اصلی ماتریس دقت طبقه‌بندی همه ۴۰ داده‌ها را نشان می‌دهد. توضیحات شکل ۹ هم مطابق شکل ۸ است.



شکل ۸: دقت حاصل از طبقه‌بندی ۸۰٪ از داده‌ها به عنوان داده‌های آموزشی



شکل ۹: دقت حاصل از طبقه‌بندی ۹۰٪ از داده‌ها به عنوان داده‌های آموزشی

۴-۲- مقایسه روش پیشنهادی با روش‌های قبلی

در جدول (۳) میزان دقت روش پیشنهادی با روش‌های قبلی ارائه شده است. در جدول (۳) میزان دقت روش پیشنهادی را با توجه به داده‌های جدول (۱) در مقایسه با سایر روش‌ها مشخص شده است که در اکثر موارد دقت بالایی دارد.

مراجع

- network, Signal, Image and Video Processing, Vol. 8, No. 7, pp. 1323-1334, 2012.
- [11] W. Weng and K. Khorasani, "An adaptive structure neural network with application to EEG automatic seizure detection," Trans. Biomed. Eng., vol. 44, no. 2, pp. 115-122, Feb. 1997.
- [12] Tzallas, A., Tsipouras, M., Fotiadis, D., Automatic seizure detection based on time-frequency analysis and artificial neural networks, Computational Intelligence and Neuroscience, 2007.
- [13] R. Dhiman and J. Saini, "Genetic algorithms tuned expert model for detection of epileptic seizures from EEG signatures," Applied Soft Computing, vol. 19, pp. 8-17, 2014.
- [14] G. Kiser, "Afriendly guide to wavelets," Department of Mathematics, University of Massachusetts, 1995.
- [15] B. E. Boser and I. Guyon, "A Training Algorithm for Optimal Margin Classifiers," in Proceedings of the Fifth Annual Workshop on Computational Learning Theory, Vol. 5, pp. 144-152, 1992.
- [16] V. Vapnik and A. Chervonenkis, "The necessary and sufficient conditions for consistency in the empirical riskminimization," Pattern Recognition and Image Analysis, vol. 1, no. 3, pp. 283-305, 1991.
- [17] www.meb.uni-bonn. de /epileptologie/ science/ physik/ eegdata.html.
- [18] R.G. Andrzejak, K. Lehnertz, F. Mormann, C. Rieke, P. David, and C.E. Elger, "Indications of nonlinear deterministic and finited imensional structures in timeseries of brain electrical activity: dependence on recordin region and brain state," Physical Review E, 64, 061907, 2001.
- [19] Torrence C, Compo GP (1998) a practical guide to wavelet analysis. Bulletin of the American Meteorological Society 79: 61-78.
- [20] Adeli H. Ghosh-DastidarS, Dadmehr (2007). A wavelet-chaos methodology for analysis of EEGs and EEG subbands to detect.
- [1] Yamaguchi, C. "Fourier and wavelet analyses of normal and epileptic electroencephalogram (EEG)." Neural Engineering, 2003. Conference Proceedings. First International IEEE EMBS Conference on 33(1): 305-312. 2003.
- [2] Nigam, V. P. and D. Graupe "A neural-networkbased detection of epilepsy." Neurological Research 26(1): 55-60. 2004.
- [3] Srinivasan, V., Eswaran, C., Sriraam, N., Artificial neural network based epileptic detection using time-domain and frequency-domain features, Journal of Medical Systems, Vol. 29, No. 6, pp: 647-660, 2005.
- [4] Kannathal, N., Choo, M.L., Acharya, U.R., Sadasivan, P. K., Entropies for detection of epilepsy in EEG, Computer Methods and Programs in Biomedicine, Vol. 80, No. 3, pp. 187-194, 2005.
- [5] Polat, K., Günes, S., Classification of epileptic form EEG using a hybrid system based on decision tree classifier and fast Fourier transform, Applied Mathematics and Computation, Vol. 187, No. 2, pp. 1017-1026, 2007.
- [6] Subasi, A., EEG signal classification using wavelet feature extraction and a mixture of expert model, Expert Systems with Applications, Vol. 32, No. 4, pp. 1084-1093, 2007.
- [7] Guo, L., Riveero, D., Pazaos, A., Epileptic seizure detection using multiwavelet transform based approximate entropy and artificial neural networks, Journal of Neuroscience Methods, Vol. 193, No. 1, pp. 156-163, 2010.
- [8] Mashakbeh, A.A."analysis electroencephalogram detect epilepsy" International Journal of Academic Research 2(3): 2010.
- [9] Nicolaou, N., Georgiou, J., Detection of epileptic electroencephalogram based on permutation entropy and support vector machine, Expert Systems with Applications, Vol. 39, No. 1, pp. 202-209, 2012.
- [10] Kumar, Y., Dewal, M. L., & Anand, R. S., Epileptic seizures detection in EEG using DWT-based ApEn and artificial neural

زیر نویس‌ها

¹Morlet
²complex conjugate
³maximum margin
⁴Sensitivity
⁵Accuracy
⁶Error Rate
⁷True Positives
⁸True Negatives
⁹False Positives
¹⁰False Negatives

¹Epilepsy
²Electroencephalography
³signal amplitude
⁴Global Wavelet Spectrum
⁵Support Vector Machine
⁶Entropy
⁷Multi-layer perceptron
⁸Genetics Algorithm
⁹Margin
¹⁰Continuous Wavelet Transform
¹¹marginal effects