

Identification of Attention Deficit Hyperactivity Disorder Patients Using Wavelet-Based Features of EEG Signals

Sahar Karimi Shahraki^{1,2}, M.Sc, Mahdi Khezri^{1,2}, Assistant Professor

¹Department of Electrical Engineering, Najafabad Branch, Islamic Azad University, Najafabad, Iran
²Digital Processing and Machine Vision Research Center, Najafabad Branch, Islamic Azad University, Najafabad, Iran

saharkarimi_1369@yahoo.com, mahdi.khezri@pel.iaun.ac.ir

Abstract:

Attention Deficit Hyperactivity Disorder (ADHD) is a neurological and psychiatric disorder which causes to attention deficit, anxiety, hyperactivity and impulsive behaviors. ADHD is more common in children and directly leads to their learning disability. The aim of this study was to accurately identify ADHD patients by using wavelet-based features of EEG signals. Recorded EEG signals from 61 children with ADHD (diagnosed according to the DSM-IV criteria) and 60 healthy controls in the age range of 7-12 years were used to design the system. In the proposed method by applying wavelet transform, EEG signals were decomposed into sub-bands. For the time version of the signals in each sub-band, the temporal and statistical features were calculated. The reduced feature set by principal component analysis (PCA) method was then used to train the classification unit to identify ADHD patients from healthy individuals. To obtain the desired results, different types of wavelet functions and decomposition levels were investigated. The bior3.1 wavelet function with the support vector machine (SVM) classifier and the rbio1.1 wavelet function with the k-nearest neighbor (kNN) classifier presented the best performance with the recognition accuracy of 98.33% and 99.17%, respectively. The SVM classification method with radial basis kernel function (RBF) and the kNN method with three nearest neighbors, $k = 3$ obtained the best results. The results obtained in this study compared to the results reported in previous studies showed at least a 2% improvement in the recognition accuracy of ADHD patients.


Keywords: ADHD, time domain features, wavelet transform, kNN classifier, SVM classifier

Received: 23 August 2020

Revised: 1 December 2020

Accepted: 17 April 2021

Corresponding Author: Dr Mahdi Khezri

 DOR: 20.1001.1.23223871.1400.12.3.1.1

مقاله پژوهشی

شناسایی بیماران نقص توجه-بیش فعال با استفاده از ویژگی‌های بر مبنای موجک سیگنال‌های EEG

سحر کریمی شهرکی^{۱،۲}، دانش‌آموخته کارشناسی‌ارشد، مهدی خضری^{۱،۲}، استادیار

۱- دانشکده مهندسی برق- واحد نجف‌آباد، دانشگاه آزاد اسلامی، نجف‌آباد، ایران

۲- مرکز تحقیقات پردازش دیجیتال و بینایی ماشین، واحد نجف‌آباد، دانشگاه آزاد اسلامی، نجف‌آباد، ایران
saharkarimi_1369@yahoo.com, mahdi.khezri@pel.iaun.ac.ir

چکیده: اختلال توجه-بیش فعالی (ADHD)، نوعی بیماری روانی توسعه عصبی است که باعث عدم توجه، اضطراب، بیش‌فعالی و رفتارهای تکانشگری فرد می‌شود. این بیماری بیشتر در کودکان دیده می‌شود و به‌طور مستقیم منجر به ناتوانی آن‌ها در یادگیری می‌شود. هدف این مطالعه، ارائه سیستمی به‌منظور شناسایی دقیق‌تر بیماران ADHD با استفاده از ویژگی‌های بر مبنای موجک سیگنال‌های مغزی (EEG) است. سیگنال‌های EEG ثبت شده از ۶۱ کودک ADHD (شناسایی شده بر مبنای معیار DSM-IV) و ۶۰ کودک سالم به‌عنوان گروه کنترل در محدوده سنی ۷ الی ۱۲ سال برای طراحی سیستم مورد استفاده قرار گرفتند. در روش پیشنهادی، سیگنال‌های EEG با اعمال تبدیل موجک به زیرباندهایی تجزیه شدند؛ و برای نسخه زمانی سیگنال‌ها در هر زیرباند، ویژگی‌های زمانی و آماری محاسبه شدند. مجموعه ویژگی کاهش یافته با روش تحلیل مولفه اصلی (PCA) سپس برای آموزش واحد طبقه‌بندی به‌منظور شناسایی بیماران ADHD از افراد سالم به‌کار رفت. برای کسب نتایج مطلوب، انواع مختلف توابع موجک و سطوح تجزیه مورد بررسی قرار گرفتند. تابع موجک bio3.1 با روش طبقه‌بندی ماشین بردار پشتیبان (SVM) و تابع موجک rbio1.1 با روش طبقه‌بندی k نزدیک‌ترین همسایه (kNN) با کسب دقت‌های شناسایی به‌ترتیب ۹۸/۳۳ و ۹۹/۱۷ درصد، بهترین عملکرد را ارائه کردند. روش طبقه‌بندی SVM با تابع کرنل پایه شعاعی (RBF) و روش kNN با تعداد سه نزدیک‌ترین همسایگی $k=3$ ، بهترین نتایج را کسب کردند. نتایج به‌دست آمده در این مطالعه، در مقایسه با نتایج گزارش شده در مطالعات قبلی حداقل ۲ درصد بهبود در دقت شناسایی بیماران ADHD را نشان می‌دهند.

کلمات کلیدی: نقص توجه-بیش فعال، ویژگی‌های زمانی، تبدیل موجک، طبقه‌بند SVM، طبقه‌بند kNN.

تاریخ ارسال مقاله: ۱۳۹۹/۶/۲

تاریخ بازنگری مقاله: ۱۳۹۹/۹/۱۱

تاریخ پذیرش مقاله: ۱۴۰۰/۱/۲۸

نام نویسنده مسئول: دکتر مهدی خضری

نشانی نویسنده مسئول: نجف‌آباد- بلوار دانشگاه- دانشگاه آزاد اسلامی واحد نجف‌آباد- دانشکده مهندسی برق

۱- مقدمه

بیش‌فعالی همراه با نقص توجه یکی از شایع‌ترین اختلالات روانی در کودکان است که به اختصار ADHD (اختلال بیش‌فعالی با کمبود توجه)^۱ نامیده می‌شود. این بیماری شامل ترکیبی از اختلالات در حفظ توجه، بیش‌فعالی و رفتارهای ناگهانی است. کودکان بیش‌فعال ممکن است دچار اضطراب، مشکلات یادگیری، تحریک‌پذیری و هم‌چنین اختلال در برقراری ارتباط با دیگران و عملکرد ضعیف در مدرسه شوند [۱]. روش‌هایی به‌منظور پیش‌گیری از شدت بیماری و درمان کودکان مبتلا در نظر گرفته می‌شوند که از آن جمله می‌توان به آموزش والدین و معلمان، درمان دارویی و درمان‌های روان‌شناختی و نوروفیدبک اشاره کرد [۲،۳]. از هر صد کودک، معمولاً پنج نفر به ADHD مبتلا می‌شوند. پزشکان معتقدند افراد مبتلا به ADHD فاقد میزان کافی از مواد شیمیایی ویژه تحت عنوان میانجی‌های عصبی در مغز هستند. این مواد شیمیایی به مغز در کنترل رفتار فرد کمک می‌کنند. با توجه به دستورالعمل تشخیصی و آماری اختلالات روانی^۲ (DSM-IV)، بیماری ADHD در سه گروه تقسیم بندی شده است. نوع اول که بیماری علایم ظاهری مشخصی ندارد و به اصطلاح به مبتلایان، بی‌دقت گفته می‌شود. در این نوع از بیماری، کودک نمی‌تواند روی تکلیفی که به او می‌دهند و یا یک فعالیت خاص تمرکز داشته باشد. بیشتر کودکان مبتلا به ADHD در دقت و توجه کردن دچار مشکل هستند. در نوع دوم که تکانشگری-بیش‌فعالی است، کودک بسیار فعال است و بدون فکر کردن اقدام به فعالیت و انجام کار می‌کند. فعالیت بیش از حد، قابل توجه ترین مشخصه این حالت است. در نوع سوم بیماری، ترکیب این دو حالت وجود دارد و کودکان نشانه‌هایی از هر دو نوع قبل را دارند. آن‌ها در توجه کردن و کنترل فعالیت‌های خود دچار مشکل هستند [۴].

تاکنون تلاش‌های زیادی برای تشخیص و سپس درمان ADHD صورت گرفته است. در افراد مبتلا به ADHD، تغییراتی در فعالیت مغز به‌ویژه در لوب پیشانی ایجاد می‌شود. کارکرد لوب پیشانی به فرد اجازه می‌دهد که به چیزی توجه و تمرکز کند، هیجانانش را کنترل کند، برای امور خود برنامه‌ریزی کند و رفتارهای خود را سازماندهی و تنظیم کند. برانگیختگی در لوب پیشانی، کارکردهای اجرایی را دچار مشکل می‌کند و به‌ویژه توانایی فرد را در توجه، تمرکز و بازداری هیجانان تحت تأثیر قرار می‌دهد. به این دلیل ثبت فعالیت مغز به وسیله سیگنال الکتروانسفالوگرم^۳ (EEG) برای ارزیابی اختلالات ADHD مورد توجه قرار می‌گیرد. برای درمان این بیماری به‌طور معمول تجویز دارو مدنظر قرار می‌گیرد. اما استفاده از دارو به‌دلیل داشتن عوارضی چون تأثیر منفی بر روی سیستم قلبی-عروقی و هم‌چنین نداشتن تضمین صددرصدی برای درمان، چندان رضایت‌بخش نیست. نوروفیدبک یکی از درمان‌های رایج برای بیماری ADHD است که در آن فعالیت‌های مغزی در جلسات مختلف درمان معمولاً با استفاده از سیگنال EEG مورد ارزیابی قرار می‌گیرد. در واقع نوروفیدبک یا بازخورد عصبی، آموزش و تنظیم فعالیت‌های مغزی است که از طریق اعمال تحریکاتی برای فرد ایجاد می‌شود. در این روش الکترودهایی بر روی سطح جمجمه قرار می‌گیرند و فعالیت الکتریکی مغز بیمار را ثبت می‌کنند. به‌طور هم‌زمان تحریکاتی به‌صورت پخش موسیقی، نمایش تصاویر، فیلم یا قطعه‌های ویدیویی و یا انجام بازی‌های رایانه‌ای، به فرد ارائه می‌شوند تا روند فعالیت سلول‌های مغزی به‌طور مطلوب تغییر کنند [۵،۶]. سیگنال EEG درحوزه زمان، سیگنالی با تغییرات زیاد و دامنه ضعیف است. به‌همین دلیل با توجه به ماهیت غیرایستای EEG، تحلیل آن درحوزه زمان مورد توجه قرار نمی‌گیرد؛ بلکه اطلاعات سیگنال درحوزه تبدیل (فرکانس، زمان-فرکانس) معمولاً به‌کار گرفته می‌شوند [۷،۸]. اطلاعات فرکانسی سیگنال EEG برحسب کارکرد مغز به پنج زیربند دسته‌بندی می‌شوند [۹،۱۰]. این امواج شامل: دلتا (۴-۵/۰ هرتز)، تتا (۴-۷ هرتز)، آلفا (۸-۱۲ هرتز)، بتا (۱۳-۳۹ هرتز) و گاما (۳۹-۶۰ هرتز) هستند [۱۱،۱۲]. در افراد مبتلا به اختلالات ADHD افزایش غیرطبیعی دامنه موج تتا و کاهش دامنه امواج بتا مشاهده شده است؛ همین امر باعث ناتوانی در یادگیری و عدم تمرکز در این بیماران می‌شود [۱۳].

به‌منظور شناسایی بیماران ADHD تاکنون مطالعات بسیاری صورت گرفته است [۱۴]. در مطالعه سرکوئرا و همکارانش چهار ویژگی غیرخطی سیگنال EEG شامل: بزرگترین توان لیاپانوف^۴ (LLE)، بعد همبستگی، پیچیدگی لیمپل-زیو^۵ (LZC) و توان هرست به‌منظور تعیین اثر نوروفیدبک اعمال شده مورد بررسی قرار گرفتند [۱۵]. طبقه‌بندی افراد سالم و بیمار و هم‌چنین شناسایی افرادی که به درمان به‌طور مطلوب پاسخ می‌دهند، از اهداف این مطالعه بود. نتایج به‌دست آمده، افزایش توان لیاپانوف و کاهش توان هرست و پیچیدگی لیمپل-زیو را پس از اعمال نوروفیدبک در بعضی از کانال‌ها نشان دادند. وانگ و سورینا

روشی نوین تحت عنوان طیف بعد فرکتال هیگوجی تعمیم یافته^۶ (GHFDS) برای تحلیل سیگنال‌های EEG در طبقه‌بندی فعالیت‌های ذهنی ارائه کردند [۱۶]. روش هیگوجی برای تعیین میزان آشفتگی سیگنال‌ها مثل سیگنال‌های پزشکی، از روی سری‌های زمانی آن‌ها به کار می‌رود. هم‌چنین ویژگی‌های دیگری مثل ضرایب مدل خود بازگشتی^۷ (AR)، چگالی طیف توان^۸ (PSD) و ویژگی‌های آماری سیگنال نیز مورد استفاده قرار گرفتند. در این مطالعه، استفاده از ویژگی آشوبی پیشنهاد شده در ترکیب با سایر ویژگی‌ها بهترین عملکرد را در شناسایی عملکرد ذهنی فرد به دست آورد. این آزمایش بر روی ۱۰ نفر در رده سنی ۲۲ تا ۳۰ سال انجام شد و حالت آرامش و فعالیت ذهنی در حین محاسبات ریاضی مورد توجه قرار گرفت. از ماشین بردار پشتیبان^۹ (SVM) با تابع کرنل پایه شعاعی^{۱۰} (RBF) برای طبقه‌بندی فعالیت‌های ذهنی استفاده شد و دقت متوسط برابر با ۹۷/۱۴ درصد به دست آمد. هم‌چنین نتایج به دست آمده نشان داد مقدار بعد فرکتال^{۱۱} (FD) در لوب پیشانی و در کانال F8 در حالت فعالیت ذهنی بیشتر از حالت استراحت است.

در مطالعه‌ی وحید و همکارانش، امکان تشخیص بیماران ADHD از افراد سالم با اعمال الگوهای سیگنال EEG مورد توجه قرار گرفت [۱۷]. با استفاده از یک الگوریتم یادگیری عمیق تحت عنوان EEGNet، دقت تشخیص ۸۳ درصد برای شناسایی بیماران و هم‌چنین انواع بیماری به دست آمد. EEGNet شامل دو بلوک است که در بلوک اول با اعمال فیلترهای کانولوشنی نقشه‌های ویژگی زمانی سیگنال‌ها محاسبه می‌شوند و سپس در بلوک دوم برای هر نقشه ویژگی زمانی، فیلترهای مکانی برای همه کانال‌های EEG اعمال می‌شوند. ۱۴۴ کودک در آزمایش شرکت کردند که ۱۰۰ نفر آن‌ها بیمار ADHD بودند. شرکت‌کنندگان در آزمایش در معرض یک تحریک بصری قرار گرفتند. آن‌ها باید زمان ۱۲۰۰ میلی ثانیه پس از نمایش تصویر (دایره سفید در یک پس زمینه سیاه) را تخمین می‌زدند. به این منظور باید موقعی که فکر می‌کردند زمان موردنظر سپری شده کلیدی را فشار می‌دادند. پاسخ‌های بین ۱۰۰۰ تا ۱۴۰۰ میلی ثانیه به‌عنوان درست در نظر گرفته می‌شدند. آزمایش شامل ۳۰۰ تلاش بود و به‌طور هم‌زمان سیگنال‌های EEG ثبت می‌شدند. در مطالعه محمدی و همکارانش، طبقه‌بندی کودکان ADHD و سالم با استفاده از ویژگی‌های غیرخطی سیگنال EEG مورد توجه قرار گرفت [۱۸]. ۳۰ کودک ADHD با همین تعداد کودکان سالم در آزمایش شرکت کردند. ویژگی‌های بعد فرکتال، توان لیاپانوف و آنتروپی تقریب به‌عنوان ویژگی‌های سیگنال EEG محاسبه شدند. به‌منظور بهبود نتایج طبقه‌بندی، روش‌های رابطه تقارن ورودی دوگانه^{۱۲} (DISR) و بیشترین ارتباط، کمترین افزونگی^{۱۳} (mRMR) برای انتخاب ویژگی‌های مؤثرتر به کار گرفته شدند. در این مطالعه شبکه عصبی پرسپترون چند لایه^{۱۴} (MLP) به عنوان طبقه‌بندی‌کننده مورد استفاده قرار گرفت. مطابق انتظار، کودکان ADHD تأخیر بیشتر و دقت کمتر در انجام اعمال شناختی داشتند. هم‌چنین ویژگی‌های مورد استفاده نشان دادند که شاخص غیرخطی بودن ویژگی‌های کودکان ADHD در نقاط مختلف مغز در مقایسه با افراد سالم بیشتر بود. در نهایت دقت‌های طبقه‌بندی ۹۲/۲۸ درصد و ۹۳/۶۵ درصد به ترتیب با اعمال روش‌های mRMR و DISR به دست آمدند. الچلابی و همکارانش از بازی‌های فکری به‌عنوان تحریک برای بررسی عملکرد شناختی کودکان ADHD و سالم و تشخیص آن‌ها از یکدیگر استفاده کردند [۱۹]. در واقع هدف این مطالعه طراحی یک بازی فکری کنترل شده با EEG به‌منظور آموزش و تقویت سطح توجه افراد شرکت‌کننده و هم‌چنین استفاده از روش‌های یادگیری ماشین برای آشکارسازی سطح توجه آن‌ها بود. ویژگی‌هایی شامل توان‌های آلفا، بتای پایین، بتای بالا، تتا، گاما، نسبت تتا به بتای پایین، نسبت تتا به بتای بالا، نسبت آلفا به بتای بالا و نسبت آلفا به بتای پایین به‌همراه طبقه‌بندی‌کننده SVM برای طراحی سیستم در شناسایی میزان توجه و بیماران ADHD از افراد سالم به کار رفتند. با استفاده از کرنل RBF بهترین دقت سیستم در شناسایی افراد بیمار از سالم برابر ۹۸/۶۲ درصد به دست آمد. در مطالعه خانم کیانی و همکارانش، استفاده از ویژگی‌های غیرخطی سیگنال EEG با هدف آشکارسازی شاخص‌های آشوبی سیگنال مورد توجه قرار گرفت [۲۰]. توان لیاپانوف، بعد فرکتال، بعد همبستگی و آنتروپی‌های فازی و تقریب به‌عنوان ویژگی‌های غیرخطی سیگنال‌های EEG که از لوب پیشانی ثبت شده بودند، به کار گرفته شدند. سیگنال‌ها از ۵۰ بیمار ADHD و ۲۶ فرد نرمال در محدوده سنی ۴ تا ۱۵ سال، جمع‌آوری شدند. با استفاده از تابع کرنل چند جمله‌ای برای طبقه‌بندی‌کننده SVM، دقت تشخیص ۹۶/۰۵ درصد برای شناسایی بیماران ADHD از افراد سالم به دست آمد. هم‌چنین در مطالعه‌ای چن و همکارانش سیستم شناسایی بیماران ADHD را بر مبنای الگوریتم یادگیری عمیق طراحی کردند [۲۱]. به این منظور از ترکیب یک شبکه مغزی مبتنی بر EEG با

شبکه عصبی کانولوشنی^{۱۵} (CNN) استفاده کردند. با سازماندهی مجدد ترتیب کانال‌ها، فرم جدیدی از ماتریس اتصال برای تطبیق با مفهوم کانولوشن در روش CNN ارائه شد. سیگنال‌های EEG از ۵۰ کودک مبتلا به ADHD شامل ۹ دختر با میانگین سنی $10/44 \pm 0/75$ و تعداد ۵۱ فرد سالم به عنوان گروه کنترل ثبت شدند. روش پیشنهادی در این مطالعه دقت $94/67$ درصد را در شناسایی بیماران از افراد سالم به دست آورد. هدفه ویژگی عمیق تفاوت‌های معنی‌دار بین گروهی را نشان دادند. به علاوه این ویژگی‌ها با ویژگی‌های استخراج شده دستی، همبستگی معنی‌داری داشتند. این امر توانایی روش یادگیری عمیق را برای یافتن انحراف در شبکه مغزی کودکان مبتلا به ADHD نشان می‌دهد.

در مطالعه حاضر، هدف این است که با استفاده از الگوهای سیگنال EEG به‌طور دقیق‌تری بیماران ADHD شناسایی شوند. ضمن اینکه سعی شده سیستم موردنظر تا حد ممکن با پیچیدگی کم پیاده‌سازی شود و قادر به تولید پاسخ‌های سریع باشد. در طراحی سیستم از ویژگی‌های بر مبنای تبدیل موجک سیگنال EEG با قابلیت تولید اطلاعات بالا در کنار طبقه‌بندی‌کننده‌هایی با عملکرد مطلوب و پیچیدگی محاسباتی به‌طور نسبی کم بهره می‌گیریم. استفاده از ویژگی‌های زمان-فرکانس استخراج شده با تبدیل موجک می‌تواند با فراهم کردن اطلاعات بالاتر در مورد سیگنال‌ها، دقت تشخیص سیستم را افزایش دهد. به‌عنوان هدف دیگر با مقایسه ویژگی‌های استخراج شده برای افراد بیمار و سالم، شناسایی ویژگی‌های با اهمیت که روند مشابهی برای همه افراد داشته‌اند را مدنظر قرار دادیم. این ویژگی‌ها می‌توانند در تعیین روند بهبود بیماران ADHD پس از اعمال فرایند درمان و بررسی سودمندی آن مفید باشند. در ادامه در بخش دوم روش‌های مورد استفاده در طراحی سیستم را معرفی می‌کنیم. هم-چنین بخش‌های سه و چهار به ارایه نتایج، ارزیابی عملکرد سیستم و نتیجه‌گیری اختصاص خواهند داشت.

۲- مواد و روش‌ها

۲-۱- آماده‌سازی و پیش پردازش سیگنال‌ها

در این مطالعه از داده‌های ثبت شده و استفاده شده توسط آقای محمدی و همکاران‌شان بهره گرفته شده است [۱۸]. شرکت-کنندگان در آزمایش ۶۱ کودک مبتلا به ADHD و ۶۰ کودک سالم به‌عنوان گروه کنترل (دختر و پسر با محدوده سنی ۷-۱۲ سال) هستند. کودکان ADHD توسط یک روانپزشک با توجه به معیارهای DSM-IV تشخیص داده شدند. هیچ‌کدام از کودکان گروه کنترل سابقه اختلالات روانپزشکی، صرع و یا گزارشی از رفتارهای پرخطر را نداشتند. ثبت سیگنال‌های EEG بر اساس استاندارد ۲۰-۱۰ در ۱۹ کانال (O2 و O1, T6, T5, P4, P3, F8, F7, F4, F3, Fp2, Fp1, T4, C4, T3, C3, Pz, Cz, Fz) با فرکانس نمونه‌برداری ۱۲۸ هرتز انجام شده است. الکترودهای A1 و A2 الکترودهای مرجع هستند که بر روی لاله گوش نصب شدند. حرکات چشم توسط دو الکتروده که در زیر و بالای چشم راست قرار گرفته بودند، ثبت شدند. با توجه به این که یکی از اختلالات کودکان ADHD توجه بصری است، ثبت EEG براساس بررسی توجه بصری با نمایش مجموعه‌ای از تصاویر شخصیت‌های کارتونی به کودکان انجام شد؛ و از آن‌ها خواسته شد تا تعداد شخصیت‌ها را در هر تصویر مشخص کنند. تعداد شخصیت‌های هر تصویر به‌طور تصادفی بین ۵ تا ۱۶ انتخاب شده بود و مدت زمان ثبت سیگنال‌های EEG به عملکرد کودک در ارایه پاسخ‌ها بستگی داشت. سیگنال‌ها توسط یک دستگاه دیجیتالی (SD-C24) در مرکز تحقیقات روانشناسی و روانپزشکی بیمارستان روزبه (تهران، ایران) ثبت شد. فرایند ثبت توسط هیئت بازنگری^{۱۶} (IRB) و کمیته اخلاق دانشگاه علوم پزشکی تهران^{۱۷} (TUMS) تأیید شده است.

والدین همه شرکت‌کنندگان فرم رضایت آگاهانه را برای شرکت فرزندان‌شان در آزمایش‌ها مطالعه و امضا کرده بودند. به‌منظور حذف نویزها و اثرات تداخلی و هم‌چنین جدا کردن مولفه‌های فرکانسی موردنظر در زیرباندهای تتا، آلفا، بتا و گاما از یک فیلتر باترورت با مرتبه ۱۰ به‌صورت میان‌گذر با محدوده فرکانسی ۴۵-۳ هرتز استفاده کردیم. هم‌چنین به‌منظور کاهش تغییرات و ایجاد شرایط ایستایی، سیگنال‌ها به بخش‌هایی با طول زمانی ده ثانیه تقسیم شدند.

۲-۲- استخراج ویژگی

برای استخراج ویژگی‌ها، ابتدا با استفاده از تبدیل موجک گسسته^{۱۸} (DWT) سیگنال‌های EEG به زیرباندی تجزیه می‌شوند. برای سطح تجزیه اول، سیگنال $x(k)$ از فیلترهای بالاگذر و پایین‌گذر یعنی $h(\cdot)$ و $g(\cdot)$ عبور می‌کند. خروجی هر سطح تجزیه z به شکل دو سیگنال با ضرایب A_z و D_z نشان داده می‌شوند؛ که به ترتیب به نام ضرایب تقریب و جزئیات شناخته می‌شوند. این توابع با روابط زیر تعیین می‌شوند [۲۲]:

$$D_j[i] = \sum_k x[k]h[2i-k] \quad (1)$$

$$A_j[i] = \sum_k x[k]g[2i-k] \quad (2)$$

فرایند ذکر شده بر روی ضرایب تقریب A_z تا زمانی تکرار می‌شود که z سبب کاهش j_m (سطح تجزیه سیگنال موردنظر) نشود. پس از اعمال تبدیل موجک گسسته، ویژگی‌های زمانی و آماری برای ضرایب موجک به دست آمده در سطوح مختلف محاسبه می‌شوند. در صورتی که $x(n)$ سیگنال موردنظر برای $n = 1, 2, \dots, N$ باشد، خواهیم داشت:

میانگین سیگنال: میانگین یا متوسط مقادیر دامنه سیگنال با رابطه زیر تعیین می‌شود [۲۳]:

$$\mu_x = \frac{1}{N} \sum_{n=1}^N x(n) \quad (3)$$

واریانس: واریانس یا جذر آن، انحراف استاندارد، معیاری است که محدوده تغییرات دامنه سیگنال را و اینکه داده‌ها به چه صورت حول میانگین پراکنده شده‌اند، نشان می‌دهد. واریانس هم‌چنین معیاری از توان سیگنال مورد استفاده است [۲۳].

$$\sigma_x = \sqrt{\frac{1}{N} \sum_{n=1}^N (x(n) - \mu_x)^2} \quad (4)$$

میانگین قدرمطلق^{۱۹} (MAV) [۲۳]:

$$\overline{\mu x_i} = \frac{1}{N} \sum_{n=1}^N |x(n)| \quad \text{for } i = 1, \dots, I-1 \quad (5)$$

شیب میانگین قدرمطلق^{۲۰} (MAVSLP): این ویژگی از تفاضل مقادیر میانگین قدرمطلق دو بخش همسایه با i و $i+1$ نمونه به دست می‌آید [۲۳].

$$\Delta \overline{\mu x_i} = \overline{\mu x_{i+1}} - \overline{\mu x_i} \quad \text{for } i = 1, \dots, I-1 \quad (6)$$

عبور از صفر^{۲۱} (ZC): تعداد دفعاتی است که سیگنال مقدار صفر به خود می‌گیرد یا شکل موج سیگنال از مقدار صفر عبور می‌کند. به منظور کاهش عبور از صفر ایجاد شده به وسیله نویزها، یک سطح آستانه باید در نظر گرفته شود. برای دو نمونه متوالی و طبق رابطه زیر مقدار عبور از صفر افزایش پیدا می‌کند اگر:

$$\text{sgn}(-x_k \times x_{k+1}) \text{ and } (|x_k - x_{k+1}| \geq \text{threshold}) \quad (7)$$

اگر $x > 0$ باشد آنگاه $\text{sgn}(x)$ در رابطه برابر ۱ می‌شود و در بقیه نقاط برابر صفر است [۲۳].

تغییرات علامت شیب^{۲۲} (SSC): افزایش تغییرات علامت شیب برای سه نمونه متوالی x_{k+1} ، x_k ، x_{k-1} به صورت زیر است. در این رابطه $k = 1, \dots, N$ در نظر گرفته می‌شود [۲۳].

$$(x_k - x_{k-1}) \times (x_k - x_{k+1}) \geq \text{threshold} \quad (8)$$

میانگین قدرمطلق اولین تفاضل سیگنال^{۲۳} (MAVFD) [۲۴]: این ویژگی میانگین تفاضل دو مقدار متوالی سیگنال را محاسبه می‌کند و می‌تواند به عنوان معیاری از نوسانات کلی سیگنال در نظر گرفته شود.

$$\delta_x = \frac{1}{N-1} \sum_{n=1}^{N-1} |x(n+1) - x(n)| \quad (9)$$

میانگین قدرمطلق دومین تفاضل سیگنال^{۲۴} (MAVSD) [۲۴]:

$$\gamma_x = \frac{1}{N-2} \sum_{n=1}^{N-2} |x(n+2) - x(n)| \quad (10)$$

مقدار میانگین قدرمطلق از اولین تفاضل سیگنال استاندارد شده^{۲۵} (MAVFDS) [۲۴]: سیگنال استاندارد یا بهنجار شده به صورت $\bar{x}(n) = (x(n) - \mu_x) / \sigma_x$ تعریف می‌شود [۱۹]. این شکل از تعریف سیگنال استاندارد شده، تغییرات سیگنال بین نمونه‌های اخذ شده از نفرات مختلف و اثرات نویزهای مختلف را به کمترین مقدار می‌رساند.

$$\bar{\delta}_x = \frac{1}{N-1} \sum_{n=1}^{N-1} |\bar{x}(n+1) - \bar{x}(n)| = \frac{\delta_x}{\sigma_x} \quad (11)$$

مقدار میانگین قدرمطلق از دومین تفاضل سیگنال استاندارد شده^{۲۶} (MAVSDS) [۲۴]:

$$\bar{\gamma}_x = \frac{1}{N-2} \sum_{n=1}^{N-2} |\bar{x}(n+2) - \bar{x}(n)| = \frac{\gamma_x}{\sigma_x} \quad (12)$$

مدل خودبازگشتی (AR): با در نظر گرفتن $x(n)$ به عنوان یک سیگنال تصادفی و ورودی $u(n)$ ، رابطه مدل خودبازگشتی به صورت زیر تعریف می‌شود [۲۳]:

$$x(n) = -\sum_{k=1}^p a(k) * x(n-k) + u(n) \quad (13)$$

۲-۳- طبقه‌بندی

پس از استخراج ویژگی‌ها، به منظور بهبود عملکرد سیستم، استفاده از ویژگی‌های مؤثرتر و حذف ویژگی‌های نامطلوب، از روش تحلیل مؤلفه اصلی^{۲۷} (PCA) استفاده می‌کنیم. روش PCA یکی از روش‌های پرکاربرد در کاهش ابعاد مجموعه ویژگی-هاست. هدف روش PCA تبدیل مجموعه داده‌ها به مجموعه‌ای با ابعاد کمتر است؛ به گونه‌ای که داده‌ها در فضای جدید واریانس بالاتری داشته باشند [۲۲]. در این روش ماتریس کواریانس یا همبستگی از روی مجموعه داده‌های ورودی تعیین می‌شوند. سپس k تا از بردارهای ویژه متناظر با k بزرگترین مقدار ویژه ماتریس کواریانس (یا همبستگی) تعیین می‌شوند. ماتریس تبدیل با توجه به بردارهای ویژه انتخاب شده ساخته شده و با اعمال بر مجموعه داده ورودی، ابعاد آن را به k کاهش می‌دهد. در ارزیابی انجام شده در این مطالعه، انتخاب ۵ مقدار ویژه بزرگتر منجر به کسب نتایج مطلوب‌تر و دقت بالاتر در شناسایی بیماران از افراد سالم شد. با انتخاب ویژگی‌ها، روش‌های طبقه‌بندی SVM و k نزدیک‌ترین همسایه^{۲۸} (kNN) به منظور شناسایی بیماران ADHD از افراد سالم به کار گرفته می‌شوند.

ماشین بردار پشتیبان (SVM): این روش سعی در ایجاد یک صفحه جداکننده به گونه‌ای دارد که فاصله بین داده‌های کلاس‌های مختلف بیشینه شود. برای یک مجموعه آموزشی مفروض با زوج ورودی و خروجی (x_i, y_i) که $x_i \in \mathbb{R}^n$ با $i = 1, 2, \dots, l$ و $y \in \{1, -1\}^l$ ، مسأله بهینه‌سازی زیر باید حل شود [۲۵]:

$$\min_{\omega, b, \xi} \frac{1}{2} \omega^T \omega + c \sum_{i=1}^l \xi_i \quad (14)$$

$$y_i (\omega^T \phi(x_i) + b) \geq 1 - \xi_i \quad \text{به شرط} \quad (15)$$

$\xi_i \geq 0$ مقدار خطا یا طبقه‌بندی نادرست x_i را اندازه گیری می‌کند. $C > 0$ پارامتر جبران‌کننده برای بخش خطاست و ω ، بردار نرمال صفحه جداکننده است. تابع ϕ ، بردار آموزشی x_i را به فضایی با ابعاد بالاتر نگاشت می‌کند که داده‌ها در آنجا قابل جداسازی هستند. در واقع SVM یک صفحه جداکننده خطی با بیشترین مرز را تعیین می‌کند. توابع کرنل متعددی به فرم کلی $k(x_i, x_j) \equiv \phi(x_i)^T \phi(x_j)$ وجود دارند که برای طبقه‌بندی و ایجاد تمایز ما بین داده‌ها به کار برده می‌شوند. تابع کرنل RBF که در این مطالعه مورد استفاده قرار گرفته است، به صورت زیر تعریف می‌شود:

$$k(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{2\sigma^2}\right)^p \quad (16)$$

K نزدیک‌ترین همسایه (kNN): یک داده نمونه در بین k تا از نزدیکترین همسایه‌هایش به کلاسی که تعداد نمونه بیشتری داشته باشد، طبقه‌بندی می‌شود [۲۴]. معیار فاصله اقلیدسی که با رابطه زیر تعریف می‌شود، در سیستم ما مورد استفاده قرار می‌گیرد. x_1^1 و x_1^2 به ترتیب ویژگی نام از کلاس‌های اول و دوم هستند.

$$d = \sqrt{\sum_{i=1}^n (x_i^1 - x_i^2)^2} \quad (۱۷)$$

برای پیاده سازی روش kNN، ابتدا پارامتر k تعیین شده و محاسبه فاصله نمونه‌ی ورودی با تمام نمونه‌های آموزشی انجام می‌شود. سپس با مرتب کردن نمونه‌های آموزشی براساس معیار فاصله، k همسایه نزدیک‌تر مشخص می‌شوند. در نهایت کلاسی که اکثریت را در بین k همسایه‌ی نزدیک دارد، به‌عنوان کلاس نمونه ورودی در نظر گرفته می‌شود.

۳- نتایج

در این مطالعه هدف ارایه سیستمی هوشمند به‌منظور شناسایی دقیق و تا حد ممکن سریع بیماران ADHD است. در این راستا استفاده از ویژگی‌های سیگنال EEG استخراج شده از زیرباندهای مختلف سیگنال، مورد توجه قرار گرفت. سیگنال‌های EEG با استفاده از تبدیل موجک برحسب سطح تجزیه انتخاب شده، به زیرباندهایی تجزیه شدند. سپس برای سیگنال زمانی به‌دست آمده در هریک از زیرباندها، ویژگی‌های آماری و زمانی با قابلیت محاسبه سریع تعیین شدند. تبدیل موجک با اعمال موجک-های مادر و سطوح تجزیه مختلف مورد استفاده و ارزیابی قرار گرفت. با محاسبه ویژگی‌ها، به‌منظور کاهش ابعاد مجموعه ویژگی تشکیل‌شده و بهبود سرعت پاسخ‌دهی سیستم، روش تحلیل مؤلفه اصلی (PCA) به‌کار گرفته شد. ویژگی‌های انتخاب شده سپس به روش طبقه‌بندی مورد نظر اعمال شدند تا افراد با اختلال ADHD تشخیص داده شوند. عملکرد طبقه‌بندی‌کننده با معیارهای دقت (Accuracy)، حساسیت (Sensitivity) و معین‌پذیری (Specificity) که با روابط زیر تعریف می‌شوند، ارزیابی شدند [۲۰]:

$$\text{Accuracy} = \frac{TP + TN}{TP + FN + FP + TN} \quad (۱۸)$$

$$\text{Sensitivity} = \frac{TP}{TP + FN} \quad (۱۹)$$

$$\text{Specificity} = \frac{TN}{TN + FP} \quad (۲۰)$$

در روابط بالا، TP بیانگر حالت مثبت حقیقی^{۲۹}، TN منفی حقیقی^{۳۰}، FP مثبت کاذب^{۳۱} و FN بیانگر منفی کاذب^{۳۲} هستند. TP مربوط به زمانی است که فرد بیمار به‌درستی بیمار تشخیص داده شده است. در TN فرد سالم به‌درستی سالم تشخیص داده شده است. در مورد FN، در فرد بیماری وجود دارد اما به‌طور اشتباه فرد سالم و بدون بیماری تشخیص داده شده است. در حالت FP بیماری در فرد وجود ندارد، اما او به‌اشتباه بیمار تشخیص داده شده است. در پیاده‌سازی طبقه‌بندی‌کننده SVM به‌دلیل پیچیدگی داده‌های ورودی، از کرنل‌های غیرخطی رایج مثل RBF، MLP و چندجمله‌ای استفاده کردیم. هم‌چنین پارامترهای روش مثل پارامتر خطا و جبران‌کننده، با روش جستجوی شبکه تعیین شدند. برای طبقه‌بندی‌کننده kNN مقادیر متنوعی از پارامتر تعداد همسایگی یعنی k ، مورد ارزیابی قرار گرفت. برای آموزش طبقه‌بندی‌کننده‌ها روش یک نمونه بیرون^{۳۳} LOO به‌عنوان روش اعتبارسنجی به‌کار گرفته شد. هدف استفاده از روش اعتبارسنجی آن است که تمام ویژگی‌های ورودی هرکدام یک بار به‌عنوان داده تست مورد ارزیابی قرار بگیرند.

با استفاده از انواع موجک‌های مادر در سطوح تجزیه مختلف، عملکرد سیستم با تعیین میزان دقت، حساسیت و معین‌پذیری مورد بررسی قرار گرفت. تجزیه سیگنال‌ها در دو و سه سطح منجر به کسب دقت بالاتری در شناسایی اختلال ADHD شد. هم-چنین روش طبقه‌بندی SVM، با کرنل RBF و روش kNN با تعداد همسایگی $k=3$ و $k=5$ عملکرد بهتری ارایه کردند. موجک بای ارتوگونال معکوس^{۳۴} (rbio3.1) در سطح تجزیه ۲ با طبقه‌بند SVM، دقت شناسایی ۹۸/۳۳ درصد را در تشخیص بیماران

ADHD به دست آورد. جدول (۱) نتایج کسب شده توسط بهترین توابع موجک در هر خانواده از موجکها را با استفاده از طبقه‌بندی‌کننده SVM ارائه می‌کند.

همچنین طبقه‌بندی‌کننده kNN با استفاده از معیار فاصله اقلیدسی و برحسب تعداد نزدیک‌ترین همسایه‌های مختلف (پارامتر k)، پیاده‌سازی شد. با توجه به نتایج به دست آمده، موجک بای ارتوگونال (Bior1.1) در سطح تجزیه ۲ با مقدار $k=3$ برای طبقه‌بندی‌کننده kNN بالاترین دقت به میزان ۹۹/۱۶۷ درصد را به دست آورد. جدول (۲) نتایج کسب شده توسط بهترین توابع موجک در هر خانواده از موجکها را با استفاده از طبقه‌بندی‌کننده kNN ارائه می‌کند. سیستم طراحی شده در این مطالعه در مقایسه با مطالعات گذشته ضمن کاهش پیچیدگی محاسباتی، عملکرد مطلوبی به لحاظ دقت شناسایی ارائه کرده است. هم-چنین استفاده از ویژگی‌های زمانی و روش‌های طبقه‌بندی که به لحاظ محاسباتی پیچیدگی بالایی ندارند، منجر به ارائه پاسخ‌های سریع‌تری می‌شود.

Table (1): The best results in identifying ADHD disorder using different types of mother wavelets and decomposition levels and SVM classifier with RBF kernel

جدول (۱): بهترین نتایج به دست آمده در شناسایی اختلال ADHD با اعمال موجک مادر و سطوح تجزیه مختلف و روش طبقه‌بندی-

کننده SVM با کرنل RBF

موجک مادر	سطح تجزیه	دقت	حساسیت	معین پذیری
سیملت ^{۳۵} (Sym4)	۲	۹۶/۶۷	٪۱۰۰	۹۳/۷۵
دایچیز ^{۳۶} (Db1)	۳	۹۷/۵	٪۱۰۰	۹۵/۲۴
کویفلت ^{۳۷} (Coif3)	۳	۹۶/۶۷	٪۱۰۰	۹۳/۷۵
بای ارتوگونال ^{۳۸} (Bior1.1)	۲	۹۷/۵	٪۱۰۰	۹۵/۲۴
بای ارتوگونال معکوس (rbio3.1)	۲	۹۸/۳۳	۹۶/۷۷	٪۱۰۰

جدول (۳) به مقایسه نتایج کسب‌شده در این تحقیق با برخی از مطالعات گذشته که نتایج مطلوبی داشته‌اند، می‌پردازد. همانطور که مشاهده می‌شود، در مطالعه حاضر با استفاده از روش‌های کارآمد، با وجود این که به محاسبات کمتری نیاز دارند، دقت شناسایی کسب شده بهبود یافته است. هم‌چنین در مقایسه نتایج این مطالعه و مرجع شماره ۱۰ که از سیگنال‌های یکسانی استفاده کرده‌اند، عملکرد بهتر روش پیشنهادی تأیید می‌شود.

مهمترین هدف روش‌های درمان از جمله نوروفیدبک برای بیماران ADHD تغییر در عملکرد و بهبود فعالیت مغزی پس از انجام درمان است. به این منظور ما در این مطالعه به بررسی ویژگی‌های استخراج شده از سیگنال‌های EEG برای بیماران ADHD و افراد سالم نیز پرداختیم؛ با این هدف که ویژگی‌هایی که تغییرات با مفهوم در بین همه افراد دارند را شناسایی کنیم. این می‌تواند به ما در تعیین مؤثر بودن درمان اعمال شده و روند بهبودی بیماران کمک کند.

Table (1): The best results in identifying ADHD disorder using different types of mother wavelets and decomposition levels and kNN classifier with $k=3$

جدول (۲): بهترین نتایج به دست آمده در شناسایی اختلال ADHD با اعمال موجک مادر و سطوح تجزیه مختلف و روش طبقه‌بندی-

کننده kNN با تعداد همسایه $k=3$

موجک مادر	سطح تجزیه	دقت	حساسیت	معین پذیری
سیملت (Sym3)	۲	۹۸/۳۳	۹۸/۳۳	٪۹۸،۳۳
دایچیز (Db2)	۲	۹۸/۳۳	۹۸/۳۳	۹۸/۳۳
کویفلت (Coif3)	۳	۹۷/۵	۹۸/۳۱	۹۶/۷۲
بای ارتوگونال (Bior1.1)	۲	۹۹/۱۷	۹۸/۳۶	٪۱۰۰
بای ارتوگونال معکوس (rbio1.1)	۲	۹۹/۱۷	۹۸/۳۶	٪۱۰۰

Table (6): Comparison of the methods used and the results obtained in identifying the ADHA patients in this work and some previous studies
جدول (۳): مقایسه روش‌های به‌کار رفته و نتایج کسب شده در تشخیص بیماران ADHD در این مطالعه و بعضی از مطالعات گذشته

دقت تشخیص	روش‌های استفاده شده	شماره مرجع مطالعه انجام شده
۹۷/۱۴٪	استفاده از بعد فرکتال هیگوجی تعمیم یافته (GHFDS)، ضرایب مدل خودبازگشتی (AR) و چگالی طیف توان (PSD) به‌همراه ویژگی‌های آماری به‌عنوان ویژگی‌ها و طبقه‌بند SVM با توابع کرنل RBF و چندجمله‌ای	[۱۶]
۸۳٪	فیلترهای کانولوشنی برای محاسبه ویژگی‌های زمانی و فیلترهای مکانی برای انتخاب کانال به‌همراه الگوریتم یادگیری عمیق EEGNet	[۱۷]
۹۳/۶۵٪ و ۹۲/۲۸٪	بعد فرکتال، توان لیاپانوف و آنتروپی تقریب به‌عنوان ویژگی‌ها، روش‌های رابطه تقارن ورودی دوگانه (DISR) و بیشترین ارتباط کمترین افزونگی (mRMR) برای انتخاب ویژگی‌های مؤثرتر و شبکه عصبی MLP به‌عنوان طبقه‌بندی‌کننده	[۱۸]
۹۶/۰۵٪	توان لیاپانوف، بعد فرکتال، بعد همبستگی و آنتروپی‌های فازی و تقریب به‌عنوان ویژگی‌ها، روش SVM با تابع کرنل چندجمله‌ای به‌عنوان طبقه‌بندی‌کننده	[۲۰]
بهترین دقت ۹۹/۱۷٪	ویژگی‌های زمانی (میانگین، واریانس، عبور از صفر و ...) در زیرباندهای سیگنال‌های تجزیه شده با تبدیل موجک به‌همراه روش PCA برای کاهش ابعاد ویژگی‌ها و روش‌های SVM با تابع کرنل RBF و kNN به‌عنوان طبقه‌بندی‌کننده	مطالعه حاضر

ویژگی‌هایی که برای همه افراد شرکت‌کننده روند مشابهی داشته‌اند را معرفی می‌کنیم. به عبارت دیگر هدف آن است ویژگی‌هایی را مشخص کنیم که در همه افراد بیمار تغییر مشابهی در مقایسه با افراد سالم داشته‌اند. برطبق نتایج، ضرایب مدل AR که در این مطالعه با مرتبه $p=5$ به‌عنوان ویژگی مورد استفاده قرار گرفتند، برای اکثریت افراد بیمار روند مشابهی در مقایسه با افراد سالم داشتند. بنابراین از این ضرایب به‌عنوان ویژگی‌های بامفهوم در تعیین و ارزیابی روند اجرای درمان برای بیماران ADHD می‌توان بهره گرفت.

۴- نتیجه‌گیری

در این مطالعه طراحی یک سیستم تشخیص الگو برای شناسایی بیماران ADHD از افراد سالم مورد توجه قرار گرفت. به این منظور از ویژگی‌های سیگنال EEG تجزیه شده با اعمال تبدیل موجک بهره گرفتیم. برای هر زیرباند از ضرایب موجک، ویژگی‌های آماری و زمانی محاسبه شدند. مجموعه ویژگی‌های کاهش یافته با روش PCA سپس برای آموزش سیستم طبقه‌بندی الگوهای سیگنال EEG به‌کار رفت. با استفاده از روش طبقه‌بندی SVM با تابع کرنل RBF و هم‌چنین طبقه‌بند kNN با $k=3$ بهترین دقت‌های شناسایی به‌ترتیب برابر با ۹۸/۳۳ درصد و ۹۹/۱۷ درصد کسب شدند. نتایج به‌دست آمده در مقایسه با مطالعات گذشته که از روش‌های با پیچیدگی محاسباتی بیشتر استفاده کرده بودند، قابل ملاحظه است. هم‌چنین با استفاده از ویژگی‌های ضرایب مدل AR برای زیرباندهای سیگنال‌های تجزیه شده، می‌توان در صورت اعمال درمان برای بیماران ADHD، تأثیرگذاری آن را تعیین کرد. این مسأله بسیار حایز اهمیت است چرا که می‌تواند برای انتخاب نوع درمان، پیگیری روند درمان بیماران و هم‌چنین تعیین سودمندی آن‌ها مفید باشد.

References

مراجع

- [1] L. D. Adler, A. Nierenberg, "Review of medication adherence in children and adults with ADHD", *Postgraduate Medicine*, vol. 122, no. 1, pp. 184-191, Jan. 2010 (doi:10.3810/pgm.2010.01.2112).
- [2] S. C. Yeh, S. Y. Lin, E. H. K. Wu, K. F. Zhang, X. Xiu, A. Rizzo, C. R. Chung, "A virtual-reality system integrated with neuro-behavior sensing for attention-deficit/hyperactivity disorder intelligent assessment", *IEEE Trans. on Neural Systems and Rehabilitation Engineering*, vol. 28, no. 9, pp. 1899-1907, Sept. 2020 (doi: 10.1109/TNSRE.2020.3004545).

- [3] S. Kim, J. Ryu, Y. Choi, Y. Kang, H. Li and K. Kim, "Eye-contact game using mixed reality for the treatment of children with attention deficit hyperactivity disorder", *IEEE Access*, vol. 8, pp. 45996-46006, 2020 (doi: 10.1109/ACCESS.2020.2977688).
- [4] J. T. Nigg, L. G. Blakely, C. L. Huang-Pollock, M.D. Rappley, "Neuropsychological executive functions and DSM-IV ADHD subtypes", *Journal of the American Academy of Child and Adolescent Psychiatry*, vol. 41, no. 1, pp. 59- 66, Jan. 2002 (doi:10.1097/00004583-200201000-00012).
- [5] N. Lofthouse, L. E. Arnold, S. Hersch, E. Hurt, R. DeBeus, "A review of neurofeedback treatment for pediatric ADHD", *Journal of Attention Disorders*, vol. 16, no. 5, pp. 351-372, Jul. 2012 (doi: 10.1177/10-87054711427530).
- [6] S. Enriquez-Geppert, D. Smit, M.G. Pimenta, M. Arns, "Neurofeedback as a treatment intervention in ADHD: Current evidence and practice", *Current Psychiatry Reports*, vol. 21, no. 6, pp. 46, May. 2019 (doi: 10.1007/s11920-019-1021-4).
- [7] I. Ebrahimnejad, M. Kahkesh, A. Naghsh, "Classification and feature extraction of electroencephalogram signals for epilepsy using PCA, ICA, DWT and SVM methods", *Journal of Intelligent Procedures in Electrical Technology*, vol. 9, no. 36, pp. 15-22, Winter 2019 (in Persian).
- [8] N. Behzadfar, S. M. P. Firoozabadi, K. Badie, "Analysis of regularity in the EEG before/after working memory task", *Proceeding of the IEEE/ICBME*, pp. 1-5, Tehran, Iran, Dec. 2017 (doi: 10.1109/ICBME.20-17.8430260).
- [9] H. Akbari, S. Saraf-Esmaili, S. Farzollah-Zadeh, "Detection of seizure EEG signals based on reconstructed phase space of rhythms in EWT domain and genetic algorithm", *Signal Processing and Renewable Energy*, vol. 4, no. 2, pp. 23-36, Spring 2020.
- [10] M. Khezri, M. Jahed, "Introducing a new multi-wavelet function suitable for sEMG signal to identify hand motion commands", *Proceeding of the IEEE/IEMBS*, pp. 1924-1927, Lyon, France, Aug. 2007 (doi: 10.1109/IEMBS.2007.4352693).
- [11] M. Dorvashi, N. Behzadfar, G. Shahgholian, "Classification of alcoholic and non-alcoholic individuals based on frequency and non-frequency features of electroencephalogram signal", *Iranian Journal of Biomedical Engineering*, vol. 14, no. 2, pp. 121-130, Summer 2020 (doi: 10.22041/ijbme.2020.119841.1551) (in Persian).
- [12] N. Dashti, M. Khezri, "Recognition of motor imagery based on dynamic features of EEG signals", *Journal of Intelligent Procedures in Electrical Technology*, vol. 11, no. 43, pp. 13-27, Autumn 2020 (in Persian).
- [13] M. Congedo, J. F. Lubar, D. Joffe, "Low-resolution electromagnetic tomography neurofeedback", *IEEE Trans. on Neural Systems and Rehabilitation Engineering*, vol. 12, no. 4, pp. 387-397, Dec. 2004 (doi: 10.1-109/TNSRE.2004.840492).
- [14] M. Adamou, T. Fullen, S. L. Jones, "EEG for diagnosis of adult ADHD: a systematic review with narrative analysis", *Frontiers in Psychiatry*, vol. 11, pp. 871, Aug. 2020 (doi: 10.3389/fpsy.2020.00871).
- [15] M. Cerquera, M. Arns, R.M. Gutiérrez, J. Freund, "Dynamical measures for characterization of EEG registers in patients with attention deficit hyperactivity disorder treated with neurofeedback", *Proceeding of the IEEE/STSIVA*, pp. 213-217, Antioquia, Colombia, Sep. 2012 (doi:10.1109/STSIVA.2012.6340584).
- [16] Q. Wang and O. Sourina, "Real-time mental arithmetic task recognition from EEG signals", *IEEE Trans. on Neural Systems and Rehabilitation Engineering*, vol. 21, no. 2, pp. 225-232, Jan. 2013 (doi: 10.1109/TNSRE.2012.2236576).
- [17] A. Vahid, A. Bluschke, V. Roessner, S. Stober, C. Beste, "Deep learning based on event-related EEG differentiates children with ADHD from healthy controls", *Journal of Clinical Medicine*, vol. 8, no.7, pp. 1055, July 2019 (doi:10.3390/jcm8071055).
- [18] M. R. Mohammadi, A. Khaleghi, A. M. Nasrabadi, S. Rafieivand, M. Begol, H. Zarafshan, "EEG classification of ADHD and normal children using non-linear features and neural network", *Biomedical Engineering Letters*, vol. 6, pp. 66-73, June 2016 (doi:10.1007/s13534-016-0218-2).
- [19] A. E. Alchalabi, S. Shirmohammadi, A. N. Eddin, M. Elsharnouby, "FOCUS: detecting ADHD patients by an EEG-based serious game", *IEEE Trans. on Instrumentation and Measurement*, vol. 67, no. 7, pp. 1512-1520, June 2018 (doi: 10.1109/TIM.2018.2838158).
- [20] Y. K. Boroujeni, A. A. Rastegari, H. Khodadadi, "Diagnosis of attention deficit hyperactivity disorder using non-linear analysis of the EEG signal", *IET Systems Biology*, vol. 13, no. 5, pp. 260-266, Oct. 2019 (doi: 10.1049/iet-syb.2018.5130).
- [21] H. Chen, Y. Song, X. Li, "A deep learning framework for identifying children with ADHD using an EEG-based brain network", *Neurocomputing*, vol. 356, pp. 83-96, Sept. 2019 (doi: 10.1016/j.neucom.2019.04.05-8).
- [22] J. Kevric, A. Subasi, "Comparison of signal decomposition methods in classification of EEG signals for motor-imagery BCI system", *Biomedical Signal Processing and Control*, vol. 31, pp.398-406, Jan. 2017 (doi: 10.1016/j.bspc.2016.09.007).

- [23] M. Zecca, S. Micera, M. C. Carrozza, P. Dario, "Control of multifunctional prosthetic hands by processing the electromyographic signal", *Critical Reviews in Biomedical Engineering*, vol. 30, no. 4-6, pp. 459-485, 2002 (doi: 10.1615/critrevbiomedeng. v30.i456.80).
- [24] P. C. Petrantonakis, L. J. Hadjileontiadis, "Emotion recognition from EEG using higher order crossings", *IEEE Trans. on Information Technology in Biomedicine*, vol. 14, no. 2, pp. 186-197, Mar. 2010 (doi: 10.1109/TITB.2009.2034649).
- [25] C. A. Frantzidis, C. Bratsas, C. L. Papadelis, E. Konstantinidis, C. Pappas, P. D. Bamidis, "Toward emotion aware computing: An integrated approach using multichannel neurophysiological recordings and affective visual stimuli", *IEEE Trans. on Information Technology in Biomedicine*, vol. 14, no. 3, pp. 589-597, May. 2010 (doi: 10.1109/TITB.2010.2041553).

زیر نویس‌ها:

1. Attention deficit hyperactivity disorder
2. Diagnostic and statistical manual of mental disorders
3. Electroencephalogram
4. Largest Lyapunov exponent
5. Lempel-Ziv complexity
6. Generalized Higuchi fractal dimension spectrum
7. Auto regressive
8. Power spectrum density
9. Support vector machine
10. Radial basis function
11. Fractal dimension
12. Double input symmetrical relevance
13. Minimum redundancy maximum relevance
14. Multi-layer perceptron
15. Convolutional neural network
16. Institutional review board
17. Tehran university of medical sciences
18. Discrete wavelet transform
19. Mean absolute value
20. Mean absolute value slope
21. Zero crossing
22. Slope sign changes
23. Mean of the absolute values of the first differences of the raw signal
24. Mean of the absolute values of the second differences of the raw signal
25. Mean of the absolute values of the first differences of the standardized signal
26. Mean of the absolute values of the second differences of the standardized signal
27. Principle component analysis
28. K-nearest neighbors
29. True positive
30. True negative
31. False positive
32. False negative
33. Leave-one-out
34. Reverse biorthogonal wavelet
35. Symlet wavelet
36. Daubechies wavelet
37. Coiflet wavelet
38. Biorthogonal wavelet