

Extracting suitable features for detecting voluntary movements from EEG signals

Parastoo Ghafoorpour¹, M.Sc, Reza Ghafouri², Assistant Professor, Omid Mahdiyar³, Assistant Professor

¹ Department of Electrical and Computer, Kazerun Branch, Islamic Azad University, Kazerun, Iran
parastooghafour@gmail.com

² Department of Electrical and Computer, Kazerun Branch, Islamic Azad University, Kazerun, Iran
reza.ghafouri@iau.ac.ir

³ Department of Electrical and Computer, Kazerun Branch, Islamic Azad University, Kazerun, Iran
Omid.mahdiyar@iau.ac.ir

Received: 18 January 2025

Revised: 08 March 2025

Accepted: 17 March 2025

Abstract:

This research focuses on extracting suitable features for detecting voluntary movements from EEG signals. To achieve this, a method with three main stages was proposed: noise removal, feature extraction, and classification. In the first step, brain signals were cleaned of recording device noise using four methods. These included two classic techniques (Independent Component Analysis - ICA and Wavelet Transform) and two newer approaches (Walsh Transform and a combination of Walsh Transform with ICA). The performance of these methods was evaluated using three criteria: Signal-to-Noise Ratio (SNR), Mean Squared Error (MSE), and Percentage Root Mean Square Difference (PRD). The results showed that the combined Walsh and ICA method, as well as the Walsh Transform alone, performed better than other methods by yielding the highest SNR values and the lowest MSE and PRD values. In the feature extraction stage, vectors consisting of 22 components were calculated for various channels and the entire signal. These components included entropy and power from Walsh Transform. For comparison, similar features were also extracted using the Wavelet and Fourier Transforms. Finally, data classification was performed using two methods: Support Vector Machine (SVM) and K-Nearest Neighbors (KNN). The results indicate that Walsh Transform-based features provided the best detection rates. The classification accuracy was 42.5% with SVM and 39.0% with KNN. Furthermore, evaluation with BCI Competition IV data showed that the proposed method, except in one instance, outperformed other approaches and demonstrated excellent performance in terms of training and testing time. Its average processing time was 52 seconds, which is considerably less than the comparative methods (403 and 640 seconds).

Keywords: EEG signals, voluntary movements, feature extraction, brain signal recognition, Walsh transform, signal entropy.

Corresponding Author: Reza Ghafoori

Corresponding Author Address: Department of Electrical and Computer Engineering- Mellat Blvd. - Islamic Azad University- Kazerun Branch, Iran

استخراج ویژگی مناسب برای تشخیص حرکات ارادی از روی سیگنال EEG

پرستو غفورپور^۱، دانشجوی کارشناسی ارشد، رضا غفوری^۲، مربی، امید مهدی یار^۳، استادیار

۱- دانشکده مهندسی برق و کامپیوتر - واحد کازرون، دانشگاه آزاد اسلامی، کازرون، ایران

parastooghafour@gmail.com

۲- دانشکده مهندسی برق و کامپیوتر - واحد کازرون، دانشگاه آزاد اسلامی، کازرون، ایران

reza.ghafouri@iau.ac.ir

۳- دانشکده مهندسی برق و کامپیوتر - واحد کازرون، دانشگاه آزاد اسلامی، کازرون، ایران

omid.mahdiyar@iau.ac.ir

تاریخ پذیرش مقاله: ۱۴۰۳/۱۲/۲۷

تاریخ بازنگری مقاله: ۱۴۰۳/۱۲/۱۸

تاریخ ارسال مقاله: ۱۴۰۳/۱۰/۲۹

چکیده: این تحقیق به استخراج ویژگی‌های مناسب برای تشخیص حرکات ارادی از روی سیگنال‌های EEG می‌پردازد. برای این منظور، روشی در سه مرحله اصلی ارائه شده است: حذف نویز، استخراج ویژگی و دسته‌بندی. در گام اول، سیگنال‌های مغزی با استفاده از چهار روش از نویز دستگاه ثبت پاک‌سازی شدند. این چهار روش شامل دو تکنیک کلاسیک تحلیل مؤلفه‌های مستقل ICA - و تبدیل موجک و دو روش جدیدتر تبدیل والش و ترکیب والش با ICA بودند. عملکرد این روش‌ها با سه معیار نسبت سیگنال به نویز (SNR)، میانگین مربع خطا (MSE) و جذر میانگین تفاضل مربعات در صدی (PRD) ارزیابی شد. نتایج نشان داد که روش‌های ترکیبی والش و ICA و همچنین تبدیل والش به تنهایی، با ارائه بالاترین مقدار SNR و کمترین مقادیر MSE و PRD، عملکرد بهتری نسبت به سایر روش‌ها داشتند. در مرحله استخراج ویژگی، بردارهایی متشکل از ۲۲ مؤلفه برای کانال‌های مختلف و کل سیگنال محاسبه شد. این مؤلفه‌ها شامل آنتروپی و توان تبدیل والش بودند. همچنین، برای مقایسه، ویژگی‌های مشابهی با استفاده از تبدیل موجک و فوریه نیز استخراج گردید. در نهایت، دسته‌بندی داده‌ها با دو روش ماشین بردار پشتیبان (SVM) و نزدیک‌ترین همسایه (KNN) انجام شد. نتایج نشان می‌دهد که ویژگی‌های مبتنی بر تبدیل والش، بهترین نرخ تشخیص را ارائه داده‌اند. دقت دسته‌بندی با SVM معادل ۴۲.۵٪ و با KNN برابر با ۳۹.۰٪ به دست آمد. همچنین، ارزیابی با داده‌های مسابقات چهارم BCI نشان داد که روش پیشنهادی، به جز در یک مورد، نسبت به سایر روش‌ها برتری داشته و از نظر زمان آموزش و تست نیز عملکرد بسیار مطلوبی دارد. به طوری که زمان پردازش آن به طور میانگین ۵۲ ثانیه است که به مراتب کمتر از روش‌های مقایسه‌ای (۴۰۳ و ۶۴۰ ثانیه) می‌باشد.

کلمات کلیدی: سیگنال‌های EEG، حرکات ارادی، استخراج ویژگی، تشخیص سیگنال‌های مغزی، تبدیل والش، آنتروپی سیگنال

نام نویسنده مسئول: رضا غفوری

نشانی نویسنده مسئول: کازرون - بلوار ملت - دانشگاه آزاد اسلامی واحد کازرون - دانشکده مهندسی برق و کامپیوتر

۱- مقدمه

سیگنال‌های الکتروانسفالوگرافی (EEG) که فعالیت‌های الکتریکی مغز را به صورت غیرتهاجمی ثبت می‌کنند، ابزار ارزشمندی برای مطالعه فرآیندهای مغزی به شمار می‌آیند. این سیگنال‌ها اطلاعات مهمی درباره وضعیت‌های مغزی مانند خواب، هوشیاری و حرکات ارادی فراهم می‌کنند [۱]. تشخیص حرکات ارادی از روی سیگنال EEG یکی از چالش‌برانگیزترین و در عین حال جذاب‌ترین مسائل در حوزه پردازش سیگنال‌های مغزی است. مغز پیش از انجام یک حرکت ارادی، الگوهای خاصی از فعالیت‌های الکتریکی تولید می‌کند که با روش‌های پردازش مناسب، قابل شناسایی هستند. تحلیل این الگوها می‌تواند در توسعه سیستم‌های هوشمندی مانند پروتزهای فعال، تجهیزات کمکی حرکتی و واسط‌های کنترلی مبتنی بر فکر نقش مهمی ایفا کند. با این وجود، ماهیت پیچیده و نویزپذیر سیگنال‌های EEG، تحلیل دقیق آن‌ها را به چالشی فنی تبدیل کرده است. یکی از مراحل کلیدی در پردازش این سیگنال‌ها، استخراج ویژگی‌های مؤثر و متمایزکننده است که بتوانند اطلاعات لازم برای طبقه‌بندی صحیح فعالیت‌های مغزی را فراهم سازند. این ویژگی‌ها ممکن است شامل اطلاعات زمانی، فرکانسی یا ترکیبی از آن‌ها باشند.

در این پژوهش، هدف طراحی و پیاده‌سازی یک روش مؤثر برای استخراج ویژگی و طبقه‌بندی حرکات ارادی با استفاده از سیگنال EEG است. برای این منظور، الگوریتم‌های پیشنهادی در محیط شبیه‌سازی متلب پیاده‌سازی شده‌اند. نتایج این تحقیق می‌تواند در بهبود عملکرد سیستم‌های مبتنی بر EEG، خصوصاً در کاربردهای بلادرنگ مؤثر باشند. تعامل انسان و کامپیوتر (HCI)، علمی میان‌رشته‌ای است که طراحی، ارزیابی و پیاده‌سازی سیستم‌های تعاملی را با تمرکز بر کارایی، دسترس‌پذیری و کاربرپسندی بررسی می‌کند. در این چارچوب، رابط مغز و رایانه BCI به عنوان یک واسط پیشرفته، سیگنال‌های مغزی را به دستورات کنترلی قابل فهم برای رایانه یا سایر دستگاه‌ها تبدیل می‌کند. سیستم‌های BCI با استفاده از مجموعه‌ای از الکترودها، سیگنال‌های مغزی را از سطح پوست سر ثبت می‌کنند و پس از حذف نویز و استخراج ویژگی، این اطلاعات را برای تشخیص نیت کاربر مورد استفاده قرار می‌دهند. در این مسیر، پژوهش حاضر بر آن است تا با بررسی و ترکیب روش‌های مختلف حذف نویز و استخراج ویژگی، به راه‌حلی بهینه برای تشخیص حرکات ارادی دست یابد.

۲- پیش زمینه و تعریف BCI

تعامل انسان و کامپیوتر امروزه به عنوان یکی از حوزه‌های بین‌رشته‌ای مهم، کاربردهای گسترده‌ای در طراحی و توسعه سامانه‌های هوشمند دارد. در این چارچوب، ارتباط میان کاربر و رایانه از طریق واسط‌های نرم‌افزاری و سخت‌افزاری برقرار می‌شود. یکی از زیرشاخه‌های مهم HCI، BSI است که امکان برقراری ارتباط مستقیم میان مغز انسان و رایانه را بدون نیاز به کانال‌های فیزیکی و عضلانی فراهم می‌سازد. این سامانه با بهره‌گیری از سیگنال‌های مغزی، کنترل مستقیم بر دستگاه‌های رایانه‌ای یا کمکی را ممکن می‌سازد و کاربردهای گسترده‌ای در زمینه توانبخشی و فناوری‌های کمکی دارد. یکی از روش‌های رایج و پرکاربرد برای ثبت این سیگنال‌ها، الکتروانسفالوگرافی است. امروزه، کاربردهای EEG عمدتاً در حوزه‌های تشخیص پزشکی، توانبخشی و کمک به افراد دارای ناتوانی جسمی و ذهنی متمرکز است [۱].

در مراحل ابتدایی پژوهش‌ها، به دلیل ماهیت نویزی و آشفتگی بالای سیگنال‌های مغزی، استخراج اطلاعات دقیق و قابل استفاده از آن‌ها بسیار دشوار بود. نبود تجهیزات دقیق ثبت نیز باعث محدودیت در پیشبرد پژوهش‌های مرتبط شده بود. با پیشرفت‌های صورت گرفته در حوزه سخت‌افزار، الکترونیک و رایانه، ابزارهایی برای ثبت سیگنال‌های EEG با دقت و سرعت بالا توسعه یافته‌اند که امکان تحلیل مؤثر این سیگنال‌ها را فراهم کرده‌اند.

در این سیستم، سیگنال‌های EEG به دلیل دقت زمانی بالا، سادگی در استفاده و هزینه پایین، به عنوان گزینه‌ای مناسب برای ثبت فعالیت‌های مغزی انتخاب می‌شوند. الکترودهای EEG بر روی سطح پوست سر قرار می‌گیرند و میدان‌های الکتریکی حاصل از فعالیت نورونی را اندازه‌گیری می‌کنند. پس از ثبت، سیگنال‌های EEG تحت فرآیند پیش‌پردازش و حذف نویز قرار می‌گیرند تا اطلاعات خالص‌تر و قابل تحلیل‌تری به دست آید. سپس در مرحله استخراج ویژگی، پارامترهای مرتبط با الگوهای مغزی شناسایی شده و برای مرحله طبقه‌بندی استفاده می‌شوند. خروجی طبقه‌بندی نشان می‌دهد که کاربر قصد انجام چه حرکتی را دارد.


ساختار سیستم‌های BCI ممکن است ثابت یا انطباق‌پذیر باشد؛ در حالت دوم، سامانه قادر است خود را با ویژگی‌های فردی سیگنال‌های EEG انطباق دهد. همچنین در برخی طراحی‌ها، بازخوردی از عملکرد سیستم به کاربر ارائه می‌شود که به آن بیوفیدبک گفته می‌شود. در اولین همایش بین‌المللی BCI در ژوئن ۱۹۹۹، این سامانه به عنوان یک رابط ارتباطی تعریف شد که بدون وابستگی به مسیرهای خروجی سیستم عصبی محیطی و عضلات، سیگنال‌های مغزی را به خروجی تبدیل می‌کند [۲]. از آنجا که سیگنال‌های EEG از نظر دامنه و فرکانس با سایر سیگنال‌های زیستی هم‌پوشانی دارند، در تعریف BCI تأکید می‌شود که این سامانه باید مبتنی بر سیگنال‌های مستقل مغزی باشد، نه سیگنال‌های عضلانی. هدف این پژوهش، ارائه چارچوبی ساختاریافته و علمی برای تحلیل سیگنال‌های EEG به منظور تشخیص حرکات ارادی است. با توجه به نویزپذیری بالا و پیچیدگی ساختاری این سیگنال‌ها، طراحی روشی بهینه برای پردازش و استخراج ویژگی، نقش کلیدی در موفقیت چنین سیستم‌هایی ایفا می‌کند. پژوهش حاضر در راستای توسعه یک سامانه تشخیص حرکات ارادی با استفاده از EEG طراحی شده است که بتواند با دقت و سرعت بالا، حرکات موردنظر را شناسایی کرده و آن را به دستورات کنترلی برای دستگاه‌های کمکی یا پروتزها تبدیل نماید.

۳- روش تحقیق و توصیف روش پیشنهادی

۳-۱- پایگاه داده مورد استفاده

داده‌های مورد استفاده در این تحقیق مربوط به چهارمین دوره مسابقات (BCI Competition IV) می‌باشد. این پایگاه داده شامل ثبت فعالیت‌های مغزی دو فرد سالم در زمان انجام حرکات ارادی میچ دست راست است. نمونه‌برداری سیگنال‌ها با نرخ ۶۲۵ هرتز انجام شده است. آزمودنی‌ها به صورت راحت روی صندلی مخصوص MEG نشسته بودند؛ آرنج روی بالش قرار داشت تا از حرکت بازو جلوگیری شود، و سر و شانه‌ها نیز با بالش ثابت شده بودند تا کمترین حرکت ناخواسته اتفاق بیفتد. در هر آزمایش، هدف، حرکت دادن نشانگر ماوس با استفاده از میچ دست راست از مرکز صفحه به یکی از چهار جهت در شعاع ۹۰ درجه با دامنه حرکتی ۴.۵ سانتی‌متر بود. انتخاب جهت حرکت در هر بار توسط خود فرد انجام می‌شد. آغاز سیگنال با نمایش یک دایره در مرکز مانیتور مشخص می‌شد. پس از ۱ تا ۲ ثانیه، دایره محو شده و سیگنال "GO" برای انجام حرکت ظاهر می‌گردید. آزمودنی می‌بایست در فاصله ۰.۷۵ ثانیه پس از سیگنال "GO"، حرکت را آغاز کرده و نشانگر را به نقطه هدف منتقل نماید. همچنین، برای ثبت صحیح داده، نشانگر باید به مدت ۱ ثانیه در محل هدف باقی می‌ماند. سیگنال‌های مغزی از طریق ۱۰ کانال MEG مستقر در نواحی مرکزی موتور مغز جمع‌آوری شده‌اند. کانال‌های مورد استفاده شامل: LC21، LC22، LC23، LC31، LC41، LC42، ZC01، ZC02 و RC41 می‌باشند. داده‌های هر آزمایش شامل بازه‌ای از ۰.۴ ثانیه قبل تا ۰.۶ ثانیه بعد از شروع حرکت می‌باشد. برای افزایش کیفیت داده، یک فیلتر میان‌گذر در بازه ۰.۵ تا ۱۰۰ هرتز بر روی سیگنال‌ها اعمال شده و نرخ نمونه‌برداری به ۴۰۰ هرتز کاهش یافته است [۲].

در شکل (۱)، نحوه قرارگیری الکترودها بر روی سر نمایش داده شده است. الکترودهایی که برای ثبت سیگنال استفاده شده‌اند، در مرکز تصویر با بیضی مشخص شده‌اند.



شکل (۱): نحوه قرارگیری الکترودها بر روی سر هنگام ثبت سیگنال‌های مغزی مورد استفاده

۳-۲- حذف نویز

همان‌طور که می‌دانیم، سیگنال‌های مغزی در هنگام ثبت، با انواع مختلفی از نویزها نظیر نویزهای محیطی، نویز ناشی از دستگاه‌های ثبت‌کننده و همچنین نویز حاصل از سایر سیگنال‌های حیاتی مانند ECG, EMG, و... آمیخته هستند. وجود این نویزها، پردازش دقیق سیگنال‌های مغزی را با چالش مواجه می‌کند و ممکن است موجب انحراف نتایج به‌دست‌آمده از واقعیت شود. بنابراین، برای دستیابی به نتایج دقیق و قابل اعتماد، لازم است ابتدا فرآیند حذف نویز از سیگنال‌ها انجام گیرد. در این تحقیق، بخش نخست به پیش‌پردازش و حذف نویزهای محیطی و نویزهای ناشی از تجهیزات ثبت سیگنال اختصاص دارد. در این بخش، ابتدا روش‌های متداول حذف نویز بررسی می‌شوند و در ادامه، روش پیشنهادی ما برای حذف نویز از سیگنال‌های EEG ارائه خواهد شد.

۳-۳- آنالیز مؤلفه‌های مستقل

آنالیز مؤلفه‌های مستقل (ICA) به عنوان یک راهکار قدرتمند در حل مسئله جداسازی کور منابع (BSS) مطرح شده است. در این مسئله، تنها مجموعه‌ای از مشاهدات در اختیار داریم، در حالی که اطلاعات مربوط به منابع اصلی سیگنال پنهان هستند. ICA به دنبال یافتن یک تبدیل خطی است که مجموعه‌ای از متغیرهای تصادفی را به صورت ترکیب خطی از منابع مستقل بازسازی کند.

از آن‌جا که سیگنال EEG ترکیبی از فعالیت‌های الکتریکی بخش‌های مختلف مغز است، روش ICA می‌تواند این سیگنال‌های ترکیبی را بدون نیاز به اطلاعات اضافی و تنها با تکیه بر فرض‌های آماری، به مجموعه‌ای از مؤلفه‌های آماری مستقل تجزیه کند. فرض کنیم که $x_1, x_2, \dots, x_n$ ترکیب‌های خطی n از منبع مستقل باشند به طوری که برای هر $j=1, 2, \dots, n$ داشته باشیم:

$$x_j = x_{j1}s_1 + a_{j2}s_2 + \dots + a_{jn} \quad (۱)$$

که به صورت برداری به شکل زیر بیان می‌شود:

$$X = As \quad (2)$$


در این رابطه، X بردار سیگنال‌های ورودی، s بردار منابع مستقل، و A ماتریس ترکیب‌کننده است [۳]. در این مدل می‌توان نویز را نیز به سیگنال اضافه کرد. هدف ICA، تخمین دو مؤلفه ناشناخته یعنی ماتریس A و بردار s از سیگنال ورودی است، با این فرض‌ها که ترکیب منابع به صورت خطی است؛ منابع آماری مستقل هستند؛ نویز جمع‌شونده در مشاهدات وجود ندارد و توزیع منابع غیرگوسی است. هدف نهایی، یافتن ماتریس جداکننده به‌گونه‌ای است که:

$$S = WX = WAs \quad (3)$$


که در آن بردار s برآوردی از منابع مستقل و W ماتریس جداساز نامیده می‌شود [۴]. در عمل، برای تخمین دقیق تمامی منابع، تعداد سنسورها باید حداقل برابر با تعداد منابع باشد. اما از آنجا که تعداد منابع مغزی مشخص نیست و عملاً بی‌نهایت فرض می‌شود، باید در به‌کارگیری ICA به این نکته توجه کرد. اگر سیگنال‌ها توسط m سنسور ثبت شده باشند، در نتیجه m مؤلفه مستقل به دست خواهد آمد که معمولاً بخش عمده‌ای از آن‌ها مربوط به منابع قوی و متمایز اولیه هستند، و باقی‌مانده ترکیبی از منابع ضعیف‌تر و کمتر مستقل‌اند. نتایج اعمال ICA روی داده‌های با چگالی بالا (مثلاً ۲۵۶ کانال ثبت‌شده از یک فرد نرمال حین انجام فعالیت‌های شناختی) نشان داده‌اند که تنها چند ده مؤلفه مستقل از لحاظ فیزیولوژیکی قابل تفسیر هستند. این مؤلفه‌ها نگاشت‌های مجموعه‌ای مشخصی داشته و با فعالیت مغزی قابل تطبیق‌اند، در حالی که بیش از ۲۰۰ مؤلفه باقی‌مانده، یا ناشی از آرتیفک‌های غیرمغزی هستند، یا ترکیبی از منابع با انرژی پایین محسوب می‌شوند که برای بازسازی کامل داده، با هم ترکیب شده‌اند [۵].

۳-۴- حذف نویز با استفاده از آنالیز مؤلفه‌های مستقل

به منظور حذف نویز از سیگنال‌های مغزی، الگوریتم ICA بر روی سیگنال اعمال می‌شود. در این فرآیند، مؤلفه یا مؤلفه‌های نویزی (آرتیفک‌ها) شناسایی و سپس حذف می‌شوند. پس از حذف، سیگنال بازسازی شده و به حوزه زمانی اولیه بازگردانده می‌شود، به‌طوری که سیگنالی بدون نویز و آرتیفکت حاصل گردد.



شکل (۲): سیگنال‌های گرفته شده توسط هر کانال



شکل (۳): مولفه‌های بدست آمده توسط ICA

در شکل (۲)، ده کانال از یک سیگنال EEG نشان داده شده است که ICA روی آن اعمال شده است. برای اجرای ICA از نرم‌افزار متلب استفاده می‌کنیم. در شکل (۳)، مولفه‌های استخراج شده به وسیله ICA نمایش داده شده‌اند. شناسایی مولفه‌های نویزی معمولاً دشوار است و نیاز به تفسیر یک فرد متخصص دارد. در این روش، اگر نویز منبع مشخصی داشته باشد مثلاً فعالیت قلبی (ECG)، حرکات چشم یا پلک زدن (EOG)، یا انقباضات عضلانی (EMG) که توسط یک یا چند الکتروود خاص ثبت شده‌اند می‌توان با اعمال ICA، مولفه‌های مربوط به این نویزها را جدا و حذف کرد، سپس سیگنال اصلی را بازسازی نمود. اما اگر نویز منبع مشخصی نداشته باشد و در تمام کانال‌ها به صورت یکنواخت پراکنده باشد، حذف آن با این روش دشوار و در بسیاری موارد غیرممکن خواهد بود. در مجموع، روش ICA می‌تواند با استفاده از ثبت چندکاناله سیگنال EEG، فعالیت‌های غیرمغزی مانند پلک زدن، حرکات چشم، ECG و EMG را به صورت مولفه‌های مستقل شناسایی و حذف کند؛ به شرط آنکه منبع این سیگنال‌ها مشخص باشد. در صورتی که منابع نویز ناشناخته باشند، کارایی ICA در حذف آن‌ها کاهش می‌یابد.

۳-۵- حذف نویز با استفاده از تبدیل موجک

تبدیل موجک یکی از ابزارهای قدرتمند در پردازش سیگنال است که کاربردهای متعددی از جمله استخراج ویژگی، فشرده‌سازی و حذف نویز دارد. فرآیند حذف نویز با استفاده از تبدیل موجک معمولاً در سه مرحله اصلی انجام می‌شود: ابتدا یک موجک پایه و تعداد سطوح تجزیه انتخاب می‌شود. سپس با استفاده از تبدیل گسسته موجک (DWT)، سیگنال به سطح تجزیه می‌شود. این تجزیه باعث تولید ضرایبی در مقیاس‌های مختلف می‌شود که اندازه آن‌ها با توجه به محتویات فرکانسی سیگنال متفاوت است. فرآیند حذف نویز از ضرایب جزئیات در سطوح ۱ تا n طی دو مرحله انجام می‌گیرد. در نمونه‌هایی که نویز وجود ندارد، ضرایب موجک معمولاً دارای مقادیر بزرگی هستند. بنابراین برای حذف نویز، باید حد آستانه‌ای تعیین کرد تا ضرایب کوچکتر از آن به عنوان نویز شناسایی و حذف شوند. یکی از روش‌های متداول، استفاده از حد آستانه‌ای است که توسط Donoho پیشنهاد شده است. این آستانه طبق رابطه زیر محاسبه می‌شود:


$$T = \sqrt{2\sigma^2} \log N \quad (۳)$$

در این رابطه N تعداد نمونه‌ها و σ توان نویز است. ما در این تحقیق از این حد آستانه استفاده کرده‌ایم. پس از محاسبه حد آستانه، آن را به ضرایب جزئیات اعمال می‌کنیم. ضرایبی که مقدارشان کمتر از آستانه باشد به صفر تبدیل می‌شوند. زیرا این ضرایب معمولاً حاصل نویز هستند، در حالی که ضرایب سیگنال اصلی معمولاً بزرگ‌تر هستند و حفظ می‌شوند. این کار باعث حذف مؤثر نویز از سیگنال می‌شود. سیگنال پاک‌سازی شده از نویز، از طریق اعمال تبدیل موجک معکوس (IDWT) بر ضرایب اصلاح شده، بازسازی می‌شود. بدین منظور، تبدیل موجک معکوس به ضرایب حد آستانه گذاری شده اعمال می‌گردد تا نسخه‌ای تخمینی و نویززدایی شده از سیگنال اولیه به دست آید.


۳-۶- حذف نویز با استفاده از تبدیل والش

در این مقاله از تبدیل والش و همچنین روش ترکیبی تبدیل والش و ICA برای حذف نویز بهره گرفته‌ایم. در این بخش و بخش بعدی، این دو روش به صورت جداگانه مورد بررسی قرار می‌گیرند. فرآیند حذف نویز با استفاده از تبدیل والش شامل سه مرحله است: در ابتدا، بر روی هر کانال از سیگنال، تبدیل والش اعمال می‌شود. نتیجه این تبدیل، مقادیر توالی برای هر نمونه از سیگنال است. این مقادیر میزان اهمیت نسبی هر نمونه را نشان می‌دهند. پس از محاسبه مقادیر توالی، با در نظر گرفتن این نکته که اطلاعات اصلی سیگنال معمولاً دارای توالی‌های بزرگ‌تر و نویزها دارای توالی‌های کوچک‌تر هستند، نمونه‌هایی که مقدار توالی آن‌ها کمتر از یک مقدار مشخص است، حذف می‌شوند. در واقع، نمونه‌های باقیمانده معرف اطلاعات اصلی سیگنال هستند. شایان ذکر است که در این روش، برخلاف روش‌های مرسوم، از حد آستانه مشخص و از پیش تعیین شده استفاده نشده است؛ بلکه مقدار آستانه به صورت بصری و با ارزیابی چشمی تعیین شده است. پس از حذف نمونه‌های نویزی، سیگنال پاک‌سازی شده با استفاده از تبدیل معکوس والش بازسازی می‌شود.

مطابق شکل (۴)، مقادیر توالی نمونه‌ها در کلنال‌های مختلف نمایش داده شده‌اند. نمونه‌هایی با مقادیر توالی بالا نمایانگر اطلاعات اصلی هستند که باید حفظ شوند، در حالی که نمونه‌هایی با توالی پایین، نویز تلقی شده و حذف می‌گردند. در شکل (۵)، مشاهده می‌شود که از یک نقطه مشخص (خط عمود) به بعد، نمونه‌ها صفر شده‌اند. این حذف به منظور از بین بردن بخش‌های کم‌اهمیت و نویزی سیگنال انجام شده است، به گونه‌ای که اطلاعات اصلی حفظ و نویز حذف شود.



شکل (۴): تبدیل والش از کانال های سیگنال



شکل (۵): حد آستانه مشخص شده بر روی تبدیل والش برای حذف نویز

۳-۷- حذف نویز با استفاده از روش ترکیبی تبدیل والش و ICA


در سال‌های اخیر، استفاده از روش‌های ترکیبی برای حذف نویز از سیگنال‌های مغزی مورد توجه ویژه‌ای قرار گرفته است. در این روش‌ها عمدتاً از ترکیب ICA و تبدیل موجک استفاده می‌شود؛ بدین صورت که ابتدا مولفه‌های مستقل با استفاده از ICA استخراج شده و سپس بر روی هر مولفه تبدیل موجک اعمال می‌شود تا اجزای نویزی شناسایی و حذف شوند. در این روش، ابتدا مولفه‌های مستقل سیگنال با بهره‌گیری از الگوریتم ICA استخراج می‌شوند. هر یک از این مولفه‌ها ممکن است نمایانگر نویز یا بخشی از سیگنال اصلی باشند.

در مرحله بعد، بر روی هر یک از مولفه‌های مستقل، تبدیل والش اعمال می‌شود. به‌طور مشابه با آنچه در روش مبتنی بر تبدیل والش شرح داده شد، برای هر مولفه میزان توالی هر نمونه محاسبه می‌شود. در صورتی که مقدار توالی یک نمونه کمتر از آستانه‌ی مشخصی باشد، آن نمونه به عنوان نویز در نظر گرفته شده و حذف می‌گردد. برخلاف روش ICA که در آن ممکن است یک مولفه به‌طور کامل حذف شود، در این روش ترکیبی، تنها نمونه‌های بی‌اهمیت و نویزی درون هر مولفه حذف می‌شوند و مولفه به‌طور کامل کنار گذاشته نمی‌شود. این موضوع موجب حفظ بهتر اطلاعات سیگنال اصلی و بهبود کیفیت بازسازی نهایی خواهد شد.


در شکل (۶)، تبدیل والش مولفه‌های حاصل از ICA نمایش داده شده است. در این نمودار، نمونه‌هایی که پس از موقعیت مشخصی (مشخص شده با خط عمود) قرار دارند، به عنوان نویز در نظر گرفته شده و حذف می‌گردند.

۳-۸- شبیه سازی روش های حذف نویز

در این پژوهش، چهار روش حذف نویز که در بالا اشاره شد، مورد بررسی قرار می‌گیرد. برای شبیه‌سازی آن، نویز تصادفی با فرکانس بالا به سیگنال اضافه شده است. در شکل (۷)، سیگنال اصلی و سیگنال آلوده به نویز تصادفی نشان داده شده است. در شکل (۸)، نتایج حاصل از حذف نویز با استفاده از چهار روش فوق ارائه شده‌اند. همان‌طور که مشاهده می‌شود، روش ICA به تنهایی نتوانسته اطلاعات اصلی سیگنال را به خوبی حفظ کند.



شکل (۶): حد آستانه مشخص شده بر روی تبدیل والش، مولفه‌های ICA برای حذف نویز




شکل (۷): سیگنال اصلی و سیگنال دارای نویز

۳-۸-۱-ارزیابی عملکرد

برای مقایسه کارایی روش‌ها، از سه معیار استفاده شده است: الف) میانگین مربعات خطا (MSE)، ب) جذر میانگین مربعات اختلاف (RMSE) به صورت درصد و ج) نسبت سیگنال به نویز (SNR).

نسبت سیگنال به نویز

نسبت سیگنال به نویز معیاری برای مقایسه سطح سیگنال مفید با سطح نویز پس‌زمینه است. مقدار بالاتر این نسبت نشان‌دهنده کیفیت بهتر سیگنال بازسازی‌شده و حذف موفق‌تر نویز می‌باشد. در سیگنال‌های بیولوژیکی مانند EEG، معمولاً نسبت سیگنال به نویز پایین (حتی کمتر از صفر) است؛ بنابراین نزدیک شدن به مقدار صفر یا بیشتر از آن نشان‌دهنده عملکرد بهتر روش حذف نویز است.



شکل (۸): سیگنال حاصل از حذف نویز با استفاده از روش ICA، روش ترکیبی والش-ICA، تبدیل والش و تبدیل موجک

فرض کنید سیگنال ثبت شده ترکیبی از سیگنال اصلی EEG به صورت و نویز غیرمغزی باشد. در این صورت، سیگنال مشاهده شده به صورت رابطه زیر تعریف می شود:

$$s[t] = x[t] + n[t] \quad (۴)$$

بر اساس این رابطه، نسبت سیگنال به نویز از رابطه زیر بدست می آید.

$$SNR (dB) = 10 * \log \frac{\sum_{n=0}^N s(n)^2}{\sum_{n=0}^N x(n)^2} \quad (۵)$$


در شکل (۹)، مقادیر SNR برای ۱۰ نمونه از سیگنال های EEG، پس از حذف نویز با استفاده از چهار روش مورد بررسی، نمایش داده شده است. نتایج نشان می دهند که روش ترکیبی ICA و تبدیل والش بالاترین مقدار SNR را دارد و موفق ترین عملکرد را در حذف نویز از سیگنال ارائه داده است. همچنین روش تبدیل والش به تنهایی نیز نسبت سیگنال به نویز قابل قبولی ارائه کرده است.

میانگین مربع خطا


میانگین مربع خطا، یکی از معیارهای رایج برای ارزیابی دقت مدل های تخمین زننده است. این معیار، میانگین مربعات تفاوت بین مقدار واقعی و مقدار تخمینی را اندازه گیری می کند. مقدار MSE برآوردی از میزان خطای موجود در تخمین است. هرچه این مقدار کمتر باشد، نشان دهنده دقت بالاتر تخمین و نزدیکی بیشتر سیگنال حذف نویز شده به سیگنال اصلی خواهد بود. در صورتی که مقدار تخمینی دقیقاً با مقدار واقعی برابر باشد، مقدار MSE صفر خواهد بود که حالت ایده آل محسوب می شود. بنابراین، دامنه این معیار از صفر تا بی نهایت است و مقدار صفر بهترین وضعیت ممکن را نشان می دهد. برای محاسبه ی این معیار از رابطه ۶ استفاده می کنیم.

$$MSE = \frac{1}{MN} \sum_{m=1}^M \sum_{n=1}^N (ds(n, m) - s(n, m))^2 \quad (۶)$$

در این رابطه ds سیگنال حذف نویز شده و s سیگنال اصلی می باشد.




شکل (۹): نسبت سیگنال به نویز ده سیگنال



شکل (۱۰): میانگین مربع خطا برای ده سیگنال

در شکل (۱۰)، مقادیر MSE برای ده نمونه از سیگنال‌ها نمایش داده شده است. همان‌طور که مشاهده می‌شود، روش ترکیبی والش و ICA کمترین مقدار MSE را دارد که نشان‌دهنده عملکرد بهتر آن در حذف نویز است، در حالی که روش ICA بیشترین مقدار خطا را نشان می‌دهد.



شکل (۱۱): جذر میانگین تفاضل مربعات (درصد) برای ده سیگنال

جذر میانگین تفاضل مربعات (درصد)

این معیار، میانگین مربعات اختلاف بین سیگنال اصلی و سیگنال بازسازی‌شده را به صورت درصدی بیان می‌کند. PRD بیانگر میزان اعوجاج یا تحریف بین سیگنال اصلی و سیگنال حذف‌نویز شده است. به عبارت دیگر، هرچه مقدار این معیار کمتر باشد،

نشان‌دهنده شباهت بیشتر سیگنال بازسازی‌شده به سیگنال اصلی است، و در نتیجه عملکرد بهتر روش حذف نویز را نشان می‌دهد. این معیار از رابطه‌ی (۷) محاسبه می‌شود:

$$PRD = \sqrt{\frac{\sum_{n=0}^N (s(n) - x(n))^2}{\sum_{n=0}^N s(n)^2}} * 100\% \quad (7)$$

در این رابطه، $s(n)$ سیگنال اصلی و $x(n)$ سیگنال حذف‌نویز شده است. در شکل (۱۱)، مقدار PRD برای ده نمونه از سیگنال‌ها نمایش داده شده است. همان‌طور که مشاهده می‌شود، روش ترکیبی دارای بیشترین مقدار PRD و روش ICA کمترین مقدار را داراست. این نتایج، برتری روش ترکیبی را در بازسازی دقیق‌تر سیگنال نسبت به روش‌های دیگر نشان می‌دهد.

۳-۹- استخراج ویژگی

در این پژوهش، از تبدیل والش و مفهوم آنتروپی برای استخراج ویژگی بهره گرفته شده است. به منظور درک بهتر، ابتدا مفهوم آنتروپی را معرفی کرده و سپس روش‌های استخراج ویژگی مبتنی بر تبدیل فوریه، موجک، والش و آنتروپی را بررسی خواهیم کرد. در نهایت، دقت دسته‌بندی حاصل از این ویژگی‌ها با استفاده از دو الگوریتم طبقه‌بندی رایج یعنی ماشین بردار پشتیبان (SVM) و نزدیک‌ترین همسایه (KNN) مورد ارزیابی قرار می‌گیرد.

۳-۹-۱- استفاده از آنتروپی

برای محاسبه آنتروپی توالی، ابتدا تبدیل والش بر سیگنال EEG اعمال می‌شود و مقدار توالی هر نمونه به دست می‌آید. سپس با استفاده از مقادیر نرمال‌شده این توالی‌ها، توزیع احتمالاتی مربوط به آن‌ها محاسبه شده و با استفاده از رابطه آنتروپی (رابطه ۱۱) مقدار آنتروپی توالی به‌عنوان ویژگی استخراج می‌شود. در داده‌های متغیر مانند سیگنال که دارای تغییرات زیادی است، از این داده‌ها می‌توان اطلاعات مفید و ارزشمند را استخراج کرد این اطلاعات مفید آنتروپی می‌باشند که بی‌نظم و کاملاً تصادفی هستند [۷]. در یک داده متغیر، فرض کنید که متغیر تصادفی X حالت‌های سیستم را بیان می‌کند. مقدارهای متغیر X به صورت زیر هستند.

$$X = \{x_1, x_2, \dots, x_n\}, (N > 0) \quad (8)$$

و احتمال هر یک برابر است با :

$$P = \{p_1, p_2, \dots, p_n\}, 0 \leq p_i \leq 1, i = 1, 2, \dots, n \quad (9)$$

که باید داشته باشیم

$$\sum_{i=1}^n p_i = 1 \quad (10)$$

بنابر این اطلاعات آنتروپی از این سیستم به وسیله فرمول زیر بدست می‌آید:

$$H = \sum_{i=1}^n p_i \ln p_i \quad (11)$$

در این پژوهش همچنین ویژگی‌های حاصل از تبدیل فوریه و تبدیل موجک نیز برای مقایسه مورد استفاده قرار گرفته‌اند. در تبدیل فوریه، ویژگی‌هایی مانند انرژی باندهای فرکانسی مختلف و در تبدیل موجک، انرژی ضرایب در سطوح مختلف تجزیه به عنوان ویژگی استفاده شده است. نرخ دسته‌بندی برای هر یک از روش‌های استخراج ویژگی محاسبه شده و نتایج نشان می‌دهند که ویژگی‌های مبتنی بر آنتروپی توالی حاصل از تبدیل والش، عملکرد بهتری در تشخیص حرکات مختلف دست در سیگنال EEG دارند.

۳-۹-۲- استفاده از تبدل والش

در این تحقیق از تبدیل والش برای به‌دست آوردن یک ویژگی جدید به نام آنترپی توالی (Sequence Entropy) استفاده شده است. این نوع آنترپی معیاری برای سنجش میزان تغییرات و پیچیدگی سیگنال EEG پس از اعمال تبدیل والش می‌باشد. مراحل محاسبه آنترپی توالی بدین صورت است: ابتدا تبدیل والش بر سیگنال EEG اعمال می‌شود. خروجی این تبدیل مجموعه‌ای از ضرایب به نام است که بیانگر میزان توالی در نقطه از سیگنال می‌باشد. سپس چگالی توالی برای هر نقطه با استفاده از رابطه زیر محاسبه می‌شود:

$$\hat{P}(w_i) = \frac{1}{N} |X(w_i)|^2 \quad (12)$$

به منظور ساخت یک توزیع احتمال معتبر، چگالی‌ها نرمال می‌شوند

$$p_i = \frac{\hat{P}(w_i)}{\sum_i^n \hat{P}(w_i)} \quad (13)$$

۳-۹-۳- استفاده تبدیل فوریه و موجک

آنترپی طیف، یکی از شاخص‌های مهم برای سنجش میزان پیچیدگی سیگنال‌های زمانی است. این آنترپی بر پایه تحلیل طیف سیگنال تعریف می‌شود و نمایانگر مقدار اطلاعات تصادفی در حوزه فرکانس است. برای محاسبه آنترپی طیف، از تبدیل‌های متداول مانند تبدیل فوریه یا تبدیل موجک استفاده می‌شود که طیف سیگنال را به صورت تابعی از فرکانس نمایش می‌دهند. مراحل استخراج ویژگی به شرح زیر است:

۱. **محاسبه تبدیل فوریه یا موجک:** ابتدا تبدیل فوریه (یا موجک) سیگنال EEG را انجام می‌دهیم تا مؤلفه‌های فرکانسی در نقاط مختلف به دست آید.

۲. **محاسبه چگالی طیف:** برای هر نقطه، چگالی طیف طبق رابطه زیر محاسبه می‌شود:

$$\hat{P}(w_i) = \frac{1}{N} |X(w_i)|^2 \quad (14)$$

۳. **نرمال‌سازی چگالی طیف:** برای تبدیل مقادیر چگالی به مقادیر احتمال، از فرمول نرمال‌سازی زیر استفاده می‌کنیم:

$$P_i = \frac{\hat{P}(w_i)}{\sum_i^n \hat{P}(w_i)} \quad (15)$$

۴. **محاسبه آنترپی طیف:** در نهایت آنترپی طیف محاسبه می‌شود.

با توجه به موارد فوق در این پژوهش برای هر روش تبدیل، ۲۲ ویژگی از هر سیگنال استخراج شده است: ۱۰ ویژگی مربوط به آنترپی کانال‌های سیگنال، ۱ ویژگی مربوط به آنترپی کل سیگنال، ۱۰ ویژگی مربوط به توان کانال‌های سیگنال و ۱ ویژگی مربوط به توان کل سیگنال. با توجه به استفاده از سه روش تبدیل (فوریه، موجک، والش)، مجموعاً ۶۶ ویژگی از هر سیگنال استخراج شده و مبنای دسته‌بندی قرار گرفته‌اند.

۴- طبقه بندی به کمک ماشین بردار پشتیبان

اما در مرحله بعد از استخراج ویژگی لازم است طبقه بندی داده ها انجام گردد. ماشین بردار پشتیبان (SVM) یکی از روش‌های نسبتاً جدید و مؤثر در حوزه یادگیری ماشین برای طبقه‌بندی داده‌هاست که عملکرد بسیار بهتری نسبت به برخی روش‌های قدیمی‌تر مانند شبکه‌های عصبی در بسیاری از مسائل از خود نشان داده است. این الگوریتم یکی از روش‌های یادگیری


نظارت شده بوده و در شاخه روش های کرنلی قرار می گیرد. SVM هم برای شناسایی الگو و هم برای دسته بندی داده ها کاربرد دارد.

همان طور که پیش تر بیان شد، دو مجموعه داده برای آموزش و تست در نظر گرفته شده است:

مجموعه اول: ۱۶۰ داده ی آموزش و ۷۴ داده ی تست

مجموعه دوم: ۱۶۰ داده ی آموزش و ۷۳ داده ی تست

در هر مجموعه، چهار کلاس مختلف وجود دارد که هر کلاس شامل ۴۰ سیگنال و هر سیگنال شامل ۱۰ کانال است. برای هر سیگنال چهار نوع ویژگی از طریق تبدیل والش استخراج شده است. در این روش ابتدا از هر کانال، تبدیل والش گرفته شده، سپس آن تروپی توالی آن محاسبه می شود و برای هر سیگنال، ۱۰ مقدار به عنوان ویژگی به دست می آید. برای نمونه، در کلاس اول (حرکت دست به سمت راست)، ۴۰ سیگنال وجود دارد که هر کدام دارای ۱۰ کانال هستند؛ بنابراین برای هر کانال، ۴۰ مقدار آن تروپی به دست می آید که در شکل (۱۲) نمایش داده شده اند.




شکل (۱۲): آن تروپی توالی کانال های سیگنال های کلاس اول

پس با استفاده از این روش، برای هر سیگنال ۱۰ عدد بدست می آید. این اعداد از آن تروپی توالی هر کانال آن سیگنال بدست می آید. ماتریس ویژگی های استخراج شده، مبنای دسته بندی سیگنال ها قرار گرفته و در جدول (۱)، نرخ تشخیص برای مجموعه داده های اول و دوم با استفاده از الگوریتم های ماشین بردار پشتیبان (SVM) و نزدیک ترین همسایه (KNN) نشان داده شده است.

جدول (۱): نرخ تشخیص طبقه بندی کننده SVM و نزدیک ترین همسایه برای دو مجموعه داده بر اساس ویژگی های تبدیل والش

روش	نرخ تشخیص برای مجموعه داده		نرخ متوسط تشخیص برای دو مجموعه داده
	اول	دوم	
دسته بندی روش SVM	۴۴.۴۵	۳۹.۵۵	۴۲.۵٪
دسته بندی روش نزدیک ترین همسایه	۴۰.۵٪	۳۷.۵۲٪	۳۹.۰۱٪

با استفاده از تبدیل فوریه نیز همان چهار نوع ویژگی‌ای که با تبدیل والش استخراج شدند، به دست می‌آیند. برای استخراج این ویژگی، ابتدا تبدیل فوریه را بر روی هر کانال از سیگنال EEG اعمال می‌کنیم. سپس با استفاده از روش‌های مناسب، آنتروپی طیف هر کانال را محاسبه کرده و بردار ویژگی مربوطه را تشکیل می‌دهیم. برای مثال، در کلاس اول که مربوط به حرکت دست به سمت راست است، ۴۰ سیگنال برای استخراج ویژگی داریم. هر سیگنال شامل داده‌هایی از ۱۰ کانال است. بنابراین، برای هر کانال ۴۰ مقدار آنتروپی طیفی به دست می‌آید که بیانگر میزان آنتروپی سیگنال‌ها در آن کانال خاص است. در شکل (۱۳)، آنتروپی طیفی کانال‌ها برای کلاس اول نمایش داده شده است. به این ترتیب، بردار ویژگی شامل ۴۰۰ مقدار خواهد بود که آنتروپی کانال‌های مختلف برای سیگنال‌های این کلاس را نشان می‌دهد. در نهایت، برای هر سیگنال ۱۰ عدد (یک عدد برای هر کانال) به عنوان ویژگی استخراج می‌شود.




شکل (۱۳). آنتروپی تبدیل فوریه کانال‌های سیگنال‌های کلاس اول

پس از استخراج ویژگی‌ها، برای هر سیگنال یک بردار ویژگی ساخته می‌شود. با تشکیل ماتریس ویژگی‌ها، دقت طبقه‌بندی داده‌های مجموعه اول و دوم با استفاده از دو الگوریتم SVM و KNN در جدول (۲) ارائه شده است.

جدول (۲): نرخ تشخیص طبقه‌بندی کننده SVM و نزدیکترین همسایه برای دو مجموعه داده بر اساس ویژگی‌های تبدیل فوریه

روش	نرخ تشخیص برای مجموعه		نرخ متوسط تشخیص برای دو مجموعه داده
	داده اول	داده دوم	
SVM دسته بندی روش	۲۳٪	۲۱٪	۲۲٪
دسته بندی روش نزدیکترین همسایه	۲۱٪	۱۹٪	۲۰٪

با استفاده از تبدیل موجک نیز چهار نوع ویژگی مشابه با تبدیل والش استخراج می‌شود. ابتدا تبدیل موجک را بر روی هر کانال اعمال می‌کنیم و سپس با استفاده از روش‌های موجود، آنتروپی هر کانال را محاسبه کرده و بردار ویژگی را تشکیل می‌دهیم. برای مثال، در کلاس اول که شامل ۴۰ سیگنال و ۱۰ کانال است، برای هر کانال ۴۰ مقدار آنتروپی موجکی به دست می‌آید. در شکل (۱۴)، آنتروپی تبدیل موجک برای کلاس اول نمایش داده شده است. به این ترتیب، برای هر سیگنال ۱۰ ویژگی استخراج می‌شود.



شکل (۱۴): آنتروپی تبدیل موجک کانال‌های سیگنال‌های کلاس اول

در نهایت، همانند تبدیل والش، بردار ویژگی برای هر سیگنال ساخته می‌شود. پس از تشکیل ماتریس ویژگی‌ها، دقت طبقه‌بندی برای داده‌های مجموعه اول و دوم با استفاده از الگوریتم‌های SVM و KNN در جدول (۳) آمده است. برای مقایسه کلی ارزش ویژگی‌های استخراج‌شده، در جدول (۴) نرخ طبقه‌بندی سه روش مختلف ارائه شده است. همان‌طور که مشاهده می‌شود، ویژگی‌های استخراج‌شده با تبدیل والش عملکرد بهتری نسبت به دو روش دیگر دارند. علاوه بر دقت بالا، تبدیل والش از نظر سرعت اجرا نیز مزیت دارد، که آن را برای کاربردهای بلادرنگ مناسب می‌سازد. مجموع زمان مراحل آموزش، تست و استخراج ویژگی برای سه روش در جدول (۵) نمایش داده شده است.

جدول (۳): نرخ تشخیص طبقه‌بندی کننده SVM و نزدیکترین همسایه برای دو مجموعه داده بر اساس ویژگی‌های تبدیل موجک

نرخ متوسط تشخیص برای دو مجموعه داده	نرخ تشخیص برای مجموعه داده دوم	نرخ تشخیص برای مجموعه داده اول	روش
۲۸.۵٪	۲۶٪	۳۱٪	نرخ دسته‌بندی بر اساس SVM
۲۸.۵٪	۲۶٪	۳۱٪	دسته‌بندی روش نزدیکترین همسایه

جدول (۴): نتایج دسته‌بندی بر اساس ویژگی‌های سه روش

ویژگی‌های تبدیل موجک	ویژگی‌های تبدیل فوریه	ویژگی‌های تبدیل والش	نرخ دسته‌بندی بر اساس SVM
۲۸.۵٪	۲۲٪	۴۲.۵٪	نرخ دسته‌بندی بر اساس SVM
۲۸.۵٪	۲۰٪	۳۹.۰۱٪	نرخ دسته‌بندی بر اساس نزدیکترین همسایه

جدول (۵): مقایسه متوسط زمان اجرای تبدیل والش، تبدیل فوریه و تبدیل موجک

زمان	روش
۷۱ ثانیه	دسته‌بندی با ویژگی‌های تبدیل فوریه
۷۴ ثانیه	دسته‌بندی با ویژگی‌های تبدیل موجک
۵۲ ثانیه	دسته‌بندی با ویژگی‌های تبدیل والش

۴-۱- مقایسه با کارهای مرتبط بر روی این مجموعه داده

برای ارزیابی عملکرد روش پیشنهادی، نتایج حاصل با سایر روش‌هایی که پیش‌تر بر روی این مجموعه داده پیاده‌سازی شده‌اند، مقایسه شده است. در مسابقات BCI، چندین گروه بر روی این داده‌ها فعالیت داشته‌اند و روش‌های نفرت برتر (رتبه‌های اول تا چهارم) در سایت مسابقات منتشر شده‌اند. روش نفر اول، خانم حاجی‌پور از دانشگاه صنعتی شریف به سرپرستی دکتر شمس‌اللهی، شامل استخراج تعداد زیادی ویژگی آماری، فرکانسی و زمان-فرکانسی است. به دلیل زیاد بودن تعداد ویژگی‌ها، از الگوریتم ژنتیک برای انتخاب ویژگی‌های مؤثر استفاده شده و در نهایت دسته‌بندی با دو طبقه‌بند LDA و SVM خطی انجام شده است. هر طبقه‌بند سه بار اجرا شده و تصمیم نهایی با رأی‌گیری بین نتایج آن‌ها گرفته شده است.

نفر دوم، ابتدا با استفاده از فیلتر پایین‌گذر، سیگنال را پیش‌پردازش کرده و سپس با استفاده از تحلیل تفکیکی فیشر (FDA)، ویژگی‌های فرکانسی را کاهش داده و عمل دسته‌بندی را با تابع جداساز فیشر انجام داده است.

روش نفر سوم نیز از دانشگاه صنعتی شریف و تحت نظر دکتر شمس‌اللهی است. در این روش، از ویژگی‌های آماری، زمانی و ضرایب موجک استفاده شده و کاهش ویژگی‌ها با استفاده از PCA و الگوریتم ژنتیک انجام گرفته است. در مرحله دسته‌بندی، طبقه‌بند SVM خطی به کار گرفته شده است. در جدول (۶)، نتایج روش‌های فوق در کنار نتایج روش پیشنهادی در این مقاله نمایش داده شده است. همان‌طور که مشاهده می‌شود، نرخ تشخیص روش پیشنهادی نسبت به تمامی روش‌ها به جز روش نفر اول بالاتر است. همچنین، این روش از نظر زمان اجرا نیز برتری محسوسی دارد. متوسط زمان موردنیاز برای اجرای کل مراحل آموزش و تست حدود ۵۲ ثانیه است که این ویژگی، روش پیشنهادی را برای کاربردهای بلادرنگ مناسب می‌سازد.

جدول (۶): مقایسه متوسط زمان اجرای روش پیشنهادی با نفر اول مسابقات BCI و تبدیل فوریه و تبدیل موجک

روش	زمان
نفر اول در مسابقات BCI دسته‌بندی با استفاده از SVM	۴۰۳ ثانیه
نفر اول در مسابقات BCI دسته‌بندی با استفاده از LDA	۶۴۰ ثانیه
دسته‌بندی با ویژگی‌های تبدیل فوریه	۷۱ ثانیه
دسته‌بندی با ویژگی‌های تبدیل موجک	۷۴ ثانیه
دسته‌بندی با ویژگی‌های تبدیل والش	۵۲ ثانیه

جدول (۷): مقایسه نرخ تشخیص روش پیشنهادی با ۴ نفر اول مسابقات BCI

روش	نرخ تشخیص برای مجموعه داده اول	نرخ تشخیص برای مجموعه داده دوم	نرخ متوسط تشخیص برای دو مجموعه داده
نفر اول در مسابقات BCI	۵۹.۵٪	۳۴.۳٪	۴۶.۹٪
نفر دوم در مسابقات BCI	۳۱.۱٪	۱۹.۲٪	۲۵.۱٪
نفر سوم در مسابقات BCI	۱۶.۲٪	۳۱.۵٪	۲۳.۹٪
نفر چهارم در مسابقات BCI	۲۳٪	۱۸.۷٪	۲۰.۴٪
دسته بندی روش SVM	۴۴.۴۵٪	۳۹.۵۵٪	۴۲.۵٪
دسته بندی روش نزدیکترین همسایه	۴۰.۵٪	۳۷.۵۳٪	۳۹.۰۱٪

در جدول (۷)، زمان اجرای این روش با روش نفر اول و نیز روش‌های مبتنی بر تبدیل فوریه و موجک مقایسه شده است. همان‌طور که در جدول مشاهده می‌شود، زمان اجرای روش پیشنهادی بسیار کمتر از سایر روش‌هاست. لازم به ذکر است که

تمام روش‌ها بر روی سیستمی با مشخصات سخت‌افزاری 43.00 GHz Pentium و 1.00 GB RAM اجرا شده‌اند. همچنین زمان اجرای روش نفر اول بر اساس پیاده‌سازی آزمایشگاه پردازش سیگنال دانشگاه شریف برای SVM خطی و LDA به ترتیب ۴۰۳ و ۶۴۰ ثانیه گزارش شده است.

۵- نتیجه گیری

این پژوهش بر دو بخش اصلی تمرکز داشت: ابتدا، حذف نویز از سیگنال‌های EEG با ارزیابی چهار روش شامل ICA، تبدیل موجک، تبدیل والش، و ترکیب تبدیل والش با ICA انجام شد. نتایج نشان داد که تبدیل والش، چه به تنهایی و چه در ترکیب با ICA، بهترین عملکرد را در افزایش کیفیت سیگنال و کاهش نویز ارائه می‌دهد. سپس، به استخراج ویژگی و دسته‌بندی سیگنال‌ها پرداخته شد؛ جایی که ویژگی‌ها با استفاده از تبدیل والش و آنتروپی، تبدیل فوری و آنتروپی، و تبدیل موجک و آنتروپی استخراج و سپس با طبقه‌بندهای SVM و نزدیک‌ترین همسایه، دسته‌بندی شدند. در این مرحله نیز ویژگی‌های مبتنی بر تبدیل والش هم از نظر دقت و هم از نظر زمان اجرا، عملکرد بهتری را به نمایش گذاشتند که سادگی و هزینه محاسباتی پایین این تبدیل از مزایای مهم آن محسوب می‌شود. در نهایت، با مقایسه نتایج به‌دست‌آمده با داده‌های مسابقات BCI، مشخص شد که روش پیشنهادی، دقت تشخیص بالاتری نسبت به اکثر روش‌های دیگر (به جز نفر اول) دارد و از نظر زمان اجرا نیز به‌طور قابل توجهی سریع‌تر است (حدود ۳۵۰ ثانیه سریع‌تر از روش برنده مسابقات)، که این سرعت برای کاربردهای بلندرنج بسیار ارزشمند است. با این حال، لازم به ذکر است که نرخ‌های تشخیص کلی در این حوزه به دلیل پیچیدگی بالای سیگنال‌های EEG و شباهت زیاد بین کلاس‌های حرکتی، همچنان پایین هستند.

References

مراجع

- [1] R. G. Babu, P. Karthika, K. Elangovan, "Performance analysis for image security using SVM and ANN classification techniques", in Proc. 3rd Int. Conf. Electron., Commun. Aerosp. Technol. (ICECA), pp. 460–466, 2019.
- [2] A. Swetapadma, A. Yadav, A. Y. Abdelaziz, "Intelligent schemes for fault classification in mutually coupled series-compensated parallel transmission lines", *Neural Comput. Appl.*, vol. 32, no. 11, pp. 6939–6956, 2020.
- [3] BCI Competition IV - Dataset Results. Available at: <http://www.bbc.de/competition/iv/>, Accessed: May 5, 2025.
- [4] A. Hyvarinen, J. Karhunen, E. Oja, *Independent Component Analysis - Theory and Applications*. New York, NY, USA: Springer, 2010.
- [5] G. Baghdadi, F. Hadaeghi, C. Kamarajan, "Multimodal approaches to investigating neural dynamics in cognition and related clinical conditions: Integrating EEG, MEG, and fMRI data", *Front. Syst. Neurosci.*, vol. 19, pp. 149–158, 2025.
- [6] S. A. Hosseini, M. Houshmand, "Analysis of the EEG Signal Using Higher-Order Spectra (HOS) in the Neuro-marketing Application", *New Marketing Research Journal*, vol. 12, no. 1, pp. 25–42, 2022.
- [7] S. A. Othman, K. M. Omar, "An enhanced shrinkage function for denoising economic time series data using wavelet analysis", *Sci. J. Univ. Zakho*, vol. 12, no. 1, pp. 138–143, 2024.
- [8] N. Boukhennoufa, Y. Laamari, R. Benzid, "Signal denoising using a low computational translation-invariant-like strategy involving multiple wavelet bases: Application to synthetic and ECG signals", *Metrol. Meas. Syst.*, pp. 259–278, 2024.
- [9] S. M. Najeeb, H. T. Al Rikabi, S. M. Ali, "Finding the discriminative frequencies of motor electroencephalography signal using genetic algorithm", *TELKOMNIKA (Telecommun. Comput. Electron. Control)*, vol. 19, no. 1, pp. 285–292, 2021.
- [10] T. F. Zaidi, O. Farooq, "EEG sub-bands based sleep stages classification using Fourier Synchrosqueezed transform features", *Expert Syst. Appl.*, vol. 212, p. 118752, 2023.