

Recognition of Motor Imagery Based on Dynamic Features of Electroencephalography Signals

Negar Dashti^{1,2}, M.Sc, Mahdi Khezri^{1,2}, Assistant Professor

1. Department of Electrical Engineering, Najafabad Branch, Islamic Azad University, Najafabad, Iran
2. Digital Processing and Machine Vision Research Center, Najafabad Branch, Islamic Azad University, Najafabad, Iran
negar.dashti@ymail.com,
mahdi.khezri@pel.iaun.ac.ir

Abstract:

The control of artificial limbs can be done by distinguishing the patterns of imagined movement using the Electroencephalography (EEG) signals. The aim of this study was to identify hand and foot imagery movements based on EEG signals. The IVA dataset of BCI Competition III, which includes EEG signals from 5 healthy individuals in C3, C4 and CZ channels, was used to design the imagery movements detection system. Initially, the basic components of EEG signal noise were removed using the MSPCA method. In the next step, the EEG signals were decomposed in two different ways including frequency filtering using the Butterworth filter and the wavelet packet transform (WPT). In this study, the detrended Fluctuation analysis, Fractal dimension, Correlation dimension, Lempel-ziv complexity and Entropy as nonlinear dynamics features, were calculated for the signals. In both decomposition methods, the desired features were calculated for the temporal version of the specified subbands. In order to determine the best performance of the system, different combinations of the channels and the features were evaluated. The wavelet-based decomposition method, in the case of using all three channels and five features, provided the highest recognition accuracy; So that using support vector machine (SVM) classification method, the accuracy of 93% was obtained in identifying the desired movements.

Keywords: Motor imagery, Classification, Nonlinear features, Wavelet transform, SVM.

Received: 25 April 2020

Revised: 24 June 2020

Accepted: 24 July 2020

Corresponding Author: Dr. Mahdi Khezri

Citation: N. Dashti, M. Khezri, "Recognition of motor imagery based on dynamic features of electroencephalography signals", Journal of Intelligent Procedures in Electrical Technology, vol. 11, no. 43, pp. 13-27, Spring 2020 (in Persian).

شناسایی حرکات تصور شده بر مبنای ویژگی‌های دینامیکی سیگنال الکتروانسفالوگرافی

نگار دشتی^{۱،۲}، دانش‌آموخته کارشناسی ارشد، 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

negar.dashti@ymail.com

mahdi.khezri@pel.iaun.ac.ir

چکیده: کنترل اندام‌های مصنوعی می‌تواند از طریق تفکیک الگوهای تصور حرکت با استفاده از سیگنال‌های الکتروانسفالوگرافی (EEG) انجام شود. هدف از انجام این مطالعه تشخیص تصور حرکات دست و پا بر مبنای سیگنال EEG است. مجموعه آزمون-های IVA از داده‌های BCI Competition III که شامل سیگنال‌های EEG ثبت شده از ۵ فرد سالم و در سه کانال C3، C4 و Cz است، برای طراحی سیستم تشخیص حرکات تصور شده به کار رفت. در ابتدا، با استفاده از روش تحلیل مولفه اصلی چند مقیاسی (MSPCA) اجزای اساسی نويز سیگنال EEG حذف شدند. در مرحله بعد، سیگنال‌های EEG با دو روش مختلف شامل فیلترینگ فرکانسی با استفاده از فیلتر باتوروث و روش تبدیل بسته ویولت (WPT) به بخش‌هایی تجزیه شدند. در این مطالعه، تجزیه و تحلیل نوسانات تفکیک شده، بعد فرکتال، بعد همبستگی، پیچیدگی لیمپل-زیو و آنتروپی به‌عنوان ویژگی‌های دینامیکی برای سیگنال‌ها محاسبه شدند. ویژگی‌های مورد نظر در هر دو روش تجزیه، برای نسخه زمانی زیرباندهای تعیین شده محاسبه شدند. به‌منظور تعیین بهترین عملکرد سیستم، ترکیب‌های متفاوتی از کانال‌ها و ویژگی‌ها مورد ارزیابی قرار گرفتند. روش تجزیه بر مبنای تبدیل ویولت، در حالت استفاده از هر سه کانال و پنج ویژگی، بالاترین دقت تشخیص را ارائه کرد؛ به‌گونه‌ای که با استفاده از روش طبقه‌بندی ماشین بردار پشتیبان (SVM)، دقت ۹۳ درصد در شناسایی حرکات مورد نظر به‌دست آمد.

کلمات کلیدی: تصور حرکت، طبقه‌بندی، ویژگی‌های غیرخطی، تبدیل ویولت، SVM.

تاریخ ارسال مقاله: ۱۳۹۹/۲/۶

تاریخ بازنگری مقاله: ۱۳۹۹/۴/۴

تاریخ پذیرش مقاله: ۱۳۹۹/۵/۳

نام نویسنده‌ی مسئول: دکتر مهدی خضری

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

۱- مقدمه

حرکت دادن یک عضو بدن یا حتی منقبض کردن یک ماهیچه، تغییراتی را در فعالیت قشر مغز ایجاد می‌کند. در واقع حرکت یا تصور حرکت، ریتم‌های حسی-حرکتی و حرکتی مغز را تحت تأثیر قرار می‌دهد. بنابراین ثبت و بررسی سیگنال‌های الکتروانسفالوگرام^۱ (EEG) می‌تواند به‌عنوان ابزاری برای شناسایی حرکات تصور شده مدنظر قرار گیرد. با پیشرفت سیستم‌های کامپیوتری و روش‌های پردازش، کسب اطلاعات از سیگنال‌های EEG توسط واسط‌های مغز-کامپیوتر^۲ (BCI) انجام می‌شود؛ که وظیفه آن پردازش سیگنال‌های مغزی و ایجاد ارتباط بین مغز و دنیای بیرون است. امروزه از این سیستم‌ها به‌عنوان دستگاه‌هایی برای تایپ، بازی‌های رایانه‌ای، کنترل عوامل محیطی، کنترل ابزار و سیستم‌های حرکتی جایگزین شده‌ی اندام-های بدن استفاده می‌شود [۱،۲]. علاوه بر این کاربر را قادر می‌سازند تا ترکیبی از دستورات را اجرا کند؛ به‌عنوان مثال فرد می‌تواند عمل نوشتن را انتخاب و سپس جمله مورد نظر خود را توسط یک سیستم BCI بنویسد [۳]. اطلاعات فرکانسی سیگنال EEG، به‌ویژه در زیرباند‌های آلفا (۸-۱۳ هرتز) و بتا (۱۳-۳۲ هرتز) برای تصور حرکت و زیرباند گاما (۳۲-۶۰ هرتز) در سیستم‌های BCI تهاجمی دارای اهمیت بیشتری هستند [۴].

مطالعات گذشته در تشخیص نوع تصور حرکت را می‌توان با توجه به روش‌های استفاده شده در بخش‌های مختلف سیستم، مورد ارزیابی قرار داد. به‌عنوان مثال: در سال ۲۰۰۹ میلادی منگ و همکارانش از روش الگوی فضای مشترک^۳ (CSP) برای انتخاب کانال‌های مطلوب و همچنین برای استخراج ویژگی‌ها استفاده کردند. روش ماشین بردار پشتیبان^۴ (SVM) با کرنل تابع پایه شعاعی^۵ (RBF) برای طبقه‌بندی حرکات مورد نظر به کار رفت. استفاده از CSP به‌همراه روش انتخاب کانال نرم L_1 برای انتخاب کانال‌های موثر در چهار فرد شرکت‌کننده، دقت‌های تشخیص ۷۶ درصد تا ۹۶ درصد را به‌دست آورد که در مقایسه با حالت بدون انتخاب کانال، نتایج بهتری ارائه کردند [۵]. لی و همکارانش الگوهای سیگنال EEG در تصور حرکات مختلف را با استفاده از الگوریتم تجزیه زیرفضای مشترک^۶ (CSSD) و طبقه‌بندی کننده SVM شناسایی کردند و دقت طبقه‌بندی ۸۵/۹ درصد را کسب کردند [۶]. سیگنال‌ها از پنج فرد سالم که حرکات دست چپ و راست و پای راست را انجام دادند، ثبت شدند. برای بهبود الگوریتم CSSD، دو پارامتر کنترلی در نظر گرفته شدند. سپس با استفاده از الگوریتم بهبودیافته، ویژگی‌های سیگنال‌ها را استخراج کردند. با اعمال پارامترهای کنترلی، دقت شناسایی سیستم در تصورات حرکت بیش از ۱۰ درصد بهبود را نشان داد. رابینسون و همکارانش دسته‌بندی حرکات سریع و آرام دست بر مبنای الگوهای سیگنال EEG را مورد بررسی قرار دادند. ویژگی‌های سیگنال‌ها با استفاده از الگوریتم الگوی فضای مشترک موجک^۷ (W-CSP) استخراج شدند؛ دقت میانگین ۸۳/۷۱ درصد برای طبقه‌بندی سرعت حرکت در زیرباند‌های سیگنال به‌دست آمد [۷]. آرتیفکت‌های سیگنال حرکات چشم^۸ (EOG)، با استفاده از روش تحلیل مولفه مستقل^۹ (ICA) حذف شدند. سپس الگوریتم W-CSP برای استخراج ویژگی‌ها و طبقه‌بندی کننده خطی فیشر^{۱۰} (FLD) برای شناسایی الگوهای حرکتی مورد نظر به کار رفتند.

سیولی و همکارانش روش همبستگی متقابل مبتنی بر رگرسیون منطقی^{۱۱} (CC-LR) را در سه مجموعه برای طبقه‌بندی تصور حرکت از روی سیگنال EEG به کار بردند. دنباله‌های همبستگی با استفاده از روش همبستگی متقابل^{۱۲} (CC) برای کانال‌های مختلف سیگنال EEG نسبت به کانال مرجع C_3 تعیین شدند. سپس ویژگی‌های آماری از هر دنباله همبستگی در سه مجموعه شامل مجموعه اول: میانگین و انحراف استاندارد، مجموعه دوم: دو ویژگی مجموعه اول به‌همراه چولگی و کشیدگی و مجموعه سوم شامل ویژگی‌های قبلی و ماکزیمم و مینیمم تعیین شدند. میانگین دقت طبقه‌بندی، ۶۵/۸ درصد برای مجموعه اول، ۸۲/۲ درصد برای مجموعه دوم و ۹۳/۳ درصد برای مجموعه سوم به‌دست آمدند [۸]. سورسن و همکارانش به بررسی مشخصه-های مرتبط با راه رفتن حقیقی و تصور آن پرداختند. علاوه بر این، تأثیر پیچیدگی راه رفتن بر عملکرد دسته‌بندی مورد بررسی قرار گرفت. دقت سیستم برای شناسایی راه رفتن ثابت^{۱۳} (CW)، راه رفتن تطبیقی^{۱۴} (AW)، راه رفتن مجازی با سرعت ثابت^{۱۵} (ICW) و راه رفتن مجازی تطبیقی^{۱۶} (IAW) به ترتیب ۷۹ درصد، ۷۸ درصد، ۷۰ درصد و ۶۹ درصد به‌دست آمد [۹]. ما و همکارانش در سال ۲۰۱۷ میلادی روشی برای استخراج ویژگی‌های EEG بر اساس ترکیب تبدیل موجک و آنتروپی ارائه دادند. در مطالعه آن‌ها دقت طبقه‌بندی ۸۸/۹ درصد برای شناسایی حرکات تصور شده به‌دست آمد [۱۰]. انشایی فر و همکارانش الگوریتم فضایی مشترک جدید^{۱۷} (QCSP) را برای مدل کردن ارتباط بین کانال‌ها معرفی کردند. از این روش برای

استخراج ویژگی‌ها به منظور ایجاد تمایز بین حرکات دست چپ و راست استفاده کردند؛ و دقت طبقه‌بندی ۷۰ درصد به دست آوردند. علاوه بر این، روش پیشنهادی برای تمایز بین بیماران مبتلا به بیماری پارکینسون^{۱۸} (PD) و افراد سالم مورد استفاده قرار گرفت و دقت ۸۷ درصد را ارائه کرد [۱۱].

ژولین ما و همکارانش از روشی مبتنی بر یادگیری عمیق برای شناسایی سه نوع تصور حرکت شامل حالت استراحت، تصور حرکت دست راست و بازوی راست استفاده کردند [۱۲]. ماتریس همبستگی شامل ضرایب همبستگی بین الکترودها به عنوان ویژگی‌های مورد نظر و شبکه کانال-همبستگی^{۱۹} برای یادگیری ارتباط بین کانال‌ها به کار رفتند. برای بهبود عملکرد سیستم، ترکیب خروجی چندین شبکه‌ی کانال-همبستگی در این مطالعه مورد توجه قرار گرفت و دقت ۸۷/۰۳ درصد برای شناسایی سه نوع تصور حرکت مورد نظر به دست آمد.

در این تحقیق به بررسی الگوهای مرتبط با حرکات تصور شده با استفاده از سیگنال EEG اشاره می‌شود. در مطالعات گذشته با وجود استفاده از روش‌های با پیچیدگی بالا، نتایج سیستم در شناسایی حرکات با تطبیق الگوهای سیگنال EEG بهبود چندانی نداشته است. به علاوه سیستم‌های ارائه شده دقت شناسایی مطلوبی ارائه نکرده‌اند. در این مطالعه، بهبود عملکرد سیستم در شناسایی حرکات تصور شده، در کنار کاهش پیچیدگی از اهداف مورد نظر هستند. استفاده از روش‌های پردازشی کارآمد در مراحل آماده‌سازی و کاهش اثرات نویزی، تجزیه سیگنال‌های مورد استفاده به دلیل کاهش تغییرات سیگنال‌ها و همچنین به کار بردن ویژگی‌های دینامیکی با توجه به ماهیت تغییرپذیر و پویای سیگنال‌های EEG در این مطالعه مورد توجه قرار گرفت. ویژگی‌های دینامیکی سیگنال EEG، شامل تجزیه و تحلیل نوسانات تفکیک شده، بعد فرکتال، بعد همبستگی، پیچیدگی لیمپل زیو و آنتروپی مورد استفاده قرار می‌گیرند. علاوه بر این به منظور تعیین بهترین عملکرد سیستم و همچنین بررسی امکان ساده‌سازی سیستم، ترکیب‌های گوناگونی از کانال‌ها و ویژگی‌های استخراج شده برای طراحی سیستم ارزیابی می‌شوند. در ادامه به معرفی روش‌های استفاده شده در طراحی سیستم خواهیم پرداخت. سپس در بخش‌های سوم و چهارم نتایج به دست آمده و نتیجه‌گیری‌ها در رابطه با عملکرد سیستم ارائه خواهند شد.

۲- مواد و روش‌ها

۲-۱- ثبت سیگنال EEG

در این تحقیق مجموعه داده IVA از BCI Competition III مورد استفاده قرار گرفته است. سیگنال‌های EEG ثبت شده به طور پیوسته و از ۵ فرد سالم در طول تصور حرکات مورد نظر جمع‌آوری شده‌اند [۱۳]. همه شرکت‌کننده‌ها در طول آزمایش بر روی یک صندلی راحت نشسته و دست آن‌ها در حالت استراحت بوده است. در طول آزمایش برای هر فرد علامتی بر حسب نوع تصور حرکتی که باید انجام دهد، نمایش داده شده است. به طوری که با نمایش علامت برای مدت ۳/۵ ثانیه، فرد تصور حرکات پای راست، دست راست و دست چپ را به مدت ۲ ثانیه انجام داده است. سیگنال‌های EEG در ۱۱۸ کانال، با آرایش ۲۰-۱۰ و پس از عبور از یک فیلتر میان‌گذر با باند عبور بین فرکانس‌های ۰/۵ تا ۲۰۰ هرتز ثبت شده‌اند. فرکانس نمونه‌برداری برای ثبت سیگنال ۱۰۰۰ هرتز تنظیم شده است. برای کاهش حجم محاسبات از داده‌های نمونه کاهش یافته با فرکانس نمونه‌برداری ۱۰۰ هرتز استفاده می‌شود.

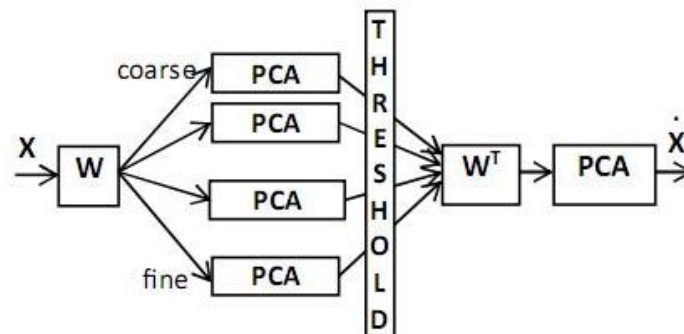
۲-۲- انتخاب کانال

در این مطالعه از سه کانال C₃، C₄ و C_Z به عنوان مرجع اطلاعات تصور حرکت استفاده شده است. مکان الکتروود C₃، C₄ و C_Z حاوی اطلاعات مهمی از منطقه‌ی قشر حرکتی است. قابل ذکر است که اطلاعات مرتبط با حرکت دست راست معمولاً در بالای قشر حرکتی سمت چپ که در اطراف الکتروود C₃ قرار دارد، مشاهده می‌شوند. همچنین اطلاعات مرتبط با حرکت دست چپ معمولاً در بالای قشر حرکتی سمت راست که در اطراف الکتروود C₄ قرار دارد، یافت می‌شوند. به همین طریق، حرکت‌های پا در اطراف الکتروود C_Z مشاهده می‌شوند. لذا با توجه به این نکات و نتایج تحقیقات گذشته، ۳ کانال C₃، C₄ و C_Z به عنوان مرجعی از اطلاعات در مورد تصور حرکات دست و پا انتخاب شده‌اند [۱۴-۱۶]. در واقع سه کانال مذکور را در مطالعات انجام

شده به این دلیل انتخاب کرده‌اند که دارای اطلاعات متمایزتری در زمینه عملکردهای حسی حرکتی در طول حرکات دست و پا هستند.

۲-۳- پیش پردازش

بر روی سیگنال EEG، نویزها و اثرات تداخلی زیادی قرار می‌گیرند که می‌توانند باعث کاهش کیفیت و قابلیت سیگنال در کاربرد مورد نظر شوند. روش‌های خطی حذف نویز به‌طور قابل توجهی قسمت‌های تیز سیگنال (که در آن تغییرات سیگنال سریع است) را از بین می‌برند. این مسأله باعث از بین رفتن اطلاعات مهمی از سیگنال می‌شود. در این مطالعه، پس از انتخاب کانال از روش غیرخطی تحلیل مولفه اصلی چند مقیاسی^{۲۰} (MSPCA) برای حذف نویز بدون کاهش قابل توجه تغییرات سریع سیگنال، استفاده شد. سیگنال رفع نویز شده نسبت به سیگنال اصلی دارای تغییرات ناگهانی کمتر و مشخصه هموارتری است. روش MSPCA را مطابق با شکل (۱) می‌توان در چند مرحله خلاصه کرد [۱۷]. در مرحله اول، تبدیل موجک تمام سیگنال-های موجود را تجزیه می‌کند. در این مرحله سطح تجزیه موجک برابر با ۵ و موجک مادر سیملت^{۲۱} (SYM4) انتخاب شدند. در مرحله بعد، الگوریتم تحلیل مولفه اصلی^{۲۲} (PCA) به‌صورت جداگانه بر روی بخش‌های تجزیه شده اجرا می‌شود. سپس ضرایبی از تبدیل موجک که از مقدار آستانه از پیش انتخاب شده بیشتر باشند، حفظ می‌شوند. برای انجام درست حذف نویز، معمولاً با استفاده از معیار کایزر آستانه از روی مقدار ویژه بزرگ‌تر از میانگین مقادیر ویژه‌ها به دست می‌آید. در مرحله سوم، تبدیل موجک معکوس اعمال و در نهایت برای سیگنال به‌دست‌آمده، PCA اعمال می‌شود. با اعمال مراحل ذکر شده سیگنال رفع نویز شده به‌دست می‌آید. نمونه‌ای از سیگنال حذف نویز شده به‌همراه نسخه خام سیگنال در شکل (۲) نشان داده شده است.




شکل (۱): مراحل مختلف الگوریتم MSPCA [۱۴]
 Figure (1): Different steps of MSPCA algorithm [14]

۲-۴- تجزیه سیگنال‌های مغزی

سیگنال EEG دارای طیف فرکانسی غالب در بازه ۰/۵ تا ۵۰ هرتز است. در این مرحله سیگنال‌های EEG با دو روش مختلف به زیرسیگنال‌هایی تجزیه شدند. در روش اول، سیگنال‌های ورودی با توجه به طیف فرکانسی‌شان، به ۵ زیرباند و در روش دوم، با استفاده از تبدیل موجک، به ۱۶ زیر سیگنال تجزیه شدند.

۲-۴-۱- روش اول: تجزیه سیگنال‌ها به زیر باندهای فرکانسی

در این روش که یکی از متداول‌ترین روش‌های تجزیه سیگنال EEG است، سیگنال‌ها به ۵ زیر باند دلتا، تتا، آلفا، بتا و گاما که به ترتیب دارای مولفه‌های فرکانسی بین ۰/۵ تا ۴ هرتز، ۴ تا ۸ هرتز، ۸ تا ۱۳ هرتز، ۱۳ تا ۳۰ هرتز و ۳۰ تا ۵۰ هرتز هستند، تجزیه می‌شوند. در این مطالعه از فیلتر باترورث با مرتبه‌ی ۲ برای تجزیه سیگنال‌های ورودی به زیرباندهای آنها استفاده شده است.



شکل (۲): سیگنال EEG خام اولیه و سیگنال رفع نویز شده با روش MSPCA در حوزه‌ی زمان
Figure (2): Recorded raw EEG signal and noise reduced version using MSPCA method in time domain


۲-۴-۲- روش دوم: تجزیه به روش موجک

در این روش با استفاده از روش بسته موجک (WPD)²³ سیگنال‌ها به زیرباندهایی تجزیه می‌شوند. برای سطح تجزیه ابتدایی $j=1$ ، سیگنال $x(k)$ از فیلترهای بالاگذر و پایین‌گذر یعنی $h(\cdot)$ و $g(\cdot)$ عبور می‌کند. خروجی هر سطح تجزیه j به شکل دو سیگنال ارایه می‌شود؛ که یکی به نام ضرایب جزئیات (D_j) و دیگری به عنوان ضرایب تقریب (A_j) شناخته می‌شوند. این توابع با روابط زیر تعیین می‌شوند [۱۴]:

$$D_j[i] = \sum_k x[k]h[2i - k] \tag{1}$$

$$A_j[i] = \sum_k x[k]g[2i - k] \tag{2}$$

با ورود به مرحله و سطح تجزیه بعد، تقریب A_j معادل با $x(k)$ در نظر گرفته و تجزیه سیگنال دوباره انجام می‌شود. فرایند ذکر شده جهت تولید D_j و A_j تا زمانی تکرار می‌شود که j سبب کاهش j_m (سطح تجزیه سیگنال مورنظر) نشود. تجزیه بسته موجک (WPD)، تعمیم یافته تبدیل موجک گسسته (DWT)²⁴ است، که در آن ضرایب جزئیات D_j علاوه بر ضرایب A_j تجزیه می‌شوند. این سبب ایجاد تعداد متفاوتی از مجموعه ضرایب در روش می‌شود. روش WPD تعداد 2^j مجموعه از ضرایب را تولید می‌کند. این روش وضوح فرکانسی مطلوب‌تری را در مقایسه با روش DWT ارایه می‌دهد؛ زیرا شاهد از دست رفتن اطلاعات در اجزای فرکانس بالا نیستیم. شکل (۳) تجزیه WPD را در دو سطح تجزیه نشان می‌دهد. در مطالعه ما، تعداد سطوح مقیاس برای WPD برابر با ۴ انتخاب شد. این منجر به ایجاد $2^4=16$ زیر باندها می‌شود.



شکل (۳): روش تجزیه‌ی WPD با سطح مقیاس ۲ [۱۴]
Figure (3): WPD method with two levels of decomposition [14]

۲-۵- بخش بندی سیگنال‌ها


در مرحله‌ی قبل سیگنال‌های رفع نویز شده با دو روش مختلف به سیگنال‌هایی با طول و فرکانس‌های مختلف تجزیه شدند. در روش اول تجزیه، سیگنال‌های به دست آمده (نسخه زمانی سیگنال‌ها در هر زیرباند فرکانسی) دارای طول زمانی نسبتاً زیاد

هستند. لذا ابتدا هر یک از سیگنال‌های به‌دست‌آمده از روش تجزیه اول را به بخش‌های مساوی تقسیم نموده و سپس ویژگی‌های موردنظر را از هر کدام از آنها استخراج کردیم. لازم به‌ذکر است که در روش دوم تجزیه (با استفاده از تبدیل موجک)، چون سیگنال‌های به‌دست‌آمده دارای طول زمانی کوچک و مناسب هستند، نیاز به بخش‌بندی آن‌ها وجود ندارد. لازم به‌ذکر است که پس از تجزیه سیگنال‌ها با دو روش ذکر شده، مراحل پردازش بعدی (بخش بندی، استخراج ویژگی‌ها و ..) بر روی نسخه زمانی زیرباندهای تعیین شده انجام شدند.

برای بخش‌بندی سیگنال‌های به‌دست‌آمده در روش اول تجزیه، از پنجره همینگ استفاده کردیم. پنجره همینگ با طول ۱۰۰ نمونه (با توجه به فرکانس نمونه‌برداری که ۱۰۰ است، طول پنجره برابر با یک ثانیه خواهد بود) و گام ۱۰ نمونه بر روی سیگنال حرکت و در آن ضرب شد. هر بخش به‌دست‌آمده از ضرب پنجره‌ی همینگ در سیگنال اصلی، یک فریم نام دارد. در نتیجه هر یک از سیگنال‌های تجزیه‌شده با توجه به طول زمانی که دارند به چندین فریم تقسیم‌بندی شدند. در ادامه ویژگی‌های موردنظر از هر یک از این فریم‌ها استخراج شدند و در نهایت با میانگین‌گیری از ویژگی‌های استخراج‌شده از همه‌ی فریم‌ها، ویژگی سیگنال تجزیه‌شده به دست آمد. در شکل (۴) نمونه‌ای از یک سیگنال EEG به مدت ۱/۵ ثانیه (۱۵۰ نمونه) به‌همراه فریم‌های آن را مشاهده می‌کنیم. لازم به‌ذکر است که در این شکل فقط برای بهتر دیده شدن، فریم‌ها به‌صورت زیر هم ترسیم شده‌اند.

۲-۶- استخراج ویژگی‌ها

پس از بخش‌بندی سیگنال به فریم‌ها در روش اول تجزیه (مبتنی بر زیرباندهای فرکانسی)، ۵ ویژگی غیرخطی از هر یک از فریم‌ها استخراج شدند. در نهایت با میانگین‌گیری ویژگی‌های به‌دست‌آمده از همه فریم‌ها، مقدار هر یک از ویژگی‌های موردنظر برای سیگنال تعیین شدند. همانطور که قبلاً اشاره کردیم، در روش تجزیه مبتنی بر تبدیل موجک، دیگر نیازی به بخش‌بندی سیگنال وجود ندارد. از این‌رو با تجزیه سیگنال اصلی، هر یک از ویژگی‌ها از سیگنال زمانی ۱۶ زیرباند ایجاد شده استخراج شدند. در این پژوهش، ۵ ویژگی غیرخطی شامل: تجزیه و تحلیل نوسانات تفکیک‌شده، بعد فرکتال، بعد همبستگی، پیچیدگی لیمپل-زیو و آنتروپی برای تشخیص تصور حرکت مورد استفاده قرار گرفتند. در ادامه به‌معرفی هر یک از این ویژگی‌ها می‌پردازیم.



شکل (۴): نمونه‌ای از سیگنال EEG به همراه فریم‌های تعیین شده آن پس از انجام بخش بندی

Figure (4): An example of an EEG signal with the determined frames after segmentation

۲-۶-۱- ویژگی اول: تجزیه و تحلیل نوسانات تفکیک‌شده

تجزیه و تحلیل نوسانات تفکیک شده (DFA)²⁵، یک روش برای اندازه‌گیری خواص همبستگی درسیگنال است. مزیت استفاده از DFA در این است که بین نوسانات ذاتی تولید شده توسط سیستم و تولید شده از خارج (نویزها)، تفاوت قایل می‌شود [۱۸].

برای محاسبه‌ی DFA برای سیگنال زمانی $x(t)$ با طول محدود N ، ابتدا مقدار میانگین $x(t)$ مطابق با رابطه‌ی 3 از سیگنال کاسته می‌شود و سیگنال $y(k)$ به دست می‌آید.

$$y(k) = \sum_{i=1}^k [x(i) - \langle x \rangle] \quad (3)$$

در این رابطه، مقدار $\langle x \rangle$ برابر با میانگین x است؛ که با رابطه‌ی زیر تعیین می‌شود:

$$\langle x \rangle = \frac{1}{N} \sum_{i=1}^N x(i) \quad (4)$$

پس از به دست آوردن سری زمانی، سیگنال به بخش‌های کوچک‌تری با طول یکسان تقسیم بندی می‌شود؛ که هر یک از این بخش‌ها را یک جعبه از سیگنال نام‌گذاری می‌کنیم. پس از این مرحله، خطی با استفاده از معیار خطای حداقل مربعات بر روی داده‌های هر جعبه منطبق می‌شود که آنها را با $y_n(k)$ نشان می‌دهیم. سپس سری زمانی $y(k)$ با کم کردن خط منطبق شده در هر جعبه، از آن کاهش می‌یابد. نوسانات تفکیک شده سپس با محاسبه جذر میانگین مربعات، مطابق با رابطه‌ی زیر به دست می‌آید:

$$F(n) = \sqrt{\frac{1}{N} \sum_{k=1}^N [y(k) - y_n(k)]^2} \quad (5)$$

رابطه‌ی (۶) رابطه بین طول جعبه‌ها (مقیاس زمانی) و $F(n)$ را نشان می‌دهد. می‌توان این رابطه را برای طول‌های مختلفی از جعبه محاسبه کرد. رابطه‌ی خطی بین لگاریتم $F(n)$ و طول هر جعبه نشان‌دهنده‌ی حضور مقیاس توان است.

$$F(n) \sim n^\alpha \quad (6)$$

می‌توان مقیاس توان یا α را با اندازه‌گیری شیب نمودار $\log(F(n))$ نسبت به $\log(n)$ محاسبه کرد. این پارامتر نشان‌دهنده‌ی خواص همبستگی یک سری زمانی است [۱۶].

۲-۶-۲-ویژگی دوم: ابعاد فرکتال (های گوچی)

های گوچی الگوریتمی برای اندازه‌گیری ابعاد فرکتال یک سری زمانی است که مقدار پیچیدگی و خودهمسانی سیگنال مورد استفاده را تعیین می‌کند [۱۹]. مقدار های گوچی به‌طور مستقیم در حوزه‌ی زمان قابل محاسبه است و به‌همین دلیل ساده و سریع است. برای سری زمانی

$$x[1], x[2], \dots, x[n] \quad (7)$$

مقدار های گوچی فراکتال به‌صورت زیر قابل محاسبه است. اگر طبق رابطه‌ی (۸) تعداد k سری زمانی جدید برای $m = 1, 2, \dots, k$ ساخته شده باشد:

$$x_m^k = \left\{ x[m], x[m+k], \dots, x \left[m + \left\lfloor \frac{N-m}{k} \right\rfloor k \right] \right\} \quad (8)$$

[۱۰] بیانگر قسمت حقیقی و N طول سیگنال است. طول هر k سری زمانی با رابطه‌ی زیر تعریف می‌شود:

$$L_m(k) = \frac{1}{k} \frac{\sum_{i=1}^{\lfloor \frac{N-m}{k} \rfloor} |x(m+ik) - x(m+(i-1)k)| \times (N-1)}{\left\lfloor \frac{N-m}{k} \right\rfloor} \quad (9)$$

طول متوسط برای هر سری زمانی با همان تاخیر k ، به عنوان میانگین k ام طول $L_m(k)$ برای $m = 1, 2, \dots, k$ محاسبه می‌شود. این فرایند برای تمامی مقادیر k از k_{\min} تا k_{\max} تکرار می‌شود. مجموع میانگین هر k مقدار طول $L(k)$ ، به صورت زیر محاسبه می‌شود:

$$L(k) = \sum_{m=1}^k L_m(k) \quad (10)$$

در صورتی که خطی با معیار حداقل مربعات خطا بر روی نمودار $\ln(L(k))$ بر حسب $\ln(1/k)$ منطبق کنیم، شیب خط نشان‌دهنده‌ی تخمین مقدار بعد فراکتال داده‌های مورد استفاده است. از روش مقاله [۲۰]. برای تعیین مقدار k_{\min} و k_{\max} در این مطالعه استفاده شده است. مقادیر $k_{\min}=1$ و $k_{\max}=30$ به این ترتیب در نظر گرفته شدند.

۲-۶-۳- ویژگی سوم: ابعاد همبستگی

ابعاد سیگنال قادر است اطلاعات زیادی در مورد ماهیت یک سیستم ارائه دهد. ابعاد فراکتال یک روش غیرخطی است که برای تقریب ابعاد یک سیگنال استفاده می‌شود [۲۱]. در صورتی که سری زمانی $x = [x(1), x(2), \dots, x(N)]$ را با N نمونه داده در نظر بگیریم، با انتخاب مقدار تاخیر زمانی τ و بعد جاسازی m ، می‌توان یک بردار m بعدی را بازسازی کرد:

$$X(i) = [x(i), x(i + \tau), \dots, x(i + (m-1)\tau)] \quad i = 1, 2, \dots, N - (m-1)\tau \quad (11)$$

احتمال اینکه نقاط مجموعه در یک سلول با شعاع r قرار داشته باشند، با رابطه C نشان داده شده است.

$$C(r) = \frac{2}{N(N-1)} \sum_{i \neq j} \theta(r - |X(i) - X(j)|) \quad (12)$$

که $C(r)$ انتگرال همبستگی است و θ تابع پله هویسایدی است که به صورت زیر تعریف می‌شود:

$$\begin{aligned} \theta(x) &= 0 & \text{if } x < 0 \\ \theta(x) &= 1 & \text{if } x > 0 \end{aligned} \quad (13)$$

ابعاد همبستگی را می‌توان از روی مقدار شیب $\log(C(r))$ نسبت $\log(r)$ تخمین زد:

$$d = \lim_{r \rightarrow 0} \left[\frac{\log C(r)}{\log(r)} \right] \quad (14)$$

این فرایند با افزایش m تکرار می‌شود. با افزایش بعد جاسازی m ، مقدار d تا زمانی که به مقدار اشباع برسد افزایش پیدا می‌کند. مقدار اشباع d به عنوان ابعاد همبستگی تعریف می‌شود. در این مطالعه، ابعاد همبستگی با مقدار تاخیر زمانی τ با استفاده از روش حداقل اطلاعات متقابل تعیین می‌شود [۲۱]. همچنین مقدار برای ابعاد جاسازی از ۳ تا ۱۵ تنظیم شده است.

۲-۶-۴- ویژگی چهارم: پیچیدگی لیمپل-زیو

تجزیه و تحلیل پیچیدگی لیمپل-زیو یا به اختصار پیچیدگی (LZ) مبتنی بر یک تحلیل دانه درشت²⁸ از سیگنال مورد نظر است. قبل از محاسبه پیچیدگی لیمپل-زیو، $C(n)$ برای هر سیگنال اندازه‌گیری شده، سیگنال باید به یک دنباله‌ی متناهی تبدیل شود. در زمینه‌ی تجزیه و تحلیل سیگنال‌های حیاتی، معمولاً سیگنال گسسته $x(n)$ به یک دنباله‌ی باینری تبدیل می‌شود. اطلاعات سیگنال در مقایسه با یک حد آستانه T_h به یک دنباله‌ی ۰ و ۱ تبدیل می‌شوند؛ که این دنباله P به صورت زیر تعریف می‌شود [۲۲]:

$$P = s(1), s(2), \dots, s(n) \quad (15)$$

که داریم:

$$s(i) = \begin{cases} 0 & \text{if } x(i) < T_d \\ 1 & \text{otherwise} \end{cases} \quad (16)$$

به‌طور معمول، میانه به دلیل مقاوم بودن در برابر ناهنجاری‌ها به‌عنوان حد آستانه، مورد استفاده قرار می‌گیرد [۲۳]. تحقیقات گذشته نشان می‌دهد که تبدیل ۱۰ سیگنال برای تخمین پیچیدگی LZ در سیگنال‌های حیاتی مناسب است [۲۴]. به‌منظور محاسبه‌ی پیچیدگی LZ، دنباله‌ی P از چپ و راست اسکن می‌شود و هر بار که به یک زیردنباله از کاراکترهای متوالی برخورد کنیم، شمارنده‌ی پیچیدگی c(n) یک واحد افزایش پیدا می‌کند. به‌منظور به‌دست آوردن یک معیار پیچیدگی که به طول دنباله وابسته نیست، c(n) باید نرمالیزه شود. اگر طول مجموعه برابر با n و تعداد نمادهای متفاوت درون مجموعه نمادها برابر با α باشد، قابل اثبات است که مقدار c(n) کمتر از مقدار زیر است:

$$c(n) < \frac{n}{(1 - \beta_n) \log_\alpha^{(n)}} \quad (17)$$

β_n دارای مقدار کمی است؛ به‌طوری‌که $\beta_n \rightarrow 0$ وقتی $n \rightarrow \infty$. به‌طور کلی $\frac{n}{\log_\alpha^{(n)}}$ حد بالای c(n) است، که مبتنی بر لگاریتم α است یعنی:

$$\lim_{n \rightarrow \infty} c(n) = b(n) = \frac{n}{\log_\alpha^{(n)}} \quad (18)$$

برای یک مجموعه‌ی ۰ و ۱ داریم $\alpha=2$ ، پس خواهیم داشت:

$$b(n) = \frac{n}{\log_2^{(n)}} \quad (19)$$

و می‌توان c(n) را با استفاده از b(n) نرمالیزه کرد، به‌طوری‌که:

$$C(n) = \frac{c(n)}{b(n)} \quad (20)$$

که C(n) برابر با مقدار نرمالیزه شده‌ی پیچیدگی LZ است، که نشان دهنده‌ی نرخ ناگهانی الگوهای جدید در مجموعه است.

۲-۶-۵- ویژگی پنجم: آنتروپی

مقدار آنتروپی برای هر مجموعه‌ی $A = \langle a_1, a_2, \dots, a_M \rangle$ با طول M به‌صورت زیر قابل تعریف است:

$$H_w(A) = \sum_{i=1}^M (-P_w(a_i) \log(P_w(a_i))) \quad (21)$$

که $P_w(a_i)$ تخمینی از چگالی احتمال a_i است. از روش کرنل چگالی که پنجره‌ی پارزن نیز نامیده می‌شود، می‌توان برای تخمین مقدار چگالی احتمال $P_w(a_i)$ استفاده کرد:

$$P_w(a_i) = \frac{1}{M |a_i - a_{i+w}|} \sum_{j=1}^M K \left(\frac{a_i - a_j}{|a_i - a_{i+w}|} \right) \quad (22)$$

که K تابع کرنل مناسب و مقدار w حقیقی و بزرگ‌تر از صفر است. زیرنویس w در H و P نشان‌دهنده پارامتر عرض است که در تخمین تراکم کرنل استفاده می‌شود. دو تابع کرنل گوسین و اپانچنیکوف را می‌توان برای این منظور به‌کار برد که به‌ترتیب به‌صورت زیر تعریف می‌شوند [۲۵]:

تابع کرنل گوسی

$$K(x) = \frac{1}{\sqrt{2}} e^{-\frac{1}{2}x^2} \quad (23)$$

و تابع کرنل اپانچنیکو

$$K(x) = \begin{cases} \frac{3}{4}(1-x^2) & \text{if } |x| < 1 \\ 0 & \text{otherwise} \end{cases} \quad (24)$$

۳- نتایج به دست آمده

پس از محاسبه ویژگی‌ها، تشخیص نوع حرکات تصور شده با استفاده از طبقه‌بندی کننده صورت می‌گیرد. در این مرحله از ماشین بردار پشتیبان (SVM) استفاده کردیم. در این مرحله سعی شده است تمام حالت‌های ممکن برای کسب بهترین مقدار دقت در نتایج طبقه‌بندی کننده بررسی شود. در این راستا از تعداد ویژگی، تعداد کانال و مقدار k متفاوت (در روش اعتبارسنجی k -fold) استفاده شده است. عملکرد سیستم برای ترکیبات مختلف پنج ویژگی استخراج شده و کانال‌های ثبت سیگنال، مورد بررسی قرار گرفت. علاوه بر این در روش SVM، انواع توابع کرنل مورد ارزیابی قرار گرفتند.

چهار حالت، برای طراحی سیستم و تشخیص نوع تصور حرکت مدنظر قرار گرفت. حالت اول: یک کانال، یک ویژگی؛ حالت دوم: یک کانال، پنج ویژگی؛ حالت سوم: سه کانال، یک ویژگی و در نهایت حالت چهارم: سه کانال، پنج ویژگی مورد بررسی قرار گرفتند. در حالت چهارم از ماتریس ویژگی به دست آمده برای هر سه کانال و همه پنج ویژگی استخراج شده استفاده شد. روش SVM برای تشخیص نوع تصور حرکت با تابع کرنل RBF به دلیل کسب نتایج بهتر پیاده‌سازی شده است. در این حالت با استفاده از روش جست‌وجوی شبکه، دو پارامتر روش یعنی پارامتر پیچیدگی c و اپسیلون برای خطای گرد کردن، در بهترین مقدار از لحاظ دقت تشخیص، انتخاب شدند. در واقع با تغییر این دو پارامتر در بازه‌ی مشخص، بهترین نتیجه جست‌وجو شده و در نهایت بالاترین مقدار دقت گزارش داده می‌شود.

۳-۱- حالت اول: یک کانال، یک ویژگی

در این حالت یک ویژگی از هر کانال استخراج شده است. برای هر سیگنال در روش اول تجزیه یعنی تجزیه فرکانسی، ۵ ویژگی و در روش تجزیه دوم با تبدیل بسته موجک، ۱۶ ویژگی به دست آمد. در جدول (۱) مقدار دقت تشخیص نوع تصور حرکت برای دو روش تجزیه آمده است. ویژگی آنتروپی در هر دو روش تجزیه سیگنال در مقایسه با سایر ویژگی‌ها، نتایج بهتری را کسب کرده است. در روش تجزیه اول، ویژگی آنتروپی در کانال Cz با کسب دقت ۸۰٪ عملکرد موفقی را ارایه کرده است. همچنین با روش تجزیه دوم و ویژگی آنتروپی در کانال C۳، دقت تشخیص ۸۵٪ ثبت شده است.

۳-۲- حالت دوم: یک کانال، پنج ویژگی

در این حالت همه ۵ ویژگی استخراج شده از یک کانال برای تشخیص نوع تصور حرکت مورد استفاده قرار گرفتند. به این ترتیب برای هر سیگنال در روش تجزیه فرکانسی ۲۵ ویژگی، و در روش تجزیه موجک ۸۰ ویژگی به دست آمد. در جدول (۲) مقدار دقت تشخیص کسب شده با استفاده از روش SVM در حالت دوم طراحی سیستم نمایش داده شده است. با توجه به نتایج ارایه شده، با اعمال همه ویژگی‌ها، روش تجزیه موجک در کانال Cz با کسب دقت تشخیص ۸۸٪، بهترین عملکرد را ارایه کرده است.

همچنین مشاهده می‌شود که روش تجزیه بر مبنای تبدیل موجک، در کانال‌های متناظر در مقایسه روش تجزیه فرکانسی، بهتر عمل کرده است. با روش تجزیه فرکانسی، کانال C۴ و با روش تجزیه موجک، کانال Cz به طور کلی دقت تشخیص بالاتری ارایه کرده‌اند.

جدول (۱): نتایج به دست آمده در حالت اول (یک کانال، یک ویژگی)

Table (1): Results obtained in the first case (one channel, one feature)

روش تجزیه بر مبنای تبدیل موجک			روش تجزیه به زیرباندهای فرکانسی			نوع ویژگی
دقت	کانال	مقدار k	دقت	کانال	مقدار k	
۷۹٪	Cz	۸ و ۷	۷۵٪	C۳	۸ و ۷	تجزیه و تحلیل نوسانات تفکیک شده
۸۰٪	Cz	۹ و ۸	۷۴٪	Cz	۷	ابعاد فرکتال
۷۸٪	Cz	۸ و ۷	۷۶٪	C۳ و Cz	۸ و ۷	ابعاد همبستگی
۷۷٪	C۴ و C۳	۹	۷۶٪	Cz	۹ و ۸	پیچیدگی لیمپل- زیو
۸۵٪	C۳	۸ و ۷	۸۰٪	Cz	۸	آنتروپی

جدول (۲): نتایج به دست آمده در حالت دوم (یک کانال، پنج ویژگی)

Table (2): Results obtained in the second case (one channel, five features)

روش تجزیه بر مبنای تبدیل موجک					روش تجزیه به زیرباندهای فرکانسی						
کانال Cz		کانال C۴		کانال C۳		کانال Cz		کانال C۴		کانال C۳	
دقت	k	دقت	k	دقت	k	دقت	k	دقت	K	دقت	K
۸۸٪	۷ و ۶	۸۷٪	۸ و ۷	۸۷٪	۸ و ۷	۸۴٪	۹ و ۸ و ۷	۸۵٪	۷	۸۲٪	۹

۳-۳- حالت سوم: سه کانال، یک ویژگی

در این حالت هر کدام از ویژگی‌های استخراج شده از هر سه کانال به طور جداگانه برای تشخیص نوع تصور حرکت استفاده شده- اند. در این حالت برای هر سیگنال در روش تجزیه فرکانسی، ۱۵ ویژگی و در روش تجزیه موجک، ۴۸ ویژگی به دست آمده است. در جدول (۳) مقدار دقت تشخیص نوع تصور حرکت در این حالت و در مقادیر مختلفی از k نمایش داده شده است. با توجه به نتایج ارائه شده در جدول شماره (۳)، مشاهده می‌شود که در هر دو روش تجزیه، ویژگی‌های تجزیه و تحلیل نوسانات تفکیک شده و آنتروپی عملکرد بهتری ارائه کرده‌اند. ویژگی آنتروپی در روش تجزیه اول با کسب دقت ۷۹٪ و در روش تجزیه دوم با کسب دقت ۸۱٪ بالاترین دقت تشخیص را به دست آورده است. در این حالت هر ویژگی برای هر سه کانال ثبت سیگنال، محاسبه و اعمال شده است.

جدول (۳): نتایج به دست آمده در حالت سوم (سه کانال، یک ویژگی)

Table (3): Results obtained in the third case (three channels, one feature)

روش تجزیه بر مبنای تبدیل موجک		روش تجزیه به زیرباندهای فرکانسی		نوع ویژگی
دقت	مقدار k	دقت	مقدار k	
۸۰٪	۹ و ۸	۷۸٪	۹ و ۸	تجزیه و تحلیل نوسانات تفکیک شده
۷۵٪	۹ و ۸	۷۲٪	۸ و ۷	ابعاد فرکتال
۷۸٪	۹	۷۶٪	۹	ابعاد همبستگی
۷۹٪	۸	۷۴٪	۹ و ۸	پیچیدگی لیمپل- زیو
۸۱٪	۸ و ۷	۷۹٪	۷	آنتروپی

۳-۴- حالت چهارم: سه کانال، ۵ ویژگی

در این حالت پنج ویژگی استخراج شده از هر سه کانال برای تشخیص نوع تصور حرکت استفاده شده‌اند. در این حالت برای هر سیگنال در روش تجزیه فرکانسی ۷۵ ویژگی، و در روش تجزیه موجک ۲۴۰ ویژگی به‌دست آمده است. در جدول (۴) مقدار دقت تشخیص نوع تصور حرکت در این حالت و با استفاده از شبکه SVM و در مقادیر مختلف k نمایش داده شده است. با توجه به نتایج ارایه شده، دیده می‌شود که روش تجزیه برمبنای تبدیل موجک، عملکرد بهتری در تشخیص تصور حرکات به-دست آورده است. بالاترین دقت کسب شده در این حالت برابر با ۹۳٪ به‌دست آمده است، که تأییدکننده عملکرد مطلوب روش ارایه شده است. همچنین دقت تشخیص به‌دست آمده با روش تجزیه فرکانسی با اعمال همه ویژگی‌ها و کانال‌ها قابل ملاحظه است.

جدول (۴): نتایج به‌دست آمده در حالت چهارم (سه کانال، پنج ویژگی)
 Table (4): Results obtained in the fourth case (three channels, five features)

دقت		K
روش تجزیه برمبنای تبدیل موجک	روش تجزیه به زیرباندهای فرکانسی	
۸۸٪	۸۶٪	۶
۹۰٪	۸۷٪	۷
۹۳٪	۸۷٪	۸
۸۹٪	۸۷٪	۹
۸۷٪	۸۶٪	۱۰

با توجه به اینکه یکی از نیازمندی‌های مورد توجه در سیستم‌های تشخیص حرکات تصور شده ساده بودن سیستم در هنگام ثبت و نیاز به کمترین تعداد الکترودهاست، لذا عملکرد هریک از کانال‌های مورد استفاده در این مطالعه مورد ارزیابی قرار گرفت. جدول (۵) نتایج به‌دست آمده برای هریک از کانال‌های ثبت سیگنال را ارایه می‌کند. هر سطر از جدول نشان دهنده بهترین دقت سیستم برای هریک از کانال‌های C۳، C۴ و Cz برای ویژگی‌های استفاده شده است. همچنین سطر آخر نتایج حالتی است که همه ویژگی‌ها در هر یک از کانال‌ها استفاده شده‌اند. اختلاف قابل توجهی در نتایج به‌دست آمده در استفاده از کانال‌های مختلف دیده نمی‌شود؛ اما به طور خیلی جزئی عملکرد کانال‌های C۴ و Cz بهتر بوده است. به این ترتیب می‌توان از تعداد کانال‌های کمتر حتی مثلا یک کانال برای طراحی مطلوب سیستم استفاده کرد. همچنین با توجه به نتایج، قابلیت ویژگی آنتروپی برای تخمین نوع تصور حرکت به‌خوبی قابل مشاهده است. به‌گونه‌ای که در بسیاری از موارد، نتایج آن در مقایسه با اعمال همه ویژگی‌ها بهتر بوده است.

جدول (۵): بهترین دقت تشخیص تصور حرکات موردنظر برای هر یک از کانال‌های ثبت سیگنال.

Table (5): The best recognition accuracy of the desired imagery movements for each of the signal recording channels.

دقت			ویژگی استفاده شده
کانال Cz	کانال C۴	کانال C۳	
۷۹٪	۷۸٪	۷۷٪	تجزیه و تحلیل نوسانات تفکیک‌شده
۸۰٪	۷۹٪	۷۹٪	ابعاد فرکتال
۷۸٪	۷۷٪	۷۷٪	ابعاد همبستگی
۷۶٪	۷۷٪	۷۷٪	پیچیدگی لیمپل-زیو
۸۴٪	۸۴٪	۸۵٪	آنتروپی
۸۳٪	۸۳٪	۸۲٪	همه

۴- بحث و نتیجه‌گیری

در مطالعه حاضر، طراحی سیستم تشخیص تصور حرکات با استفاده از ویژگی‌های دینامیکی استخراج شده از سیگنال‌های EEG که با دو روش مختلف تجزیه شده بودند، مورد بررسی قرار گرفت. تجزیه سیگنال‌ها بر مبنای زیر باندهای فرکانسی و همچنین تجزیه بر مبنای تبدیل موجک انجام شد. پنج ویژگی شامل تجزیه و تحلیل نوسانات تفکیک شده، ابعاد فرکتال، ابعاد همبستگی، پیچیدگی لیمپل-زیو و آنتروپی با ترکیبات مختلف به طبقه‌بندی کننده SVM اعمال شدند تا حرکات تصور شده را شناسایی کنند.

نتایج علاوه بر تغییر تعداد ویژگی‌ها، با تغییر تعداد کانال‌های مورد استفاده سیگنال و همچنین مقدار k در روش اعتبارسنجی k -fold ارزیابی شدند. اثر هر یک از پارامترهای ذکر شده در عملکرد سیستم مورد بررسی قرار گرفت. با توجه به نتایج به دست آمده بهترین مقدار k در روش اعتبارسنجی برابر با ۷ یا ۸ انتخاب شد. همچنین نتایج کسب شده در مورد عملکرد هر یک از کانال‌ها برای تخمین نوع تصور حرکت نشان می‌دهد که اختلاف قابل توجهی در نتایج به دست آمده از کانال‌های مختلف دیده نمی‌شود. به عنوان مثال ویژگی آنتروپی با روش تجزیه موجک برای هر یک از کانال‌های $C3$ ، $C4$ و Cz به ترتیب دقت‌های تشخیص ۸۵٪، ۸۴٪ و ۸۴٪ کسب کرده است. لازم به ذکر است که با توجه به نتایج، قابلیت ویژگی آنتروپی برای تخمین نوع تصور حرکت به خوبی قابل مشاهده است. به گونه‌ای که در بسیاری از موارد، نتایج آن در مقایسه با اعمال همه ویژگی‌ها بهتر بوده است.

همان‌طور که بیان شد، در این پژوهش از دو نوع روش تجزیه برای سیگنال EEG استفاده شده است. نتایج بیانگر آن است که تجزیه سیگنال به روش موجک برای تخمین نوع تصور حرکت دارای عملکرد بهتری است؛ هر چند این امر می‌تواند به دلیل بیشتر بودن تعداد ویژگی‌های تعیین شده برای زیرباندها باشد. بهترین حالت برای تخمین نوع تصور حرکت با استفاده از همه‌ی ویژگی‌های استخراج شده از هر سه کانال، برای k برابر با ۸ با دقت ۹۳٪ ثبت شده است. همچنین با استفاده از تنها ویژگی آنتروپی و یک کانال ($C3$) مقدار دقت برابر با ۸۵٪ به دست آمده است. در این حالت با وجود کاهش دقت نسبت به اعمال همه ویژگی‌ها، میزان محاسبات به طرز قابل توجهی کاهش یافته است.

جدول (۶) نتایج کسب شده و روش‌های مورد استفاده در بعضی از سیستم‌های تشخیص تصور حرکت و مطالعه حاضر را ارائه می‌کند. در مقایسه با مطالعات گذشته، عملکرد سیستم در شناسایی سه نوع تصور حرکت قابل ملاحظه است. در حالت استفاده از همه ویژگی‌ها دقت تشخیص کسب شده حتی در مقایسه با مطالعات با تعداد کلاس‌های کمتر، بالاتر از نتایج گزارش شده قبلی است. به علاوه اینکه در بسیاری از مطالعات قبلی روش‌های پردازشی با پیچیدگی محاسباتی بالا مورد استفاده قرار گرفته‌اند. در روش ارائه شده در این مطالعه در صورتی که بخواهیم بهترین دقت را داشته باشیم، لازم است پردازش نسبتاً زیادی برای استخراج همه‌ی ۵ ویژگی از هر ۳ کانال داشته باشیم که این امر برای کاربردهای بلادرنگ سیستم مطلوب نیست. اما با این حال با استفاده از تنها بعضی از ویژگی‌ها، همان‌طور که در نتایج کسب شده مشاهده شد، عملکرد سیستم همچنان قابل توجه خواهد بود و سرعت پاسخ‌دهی نیز بهبود خواهد یافت.

References

مراجع

- [1] B. Blankertz, G. Dornhege, M. Krauledat, K. Müller, G. Curio, "The non-invasive Berlin Brain-computer interface: fast acquisition of effective performance in untrained subjects", *NeuroImage*, vol. 37, pp. 539-550, Aug. 2007 (doi: 10.1016/j.neuroimage.2007.01.051).
- [2] E.W. Sellers, E. Donchin, "A P300-based brain-computer interface: initial tests by ALS patients", *Clin Neurophysiol*, vol. 117, pp. 538-548, Mar. 2006 (doi: 10.1016/j.clinph.2005.06.027).
- [3] X. Gao, D. Xu, M. Cheng, S. Gao, "A BCI-based environmental controller for the Motion disabled", *IEEE Trans on Neural Systems and Rehabilitation Engineering*, vol. 11, no. 2, pp. 137-140, Jun. 2003 (doi: 10.1109/TNSRE.2003.814449).
- [4] B. Graimann, B. Allison, G. Pfurtscheller, "Brain-computer interfaces: A gentle introduction", In: Graimann B., Pfurtscheller G., Allison B. (eds) *Brain-Computer Interfaces*. The Frontiers Collection. Springer, Berlin, Heidelberg, pp. 1-27, 2010 (doi: 10.1007/978-3-642-02091-9_1).

جدول (۶): مقایسه روش‌های به کار رفته و نتایج کسب شده در تشخیص تصور حرکت در این مطالعه و بعضی از مطالعات گذشته

Table (6): Comparison of the methods used and the results obtained in identifying the imagined movements in this work and some previous studies

دقت تشخیص	روش‌های استفاده شده	تعداد حرکات	شماره مرجع مطالعه انجام شده
۶۵٫۸٪-۹۳٫۳٪	روش همبستگی متقابل مبتنی بر رگرسیون منطقی (CC-LR)، ویژگی‌های میانگین، انحراف استاندارد، چولگی و کشیدگی، ماکزیمم و مینیمم به همراه طبقه‌بندی کننده رگرسیون لجستیک (LR)	۲ حرکت دست راست و دست چپ	[۸]
۸۸٫۹٪	تبدیل موجک برای حذف نویز، آنتروپی به عنوان ویژگی و روش تفکیک کننده خطی فیشر برای طبقه‌بندی	۲ حرکت دست راست و دست چپ	[۱۰]
۷۰٪	روش الگوهای فضایی مشترک چهارگانه تعمیم یافته (G-QCSP) برای استخراج ویژگی‌ها و روش SVM به عنوان طبقه‌بندی کننده	۲ حرکت دست راست و دست چپ	[۱۱]
۸۷٫۰۳٪	ماتریس همبستگی به عنوان ویژگی‌ها و شبکه کانال-همبستگی چندگانه برای طبقه بندی	۳ حرکت (دست و بازوی راست و استراحت)	[۱۲]
متغیر، بهترین دقت ۹۳٪	ترکیبات مختلف ویژگی‌های دینامیکی شامل تجزیه و تحلیل نوسانات تفکیک شده، بعد فرکتال، بعد همبستگی، پیچیدگی لیمپل-زیو و آنتروپی و SVM به عنوان طبقه‌بندی کننده	۳ حرکت (دست و پای راست، دست چپ)	مطالعه حاضر

- [5] J. Meng, G. Liu, G. Huang, X. Zhu, "Automated selecting subset of channels based on CSP in motor imagery brain-computer interface system", IEEE International Conference on Robotics and Biomimetics (ROBIO), Guilin, China, pp. 2290-2294, Dec. 2009 (doi: 10.1109/ROBIO.2009.5420462).
- [6] M. Li, C. Lu, "The recognition of EEG with CSSD and SVM", Proceedings of the IEEE/WCICA, Beijing, China, pp. 4741-4746, Nov. 2012 (doi: 10.1109/WCICA.2012.6359377).
- [7] N. Robinson, A.P. Vinod, K.K. Ang, K.P. Tee, C.T. Guan, "EEG-based classification of fast and slow hand movements using wavelet-CSP algorithm", IEEE Trans on Biomedical Engineering, vol. 60, no. 8, pp. 2123-2132, Aug. 2013 (doi: 10.1109/TBME.2013.2248153).
- [8] Y. Siuly, P. Li, P. Wen, "Modified CC-LR algorithm with three diverse feature sets for motor imagery tasks classification in EEG based brain computer interface", Comput Methods Programs Biomed, vol. 113 no.13, pp. 767-780, Jan. 2014 (doi: 10.1016/j.cmpb.2013.12.020).
- [9] M. Severens, M. Perusquia-Hernandez, B. Nienhuis, J. Farquhar and J. Duysens, "Using Actual and Imagined Walking Related Desynchronization Features in a BCI", IEEE Trans Neural Syst Rehabil Eng, vol. 23, no. 5, pp. 877-886, Sept. 2015 (doi: 10.1109/TNSRE.2014.2371391).
- [10] M. Ma, L. Guo, K. Su and D. Liang, "Classification of motor imagery EEG signals based on wavelet transform and sample entropy", 2017 IEEE 2nd Advanced Information Technology, Electronic and Automation Control Conference (IAEAC), Chongqing, China, pp. 905-910, Oct. 2017 (doi: 10.1109/IAEAC.2017.8054145).
- [11] S. Enshaefar, C. C. Took, C. Park and D. P. Mandic, "Quaternion Common Spatial Patterns", IEEE Trans Neural Syst Rehabil Eng, vol. 25, no. 8, pp. 1278-1286, Aug. 2017 (doi: 10.1109/TNSRE.2016.2625039).
- [12] X. Ma, S. Qiu, W. Wei, S. Wang and H. He, "Deep Channel-Correlation Network for Motor Imagery Decoding from the Same Limb", IEEE Trans. Neural Syst Rehabil Eng, vol. 28, no. 1, pp. 297-306, Jan. 2020 (doi: 10.1109/TNSRE.2019.2953121).
- [13] B. Blankertz, K.R. Müller, D.J. Krusienski, G. Schalk, J.R. Wolpaw, A. Schlögl, G. Pfurtscheller, R.M. Jdel, M. Schröder, N. Birbaumer, "The BCI competition III: Validating alternative approaches to actual BCI problems", IEEE Tans Neural Syst Rehabil Eng, vol. 14, no. 2, pp. 153-159, Jun. 2006 (doi: 10.1109/TNSRE.2006.875642).
- [14] J. Kevric, and Subasi, "Comparison of signal decomposition methods in classification of EEG signals for motor-imagery BCI system". Biomed Signal Process Control, vol. 31, pp.398-406, Jan. 2017 (doi: 10.1016/j.bspc.2016.09.007).
- [15] J.A. Wilson, G. Schalk, L.M. Walton, J.C. Williams, "Using an EEG-Based brain-computer interface for virtual cursor movement with BCI2000", J. Vis Exp. vol.29, Jul. 2009 (doi: 10.3791/1319).

- [16] B. Hosseinifard, M.H. Moradi and R. Rostami, "Classifying depression patients and normal subjects using machine learning techniques and nonlinear features from EEG signal", *Comput methods programs biomed*, vol.109, no.3, pp.339-345, Mar. 2013 (doi: 10.1016/j.cmpb.2012.10.008).
- [17] B.R. Bakshi, "Multiscale PCA with application to multivariate statistical process monitoring", *AIChE*. Vol. 44, no.7, pp. 1596–1610, Jul. 1998 (doi: 10.1002/aic.690440712).
- [18] C. Peng, J. Hausdorff, A. Goldberger, "Fractal Mechanisms in Neural Control: Human Heartbeat and Gait Dynamics in Health and Disease", In: Walleczek J, ed. *Self-Organized Biological Dynamics and Nonlinear Control*. Cambridge: Cambridge University Press, 2000.
- [19] R. Esteller, G. Vachtsevanos, J. Echauz, B. Litt, "A comparison of waveform fractal dimension algorithms", *IEEE Trans Circuits Syst, I, Fundam Theory Appl*, vol. 48, no.2, pp. 177–183, Feb. 2001 (doi: 10.1109/81.904882).
- [20] C. Go'mez, A. Mediavilla, R. Hornero, D. Aba'solo, A. Ferna'ndez, "Use of the Higuchi's fractal dimension for the analysis of MEG recordings from Alzheimer's disease patients", *Med Eng Phys*, vol. 31, no.3, pp. 306–313, Apr. 2009 (doi: 10.1016/j.medengphy.2008.06.010).
- [21] M. Akay, "Nonlinear Biomedical Signal Processing: Dynamic Analysis and Modeling", Wiley-IEEE Press, New York, Sep. 2000.
- [22] X. S. Zhang, R. J. Roy, and E. W. Jensen, "EEG complexity as a measure of depth of anesthesia for patients", *IEEE Trans Biomed Eng*, vol. 48, no. 12, pp. 1424–1433, Dec. 2001 (doi: 10.1109/10.966601).
- [23] R. Nagarajan, "Quantifying physiological data with Lempel-Ziv complexity-certain issues", *IEEE Trans Biomed Eng*, vol. 49, no. 11, pp. 1371–1373, Nov. 2002 (doi: 10.1109/TBME.2002.804582).
- [24] X. S. Zhang, Y. S. Zhu, N. V. Thakor, and Z. Z. Wang, "Detecting ventricular tachycardia and fibrillation by complexity measure", *IEEE Trans Biomed Eng*, vol. 46, no. 5, pp. 548–555, May. 1999 (doi: 10.1109/10.759055).
- [25] G. Palshikar, "Simple algorithms for peak detection in time-series", In *Proc. 1st Int. Conf. Advanced Data Analysis, Business Analytics and Intelligence*, pp. 1-13, Jun. 2009.

زیر نویس‌ها:

1. Electroencephalogram
2. Brain Computer Interface
3. Common Spatial Pattern
4. Support Vector Machine
5. Radial Basis Function
6. Common Special Subspace Decomposition
7. Wavelet Common Spatial Pattern
8. Electrooculography
9. Independent Component Analysis
10. Fisher Linear Discriminant
11. Cross Correlation Based Logistic Regression
12. Cross Correlation
13. Constant Walking
14. Adaptive Walking
15. Imaginary Constant walking
16. Imaginary adaptive walking
17. Quaternion Common Spatial Patterns
18. Parkinson Disease
19. Channel-Correlation Network
20. Multi Scale Principle Component Analysis
21. Symlet
22. Principle Component Analysis
23. Wavelet Packet Decomposition
24. Discrete Wavelet Transform
25. Detrended Fluctuation Analysis
26. Embedding Dimension
27. Lempel Ziv
28. Coarse-graining