



افزایش دقت طبقه‌بندی سیگنال‌های مغزی مبتنی بر تصور حرکتی اندام حرکتی تحتانی با ترکیب روش‌های انتخاب کانال‌های بهینه و الگوی فضایی مشترک

حسین حسینی^۱، محمدعلی جوادزاده^۲، ایمان علیدادی شمس‌آبادی^۳

^۱ دانشجوی کارشناسی ارشد هوش مصنوعی و رباتیک، دانشکده هوش مصنوعی و علوم شناختی، دانشگاه جامع امام حسین (ع)، تهران، ایران.

hosseinhosseini@ihu.ac.ir

^۲ استادیار، دانشکده هوش مصنوعی و علوم شناختی، دانشگاه جامع امام حسین (ع)، تهران، ایران.

javadzade@ihu.ac.ir

^۳ پژوهشگر، دانشکده هوش مصنوعی و علوم شناختی، دانشگاه جامع امام حسین (ع)، تهران، ایران.

imanalidadi@ihu.ac.ir

چکیده

سیستم رابط مغز و رایانه یک مسیر ارتباطی بین مغز و رایانه فراهم می‌کند و اخیراً مورد توجه روزافزون قرار گرفته است. یکی از رایج‌ترین پارادایم‌های سیستم‌های رابط مغز و رایانه، تصور حرکتی است. سیستم رابط مغز و رایانه مبتنی بر تصور حرکتی با بهره‌گیری از سیگنال‌های الکتروانسفالوگرام در هنگام اخذ سیگنال از تعداد زیادی کانال استفاده می‌کنند. کانال‌های غیرمرتبط با کار مورد نظر، سبب ایجاد تداخل نامطلوب و افزایش سطح نویز می‌گردد. در این مقاله، ما دو روش انتخاب کانال بهینه را برای بهبود ویژگی‌های مرتبط با الگوی فضایی مشترک (CSP) جهت طبقه‌بندی وظایف تصور حرکتی ارائه می‌کنیم. از آنجایی که فعالیت‌های مغزی تصور حرکتی در ناحیه خاصی از مغز قرار دارد، نحوه انتخاب کانال‌های مناسب برای بهبود عملکرد رابط مغز و رایانه مهم است. در این مقاله، انتخاب ویژگی تحلیل واریانس (ANOVA) و انتخاب ویژگی روبه‌جلو ترکیبی (SFFS) با الگوی فضایی مشترک (CSP) برای انتخاب کانال‌های الکتروانسفالوگرام بهینه ترکیب شده است. نتایج نشان می‌دهد که دقت طبقه‌بندی‌های KNN، SVM و LDA در هنگام استفاده از روش ANOVA+CSP به ترتیب ۷۴، ۷۲ و ۷۱ درصد، در هنگام استفاده از روش SFFS+CSP به ترتیب ۷۴، ۷۳ و ۶۸ درصد، در هنگام استفاده از CSP به تنهایی به ترتیب ۶۵، ۶۲ و ۶۰ درصد، در هنگام عدم استفاده از روش‌های انتخاب کانال‌های بهینه و الگوی فضایی مشترک به ترتیب ۵۸، ۶۴ و ۵۷ درصد می‌باشد؛ بنابراین ترکیب روش‌های انتخاب کانال‌های بهینه و الگوی فضایی مشترک باعث افزایش دقت طبقه‌بندی شده است.

واژه‌های کلیدی: رابط مغز و رایانه، الکتروانسفالوگرام، تصور حرکتی، الگوی فضایی مشترک، انتخاب کانال.

۱. مقدمه

رابط مغز و رایانه^۱ مسیری را برای انتقال اطلاعات بین مغز و کامپیوتر فراهم می‌کند [1] که برای آن هیچ حرکت ماهیچه‌ای قابل توجهی در بدن لازم نیست. رابط‌های مغز و رایانه با هدف کمک به افراد دارای ناتوانی‌های عضلانی که دارای پتانسیل‌های شناختی می‌باشند، سیگنال‌های مغز را تجزیه و تحلیل و بدون استفاده مستقیم از اعصاب و عضلات محیطی به دستور کنترلی تبدیل می‌کنند. عملکرد کلی رابط‌های مغز و رایانه به این صورت است که ابتدا سیگنال‌های مغزی را به عنوان ورودی دریافت کرده، ویژگی‌های مفید را از سیگنال استخراج کرده، طبقه‌بندی کرده و در نهایت به یک فرمان کنترلی تبدیل می‌کنند. رایج‌ترین کاربرد سیستم BCI در زمینه پزشکی است و به بیماران مبتلا به سندرم قفل‌شدگی^۲ کمک می‌کند [2]. برای کمک به بیماران، آن‌ها باید سیگنال‌های مغزی مناسب فعالیت حرکتی مورد نیاز را از طریق تخیل ذهنی تولید کنند. متعاقباً، فعالیت‌های مغزی ثبت‌شده برای حرکت دادن یک اندام حرکتی مصنوعی یا ویلچر پردازش می‌شوند [3]. علاوه بر این، BCI‌ها نیز با موفقیت برای اهداف دیگری از جمله روانشناسی، بازاریابی عصبی، بازی و سرگرمی، خانه هوشمند و واقعیت مجازی استفاده می‌شوند. امروزه سیستم‌های مختلف رابط مغز و کامپیوتر بر اساس الگوهای تحریک و محل کاشت الکترود معرفی و دسته‌بندی می‌شوند. یکی از مهم‌ترین پارادایم‌ها سیگنال الکتروانسفالوگرام^۳، سیستم‌های تصور حرکتی^۴ است، زیرا غیرتهاجمی، کم‌هزینه و وضوح زمانی بالایی را در بر می‌گیرد [4] از این رو به طور فزاینده‌ای در زمینه‌های مختلف مورد استفاده قرار گرفته‌اند. در این نوع از سیستم‌های رابط مغز و رایانه، زمانی که سوژه قسمتی از اندام خود (مانند دست راست یا چپ) را حرکت می‌دهد یا تصور حرکت می‌کند، مشخصات فرکانسی مغز در بازه فرکانسی μ و β تغییر پیدا خواهد کرد. علاوه بر این، مطالعات عصب‌شناسی نشان می‌دهد که حرکت ارادی اندام‌های خاص یا به سادگی فرض یک حرکت، می‌تواند هر دو، بخش‌های مشابهی از مغز را فعال کند. در پارادایم EEG مبتنی بر تصور حرکتی، سیگنال‌های EEG تولید شده توسط فعالیت عصبی مغز از سطح پوست سر ثبت می‌شود. پس از آن، سیگنال‌های تصور حرکتی شناسایی، طبقه‌بندی و متعاقباً به یک پیام کنترلی تبدیل می‌شوند که به عنوان ورودی به اندام مصنوعی اعمال می‌شود. با این وجود، چالش اصلی BCI مبتنی بر تصور حرکتی این است که یک سیستم بهینه و قابل اعتماد باشد.

اکثر سیستم‌های BCI برای دستیابی به عملکرد خوب به داده‌های EEG چند کاناله نیاز دارند [5]. با این حال، بسیاری از کانال‌ها حاوی اطلاعات اضافی و نویز برای پردازش داده‌ها هستند و باعث ایجاد مزاحمت برای کاربرد عملی می‌شوند [6]. توافق روشی در مورد تعداد و مکان کانال‌های لازم برای تصور حرکتی وجود ندارد؛ بنابراین، روش‌های انتخاب کانال برای بهبود عملکرد BCI مبتنی بر تصور حرکتی ضروری هستند. تاکنون روش‌های انتخاب کانال‌های بهینه مختلفی پیشنهاد شده است. در چندین مطالعه، کانال‌ها به صورت دستی بر اساس دانش نوروفیزیولوژیک انتخاب شدند به نحوی که در BCI مبتنی بر تصور حرکتی معمولاً از کانال‌های C3، C4 و Cz استفاده می‌کند که این کانال‌ها ویژگی‌های مهم تصور حرکتی را ثبت می‌کنند [7]. روش‌های مبتنی بر فیلتر و روش‌های مبتنی بر بردار برای انتخاب کانال‌های EEG بیشتر از روش انتخاب دستی استفاده می‌شوند [8]. در روش‌های رتبه‌بندی کانال مبتنی بر فیلتر مانند روش انتخاب کانال مبتنی بر اطلاعات متقابل، امتیاز فیشر و تحلیل واریانس^۵ (ANOVA)، کانال‌ها به صورت جداگانه رتبه‌بندی می‌شوند. به طور کلی، ویژگی‌های خوب لزوماً به عملکرد خوب منجر نمی‌شوند [9]. روش‌های مبتنی بر بردار معمولاً کانال‌هایی را انتخاب می‌کنند که با یک طبقه‌بندی خاص

¹ Brain Computer Interface (BCI)

² Locked-in syndrome

³ Electroencephalogram (EEG)

⁴ Motor Imagery (MI)

⁵ Analysis of Variance (ANOVA)

همراه شده‌اند که عملکرد آن عمدتاً به طبقه‌بندی کننده اعمال شده بستگی دارد. به طور معمول، روش‌های انتخاب کانال مبتنی بر بردار می‌تواند در دو جهت مخالف کار کند: (۱) برای انتخاب مؤثرترین کانال‌ها به صورت یک به یک و (۲) برای حذف کانال‌های نویز به صورت یک به یک. یکی از روش‌های پر کاربرد در روش‌های انتخاب کانال مبتنی بر برداری روش انتخاب ویژگی روبه‌جلو ترکیبی^۶ (SFFS) می‌باشد. SFFS مهم‌ترین ویژگی را از ویژگی‌های باقیمانده در هر زمان می‌گیرد و آن را در زیرمجموعه ویژگی‌های انتخاب شده قرار می‌دهد. بنابراین، SFFS برای انتخاب کانال مناسب است. با این حال، این روش وقت‌گیر است، به خصوص زمانی که تعداد ویژگی‌ها زیاد باشد.

در این پژوهش، با ترکیب روش انتخاب کانال‌های بهینه فیلتر ANOVA و روش انتخاب کانال‌های بهینه برداری SFFS با الگوی فضایی مشترک، دو روش ANOVA+CSP و SFFS+CSP پیشنهاد شده است که بر یک مجموعه داده سیگنال‌های EEG مبتنی بر سیگنال EEG مبتنی بر تصور حرکتی برای دو عمل نشستن و برخاستن پیاده‌سازی شده است. ساختار مقاله به صورت زیر است: در بخش ۲ کارهای مرتبط با طبقه‌بندی سیگنال‌های مغزی مبتنی بر تصور حرکتی اندام حرکتی تحتانی شرح داده شده است. در بخش ۳ به ادبیات موضوعی مورد نیاز جهت درک مباحث پرداخته شده است. در بخش ۴ مراحل انجام روش پیشنهادی ارائه شده است. در بخش ۵ ارزیابی روش‌های پیشنهادی ANOVA+CSP و SFFS+CSP بیان شده است. در بخش ۶ نتیجه‌گیری این پژوهش مورد بحث قرار گرفته است.

۲. کارهای مرتبط

کلاین و همکاران سیگنال‌های EEG را در باند فرکانس ۸-۴۵ هرتز از شانزده داوطلب مرد سالم با میانگین سنی ۲۴.۷ سال ثبت کردند. داده‌های EEG و fMRI در حین حرکات اجرا شده و تصویری اندام حرکتی تحتانی جمع‌آوری شدند. وظایف انجام شده، تصور حرکتی و حرکت فعال بود. شرکت‌کنندگان تصویر تولید شده توسط کامپیوتر (CGI) که در حال نمایش یک انسان در حال راه رفتن بود را مشاهده می‌کردند و یک حرکت اندام حرکتی تحتانی را انجام می‌دادند یا آن را مطابق با ریتم CGI تصور می‌کردند. کلاین و همکاران نویز سیگنال EEG را از DC offset و نویز مرتبط با چشمک زدن را با استفاده از یک فیلتر باند گذر بین ۵ تا ۵۵ هرتز با roll-off ۲۰ دسی بل در دهه حذف کردند. کلاین و همکاران از مقدار طیف توان همه فرکانس‌های مورد مطالعه (آلفا، بتا و گاما) برای هر الکتروود EEG استفاده کردند. کلاین و همکاران از یک شبکه عصبی (NN) پیاده‌سازی شده در پایتون ۳.۷ برای طبقه‌بندی حرکت اندام حرکتی تحتانی راست و چپ استفاده کردند. این مدل از جعبه ابزار Keras استفاده می‌کرد که دقتی بیش از ۶۶ درصد را به دست آورد [10].

هوشینو و همکاران سیگنال‌های EEG را در باند فرکانسی آلفا (۸-۱۲ هرتز)، بتا (۱۳-۳۰ هرتز)، بتا پایین (۱۳-۱۹ هرتز) و بتا بالا (۳۰-۲۰ هرتز) از ۲۴ بیمار پس از سکته مغزی ثبت کردند. معیارهای انتخاب بیمار عبارت بودند از: اولین سکته مغزی (ایسکمیک یا هموراژیک)، ضایعه سوپراتنتوریال، بین ۲۰ تا ۸۵ سال سن داشتن، قبل از سکته مغزی به طور مستقل فعال است و دست راست غالب است. آن‌ها بیمارانی را که پس از گذشت چهار هفته از رویداد، تمام عملکرد حرکتی خود را از دست ندادند، شامل شدند. در نتیجه، ۲۴ شرکت‌کننده با میانگین سنی ۶۲ سال انتخاب شدند. بیماران در طول آزمایش با چشمان بسته روی تخت دراز کشیده بودند. کارهای انجام شده شامل حرکات مچ پا، دورسی فلکشن و فلکشن کف پا بود. هیچ سنسور اضافی استفاده نشده است. هیچ گونه تحریک دیداری یا شنیداری برای نشان دادن زمان انجام حرکت به بیماران مورد استفاده قرار نگرفته است. هوشینو و همکاران با

^۶ Sequential Forward Feature Selection (SFFS)

استفاده از فیلتر باند گذر در باندهای فرکانس ۰.۵-۱۰۰ هرتز و تجزیه و تحلیل رگرسیون خطی چندگانه، نویز را از سیگنال‌های EEG مربوط به قصد حرکت و حرکت فعال حذف کردند. هوشینو و همکاران از Amplitude Envelope Correlation (AEC) برای استخراج ویژگی سیگنال‌های EEG از حرکت فعال در حین حرکات مچ پا، دورسی فلکشن و پلانترفلکسیون (کف پا) استفاده کردند [11].

آسانزا و همکاران از پایگاه داده‌ای از سیگنال‌های EEG ۶۴ کانالی که با استفاده از سیستم موسوم به BCI2000 ضبط شده بود، استفاده کردند. سیگنال‌های EEG با ۱۶۰ نمونه در ثانیه از هشت فرد سالم ثبت شدند. وظایف مورد استفاده برای این مطالعه فعالیت حرکتی و تصور حرکتی از دورسی (خم شدن پشتی) و پلانتر (کف پا) هر دو پا بود. از سنسورهای اضافی استفاده نشده است. آسانزا و همکاران نویز سیگنال‌های EEG مربوط به فعالیت حرکتی و تصور حرکتی را با استفاده از فیلتر پاسخ ضربه نامتناهی (IIR) دویست مرتبه‌ای Butterworth از ۸ تا ۳۰ هرتز حذف کردند. آسانزا و همکاران از چگالی طیفی توان (PSD) از ۸ تا ۳۰ هرتز استفاده کردند که در ۱۰ ثانیه نمونه‌برداری از هر الکتروود EEG محاسبه شد. آسانزا و همکاران از یک شبکه عصبی (NN) آموزش‌دیده در Matlab استفاده کردند و سپس آن را بر روی آرایه‌های دروازه قابل برنامه‌ریزی میدانی (FPGA) پیاده‌سازی کردند. این مدل فعالیت حرکتی و تصور حرکتی هر دو پا را به ترتیب با دقت ۹۲.۱٪ و ۹۳.۸٪ طبقه‌بندی کرد [12].

اورتیز و همکاران سیگنال‌های EEG را در باند فرکانس ۲ تا ۶۰ هرتز از سه داوطلب بزرگسال بدون اختلالات جسمی ثبت کردند. شرکت‌کنندگان در طول آزمایش نشسته بودند و تصور حرکتی را انجام دادند. تکلیف انجام شده راه رفتن بود. از سنسورهای اضافی استفاده نشده است. از تحریک شنوایی برای نشان دادن اجرای تکلیف در حالی که شرکت‌کننده در مورد عمل فکر می‌کرد استفاده شد. اورتیز و همکاران نویز سیگنال EEG را از قصد حرکت و حرکت فعال با استفاده از فیلتر ناچ در ۶۰ هرتز حذف کردند. اورتیز و همکاران از تجزیه حالت تجربی (EMD) برای توابع حالت ذاتی (IMFs) و تغییر قدرت برای IMFs برای استخراج ویژگی سیگنال‌های EEG از تصور حرکتی راه رفتن استفاده کردند [13].

گوردلیوا و همکاران سیگنال‌های EEG را در باند فرکانسی ۸ تا ۱۵ هرتز از هشت داوطلب سالم ۲۰ تا ۲۷ ساله ثبت کردند. سیگنال‌های EEG و EMG برای انجام حرکت لیفت (بلند کردن) پا با استفاده از HMI به دست آمد. وظایف انجام شده، تصور حرکتی و حرکت فعال بود. از سنسورهای EMG نیز برای بازخورد سیستم کنترل اسکلت بیرونی اندام حرکتی تحتانی استفاده شد. گوردلیوا و همکاران از یک فیلتر باند گذر در باندهای فرکانسی ۸ تا ۱۵ هرتز برای حذف نویز از سیگنال‌های EEG مربوط به قصد حرکت و حرکت فعال استفاده کردند. گوردلیوا و همکاران از فیلتر الگوی فضایی مشترک (CSP) برای استخراج ویژگی از ویژگی‌های سیگنال EEG بسیار مرتبط با رویداد در تصور حرکتی و وظایف بلند کردن پا با حرکت فعال استفاده کردند. گوردلیوا و همکاران سیگنال‌های EEG را در تصور حرکتی و کارهای بلند کردن پا با حرکت فعال با LDA طبقه‌بندی کردند و به دقت ۶۵.۷ درصد دست یافتند [14].

۳. ادبیات موضوعی

در این مقاله سعی شده است که ادبیات موضوعی مورد نیاز جهت فهم بهتر مطالب گفته شده، در حین استفاده از آن در بخش‌های موردنظر ذکر گردد تا مخاطب بتواند با آن ارتباط بهتری برقرار کند.

۴. روش پیشنهادی

سیستم BCI تصور حرکتی پس اخذ سیگنال، دارای سه بخش اصلی پیش‌پردازش، استخراج ویژگی و طبقه‌بندی الگوهای تصور حرکتی EEG می‌باشد، که در ادامه به آن‌ها پرداخته شده است.

۱.۴ دادگان: در این مقاله از دادگانی که توسط خود ما طراحی و تولید شده است، استفاده گردیده است. این دادگان شامل سیگنال‌های EEG با ۶۴ الکترود ثبت سیگنال، که با استاندارد ۲۰-۱۰ بر روی سر افراد قرار گرفته‌اند، از ۱ سوژه نرمال ثبت شده است. سیگنال‌ها با فرکانس ۵۱۲ هرتز نمونه‌برداری شده‌اند. آزمایش ثبت سیگنال، مبتنی بر نشانه است و شامل دو وظیفه تصور حرکت (تصور حرکت نشستن و برخاستن) می‌باشد. در این دادگان ثبت سیگنال برای سوژه در یک جلسه صورت گرفته است که در مجموع ۱۰۰ آزمایش (هر کلاس تصور حرکت ۵۰ بار آزمایش) برای هر فرد ثبت شده است.

۲.۴ پیش‌پردازش: مرحله پیش‌پردازش شامل سه بخش است: در بخش اول، اطلاعات مربوط به کار تصور حرکتی (ریتیم‌های μ و β) با استفاده از فیلتر میان‌گذر^۷ باترورث استخراج می‌شود. در بخش دوم، برای برجسته کردن اطلاعات هر کانال و محلی‌سازی منبع^۸، یک فیلتر مکانی اعمال می‌شود. همچنین در بخش سوم از روش ترکیبی استخراج ویژگی مبتنی بر شیوه‌های آماری و روش‌های انتخاب ویژگی ANOVA یا SFFS برای انتخاب کانال‌های EEG بهینه استفاده شده است.

۱.۲.۴ فیلتر میان‌گذر باترورث: با توجه به ماهیت سیگنال EEG و نویزپذیری بالای آن، در گام پیش‌پردازش برای کاهش تأثیر نویز و بهبود سیگنال، فیلترینگ لازم بر روی آن انجام گیرد. در مطالعات قبلی، نشان داده شده است که وقتی افراد یک وظیفه اندام یا تخیل آن را دارند، بیشتر تغییرات سیگنال EEG در ریتیم‌های μ و β رخ می‌دهد، که نشان می‌دهد این ریتیم‌ها حاوی اکثر اطلاعات هستند. در سیگنال EEG، نرخ تغییرات موج β بین ۱۳ تا ۳۱ است و دامنه آن در یک محدوده ولتاژ پایین بین ۵ تا ۳۱ میکرو ولت تغییر می‌کند. موج β اغلب در هنگام تفکر فعال، توجه دقیق، تمرکز روی جهان خارجی یا حل مسائل مشکل ظاهر می‌شود. فرکانس‌های نزدیک ۵۱ هرتز نیز می‌تواند در هنگام فعالیت مغزی شدید در این باند ظاهر شود. موج μ ، امواج غیرارادی در سیگنال EEG هستند که در محدوده فرکانسی ۸ تا ۱۲ هرتز ظاهر می‌شوند. این امواج مربوط به فعالیت‌های حرکتی هستند که با حرکت یا تصور به حرکت، کاهش پیدا می‌کنند و فیلتر باترورث^۹ بر روی باندهای ۸ تا ۳۰ هرتز اعمال شده است. برای استخراج ریتیم‌های μ و β از سیگنال‌های EEG، فیلتر کردن با استفاده از فیلتر میان‌گذر انجام می‌شود. ابتدا، با استفاده از اطلاعات موقعیت شروع ترایال‌ها در مجموعه داده، ترایال‌های هر کلاس از سیگنال جداسازی می‌شوند. به طور کلی، مدت زمان هر ترایال ۵ ثانیه است. فیلتر کردن با استفاده از فیلتر میان‌گذر باترورث با مرتبه ۳ انجام می‌شود، به طوری که ریتیم‌های μ و β از EEG استخراج می‌شوند تا اطلاعات تصور حرکتی برجسته شوند. دامنه خروجی این فیلتر هموار است و تغییرات آن در هر قطب، یکنواخت و دارای شیب ۲۰ dB/dec^{۱۰} معادله (۱) فیلتر باترورث را نشان می‌دهد:

$$H(z) = \frac{B(z)}{A(z)} = \frac{b(1) + b(2)z^{-1} + \dots + b(n+1)z^{-n}}{a(1) + a(2)z^{-1} + \dots + a(n+1)z^{-n}} \quad (1)$$

۲.۲.۴ محلی‌سازی منبع با استفاده از فیلتر مکانی: قبل از مرحله استخراج ویژگی، ما نیاز به یک فیلتر مکانی داریم که بر روی سیگنال‌های EEG اعمال گردد. هدف از فیلتر مکانی کاهش اثر تاری مکانی از سیگنال خام است. تاری مکانی به عنوان اثر فاصله بین حسگر و منابع سیگنال در مغز، به دلیل ناهمگنی بافت‌های بین نواحی مغز رخ می‌دهد. در ادامه سه نوع فیلتر مکانی شرح داده شده است که از آن‌ها برای مقابله با اثر تاری مکانی سیگنال‌های EEG خام استفاده می‌شود.

⁷ Band Pass Filter

⁸ Source localization

⁹ Butterworth Filter

۱.۲.۲.۴ **فیلتر مکانی مرجع میانگین مشترک^{۱۰} (CAR):** یک فیلتر مکانی به عنوان تفريق فعاليت مشترک EEG در نظر گرفته می‌شود که تنها فعاليت بیکار هر EEG منفرد را در الکتروده خاص باقی می‌گذارد. پتانسیل هر الکتروده بعد از فیلتر را می‌توان مانند معادله (۲) محاسبه کرد، که در آن $x_i^{CAR}(t)$ خروجی فیلتر شده الکتروده ith است، $x_j(t)$ پتانسیل بین الکتروده و مرجع است و C تعداد کل تمام الکترودهای روی پوست سر است.

$$x_i^{CAR}(t) = x_i(t) - \frac{1}{C} \sum_{j=1}^C x_j(t)$$

(2)

۲.۲.۲.۴ **فیلتر مکانی لاپلاسیان^{۱۱}:** لاپلاسیان یک اندازه‌گیری همسانگرد دوبعدی از دومین مشتق مکانی یک تصویر است. لاپلاسیان اغلب بر روی تصویری اعمال می‌شود که ابتدا با چیزی شبیه به فیلتر صاف کننده گاوسی صاف شده است تا حساسیت آن به نویز کاهش یابد، همچنین تأثیر خوبی در پردازش سیگنال دارد. توزیع گاوسی روی سطح پوست سر، و تلاش برای معکوس کردن فرآیندی که فعاليت‌های مغزی شناسایی شده روی پوست سر را تار می‌کند. معادله (۳) فیلتر مکانی لاپلاسیان را نشان می‌دهد:

$$x_i^{LAP}(t) = x_i(t) - \sum_{j \in S_i} \omega_{ij} x_j(t) \quad (3)$$

$$\omega_{ij} = \frac{\frac{1}{d_{ij}}}{\sum_{j \in S_i} \frac{1}{d_{ij}}} \quad (4)$$

که در آن $x_i^{LAP}(t)$ سیگنال فیلتر شده الکتروده ith است و $x_i(t)$ پتانسیل الکتروده i در مقایسه با الکتروده مرجع است. ω_{ij} وزن الکتروده j را در رابطه با الکتروده i نشان می‌دهد که با استفاده از معادله (۴) محاسبه می‌شود و d_{ij} فاصله الکتروده j از الکتروده i است. برای یافتن همسایگان الکترودها از فاصله اقلیدسی استفاده می‌شود. با توجه به موقعیت مکانی الکترودها، فاصله اقلیدسی سازگار است. S_i مجموعه‌ای از الکترودهای همسایه است که در مرکز آن الکتروده قرار دارند. مونتاژ الکترودهای همسایه می‌تواند اندازه کوچک و اندازه بزرگ باشد. اندازه الکترودهای همسایه معمولاً ۴ است که در عمودی و افقی انتخاب می‌شود که در آن x_i الکتروده مرکزی است.

در میان سه روش شناخته شده برای محلی سازی منبع که شامل فیلترهای مکانی ساده مرجع میانگین مشترک، لاپلاسیان بزرگ^{۱۲} و لاپلاسیان کوچک^{۱۳} می‌باشد، از فیلتر CAR برای محلی سازی منبع در مرحله دوم پیش‌پردازش استفاده می‌شود.

۳.۲.۴ **انتخاب کانال با استفاده از روش‌های انتخاب ویژگی ANOVA و SFFS:** هنگام ضبط سیگنال EEG تصور حرکتی از تعداد زیادی الکتروده استفاده می‌شود. برخی از این کانال‌های ضبط شده حاوی اطلاعات بیشتری در مورد وظیفه تصور حرکتی مورد نظر هستند، در حالی که برخی دیگر حاوی اطلاعات مفیدی در مورد کار نیستند. به عبارت دیگر، اطلاعات مربوط به کار به دست آمده از کانال‌های EEG مبتنی بر سوژه است.

برای هر سوژه، این امکان وجود دارد که کانال‌های مختلف حاوی اطلاعات مفیدی در مورد وظیفه تصور حرکتی باشد. برای یافتن کانال‌های مناسب، با استفاده از روش ترکیبی استخراج ویژگی مبتنی بر شیوه‌های آماری و روش‌های انتخاب ویژگی ANOVA یا SFFS، این کار صورت می‌پذیرد. انتخاب کانال به ارائه یک روش سریع‌تر، دقیق‌تر و ساده‌تر برای طبقه‌بندی EEG کمک می‌کند. علاوه بر این، انتخاب کانال تعمیم مدل را افزایش می‌دهد، تأثیر ابعادی آن را کاهش می‌دهد و فرآیند یادگیری را تسريع می‌کند. انتخاب کانال منجر به حذف کانال‌های نامربوط می‌شود. در نتیجه، عملکرد مدل بهبود می‌یابد.

¹⁰ Common Average Reference (CAR)

¹¹ Laplacian

¹² High Laplacian

¹³ Low Laplacian

پس در این بخش باید کانال‌های بهینه انتخاب می‌شدند و داده مربوط به آن‌ها از کل سیگنال استخراج می‌شدند. در این بخش ما از دو روش انتخاب ویژگی عددی یا همان اسکالر^{۱۴} ANOVA و روش انتخاب ویژگی برداری^{۱۵} SFFS بهره گرفته‌ایم. رویکرد اول در انتخاب کانال بهینه، استفاده از روش انتخاب ویژگی عددی ANOVA بود. در این روش از داده‌ها باید ویژگی استخراج می‌شد تا روش انتخاب کانال بهینه ANOVA به بهترین نحو عمل می‌کرد که ویژگی انتخابی جذر میانگین مربع‌ها بود. در ادامه خروجی مرحله استخراج ویژگی به عنوان ورودی به تابع ANOVA ارسال شد و مقادیر خروجی تابع که مقادیر محاسبه شده P-value بودند به صورت صعودی مرتب شده و اندیس کانال‌های انتخابی استخراج شدند. پس از آن داده مربوط به این کانال‌ها از داده سایر کانال‌ها جدا شدند و به عنوان ورودی برای استخراج ویژگی برای طبقه‌بند مورد استفاده قرار گرفتند. استخراج ویژگی از چهار ویژگی آماری میانگین^{۱۶}، واریانس^{۱۷}، توان سیگنال^{۱۸} و جذر میانگین مربع‌ها^{۱۹} انجام شده است. پس از استخراج ویژگی با روش k-fold در هر مرحله دقت توسط طبقه‌بند محاسبه شده و در پایان میانگین هر مرحله به عنوان خروجی گزارش شد.

رویکرد دوم در انتخاب کانال بهینه، استفاده از روش انتخاب ویژگی برداری SFFS بود. در این روش کانال‌های بهینه را این بار با چند ویژگی و در نظر گرفتن نظر طبقه‌بند، انتخاب کردیم. روش SFFS بر خلاف ANOVA چندین ویژگی را انتخاب کرده و کانال بهینه را پس از محاسبه دقت ترکیب کانال‌ها در طبقه‌بند انتخاب می‌کند.

۳.۴ استخراج ویژگی: در پردازش سیگنال EEG به دست آوردن یک مجموعه مناسب از ویژگی‌ها، همواره یک مسئله چالش‌برانگیز بوده است. برای استخراج ویژگی روش‌های مختلفی همانند تئوری آشوب^{۲۰}، تبدیل فوری^{۲۱}، الگوی فضایی مشترک^{۲۲} (CSP)، تبدیل موجک^{۲۳}، تحلیل مؤلفه‌های مستقل^{۲۴} (ICA) و تحلیل مؤلفه‌های اصلی^{۲۵} (PCA) مورد استفاده قرار گرفته است. روش CSP عملکرد بهتری در مقایسه با سایر روش‌های معمول استخراج ویژگی در سیگنال EEG تصور حرکتی دارد. CSP یک روش متداول در طبقه‌بندی سیگنال‌های EEG تصور حرکتی است. با این حال، برای اولین بار، این روش برای تشخیص ناهنجاری‌ها مورد استفاده قرار گرفت و بعداً برای طبقه‌بندی الگوهای تصور حرکتی مورد استفاده قرار گرفت. در رویکرد CSP، یک سیگنال EEG خام به الگوهای فضایی تبدیل می‌شود. هدف الگوریتم CSP استخراج فیلترهای فضایی برای به حداکثر رساندن واریانس تراپال در کلاس اول و به حداقل رساندن آن در کلاس دیگر به طور همزمان است.

¹⁴ Scalar

¹⁵ Wrapper

¹⁶ Mean

¹⁷ Variance

¹⁸ Signal power

¹⁹ Root Mean Square

²⁰ Chaos theory

²¹ Fourier transform

²² Common Spatial Patterns (CSP)

²³ Wavelet transform

²⁴ Independent Component Analysis (ICA)

²⁵ Principal Component Analysis (PCA)

تابع هزینه الگوریتم CSP به صورت معادله (۵) بیان شده است، و هدف به دست آوردن مقدار W است که مقدار J را به حداکثر می‌رساند:

$$J = \operatorname{argmax}_w \left(\frac{w x_H^2}{w x_F^2} \right) \quad (5)$$

در معادله (۵)، نرم ۲ را می‌توان به صورت معادله (۶) نوشت:

$$J = \frac{W^T X_H X_H^T W}{W^T X_F X_F^T W} \quad (6)$$

جایی که X_H و X_F به ترتیب تک تریال کلاس ۱ و کلاس ۲ هستند. بعد هر تریال $N \times T$ است که N تعداد کانال‌ها و T تعداد نمونه‌های هر تریال است. محاسبه ماتریس‌های کوواریانس تک تریال کلاس ۱ و ۲ با توجه به رابطه (۷) و معادله (۸) ضروری است:

$$R_H = \frac{X_H X_H^T}{\operatorname{trace}(X_H X_H^T)} \quad (7)$$

پس از محاسبه R_H و R_F ، میانگین کوواریانس تمام تریال‌ها به صورت R_H و R_F برای هر کلاس محاسبه می‌شود. در نهایت، تابع هزینه J به صورت زیر تعریف می‌شود و باید حداکثر شود:

$$R_F = \frac{X_F X_F^T}{\operatorname{trace}(X_F X_F^T)} \quad (8)$$

$$J(W) = \frac{W^T R_H W}{W^T R_F W} \quad (9)$$

معادله (۹) را می‌توان با استفاده از تجزیه مقادیر ویژه^{۲۶} تعمیم‌یافته حل کرد. پس از آن، بردارهای ویژه^{۲۷} بر اساس مقادیر ویژه به ترتیب نزولی مرتب می‌شوند. در نهایت اولین و آخرین بردار ویژه به عنوان فیلترهای فضایی بهینه (W) انتخاب می‌شوند. اعمال این فیلترها بر روی سیگنال EEG به دستیابی به ویژگی‌هایی با بهترین عملکرد برای تمایز سیگنال‌های EEG تصور حرکتی کمک می‌کند.

۴.۴ طبقه‌بندی: پس از دریافت سیگنال و عملیات پیش‌پردازشی و نیز استخراج و کاهش ویژگی‌ها مستخرج، این ویژگی‌ها را با توجه به هدف پردازش طبقه‌بندی می‌کنند. به همین منظور انواع روش‌های طبقه‌بندی در زمینه پردازش سیگنال مغز مطرح می‌شوند. انواع طبقه‌بندی‌کننده‌ها مورد استفاده در این پژوهش به سه دسته به صورت طبقه‌بند با تابع تفکیک خطی^{۲۸} (LDA)، k تا نزدیک‌ترین همسایه^{۲۹} (k-NN) و طبقه‌بند بر پایه ماشین‌های بردار پشتیبان^{۳۰} معرفی می‌شوند؛ که در ادامه هر یک شرح داده شده است.

۱.۴.۴ طبقه‌بند با تابع تفکیک خطی (LDA): این طبقه‌بندی‌کننده آماری، با یک تبدیل خطی توسط ماتریس وزن‌ها صورت می‌گیرد، که وزن‌ها با هدف بیشینه کردن پراکندگی بین طبقه‌ها و کمینه کردن پراکندگی درون طبقه‌ای تعیین

²⁶ Eigen value

²⁷ Eigen vector

²⁸ Linear Discriminant Analysis (LDA)

²⁹ k-Nearest Neighbor (k-NN)

³⁰ Support Vector Machine (SVM)

می‌شوند. سرعت بالا و عدم نیاز به تعیین پارامتری جانبی، از محاسن این طبقه‌بندی‌کننده محسوب می‌شود. در این روش هدف این است که داده‌های مربوط به یک طبقه تا حد امکان در زیرفضای جدید ایجاد شده به هم نزدیک و داده‌های کلاس‌های مختلف از هم دور باشند. به عبارت دیگر پراکندگی بین طبقه‌ای داده‌ها حداکثر و پراکندگی درون طبقه‌ای داده‌ها حداقل شود.

۲.۴.۴ طبقه‌بند بر پایه k تا نزدیک‌ترین همسایگی (k-NN): در این ساختار طبق و وابسته به یک داده بر پایه طبقه‌های مربوط به داده‌هایی که در نزدیکی آن داده می‌باشند، به دست می‌آید. به عبارت دیگر به اندازه k (که به طور عمومی عددی فرد است) تعداد داده‌هایی که از نظر فاصله (مانند فاصله اقلیدسی) به آن داده نزدیک می‌باشند، به عنوان طبقه وابسته به آن، گزیده خواهند شد.

۳.۴.۴ طبقه‌بند بر پایه ماشین بردار پشتیبان (SVM): طبقه‌بندی SVM راهی برای جداسازی دو طبقه بر پایه تعیین ابرصفحه مرزی (مرز با معادله خطی) است به طوری که این ابرصفحه بیشترین فاصله را از داده‌های اطرافش داشته باشد. ماشین‌های بردار پشتیبان را می‌توان از خانواده الگوریتم‌های یادگیری ماشین دانست. یکی از زیرمجموعه‌های بزرگ این الگوریتم‌ها، روش‌های یادگیری بر مبنای تابع کرنل (هسته) با یادگیری آماری است. SVM از روش‌های طبقه‌بندی با ناظر است. الگوریتم اولیه و اصلی SVM بر مبنای طبقه‌بندی دودویی است. اساس این دیدگاه بر مبنای شناخت الگوی آماری است؛ ولی روش پیاده‌سازی آن شبیه شبکه‌های عصبی است. ایده اصلی در SVM کاهش ریسک است. در این روش با استفاده از تمامی باندها و یک الگوریتم بهینه‌سازی، نمونه‌هایی که مرزهای طبقه‌ها را تشکیل می‌دهند، به دست می‌آیند؛ این نمونه‌ها را بردارهای پشتیبان گویند. تعدادی از نقاط آموزشی که کمترین فاصله تا مرز تصمیم‌گیری دارند، می‌توانند به عنوان زیرمجموعه‌ای برای تعریف مرزهای تصمیم‌گیری و به عنوان بردار پشتیبان در نظر گرفته شوند.

۵.۴ معیارهای ارزیابی: یکی از مراحل مهم پس از طراحی و ساخت یک مدل، ارزیابی آن مدل است. این معیارها بر اساس چهار عنصر اصلی ماتریس کانفیوژن^{۳۱} یعنی درست مثبت یا به عبارتی پیش‌بینی‌هایی که مثبت در نظر گرفته شده‌اند و درست پیش‌بینی شده‌اند^{۳۲}، درست منفی یا به عبارتی پاسخ‌هایی که منفی در نظر گرفته شده‌اند و درست پیش‌بینی شده‌اند^{۳۳}، غلط مثبت یا به عبارتی پیش‌بینی‌هایی که مثبت در نظر گرفته شده‌اند و به اشتباه پیش‌بینی شده‌اند^{۳۴} و غلط منفی یا به عبارتی پیش‌بینی‌هایی که به عنوان کلاس منفی در نظر گرفته شده‌اند و به اشتباه پیش‌بینی شده‌اند^{۳۵}. در زیر هر یک از معیارهای ارزیابی شرح داده می‌شود:

۱.۵.۴ معیار ارزیابی دقت^{۳۶}: معادله (۱۰) نحوه به دست آوردن معیار ارزیابی دقت را نشان می‌دهد. دقت نشان‌دهنده تعداد پیش‌بینی‌های درست تقسیم بر کل پیش‌بینی‌ها است. پیش‌بینی‌های درست شامل پیش‌بینی‌های درست مثبت و پیش‌بینی‌های درست منفی است. این معیار ارزیابی به طور کلی میزان پیش‌بینی‌های درست مدل را به ما نشان می‌دهد.

$$Accuracy = \frac{TP+TN}{P+N} * 100 \quad (10)$$

³¹ Confusion matrix

³² True positive (TP)

³³ True negative (TN)

³⁴ False positive (FP)

³⁵ False negative (FN)

³⁶ Accuracy

۲.۵.۴ معیار ارزیابی حساسیت^{۳۷}: این معیار ارزیابی، عملکرد طبقه‌بند موردنظر را در نمونه‌های مثبتی که درست پیش‌بینی شده است، بیان می‌کند. معیار ارزیابی حساسیت مطابق معادله (۱۱) محاسبه می‌شود.

$$Sensitivity = \frac{TP}{P} * 100 \quad (11)$$

۳.۵.۴ معیار ارزیابی ویژگی^{۳۸}: این معیار ارزیابی، عملکرد طبقه‌بند موردنظر را در نمونه‌های منفی که درست پیش‌بینی شده است، بیان می‌کند. معیار ارزیابی ویژگی مطابق معادله (۱۲) محاسبه می‌شود.

$$Specificity = \frac{TN}{N} * 100 \quad (12)$$

۵. ارزیابی

در این بخش تأثیر یا عدم تأثیر روش‌های انتخاب کانال‌های بهینه و الگوی فضایی مشترک مورد ارزیابی قرار گرفته شده است. ابتدا بدون استفاده از روش‌های انتخاب کانال‌های بهینه و الگوی فضایی مشترک، دقت روش معمولی مورد ارزیابی قرار گرفته است. سپس با استفاده از دو روش انتخاب کانال‌های بهینه ANOVA و SFFS و روش الگوی فضایی مشترک، دقت روش مورد ارزیابی قرار گرفته است.

در جدول ۱ مقادیر پارامترها در حالت عدم استفاده از روش‌های انتخاب کانال‌های بهینه و الگوی فضایی مشترک نشان داده شده است. همان طور که در جدول ۱ قابل مشاهده است برای بخش پیش‌پردازش سیگنال از ترکیب فیلتر میان‌گذر ایده‌آل و فیلتر باترورث در محدوده فرکانسی ۸ تا ۳۰ هرتز و همچنین برای حذف نویزهای مشترک از فیلتر CAR استفاده شده است. چهار ویژگی میانگین، واریانس، توان سیگنال و جذر میانگین مربع‌ها برای تحلیل سیگنال‌ها استفاده شده است. از سه پارامتر sensitivity, accuracy و specificity برای ارزیابی روش استفاده شده است. روش اعتبارسنجی مورد استفاده روش k-fold با مقدار k=5 می‌باشد. همچنین از سه طبقه‌بند KNN با تعداد همسایه ۱۱ و معیار محاسبه فاصله بلوک شهری، SVM با فعال کردن استانداردسازی پارامترها و LDA به صورت پیش‌فرض استفاده شده است. در جدول ۲ نتایج حاصل از سه طبقه‌بند بدون استفاده از روش‌های انتخاب کانال‌های بهینه و الگوی فضایی مشترک نمایش داده شده است.

جدول ۱. مقادیر پارامترها در حالت عدم استفاده از روش‌های انتخاب کانال‌های بهینه و الگوی فضایی مشترک

butterworth – 8 to 30 Hz	فیلتر میان‌گذر
CAR	فیلتر محلی سازی منبع
mean variance signal power root mean square	ویژگی استخراج شده
accuracy sensitivity specificity	پارامتر ارزیابی طبقه‌بند

³⁷ Sensitivity

³⁸ Specificity

روش اعتبار سنجی	k-fold _ K=5
طبقه‌بندی	KNN 'NumNeighbors',11,'distance','cityblock'
	SVM 'Standardize',1
	LDA default

جدول ۲. نتایج حاصل از سه طبقه‌بند بدون استفاده از روش‌های انتخاب کانال‌های بهینه و الگوی فضایی مشترک

LDA	SVM	KNN	
57	64	58	accuracy
58	60	80	sensitivity
56	68	36	specificity

در این بخش تأثیر یا عدم تأثیر روش الگوی فضایی مشترک مورد ارزیابی قرار گرفته شده است که می‌توان با مقایسه نتایج به دست آمده در جدول ۴ با جدول ۲، تأثیر روش الگوی فضایی مشترک را مشاهده کرد.

در جدول ۳ مقادیر پارامترها در روش فیلتر مکانی پیشرفته CSP نشان داده شده است. توضیحات پارامترهای به کار گرفته شده دقیقاً مشابه توضیحات پارامترهای جدول ۱ می‌باشد با این تفاوت که در این جدول یک پارامتر به نام فیلتر مکانی CSP اضافه گردیده است. همچنین در جدول ۴ نتایج حاصل از سه طبقه‌بند با روش فیلتر مکانی پیشرفته CSP نشان داده شده است.

جدول ۳. مقادیر پارامترها در روش فیلتر مکانی پیشرفته CSP

فیلتر میان‌گذر	butterworth – 8 to 30 Hz
فیلتر محلی سازی منبع	CAR High Laplacian Low Laplacian
	variance
ویژگی استخراج شده	accuracy
	sensitivity
	specificity
روش اعتبار سنجی	k-fold _ K=5
طبقه‌بند	KNN 'NumNeighbors',3,'distance','cityblock'
	SVM

'Standardize', 1, 'kernelfunction', 'linear'	
LDA 'DiscrimType', 'pseudoLinear'	
CSP	فیلتر مکانی

جدول ۴. نتایج حاصل از سه طبقه‌بند با روش فیلتر مکانی پیشرفته CSP

LDA	SVM	KNN	
60	62	65	accuracy
78	66	68	sensitivity
42	58	62	specificity

در این بخش روش‌های انتخاب کانال‌های بهینه ANOVA و SFFS و روش الگوی فضایی مشترک با یکدیگر ترکیب شده است و نتایج آن مورد ارزیابی قرار گرفته شده است.

در جدول ۵ مقادیر پارامترها در روش ANOVA-CSP نشان داده شده است. توضیحات پارامترهای به کار گرفته شده دقیقاً مشابه توضیحات پارامترهای جدول ۱ می‌باشد با این تفاوت که در این جدول یک پارامتر به نام روش انتخاب کانال‌های بهینه ANOVA و یک پارامتر دیگر به نام فیلتر مکانی CSP اضافه گردیده است. همچنین در جدول ۶ نتایج حاصل از سه طبقه‌بند با روش ANOVA-CSP نشان داده شده است. همان طور که در جدول قابل مشاهده است، تعداد کانال‌های انتخابی که بهترین دقت را به دست آورده‌اند، نشان داده شده است.

جدول ۵. مقادیر پارامترها در روش ANOVA-CSP

butterworth – 8 to 30 Hz	فیلتر میان‌گذر
CAR	فیلتر محلی سازی منبع
variance root mean square	ویژگی استخراج شده
accuracy sensitivity specificity	پارامتر ارزیابی طبقه‌بند
k-fold _ K=5	روش اعتبار سنجی
KNN 'NumNeighbors', 11, 'distance', 'cityblock'	طبقه‌بند
SVM 'Standardize', 1, 'kernelfunction', 'linear'	
LDA 'DiscrimType', 'pseudoLinear'	

ANOVA	روش انتخاب کانال بهینه
12 17 39	تعداد کانال‌های انتخاب شده
CSP	فیلتر مکانی

جدول ۶. نتایج حاصل از سه طبقه‌بند با روش ANOVA-CSP

LDA	SVM	KNN	
71	72	74	accuracy
76	76	70	sensitivity
66	68	78	specificity
39	17	12	Number of selected channels

در جدول ۷ مقادیر پارامترها در روش SFFS-CSP نشان داده شده است. توضیحات پارامترهای به کار گرفته شده دقیقاً مشابه توضیحات پارامترهای جدول ۱ می‌باشد با این تفاوت که در این جدول یک پارامتر به نام روش انتخاب کانال‌های بهینه SFFS و یک پارامتر دیگر به نام فیلتر مکانی CSP اضافه گردیده است. در جدول ۸ نتایج حاصل از سه طبقه‌بند با روش SFFS-CSP نشان داده شده است. همان طور که در جدول قابل مشاهده است، تعداد کانال‌های انتخابی که بهترین دقت را به دست آورده‌اند، نشان داده شده است.

جدول ۷. مقادیر پارامترها در روش SFFS-CSP

butterworth – 8 to 30 Hz	فیلتر میان‌گذر
CAR	فیلتر محلی سازی منبع
mean variance signal power root mean square	ویژگی استخراج شده
accuracy sensitivity specificity	پارامتر ارزیابی طبقه‌بند
k-fold _ K=5	روش اعتبار سنجی
KNN 'NumNeighbors', 11, 'distance', 'cityblock' SVM 'Standardize', 1, 'kernelfunction', 'linear' LDA 'DiscrimType', 'pseudoLinear'	طبقه‌بند

روش انتخاب کانال بهینه	SFFS
تعداد کانال‌های انتخاب شده	48
	21
	58
فیلتر مکانی	CSP

جدول ۸. نتایج حاصل از سه طبقه‌بند با روش SFFS-CSP

LDA	SVM	KNN	
68	73	74	accuracy
78	82	74	sensitivity
57	64	74	specificity
58	51	48	Number of selected channels

در جدول ۹ مقایسه روش‌های انتخاب کانال‌های بهینه ANOVA و SFFS بر روی فیلتر مکانی پیشرفته CSP با روش معمولی که در آن از روش انتخاب کانال‌های بهینه و الگوی فضایی مشترک استفاده نشده است و همچنین روشی که از CSP به تنهایی استفاده شده، نشان داده شده است. همان‌طور که مشاهده می‌شود دقت طبقه‌بندها در هنگامی که از روش‌های انتخاب کانال‌های بهینه و الگوی فضایی مشترک بهره گرفته‌ایم، افزایش یافته است. همچنین روش ANOVA + CSP در تعداد کانال‌های انتخابی در کمترین تعداد ممکن برای سه طبقه‌بند استفاده شده قرار گرفته است.

جدول ۹. مقایسه روش‌های انتخاب کانال‌های بهینه و الگوی فضایی مشترک با روش معمولی

SFFS + CSP			ANOVA + CSP			CSP			NORMAL			
LDA	SVM	KNN	LDA	SVM	KNN	LDA	SVM	KNN	LDA	SVM	KNN	
68	73	74	71	72	74	60	62	65	57	64	58	accuracy
78	82	74	76	76	70	78	66	68	58	60	80	sensitivity
57	64	74	66	68	78	42	58	62	56	68	36	specificity
58	51	48	39	17	12	63	63	63	63	63	63	Number of selected channels

۶. نتیجه‌گیری

در این مقاله با بهره‌گیری از یک پایگاه داده تصور حرکتی مبتنی بر سیگنال EEG که برای دو عمل نشستن و برخاستن طراحی شده بود سعی داشتیم که با بهره‌گیری از دو مرحله بسیار حیاتی انتخاب کانال بهینه و فیلتر مکانی پیشرفته به دقت طبقه‌بندی قابل قبولی دست یابیم. همان‌طور که در جدول ۹ قابل مشاهده است، استفاده از روش‌های انتخاب کانال‌های بهینه و الگوی فضایی مشترک باعث شده است که دقت طبقه‌بند افزایش پیدا کند. همچنین استفاده از روش ANOVA + CSP سبب شده است که با کمترین تعداد کانال‌های بهینه ممکن، دقت طبقه‌بند بهبود یابد و پیچیدگی محاسباتی کاهش پیدا کند.

۷. قدردانی

این مقاله حاصل بخشی از نتایج پایان نامه و طرح تحقیقاتی تحت عنوان "ارائه راهکاری برای اجرای دستورات نشست و برخاست در محیط شبیه ساز با پردازش سیگنال های مغزی" در مقطع کارشناسی ارشد مهندسی کامپیوتر - هوش مصنوعی و رباتیکز در سال ۱۴۰۲ می باشد که با حمایت دانشکده و پژوهشکده هوش مصنوعی و علوم شناختی دانشگاه جامع امام حسین (ع) اجرا شده است [15].

۸. منابع و مراجع

- [1] Christoph Guger, Brendan Z Allison, "Recent Advances in Brain-Computer Interface Research—The BCI Award 2013," in *Brain-Computer Interface Research*, New York City, Springer, 2014, pp. 1-6.
- [2] Ujwal Chaudhary, Bin Xia, Stefano Silvoni, Leonardo G Cohen, Niels Birbaumer, "Brain-Computer Interface-Based Communication in the Completely Locked-In State," *PLoS Biology*, vol. 15, no. 1, 2017.
- [3] Jonathan Wolpaw, Elizabeth Winter Wolpaw, *Brain-Computer Interfaces: Principles and Practice*, Oxford: Oxford University Press, 2012.
- [4] Christopher G. Coogan, Bin He, "Brain-Computer Interface Control in a Virtual Reality Environment and Applications for the Internet of Things," *IEEE Access*, vol. 6, pp. 10840 - 10849, 2018.
- [5] Benjamin Blankertz, Florian Losch, Matthias Krauledat, Guido Dornhege, Gabriel Curio, Klaus-Robert Müller, "The Berlin Brain-Computer Interface: accurate performance from first-session in BCI-naïve subjects," *IEEE Transactions on Biomedical Engineering*, vol. 55, no. 10, pp. 2452-2462, 2008.
- [6] Mahnaz Arvaneh, Cuntai Guan, Kai Keng Ang, Chai Quek, "Optimizing the Channel Selection and Classification Accuracy in EEG-Based BCI," *IEEE Transactions on Biomedical Engineering*, vol. 58, no. 6, pp. 1865-1873, 2011.
- [7] Sheng Ge, Ruimin Wang, Dongchuan Yu, "Classification of four-class motor imagery employing single-channel electroencephalography," *PLOS One*, vol. 9, no. 6, pp. 1-7, 2014.
- [8] Huijuan Yang, Cuntai Guan, Kai Keng Ang, Kok Soon Phua, Chuanchu Wang, "Selection of effective EEG channels in brain computer interfaces based on inconsistencies of classifiers," in *Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, 2014.
- [9] Hanchuan Peng, Fuhui Long, C. Ding, "Feature selection based on mutual information criteria of max-dependency, max-relevance, and min-redundancy," *IEEE Transactions on Pattern Analysis*

- and Machine Intelligence*, vol. 27, no. 8, pp. 1226-1238, 2005.
- [10] Adrienne Kline, Nils D. Forkert, Banafshe Felfeliyan, Daniel Pittman, Bradley Goodyear, Janet Ronsky, "fMRI-Informed EEG for brain mapping of imagined lower limb movement: Feasibility of a brain computer interface," *Journal of Neuroscience Methods*, vol. 363, no. 1, 2021.
- [11] Takashi Hoshino, Kazuyo Oguchi, Kenji Inoue, Aiko Hoshino, Minoru Hoshiyama, "Relationship between lower limb function and functional connectivity assessed by EEG among motor-related areas after stroke," *Topics in Stroke Rehabilitation*, vol. 28, no. 8, pp. 614-623, 2021.
- [12] Víctor Asanza, Alisson Constantine, Stephany Valarezo, Enrique Peláez, "Implementation of a Classification System of EEG Signals Based on FPGA," in *Seventh International Conference on eDemocracy & eGovernment (ICEDEG)*, Buenos Aires, 2020.
- [13] Mario Ortiz, Eduardo Iáñez, José L Contreras-Vida, José M Azorín, "Analysis of the EEG Rhythms Based on the Empirical Mode Decomposition During Motor Imagery When Using a Lower-Limb Exoskeleton. A Case Study," *Frontiers in Neurorobotics*, vol. 14, no. 48, 2020.
- [14] Susanna Yu. Gordleeva, Sergey A. Lobov, Nikita A. Grigorev, Andrey O. Savosenkov, Maxim O. Shamshin, Maxim V. Lukoyanov, Maxim A. Khoruzhko, Victor B. Kazantsev, "Real-Time EEG–EMG Human–Machine Interface-Based Control System for a Lower-Limb Exoskeleton," *IEEE Access*, vol. 8, pp. 84070-84081, 2020.
- [۱۵] حسین حسینی، محمدعلی جوادزاده، ایمان علیدادی شمس‌آبادی، ارائه راهکاری برای اجرای دستورات نشست و برخاست در محیط شبیه‌ساز با پردازش سیگنال‌های مغزی، تهران: دانشکده و پژوهشکده هوش مصنوعی و علوم شناختی دانشگاه جامع امام حسین (ع)، ۱۴۰۲.

Increasing the accuracy of classification of brain signals based on lower limb motor imagery by combining optimal channel selection methods and common spatial pattern

Hossein Hosseini¹, Mohammad Ali Javadzadeh², Iman Alidadi Shamsabadi³

¹Master's student in artificial intelligence and robotics, Faculty of artificial intelligence and cognitive sciences, Imam Hossein Comprehensive University, Tehran, Iran.

hosseinhosseini@ihu.ac.ir

²Assistant Professor, Faculty of artificial intelligence and cognitive sciences, Imam Hossein Comprehensive University, Tehran, Iran.

javadzade@ihu.ac.ir

³Researcher, Faculty of artificial intelligence and cognitive sciences, Imam Hossein Comprehensive University, Tehran, Iran.

imanalidadi@ihu.ac.ir

Abstract— The brain-computer interface system provides a communication path between the brain and the computer and has recently received increasing attention. One of the most common paradigms of brain-computer interface systems is motor imagery. The brain-computer interface system based on motor imagery using electroencephalogram signals uses a large number of channels when receiving signals. Channels not related to the intended task cause unwanted interference and increase the noise level. In this paper, we present two optimal channel selection methods to improve common spatial pattern (CSP)-related features for classification of motor imagery tasks. Since the brain activities of motor imagery are located in a specific area of the brain, how to choose the right channels is important to improve the performance of the brain-computer interface. In this paper, analysis of variance (ANOVA) feature selection and sequential forward feature selection (SFFS) combined with common spatial pattern (CSP) are used to select optimal electrode channels. The results show that the accuracy of KNN, SVM and LDA classifications when using ANOVA+CSP method is 74, 72 and 71% respectively, when using SFFS+CSP method is 74, 73 and 68% respectively, when using CSP alone, 65, 62 and 60%, respectively, when not using the methods of selecting optimal channels and common spatial pattern, it is 58, 64 and 57%, respectively; Therefore, the combination of optimal channel selection methods and common spatial pattern has increased the accuracy of the classifiers.

Keywords: brain-computer interface, electroencephalogram, motor imagery, common spatial pattern, channel selection.