

Applying Probabilistic Classification Vector Machines in Self-paced BCI to Enhance Foot Movement Detection

R. Mohammadi¹, A. Mahloojifar^{2*}

¹Ph.D Student, Biomedical Eng. Department, Electrical and Computer Eng. College, TarbiatModares University, Tehran, Iran, raheleh.mohammadi@modares.ac.ir

²Associate Professor, Biomedical Eng. Department, Electrical and Computer Eng. College, TarbiatModares University, Tehran, Iran.

Abstract

A critical issue in designing a self-paced brain computer interface (BCI) system is onset detection of the mental task from the continuous electroencephalogram (EEG) signal to produce a brain switch. This work shows significant improvement in a movement based self-paced BCI by applying a new sparse learning classification algorithm, probabilistic classification vector machines (PCVMs) to classify EEG signal. Constant-Q filters instead of constant bandwidth filters for frequency decomposition are also shown to enhance the discrimination of movement related patterns from EEG patterns associated with idle state. Analysis of the data recorded from seven subjects executing foot movement using the constant-Q filters and PCVMs shows a statistically significant 16% ($p < 0.03$) average improvement in true positive rate (TPR) and a 2% ($p < 0.03$) reduction in false positive rate (FPR) compared with applying constant bandwidth filters and SVM classifier.

Key words: Self-paced Brain computer interface, Constant-Q filters, Probabilistic classification vector machines

*Corresponding author

Address: Biomedical Eng. Department, Electrical and Computer Eng. College, TarbiatModares University, Tehran, Iran, Postal Code: 14115-194

Tel: +982182883304

Fax: +982182884325

E-mail: mahlooji@modare.ac.ir

استفاده از طبقه‌بند PCVM در سیستم واسط مغز- رایانه کاربرفرما به منظور بهبود تشخیص حرکت پا

راحله محمدی^۱، علی محلوچی فر^{۲*}

^۱ دانشجوی دکتری مهندسی پزشکی، گروه بیوالکتریک، دانشکده برق و کامپیوتر، دانشگاه تربیت مدرس، تهران

raheleh.mohammadi@modares.ac.ir

^۲ دانشیار، گروه بیوالکتریک، دانشکده برق و کامپیوتر، دانشگاه تربیت مدرس، تهران

چکیده

اساس سیستم‌های واسط مغز-رایانه (BCI) کاربرفرما آشکارسازی و تشخیص بازه‌های رخداد یک فعالیت ذهنی مانند تصور حرکت از سیگنال خودبخودی مغز است که این مسأله به دلیل ماهیت غیرایستانت و پیچیده سیگنال الکتروانسفالوگرام (EEG) مهمترین چالش در طراحی سیستم‌های BCI است. در این مقاله برای اولین بار از یک الگوریتم جدید طبقه‌بندی مبتنی بر یادگیری تنک به نام PCVM در طراحی سیستم BCI کاربرفرما استفاده شده است. هدف اصلی مقاله بررسی میزان موفقیت این طبقه‌بند در آشکارسازی بازه‌های وقوع حرکت پا در سیگنال پیوسته EEG است. PCVM در مقایسه با SVM - که تاکنون عملکرد بسیار موفقی در سیستم‌های BCI مبتنی بر حرکت و تصور حرکت داشته است - مزایای قابل توجهی از جمله ارائه خروجی به صورت احتمال تعلق دادگان به هر یک از طبقه‌ها و همچنین تعیین پارامترهای بهینه کرنل همزمان در الگوریتم یادگیری دارد. بعلاوه در این مقاله از فیلترهای با ضریب کیفیت ثابت به منظور تجزیه فرکانسی سیگنال استفاده شده است که به دلیل ماهیت قدرت تفکیک متغیر زمانی و فرکانسی در فرکانس‌های مرکزی مختلف، نقش مؤثرتری در تمایز الگوهای مربوط به بازه حرکت از سیگنال پس‌زمینه مغزی ایفا می‌کند. متوسط نتایج حاصل از طراحی سیستم کاربرفرما با استفاده از روش پیشنهاد شده در این مقاله برای دادگان ثبت شده از ۷ کاربر حین انجام حرکت پا بصورت $TPR=90\%$ و $FPR=4\%$ بدست آمد که در مقایسه با کارهای پیشین برای همین مجموعه دادگان، بهبود قابل ملاحظه‌ای (۱۶٪ بهبود TPR و ۲٪ بهبود FPR) حاصل شد.

کلیدواژگان: سیستم‌های واسط مغز-رایانه کاربرفرما، فیلترهای Constant-Q، طبقه‌بند PCVM

*عهده‌دار مکاتبات

نشانی: تهران، بزرگراه جلال آل احمد، دانشگاه تربیت مدرس، دانشکده برق و کامپیوتر، گروه مهندسی پزشکی، کدپستی: ۱۹۴-۱۴۱۱۵

تلفن: ۰۲۱-۸۲۸۸۳۳۰۴، دورنگار: ۰۲۱-۸۲۸۸۴۳۲۵، پیام نگار: mahlooji@modares.ac.ir

۱- مقدمه

به منظور طراحی سیستم کاربرفرمای پایدار و مطمئن، فعالیت ذهنی باید انتخاب شود که در اثر اجرای آن الگوهای مغزی شناخته شده و تکرارپذیری در سیگنال مغزی EEG ظاهر شود. تصور حرکت، فعالیت ذهنی شناخته شده‌ای در حوزه علوم اعصاب است که با انجام آن در نواحی معینی از مغز و در باندهای فرکانسی خاصی، انرژی سیگنال EEG تغییر می‌کند و دو پدیده ناهمزمانی وابسته به رخداد ERD^۴ و همزمانی وابسته به رخداد ERS^۵ در باندهای میو و بتا ظاهر می‌شوند [۴]. ناهمزمانی وابسته به رخداد (ERD) کاهش انرژی در ریتمهای مغزی است که بدلیل فعال شدن همبسته شبکه‌های عصبی در نواحی خاصی از قشر مغز و حین فاز آماده‌سازی قبل از انجام حرکت و گاه حین انجام حرکت دیده می‌شود. بعبارت دیگر به علت افزایش سرعت شارژ و دشارژ شدن نورونها در پردازش اطلاعات و برنامه ریزی سیگنالهای کنترلی برای حرکت اندامها، دامنه سیگنال EEG در باندهای میو و بتا کم می‌شود. در مقابل، همزمانی وابسته به رخداد (ERS) افزایش انرژی همان ریتمهای مغزی است که بدلیل غیرفعال شدن دوباره و برگشت به حالت طبیعی و آرامش شبکه‌های عصبی در نواحی خاص مغز بوجود می‌آید [۴]. بعلاوه ثابت شده است که در حالت تصور حرکت اندامی خاص، پدیده‌های ERD/S در همان نواحی مربوط روی کورتکس حرکتی ظاهر می‌شوند [۶]. دلیل رخداد این پدیده‌ها را حین تصور حرکت می‌توان با استفاده از نورونهای آینه‌ای توضیح داد. در واقع زیرمجموعه‌ای از نورونها در کورتکس حرکتی نه تنها در حالتی که شخص عملی را انجام می‌دهد؛ بلکه در حالتی که مشاهده می‌کند دیگری نیز آن عمل را انجام می‌دهد تحریک می‌شوند. این نورونها، نورونهای آینه‌ای نامیده می‌شوند. بنا به فرضیات کاسلین^۶ [۵] نورونهای آینه‌ای می‌توانند در تصورات حرکتی نیز دخیل باشند؛ زیرا افراد معمولاً تصور حرکت را با آنکه شاهد انجام حرکت فرد دیگری هستند؛ تصور می‌کنند. از آنجایی که الگوهای ERD/S در هر دو حالت اجرای حرکت و یا تصور اجرای حرکت در سیگنال مغزی دیده می‌شوند [۶] و همچنین برچسب‌گذاری دقیق داده‌های مربوط به اجرای حرکت آسانتر است؛ معمولاً

واسط مغز- رایانه (BCI)^۱ سیستمی ارتباطی بین انسان و رایانه است که امکان انتقال پیام و دستورات انسان را به محیط بدون نیاز به ماهیچه‌ها فراهم می‌کند [۱]. در این سیستم کاربر با تولید الگوهای خاصی در سیگنال مغزی خود دستوراتی را به جهان خارج ارسال می‌کند و رایانه با آشکارسازی این الگوها در سیگنال مغزی و ترجمه آنها، دستورات مورد نظر کاربر را اجرا می‌کند. استفاده از سیستم BCI در خارج آزمایشگاه به دلیل وجود محدودیتهایی، تاکنون عملی نشده است. چندین موضوع که در راستای تحقق هدف وارد کردن سیستم BCI به زندگی روزمره افراد، باید مورد توجه قرار گیرند؛ عبارتند از: ۱) کاهش تعداد الکترودهای ثبت سیگنال EEG، ۲) روشی ساده به منظور راه‌اندازی سیستم برای هر کاربر بدون نیاز به متخصصان، ۳) استفاده از الگوهای مغزی قابل تکرار و درونزا و ۴) طراحی سیستمی که به صورت آسنکرون^۲ یا (کاربرفرما) کار می‌کند. واژه کاربرفرما یا آسنکرون به این معناست که سیستم BCI بطور پیوسته تحت اختیار کاربر باشد و بتواند بازه‌های زمانی را که کاربر قصد کنترل سیستم ندارد مانند تماشای تلویزیون، مطالعه روزنامه و ... تشخیص دهد [۲]. بطور کلی از لحاظ نحوه عملکرد، سیستم‌های BCI به دو دسته کلی سنکرون^۳ و کاربرفرما (آسنکرون) تقسیم می‌شوند [۲]. در یک سیستم BCI سنکرون، پردازش، طبقه‌بندی و فعالسازی سیستم تنها در بازه‌های زمانی از پیش تعیین شده‌ای انجام می‌شود. به عبارت دیگر لحظه وقوع فعالیت ذهنی از پیش معین است. تاکنون بیشتر مطالعات در حوزه BCI سنکرون انجام شده‌اند؛ که تنها به تفکیک انواع فعالیتهای ذهنی کاربر می‌پردازند. این نحوه ارتباط در بسیاری از کاربردهای عملی غیر طبیعی است؛ زیرا کنترل سیستم بطور پیوسته در اختیار کاربر نیست. در مقابل در سیستم‌های BCI کاربرفرما کل سیگنال مغزی به صورت پیوسته برای یافتن بازه وقوع فعالیت ذهنی پردازش می‌شود. مهمترین چالش در زمینه طراحی سیستم‌های کاربرفرما آشکارسازی لحظه وقوع فعالیت ذهنی یا بعبارت دیگر توانایی تشخیص بازه‌های رخداد یا کنترل از سیگنال پس زمینه مغزی است [۲، ۳].

^۱Brain computer interface
^۲Event related synchronization

^۳Self-paced
^۴Kosslyn

^۳ synchronous

^۴Event related de-synchronization

برای ارزیابی عملکرد الگوریتم‌های جدید یادگیری ماشین در بیشتر سیستم‌های کاربرفرما از دادگان اجرای حرکت استفاده می‌شود [۷].

سیستم BCI که تنها قادر به تشخیص یک الگوی ذهنی از سیگنال EEG پیوسته است، سوئیچ مغزی نامیده می‌شود. تاکنون روشهای متعددی در حوزه پردازش سیگنال و شناسایی الگو برای طراحی سوئیچ مغزی مبتنی بر حرکت ارائه شده است. بعنوان مثال میلان^۷ و همکارانش از یک طبقه‌بند عصبی برای حذف سیگنال‌های غیرحرکتی استفاده کرده‌اند [۸]. سوئیچ آسنکرون فرکانس پایین (LF-ASD)^۸ - که در دانشگاه بریتیش کلمبیا طراحی شده [۹] - نیز یکی از اولین سیستم‌های کاربرفرماست که به مرور زمان بر بخش‌های مختلف پردازشی آن به منظور بهبود عملکرد تغییراتی اعمال شده است [۱۰]. در آخرین نسخه این سوئیچ فتوره‌چی و همکارانش [۱۱] از ویژگی‌های استخراج شده از سه پدیده نورولوژیک: پتانسیل وابسته به حرکت (MRP)^۹، تغییرات توان باند میو (۸-۱۲) هرتز و باند بتا (۱۸-۲۵) هرتز برای آموزش مجموعه‌ای از طبقه‌بندهای SVM^{۱۰} استفاده شد و در نهایت با استفاده از ترکیب خروجی طبقه‌بندهای SVM، حرکت انگشت اشاره دست راست از سیگنال‌های خودبخودی مغز تشخیص داده می‌شود. در منبع [۱۲] گلان^{۱۱} و همکارانش از تغییرات چگالی طیف توان (PSD)^{۱۱} برای طبقه‌بندی و آشکارسازی لحظه شروع حرکت در سیگنال پیوسته EEG استفاده کرده‌اند. شیخ حسن^{۱۳} و همکارانش در دانشگاه Essex، از روش طبقه‌بندی بدون سرپرستی مبتنی بر مدل مخلوط گوسی (GMM)^{۱۴} برای آشکارسازی حرکت دست راست استفاده کردند [۷]. سوئیچ مغزی دیگری - که منابع در [۱۴، ۱۳] اسکالانتی^{۱۵} در گروه گراتز^{۱۶} آنرا طراحی کرده - از ترکیب نتایج دو طبقه‌بند SVM که بصورت مستقل برای آشکارسازی هر یک از پدیده‌های ERD و ERS آموزش داده شده‌اند، برای تشخیص وقوع حرکت پا در سیگنال EEG استفاده شده است. در پژوهش‌هایی که اخیراً در گروه‌های گراتز [۱۵] و بریتیش کلمبیا^{۱۷} [۱۷، ۱۶] انجام شده است، از

سوئیچ مغزی برای طراحی سیستم‌های هایبرید^{۱۸} استفاده شده است تا به این طریق انتخابهای متنوع‌تر کاربر در تعامل با محیط به همراه کاهش تعداد تشخیص‌های نادرست مثبت فراهم شوند. فورتسچلر^{۱۹} در منبع [۱۵] سیستم BCI هایبرید متشکل از سوئیچ مغزی مبتنی بر تصور حرکت پا و سیستم BCI مبتنی بر SSVEP^{۲۰} را ارائه کرد. یانگ^{۲۱} و همکارانش از سیستم‌های هایبریدی متشکل از سیستم کاربرفرمای مبتنی بر حرکت باز کردن دست و یک ردیاب حرکت چشم، در کاربردهای تایپ متن استفاده کردند. در سیستم طراحی شده این گروه حرکت چشم و خیره شدن به هدف نقش اشاره‌گر^{۲۲} و سیستم کاربرفرمای مبتنی بر حرکت نقش کلیک‌کننده^{۲۳} را بر عهده دارند [۱۷، ۱۶]. از میان طبقه‌بندهای مختلفی که تاکنون در سیستم‌های کاربرفرما استفاده شده‌اند، طبقه‌بند SVM مبتنی بر کرنل گوسی^{۲۴} عملکرد موفق‌تری داشته است و بیشتر از آن استفاده شده است. در سیستم‌های سنکرون نیز طبقه‌بند SVM، موفق‌ترین طبقه‌بند شناخته شده است. از دلایل موفقیت طبقه‌بند SVM قابلیت تعمیم‌پذیری بسیار خوب این طبقه‌بند است که دلیل آن برخورداری از مؤلفه تنظیم^{۲۵} است. از آنجایی که سیگنال‌های EEG معمولاً آغشته به نویز هستند، تعداد نقاط پرت^{۲۶} در این دادگان نیز زیاد است. وجود مؤلفه تنظیم قابلیت تعمیم‌پذیری SVM را در مواجهه با نقاط پرت افزایش می‌دهد. دلیل دیگر آنکه SVM در مسائل با ابعاد زیاد پایداری خوبی دارد بنابراین حتی در شرایطی که بعد بردار ویژگی در برابر تعداد دادگان آموزشی زیاد باشد (که معمولاً در BCI این مسأله رایج است) قادر است دقت طبقه‌بندی خوبی را ارائه کند. علی‌رغم توانمندی‌های قابل توجه طبقه‌بند SVM، عدم ارائه خروجی بصورت احتمال تعلق داده به هر یک از طبقه‌ها، افزایش تعداد بردارهای پشتیبان با افزایش تعداد دادگان آموزشی و در نتیجه افزایش پیچیدگی سیستم، همچنین استفاده از روش زمانبر جستجوی تو در تو و ارزیابی متقاطع به منظور یافتن پارامترهای بهینه عرض کرنل و ضریب تنظیم از جمله ضعف‌های این طبقه‌بند است.

⁷Milan¹¹Gala'n¹⁵Escalante¹⁹Pfurtscheller²³Clicking device⁸low Frequency-Asynchronous Switch Design¹²Power spectrum density¹⁶Graz²⁰Steady state evoked potential²⁴Gaussian kernel⁹Movement-related pattern¹³Sheikh Hasan¹⁷British Colombia²¹Yong²⁵regularization¹⁰Support Vector Machine¹⁴Gaussian Mixture Model¹⁸Hybrid²²Pointing device²⁶outlier

ثابت را در طراحی سوئیچ مغزی ارائه خواهیم کرد و در نهایت نتیجه‌گیری تحقیق در بخش پنجم ارائه می‌شود.

۲- معرفی مجموعه دادگان

مجموعه دادگان -که آزمایشگاه BCI دانشگاه گراتز^{۳۱} اتریش در اختیار ما قرار داد- از ۷ فرد سالم (۵ مرد و ۲ زن با میانگین سنی ۲۴/۶±۱/۴) طی انجام حرکت پا ثبت شده بود [۱۳]. ابتدا کاربر بر روی صندلی دسته‌دار راحتی، به فاصله ۱/۲ متر مقابل صفحه نمایش کامپیوتر می‌نشست. از کاربر خواسته می‌شد که در هر تک ثبت^{۳۲} با دیدن پیکانی با جهت رو به پایین در صفحه نمایش، هر دوپای خود را از ناحیه مج با خم کردن به سمت عقب و جلو به مدت یک ثانیه حرکت دهد. در ابتدای هر اجرا صفحه‌ای سیاه دیده می‌شد. در زمان $t=0$ یا ابتدای هر تک ثبت، علامت "+" به رنگ سبز در صفحه نمایش ظاهر می‌شد. در ثانیه دوم، $t=2s$ ، صدایی توجه کاربر را جلب می‌کند و در همان لحظه علامت فلش به سمت پایین ظاهر می‌شود. این علامت به معنای حرکت هر دو پا حداقل به مدت یک ثانیه بود. علامت پیکان در زمان $t=3/20s$ و علامت "+" در زمان $t=7/5s$ ناپدید می‌شدند. زمان ثانیه پایان هر تک ثبت بود. پس از آن بطور میانگین ۱ ثانیه تا شروع تک ثبت بعدی فاصله بود. [قسمت (ب) شکل (۱)] به این ترتیب برای هر شخص سه اجرای جداگانه ثبت می‌شد و هر اجرا متشکل از ۳۰ تک ثبت ۷/۵ ثانیه‌ای انجام حرکت پا بود. ۱۶ الکتروود تک قطبی -که نواحی حسی حرکتی قشر مغز را می‌پوشانند- برای ثبت سیگنال EEG استفاده می‌شدند. [قسمت (الف) شکل (۱)] با استفاده از این ۱۶ کانال، تغییر مرجع به روش لاپلاسین برای کانال Cz انجام شده است. به این ترتیب که مطابق رابطه (۱) متوسط سیگنال‌های کناری کانال Cz محاسبه و از آن سیگنال کم شده است:

$$V_{Cz}^{Lap} = V_{Cz} - \frac{1}{4} \sum_{k \in S_j} V_k \quad (1)$$

V_{Cz} در رابطه (۱) پتانسیل سطحی EEG در کانال Cz است و S_j مجموعه ۴ الکتروودی است که بصورت متعامد در همسایگی Cz قرار دارند [۱۳]. لازم است ذکر شود که تنها سیگنال V_{Cz} از سوی دانشگاه گراتز در اختیار ما قرار داده

به منظور رفع مشکلات فوق و ضعف‌های طبقه‌بند SVM بدون از دست دادن توانمندی‌های ارزشمند آن، الگوریتم طبقه‌بندی PCVM^{۳۳} در منبع [۱۸] ارائه شده است. این طبقه‌بند با ارائه خروجی بصورت احتمال تعلق هر نمونه به هر یک از طبقه‌ها و یافتن پارامترهای بهینه همزمان با فرایند یادگیری بدون نیاز به ارزیابی مقاطع و جستجوهای زمانبر در فاز آموزش و همچنین کنترل پیچیدگی با استفاده از تابع توزیع پیشین گوسی یکطرفه بر وزنه‌های مدل و ارائه بردار تنکی از وزنها، توانمندی خود را در دستیابی به عملکردی بهتر از طبقه‌بند SVM در ۱۳ دسته متنوع از دادگان مرجع^{۳۴} با استفاده از معیارهای متنوع ارزیابی ثابت کرد [۱۸].

در این مقاله برای اولین بار از طبقه‌بند PCVM در حوزه BCI، استفاده و عملکرد این روش با طبقه‌بند SVM بعنوان موفق‌ترین روش طبقه‌بندی در حوزه سیستم‌های کاربرفرما [۱۳]، در آشکارسازی پدیده ERS مقایسه شده است. به منظور کمی کردن اطلاعات پدیده ERS از لگاریتم توان باند سیگنال EEG در باندهای فرکانسی معینی در بازه ۶ تا ۳۶ هرتز استفاده شده است. روش استخراج ویژگی توان باند از روشهای موفق است که به دلیل حجم محاسباتی کم، تاکنون بطور گسترده‌ای در سیستم‌های کاربرفرمای روی خط^{۳۵} استفاده شده است [۱۹-۲۱]. در این مقاله در فاز پیش‌پردازش نیز از فیلترهای با ضریب کیفیت ثابت^{۳۰} به منظور تجزیه فرکانسی سیگنال، استفاده شده است. در منبع [۲۲] برای اولین بار ایده استفاده از بانک فیلتر با ضریب کیفیت ثابت در فاز پیش‌پردازش سیستم‌های BCI را مطرح کردیم و تأثیر استفاده از این روش تجزیه فرکانسی را در بهبود قابل توجه عملکرد سیستم‌های BCI مبتنی بر حرکت نشان دادیم.

در ادامه این مقاله، در بخش دوم ابتدا به طور خلاصه به معرفی مجموعه دادگان مورد استفاده در این تحقیق می‌پردازیم، روش استخراج ویژگی، طبقه‌بندی و نحوه ارزیابی عملکرد را در بخش سوم ارائه می‌کنیم. در بخش چهارم نتایج استفاده از طبقه‌بند PCVM و SVM به همراه هر دو نوع فیلترهای با ضریب کیفیت ثابت Q و فیلترهای با پهنای باند

²⁷Probabilistic Classification Vector Machine
³¹Graz University

²⁸benchmark
³²trial

²⁹Online

³⁰Constant-Q


خودبخودی مغز استفاده کردیم. حین انجام فعالیت وابسته به حرکت، اول ERD و بدنال آن ERS رخ می‌دهد. لازم است ذکر شود که این الگوها برای هر شخص در باند فرکانسی منحصر به فردی اتفاق می‌افتد و میزان بروز این الگوها نیز از شخصی به شخص دیگر متفاوت است. با توجه به نتایج مطالعات [۱۴،۱۳] استفاده از پدیده ERS در طراحی الگوریتم‌های آشکارسازی حرکت، نتایج بسیار خوبی در مقایسه با پدیده ERD داشته است؛ لذا در این مقاله ما به دنبال آشکارسازی پدیده ERS که پس از حرکت پا در سیگنال EEG ظاهر می‌شود، از سیگنال خودبخودی مغز هستیم. ویژگی توان باند از روشهای موفقی است که به دلیل حجم محاسباتی کم، تاکنون بطور گسترده‌ای در سیستم‌های کاربرفرمای روی خط مورد استفاده قرار گرفته است. منابع [۱۹-۲۱] ویژگی توان باند نوسانات و تغییرات توان سیگنال را در باندهای فرکانسی مختلف محاسبه کرده‌اند و لذا می‌توانند داده‌های بسیار مفیدی را برای تشخیص پدیده ERS در سیگنال EEG فراهم کنند.

۳-۱-۱-۳- پیش‌پردازش: تجزیه فرکانسی با فیلترهای

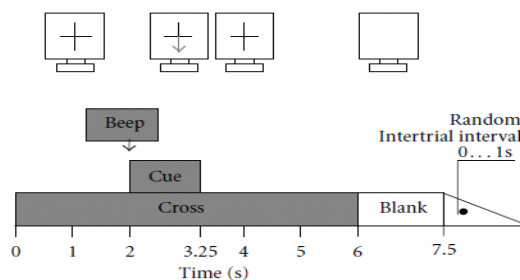
Constant-Q

از آنجایی که باند فرکانسی که پدیده ERS در آن اتفاق می‌افتد در افراد مختلف متفاوت است، لذا از دیدگاه یادگیری، دو راه برای تجزیه فرکانسی سیگنال پیشنهاد می‌شود: (۱) تعیین باند فرکانسی ERS برای هر شخص در فاز آموزش و (۲) استفاده از مجموعه بانک فیلتری و آموزش سیستم بطور همزمان با استفاده از ویژگی‌های استخراج شده در همه این زیرباندها. در این مقاله ما از یک آرایه بانک فیلتری استفاده کردیم که هر یک از آنها فیلتر میانگذر خاصی است و در مجموع همه آنها محدوده فرکانسی میو و بتا را پوشش می‌دهند. بطور کلی تجزیه فرکانسی را می‌توان با استفاده از

شد که بین ۰/۵ تا ۵۰ هرتز فیلتر و با آهنگ ۲۵۰ هرتز نمونه برداری شد.



(الف)



(ب)


شکل (۱) - موقعیت الکترودها (الف) و الگوی ثبت دادگان گراتز (ب) که زمانبندی یک تک ثبت را نشان می‌دهد [۲۲].

۳- روش

روندنمای سیستم ارائه شده در این مقاله در شکل (۲) نشان داده شده است. در این بخش به بیان جزئیات هر یک از بخش‌ها اعم از پیش‌پردازش، استخراج ویژگی، طبقه‌بندی و پس‌پردازش و همچنین نحوه ارزیابی روش پیشنهادی در آشکارسازی بازه وقوع حرکت خواهیم پرداخت.

۳-۱- استخراج ویژگی

هدف بخش استخراج ویژگی یافتن نمایش مناسبی از دادگان در فضایی مناسب است تا طبقه‌بندی و آشکارسازی الگوهای مغزی آسانتر انجام شود. در این مقاله ما از روش لگاریتم توان باند به منظور آشکارسازی الگوی ERS از سیگنال



شکل (۲) بلوک دیاگرام سیستم طراحی شده برای این تحقیق [۳۶].

پنجره‌های زمانی یک ثانیه‌ای از سیگنال، با استفاده از لگاریتم توان باند به شرح ذیل انجام شد: (۱) عبور از فیلترهای میانگذر (فیلترهای باترورث مرتبه پنج) در باندهای فرکانسی ذکر شده در بخش ۳-۱-۱، (۲) به توان دو رساندن کلیه نمونه‌ها در هر زیر باند، (۳) متوسط‌گیری همه نمونه‌های موجود در هر پنجره یک ثانیه‌ای، (۴) محاسبه لگاریتم مقدار متوسط محاسبه شده در مرحله ۳. نهایتاً بردار ویژگی متشکل از ۲۸ ویژگی توان باند برای توصیف کامل هر بخش یک ثانیه‌ای از سیگنال EEG بدست آمد. برچسب‌گذاری دادگان آموزشی بر اساس اطلاعاتی انجام شد که از نقشه زمان-فرکانس دادگان هر شخص در شکل (۳) بدست آمد. به نمونه‌های سیگنال EEG یکی از دو برچسب حرکت (طبقه ۱) و یا سیگنال پس‌زمینه (طبقه صفر) تعلق گرفت. بر اساس نقشه زمان-فرکانس [۲۶] ERD/S افراد مختلف [شکل (۳)] ERS برای همه افراد تقریباً در بازه $t=5-0$ s از هر تک ثبت اتفاق می‌افتد. بنابراین نمونه‌های موجود در این بازه زمانی از هر تک ثبت طبقه ۱ و بقیه نمونه‌ها طبقه صفر برچسب‌گذاری شدند.

۳-۲- طبقه‌بندی

انتخاب روش طبقه‌بندی مناسب در حوزه سیستم‌های BCI به دلایل متنوعی حائز اهمیت است. از آنجایی که سیگنال‌های EEG و الگوهای مغزی دارای نویز زیادی هستند، نقاط پرت در مجموعه ویژگی‌های مربوط به هر طبقه به چشم می‌خورد که وجود این نقاط می‌تواند عملکرد طبقه‌بند را در فاز آزمون به شدت تحت تأثیر قرار دهند. بنابراین باید از طبقه‌بندی استفاده شود که از قدرت تعمیم‌پذیری زیادی برخوردار است. بعد بردار ویژگی نیز به دلیل وجود تعداد کانال‌های زیاد ثبت و همچنین استخراج ویژگی در باندهای فرکانسی متنوع معمولاً زیاد است، بنابراین طبقه‌بندی که انتخاب می‌شود نباید به بعد زیاد بردار ویژگی حساس باشد. از طرف دیگر به دلیل در اختیار داشتن مجموعه دادگان آموزشی محدود در حوزه BCI، استفاده از روشهای طبقه‌بندی با الگوریتم‌های یادگیری آسان با تعداد پارامترهای محدود در حل چنین مسائلی موفق‌ترین در سالهای اخیر طبقه‌بند SVM از موفق‌ترین

فیلترهایی با پهنای باند ثابت و یا فیلترهایی با ضریب کیفیت ثابت (Q: ضریب کیفیت) انجام داد. در تجزیه فرکانسی ضریب کیفیت ثابت، نسبت فرکانس مرکزی به پهنای باند در همه فیلترها یکسان و مساوی Q است. به عبارت دیگر در فرکانس‌های کمتر قدرت تفکیک فرکانسی و در فرکانس‌های بیشتر قدرت تفکیک زمانی بهتر است. این فیلترها به دلیل برخورداری از ویژگی قدرت تفکیک فرکانسی و زمانی متغیر، در پردازش سیگنال‌های غیر ایستاد مانند سیگنال‌های موسیقی به کرات استفاده می‌شوند [۲۳]. پس از انتخاب فرکانس‌های مرکزی برای مقادیر مختلف Q، پهنای باند هر فیلتر با استفاده از رابطه (۲) محاسبه می‌شود:

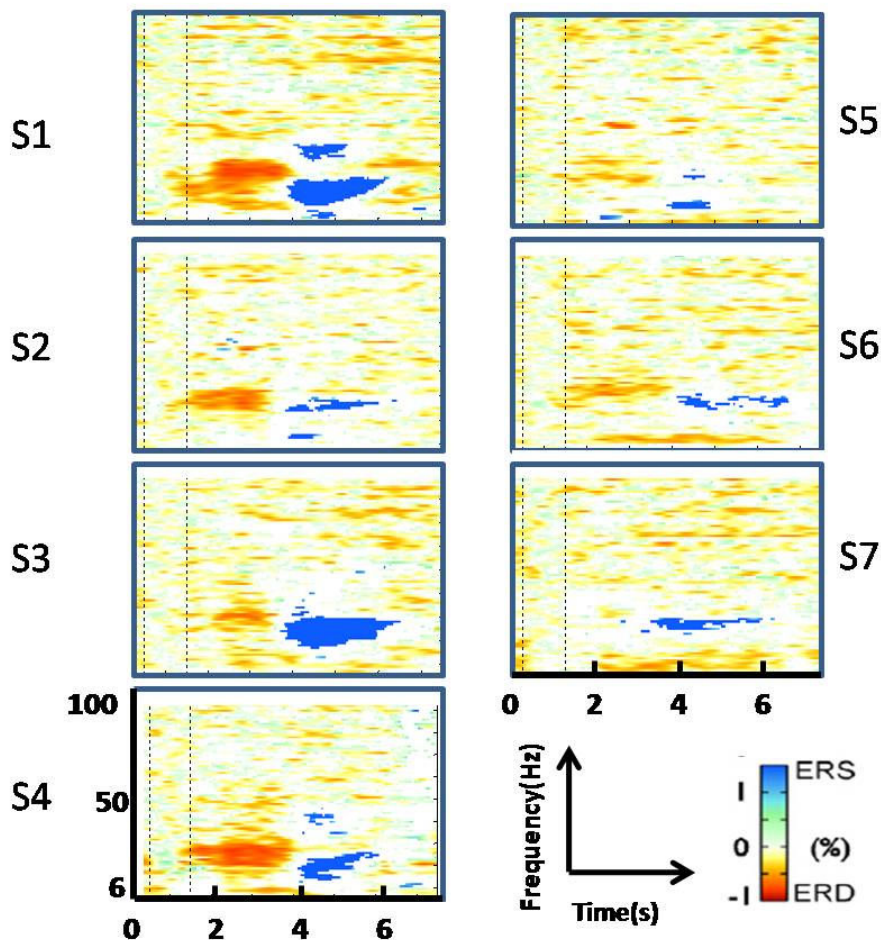
$$Bw = \frac{f_c}{Q} \quad (2)$$

که Bw پهنای باند فیلتر، f_c فرکانس مرکزی و Q ضریب کیفیت فیلتر است. مقادیر مختلف Q منجر به تجزیه‌های فرکانسی متفاوتی از سیگنال می‌شود. اگر Q کوچک انتخاب شود پهنای باند فیلتر بزرگ می‌شود که در این حالت مؤلفه‌های سیگنال EEG به نویزهای زیادی آغشته می‌شوند. در مقابل برای مقادیر بزرگ Q، پهنای باند فیلترها کوچک و همچنین درصد همپوشانی باندهای فرکانسی مجاور کم می‌شود که در نتیجه میزان افزونگی مناسب سیگنال کم خواهد شد. در این مقاله برای مقدار $Q=2,3$ ، دو دسته فیلتر باترورث^{۳۳} مرتبه پنج در فرکانس‌های مرکزی پیشنهاد شده در منبع [۲۴]، $17/5$ ، $15/3$ ، $13/4$ ، $11/7$ ، $10/2$ ، 9 ، $7/8$ ، $6/9$ ، 6 ، $20/8$ ، $26/1$ ، $29/8$ و $33/5$ طراحی شد که در مجموع بازه فرکانسی میو، بتا و گاما را می‌پوشاند. فرکانس‌های مرکزی به نحوی انتخاب شدند که ابتدای بین فرکانسی بعدی منطبق بر فرکانس مرکزی بین فرکانسی فعلی باشد.

۳-۱-۳- لگاریتم توان باند

به منظور استخراج ویژگی‌های مربوط به تک ثبت‌های دادگان آموزشی به این صورت عمل کردیم: هر تک ثبت با استفاده از پنجره‌های زمانی یک ثانیه‌ای متحرک با همپوشانی ۵۰۰ میلی ثانیه از $t=-1$ تا $t=9$ ثانیه نسبت به شروع تک ثبت ($t=0$) پردازش شد (لحظه ظاهر شدن فلش بر صفحه نمایش و شروع حرکت $t=2$ ثانیه است). توصیف طیفی هر یک از

³³Butterworth



شکل (۳) - نقشه زمان-فرکانس ERD/S مربوط به افراد S1 تا S7 که با ترکیب کلید تک ثبتهای مربوط به هر ۳ اجرا برای هر کاربر رسم شده است. تنها تغییرات توان باند بارز ($P < 0.05$) در بازه زمانی صفر تا ۷/۵ ثانیه و در باند فرکانسی ۶ تا ۳۶ هرترز نمایش داده شده (کاهش توان یا ERD به رنگ قرمز، افزایش توان یا ERS به رنگ آبی و فاصله مرجع بازه زمانی ۰/۵ تا ۱/۵ ثانیه در هر شکل با خط چین نشان داده شده است).

توجه به بحثهای ارائه شده در منبع [۲۹] این تخمینها قابل اطمینان نیستند. ثالثاً برای تعیین پارامترهای کرنل بهینه σ و ضریب جریمه C باید از روش جستجوی تودرتو^{۳۴} و ارزیابی متقاطع دادگان آموزشی استفاده کرد که این روش از نظر زمانی و محاسباتی وقت گیر است. به منظور رفع ضعفهای فوق، طبقه‌بند RVM^{۳۵} را Tipping در مطالعه [۲۹] ارائه کرد. الگوریتم RVM، روش بیزین^{۳۶} مبتنی بر کرنل تنک است که بسیاری از خصوصیات SVM برای طبقه‌بندی و رگرسیون را داراست، در حالی که مسائل و ضعفهای SVM در آن برطرف شده است. استفاده از این روش منجر به تشکیل مدل‌های تنک‌تر و در نتیجه عملکرد سریع‌تر برای دادگان


طبقه‌بندها در حوزه BCI شناخته شده است [۱۲-۲۷، ۱۴]. با وجود عملکرد بسیار خوب این روش و بهره‌مندی از ویژگی‌هایی که در بالا به آنها اشاره شد، در عمل چند مسأله و ضعف مهم در استفاده از این طبقه‌بند وجود دارد: اولاً تعداد بردارهای پشتیبان با افزایش تعداد نمونه‌های آموزشی بطور خطی افزایش می‌یابد، ثانیاً خروجی SVM به صورت احتمال قابل بیان نیست؛ بعبارت دیگر SVM برای کاربردهای طبقه‌بندی که در آنها نیاز است احتمال پسین تعلق داده‌ای به هر یک از طبقه‌ها را داشته باشیم، مناسب نیست. البته برخی روشهای پس‌پردازشی به منظور تبدیل خروجی باینری این طبقه‌بند به خروجی‌های احتمالی ارائه شده‌اند [۲۸]؛ اما با

³⁴Grid search

³⁵Relevance Vector Machines

³⁶Bayesian

دام افتادن در بیشینه‌های محلی، تعیین بهترین مقدار اولیه پارامترها در فاز آموزش است.



شکل (۴) - تابع گوسی یک طرفه بر بردار وزنها W . وقتی $y_i = +1$ آنگاه $p(w_i | \alpha_i)$ یک تابع غیر منفی (گوسی ناقص از سمت چپ) است. وقتی $y_i = -1$ آنگاه $p(w_i | \alpha_i)$ تابع غیر مثبت (گوسی ناقص از سمت راست) است [۱۸].

در مجموعه دادگان مورد استفاده در این مقاله، برای هر شخص ۳ اجرا ثبت شده بود که هر اجرا شامل ۳۰ تک ثبت بود. سیگنال‌های دو اجرا را داده‌های آموزش و سیگنال اجرای سوم را داده آزمون در نظر گرفتیم. بنابراین از داده‌های ۶۰ تک ثبت از ۲ اجرای آموزشی برای انتخاب مقادیر اولیه پارامترهای PCVM استفاده کردیم. شایان ذکر است برای یافتن مقدار اولیه بهینه از روش ارائه شده راسچ $Rastch^{38}$ [۳۰] به صورت زیر استفاده کردیم: ۵ مرتبه دادگان آموزشی را با استفاده از ارزیابی متقاطع 5-fold به دو قسمت با نسبت ۱ به ۴ به ترتیب به مجموعه‌های آزمون و آموزش ثانویه تقسیم کردیم، به نحوی که مجموعه‌های آزمون بدون همپوشانی باشند. یک مدل PCVM را با مقادیر اولیه مختلفی (۹ مقدار مختلف $\theta_{initial}$ از ۲ تا ۶ با گام ۰/۵) با استفاده از دادگان آموزش ثانویه، آموزش دادیم و عملکرد آن را به ازای هر مقدار اولیه برای دادگان آزمون ثانویه بر مبنای رابطه $TF = TPR - FPR$ (اختلاف بین نرخ تشخیص درست مثبت TPR^{39} و نرخ تشخیص نادرست مثبت FPR^{40}) اندازه‌گیری کردیم. در نهایت تمام نتایج بدست آمده را در آرایه‌ای با ۹ سطر و ۵ ستون قرار دادیم، به طوری که سطرها و ستونها به ترتیب بیانگر مقادیر اولیه و fold ها هستند. در

آزمون در مقایسه با SVM می‌شود. استفاده از تعداد توابع کرنل کمتر منجر به کاهش پیچیدگی محاسباتی تابع تصمیم‌گیری می‌شود؛

بنابراین RVM برای کاربردهای زمان واقعی مناسب‌تر است. در مسائل طبقه‌بندی، RVM یک تابع احتمال پیشین گوسی با میانگین صفر روی وزنه‌های مرتبط با دادگان طبقه‌های مثبت و منفی در نظر می‌گیرد. به این ترتیب تعدادی از دادگان آموزشی که متعلق به طبقه مثبت هستند ممکن است وزنی با مقدار منفی داشته باشند و یا برعکس. این فرمول‌بندی می‌تواند منجر به شرایطی شود که در آن تصمیم‌گیری RVM بر اساس برخی بردارهای غیر قابل اعتماد صورت گیرد و بنابراین طبقه‌بند به انتخاب دقیق پارامترهای کرنل حساس شود. به دلیل حساسیت RVM به پارامترهای کرنل است که تاکنون از این روش علی‌رغم مزیت‌های قابل توجه آن در مقایسه با SVM، در حوزه BCI استفاده نشده است. به منظور رفع این مشکل RVM، روش $PCVM^{37}$ در مطالعه [۱۸] پیشنهاد شد که در آن توابع احتمال پیشین با توزیع‌های متفاوتی بر وزنه‌های دادگان آموزشی متعلق به هر یک از طبقه‌ها تعریف می‌شود. به عبارت دیگر برای دادگان متعلق به طبقه مثبت، تابع توزیع گوسی ناقص از سمت چپ یا غیر منفی و برای دادگان طبقه منفی، تابع توزیع گوسی ناقص از سمت راست یا غیر مثبت تعریف می‌شود [شکل (۴)]. همچنین الگوریتم PCVM پارامترهای بهینه کرنل را همزمان با الگوریتم یادگیری تعیین می‌کند و بنابراین نیازی به تعیین این پارامترها نیست [ضمیمه (الف)].

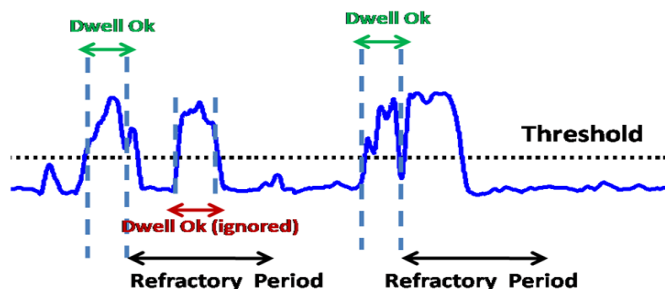
۳-۲-۲- انتخاب مقادیر اولیه پارامترها و آموزش طبقه‌بند تنها پارامتر الگوریتم PCVM - که بصورت خودکار حین فرایند آموزش مقدار بهینه آن انتخاب می‌شود و تابع توزیع پیش‌بینی روی آن تعریف نشده است - θ است. الگوریتم EM که برای انتخاب این پارامتر استفاده می‌شود، به انتخاب مقدار اولیه پارامتر حساس است؛ لذا احتمال دارد در صورت انتخاب مقدار اولیه نامناسب این الگوریتم در بیشینه‌های محلی متوقف شود. روش معمول به منظور جلوگیری از به

³⁷Probabilistic Classification Vector Machines

³⁸Rastch

³⁹True Positive Rate

⁴⁰False Positive Rate



شکل (۵)- نمایش تصویری مفاهیم مقدار آستانه، زمان سکون و زمان بازگشت.

به منظور درک بهتر این مفاهیم شکل (۵) به صورت تصویری مثالی ارائه شده است. مجموع مدت زمان سکون و زمان بازگشت، اولاً نباید از فاصله زمانی بین دو رخداد متوالی بیشتر انتخاب شود؛ بعلاوه انتخاب مقدار بزرگ برای هر یک از این دو پارامتر منجر به کاهش آهنگ انتقال اطلاعات می‌شود و یا عبارتی زمان پاسخ‌دهی سیستم کند می‌شود. در اینجا زمان سکون برابر ۱۰۰ نمونه و زمان بازگشت برابر ۷۵۰ نمونه در نظر گرفته شد که در مجموع مدت زمان ۳/۴ ثانیه بود. با این انتخاب فرض بر این است که شخص حداقل تا ۳/۴ ثانیه پس از کنترل (روشن کردن) سیستم، مجدداً قصد کنترل آن را نداشته باشد. البته این فرض در بسیاری از کاربردهای کنترلی فرضی، کاملاً عملی است.

۳-۴- ارزیابی عملکرد

از آنجایی که پدیده ERS ممکن است پس از وقوع حرکت تا چند ثانیه وجود داشته باشد، بازه کنترل و رخداد را به بازه ۳ تا ۵/۵ ثانیه در هر تک ثبت گسترش دادیم. در این قسمت از روش ارزیابی رخداد به رخداد به صورت رابطه (۳) و (۴) برای محاسبه TPR و FPR استفاده شد:

$$TPR = \frac{TPIC}{N_{TPIC}} \quad (3)$$

$$FPR = \frac{FPIC}{N_{FPIC}} \quad (4)$$

در رابطه (۳)، $TPIC$ ^{۴۲} یا رخداد کنترلی مثبت به هر تشخیص در بازه کنترلی ۳ تا ۵/۵ ثانیه گفته می‌شود و در رابطه (۴) $FPIC$ ^{۴۳} یا رخداد کنترلی نادرست مثبت، هر تشخیص در بازه‌های خارج از بازه فوق است.

N_{TPIC} تعداد بازه‌های رخداد در طول کل سیگنال و

هر ستون مقدار اولیه‌ای را انتخاب کردیم که مقدار TF حاصل از اعمال آن بیشینه باشد. در نهایت ۵ مقدار اولیه (از حاصل از اعمال آن بیشینه باشد. در نهایت ۵ مقدار اولیه (از هر ستون یک مقدار) بدست آمد که میانه آماری آنها بر اساس منبع [۳۰] بهترین مقدار $\theta_{initial}$ را حاصل می‌کرد. لازم است ذکر شود به منظور پیاده سازی این طبقه‌بند از کدهای ارائه شده در مطالعه [۳۱] در محیط متلب^{۴۱} استفاده شد.

۳-۲-۳- آزمون

همانگونه که در قسمت ۳-۲-۲ اشاره شد برای هر شخص ۲ اجرا در فاز آموزش و اجرای سوم برای ارزیابی PCVM استفاده شد. به منظور شبیه‌سازی سیستم روی خط، ویژگی‌های لگاریتم توان باند را با اعمال پنجره لغزان ۱ ثانیه‌ای با طول گام ۱ نمونه از سیگنال اجرای سوم استخراج کردیم. عبارت دقیق‌تر به هریک از نمونه‌های اجرای سوم یک برچسب توسط طبقه‌بند تعلق گرفت تا بتوانیم لحظه وقوع حرکت را تشخیص دهیم.

۳-۳- پس پردازش

به منظور بهبود عملکرد سیستم، مرحله پس‌پردازش برای خروجی طبقه‌بند (احتمال پسین طبقه رخداد یا حرکت) مربوط به نمونه‌های دادگان آزمون، اعمال شد. این مرحله با استفاده از اعمال آستانه و همچنین استفاده از دو پارامتر زمان سکون و زمان بازگشت موجب بهبود عملکرد طبقه‌بند و کاهش تعداد تشخیص‌های نادرست می‌شود [۳۲]. زمان سکون، فاصله زمانی است که باید خروجی طبقه‌بند بیش از حد آستانه باقی بماند تا تشخیص رخداد، معتبر قلمداد شود. زمان بازگشت به فاصله زمانی گفته می‌شود که پس از وقوع تشخیص رخداد معتبر، به خروجی طبقه‌بند توجهی نمی‌شود.

^{۴۱}Matlab

^{۴۲}True positive intentional control

^{۴۳}False positive intentional control

تفصیل بیان شده است. در اینجا نیز از ارزیابی متقاطع 10-fold برای دادگان آموزش هر کاربر استفاده شد؛ سپس مقادیر TPR و FPR نمونه به نمونه به ازای هر جفت از مقادیر C و σ - که در بازه [0,2] بصورت لگاریتمی تغییر می‌کنند - محاسبه شد و در نهایت با مقایسه $TF=TPR-FPR$ به ازای مقادیر مختلف پارامترها، پارامترهای بهینه طبقه‌بند انتخاب شدند. با استفاده از این پارامترهای بهینه و هر دو اجرای استفاده شده در فاز آموزش طبقه‌بند نهایی برای فاز آزمون، آموزش داده شد. علاوه بر SVM با کرنل گوسی عملکرد SVM با کرنل خطی نیز در این کاربرد بررسی شد؛ اما نتایج برتری قابل توجه کرنل گوسی را در این کاربرد نشان دادند، بنابراین تنها نتایج SVM و PCVM با کرنل گوسی در این مقاله گزارش شده‌اند.

بر اساس نتایج ارائه شده در جدول (۱)، متوسط مقدار TPR یا نرخ تشخیص درست مثبت بازه‌های رخداد حرکت پا، با استفاده از طبقه‌بند PCVM با کرنل گوسی بطور میانگین برای ۷ کاربر برابر ۸۳ درصد گزارش شده است که در مقایسه با مقدار میانگین ۷۳ درصد در حالت استفاده از طبقه‌بند SVM، ۱۰ درصد بهبود را نشان می‌دهد.

بر اساس نتایج ارائه شده برای هر کاربر بهبود نتایج با استفاده از طبقه‌بند PCVM بویژه برای افراد S_2 ، S_6 و S_7 قابل توجه است. در این حالت [جدول (۱)] استفاده از PCVM نه تنها نرخ تشخیص درست مثبت بازه‌های حرکت پا را بهبود بخشیده، میزان تشخیص‌های نادرست را نیز حدود ۱٪ کاهش داده است.

جدول (۲) نتایج عملکرد سوئیچ مغزی طراحی شده با استفاده از فیلترهای با ضریب کیفیت ثابت Q و دو طبقه‌بند SVM و PCVM را نشان می‌دهد. در اینجا نیز بهبود ۳ و ۱ درصدی میانگین TPR و FPR با استفاده از طبقه‌بند PCVM در مقایسه با SVM، حاصل شده است. در این حالت، بهبود عملکرد در افزایش تشخیص‌های درست یا TPR تنها در مورد شخص S_2 قابل توجه است؛ در حالی که نرخ تشخیص‌های نادرست مثبت FPR تقریباً در بیشتر افراد با استفاده از طبقه‌بند PCVM یافته است. بنابراین با توجه به

N_{FPIC} تعداد کل نمونه‌ها تقسیم بر مجموع زمان بازگشت و زمان سکون است. در این مقاله تعداد بازه‌های رخداد برابر ۳۰ (در هر اجرا ۳۰ تک ثبت و هر تک ثبت شامل یک بازه رخداد حرکتی است) و N_{FPIC} تقریباً به طور میانگین برابر ۱۲۰ بود.

نتایج پس از ارزیابی نمودارهای ROC^{۴۴} (TPR) برحسب FPR که به ازای مقادیر مختلف آستانه بدست می‌آیند) ارائه می‌شود. به این ترتیب که به ازای مقادیر مختلف آستانه از صفر تا ۱ و با گام ۰/۰۵، مقادیر TPR و FPR محاسبه شده‌اند و سپس مقادیر مربوط به نقطه ای از نمودار که اولاً مقدار FPR آن از ۱۰ درصد کمتر است و ثانیاً به خط $y = 1 - x$ (محور عمودی یا TPR و محور افقی یا FPR) نزدیک‌تر است، برای هر کاربر انتخاب شده است.

۴- نتایج و بحث

نتایج مربوط به آشکارسازی رخداد حرکت پا با استفاده از فیلتر با پهنای باند ثابت و فیلتر با ضریب کیفیت ثابت Q برای پیش‌پردازش و استفاده از دو طبقه‌بند PCVM و SVM در جداول (۱) و (۲) خلاصه شده‌اند. در این جدولها برای هر شخص مقادیر TPR و FPR به صورت میانگین \pm انحراف معیار گزارش شده است. برای هر شخص سه ترکیب مختلف از اجراهای آموزش/آزمون امکان‌پذیر است. متوسط سه نتیجه حاصل از این سه ترکیب در جدولها ارائه شده است. نتایج اعمال فیلترهای با پهنای باند ثابت در مرحله تجزیه فرکانسی سیگنال EEG به همراه هر یک از طبقه‌بندهای SVM و PCVM در جدول (۱) ارائه شده است. به منظور تجزیه فرکانسی با استفاده از فیلترهای با پهنای باند ثابت از مجموعه‌ای ۲۹ تایی فیلترهای باترورت مرتبه ۵ با پهنای باند ثابت ۲ هرتز و همپوشانی ۱ هرتز - که محدوده فرکانسی ۶ تا ۳۶ هرتز را می‌پوشانند - استفاده می‌شود؛ همانگونه که در منبع [۱۳] ارائه شده است.

در این مقاله از نرم‌افزار Lib-SVM [۳۳] به منظور پیاده‌سازی طبقه‌بند SVM با کرنل گوسی استفاده شد. نحوه تعیین پارامترهای C و σ این طبقه‌بند در منابع [۳۴] و [۲۲] به

⁴⁴Recursive Operating Curve

جدول (۱)- مقایسه عملکرد SVM و PCVM در حالتی که فیلترهای با پهنای باند ثابت برای تجزیه فرکانسی استفاده شدند.

Subject ID	SVM		PCVM	
	TPR(Mean±SD)	FPR(Mean±SD)	TPR(Mean±SD)	FPR(Mean±SD)
S1	94±5	2±2	91±12	3±2
S2	54±20	10±2	79±25	8±1
S3	97±4	3±3	96±2	3±2
S4	80±7	6±4	80±23	5±3
S5	56±23	10±3	60±11	7±1
S6	65±7	7±4	85±12	7±3
S7	61±2	7±2	91±2	5±3
Average	73±13	6±3	83±15	5±2

جدول (۲)- مقایسه عملکرد SVM و PCVM در حالتی که فیلترهای با ضریب کیفیت ثابت Q برای تجزیه فرکانسی استفاده شدند.

Subject ID	SVM		PCVM	
	TPR(Mean±SD)	FPR(Mean±SD)	TPR(Mean±SD)	FPR(Mean±SD)
S1	98±4	2±2	98 ±4	1±2
S2	62±12	8±1	87±9	9±1
S3	98±2	2±1	98±2	2±2
S4	93±4	6±3	93±0	3±1
S5	80±3	8±1	80±3	8±2
S6	90±12	7±3	91±2	4±3
S7	86±10	5±2	80±6	4±3
Average	87±8	5±2	90±4	4±2

فیلترهای با ضریب کیفیت ثابت در استخراج الگوهای ذهنی مربوط به حرکت (پدیده ERS) از سیگنال EEG را با استفاده از هر دو طبقه‌بند اثبات می‌کند. افزایش قدرت تفکیک زمانی در فرکانس‌های مرکزی بیشتر و افزایش قدرت تفکیک فرکانسی در فرکانس‌های مرکزی کمتر از مهمترین ویژگی‌های این نوع فیلترهاست که موجب کاهش خواص غیر ایستانی سیگنال EEG می‌شود و می‌تواند عامل بهبود عملکرد نهایی سیستم‌های مبتنی بر این روش تجزیه فرکانسی باشد.

با مقایسه ستون سمت راست جدول (۱) و ستون سمت چپ جدول (۲) می‌توان دریافت که استفاده توأم از فیلترهای با ضریب کیفیت ثابت در بخش پیش‌پردازش و طبقه‌بند PCVM در بخش طبقه‌بند، سبب بهبود قابل ملاحظه عملکرد سیستم در شناسایی بازه‌های رخداد حرکت پا می‌شود. انجام آزمون آماری دو جهته ویلکاکسون^{۴۵} بین این نتایج، ثابت می‌کند که بهبود نتایج از نظر آماری (با مقدار $p=0.015 < 0.05$) معتبر است.

نکته جالب توجهی که از مقایسه میزان بهبود عملکرد طبقه‌بند PCVM و SVM در جدولهای (۱) و (۲) حاصل می‌شود، آن است که با انتخاب ویژگی‌های ضعیفتر و در

نتایج ارائه شده در این جدولها PCVM نه تنها قادر است عملکردی مشابه SVM داشته باشد، بلکه در بسیاری از موارد به مراتب بهتر از SVM در شناسایی بازه‌های رخداد حرکت پا در سیگنال پیوسته EEG عمل می‌کند.

به منظور مقایسه عملکرد سیستم در استفاده از دو روش تجزیه فرکانسی با پهنای باند ثابت و با ضریب کیفیت ثابت، ستونهای متناظر در دو جدول را با یکدیگر مقایسه می‌کنیم. مقایسه ستونهای سمت چپ هر دو جدول نشان می‌دهد که تنها با تغییر روش تجزیه فرکانسی با استفاده از طبقه‌بند SVM می‌توانیم بطور میانگین بهبود ۱۴ و ۱ درصدی به ترتیب در میزان TPR و FPR داشته باشیم. مقایسه ستون سمت راست جدول نیز بهبود عملکرد با استفاده از روش تجزیه فرکانسی با ضریب کیفیت ثابت را در حالت بکارگیری روش طبقه‌بندی PCVM به میزان ۷ و ۱ درصد در TPR و FPR نشان می‌دهد. در مطالعه [۲۲] ما برای اولین بار نشان دادیم که استفاده از فیلترهای با ضریب کیفیت ثابت و تعیین خودکار پارامترهای بهینه پس‌پردازش یعنی زمان سکون و زمان بازگشت متناسب با هر شخص می‌تواند عملکرد سیستم کاربرفرما را بهبود بخشد. در اینجا نیز مقایسه جدولهای (۱) و (۲)، توانمندی

⁴⁵Wilcoxon

آموزش سیستم با استفاده از هر یک از الگوریتم‌های طبقه‌بندی SVM و PCVM ارائه شده است. میانگین مدت زمان لازم برای تعیین پارامترهای عرض کرنل و ضریب تنظیم در الگوریتم SVM و میانگین مدت زمان لازم برای تعیین مقدار اولیه عرض کرنل در استفاده از الگوریتم PCVM محاسبه شده؛ در سطر اول جدول ارائه شده است. همچنین در این جدول متوسط مدت زمان لازم برای تعیین برچسب‌های تمامی نمونه‌های اجرای آزمون (حاوی ۳۰ تک ثبت) و نیز تعداد متوسط بردارهای پشتیبان مورد استفاده در هر الگوریتم برای تشکیل مدل تابع تصمیم ثبت شده است. همانگونه که مشاهده می‌شود تعداد بردارهای پشتیبان یا عبارت دیگر پیچیدگی تابع تصمیم در الگوریتم PCVM بسیار کمتر از الگوریتم SVM است که این اختلاف در مدت زمان لازم برای تعیین برچسب‌های دادگان فاز آزمون نیز وجود دارد؛ اما مدت زمان لازم برای تعیین پارامترهای بهینه SVM بطور میانگین کمتر از PCVM است.

جدول (۳) - مقایسه متوسط زمان محاسبات و پیچیدگی دو روش

طبقه‌بندی

طبقه‌بند PCVM	طبقه‌بند SVM	روش طبقه‌بندی پارامترهای مورد بررسی
۶۵۴ ثانیه	۵۸۸ ثانیه	متوسط زمان آموزش سیستم
۰/۲۳ ثانیه	۶۳۱ ثانیه	متوسط زمان اجرا (فاز آزمون)
۲۱	۴۲۶	متوسط تعداد بردارهای پشتیبان

علت مشاهده این تناقض آن است که اجرای PCVM کاملاً در محیط متلب انجام شده، در حالی که برای اجرای SVM در نرم‌افزار libsvm، از فایل‌های Mex ++ C استفاده شده است. بنابراین اگر امکان پیاده سازی در شرایط یکسان وجود داشته باشد یقیناً مدت زمان لازم برای آموزش الگوریتم PCVM از زمان لازم برای آموزش الگوریتم SVM کمتر خواهد بود. لازم است ذکر شود کلیه محاسبات در محیط ویندوز ۷، و با استفاده از سیستم با مشخصات پردازشگر Intel Core 2 Due 2.4G و 2G RAM انجام شده است.

از جمله پژوهش‌های مهمی که در زمینه طراحی سیستم

حالی که همپوشانی بیشتری بین ویژگی‌های استخراج شده از دادگان دو طبقه وجود داشته باشد یعنی در شرایط استفاده از فیلترهای با پهنای باند ثابت، بهبود عملکرد PCVM در مقایسه با SVM قابل ملاحظه‌تر است [جدول (۱)]. بنابراین در شرایطی که ویژگی‌ها بخوبی انتخاب نشده باشند، روش PCVM به طور قابل توجهی موفق‌تر از SVM است؛ اما در حالی که ویژگی‌ها با استفاده از فیلترهای با ضریب کیفیت ثابت از سیگنال EEG استخراج می‌شود عملکرد PCVM در تشخیص بازه‌های رخداد حرکت پا تقریباً (جز در مورد S_2 که TPR حدوداً ۲۵ درصد بهبود می‌یابد) با SVM برابری می‌کند. البته فراموش نکنیم که استفاده از PCVM مزایای بسیاری در مقایسه با SVM دارد؛ اولاً پارامتر عرض کرنل بهینه همزمان با الگوریتم یادگیری تعیین می‌شود و ثانیاً تعداد بردارهای پشتیبان که PCVM در طول آموزش از آنها استفاده می‌کند کمتر از SVM است. عبارت دیگر این الگوریتم مدل تنک‌تری را در مقایسه با SVM ارائه می‌کند که منجر به کاهش پیچیدگی محاسباتی تابع تصمیم می‌شود.

پیچیدگی زمانی^{۴۶} الگوریتم‌های طبقه‌بندی PCVM و SVM هر دو از درجه ۳ یا $O(N^3)$ است که N نشان‌دهنده تعداد نقاط آموزشی است [۱۸]. پیچیدگی محاسباتی^{۴۷} SVM با استفاده از روش پیاده‌سازی بر مبنای الگوریتم SMO^{۴۸} از مرتبه $O(N^{2.1})$ و پیچیدگی محاسباتی PCVM از مرتبه $O(M^3)$ است که $M < N$ نشان‌دهنده تعداد توابع پایه با ضریب غیرصفر است. با استفاده از الگوریتم PCVM، بدلیل اعمال شرط پیشین تنک بودن بردار وزنها و همگرایی سریع الگوریتم EM، تعداد توابع پایه برای تشکیل مدل تصمیم از مقدار اولیه $M=N$ بسرعت به تعداد بسیار کوچکی کاهش می‌یابد. بعلاوه با استفاده از الگوریتم PCVM نیازی به اجرای جستجوی تودرتو و ارزیابی متقاطع برای تعیین مقادیر بهینه پارامترهای ضریب تنظیم و عرض کرنل نیست؛ زیرا در PCVM عرض بهینه کرنل همزمان با یادگیری در الگوریتم EM تعیین می‌شود و تنها مقدار اولیه این پارامتر برای جلوگیری از به دام افتادن در بیشینه‌های محلی در فاز آموزش تعیین می‌شود. در جدول (۳) میانگین مدت زمان لازم برای

⁴⁶Time complexity

⁴⁷Computational Complexity

⁴⁸sequential minimal optimization

SVM برای استخراج هر یک از پدیده‌ها در منبع [۱۳] استفاده شد و در نهایت با استفاده از ترکیب دو طبقه‌بند SVM سوئیچ مغزی طراحی شده حرکت پا را با میانگین $TPR=74\%$ و $FPR=6\%$ تشخیص می‌دهد. در مطالعه [۱۳] همچنین نشان داده شد که نتایج سیستم مبتنی بر پدیده ERS مشابه نتایج سیستم مبتنی بر ترکیب دو پدیده ERD و ERS است. از آنجایی که دادگان مورد استفاده در این تحقیق و منبع [۱۳] یکسان هستند امکان مقایسه دقیق نتایج و سیستم طراحی شده در این مقاله با مطالعه [۱۳] وجود دارد. با مقایسه عملکرد سیستم طراحی شده در این مقاله [ستون سمت راست جدول (۲)] و مقاله [۱۳] دیده می‌شود که مقدار میانگین TPR و FPR به ترتیب ۱۶ و ۲ درصد بهبود یافته‌اند. البته این بهبود عملکرد به قیمت کاهش زمان پاسخ‌دهی سیستم است؛ زیرا مجموع مقدار زمان سکون و زمان بازگشت در منبع [۱۳] برابر ۲/۵ ثانیه و در این مقاله برابر ۳/۴ ثانیه انتخاب شده است. کاهش مدت زمان پاسخ‌دهی سیستم برای بسیاری از کاربردهای کنترلی ساده در ازای بدست آوردن تعداد تشخیص‌های صحیح بیشتر و کاهش تشخیص‌های نادرست مثبت ارزشمند است.

بطور خلاصه ویژگی‌های مثبت سیستم طراحی شده در این مقاله عبارتند از: استفاده از تعداد کانال‌های ثبت محدود، آموزش سیستم با استفاده از دادگان ثبت شده در مدت ۱۵ دقیقه (دو اجرا شامل ۶۰ تک ثبت)، استفاده از پدیده نورولوژیک پایدار و تکرارپذیر ERS که نه تنها در حین حرکت واقعی بلکه در تصور حرکت در سیگنال EEG اتفاق می‌افتد، فاز آموزشی ساده بدون نیاز به انتخاب پارامترهای متعدد طبقه‌بند، استفاده از مجموعه ویژگی‌های یکسان برای همه کاربران بدون تعیین باندهای فرکانسی و زمانی بهینه برای هر کاربر و در نهایت دستیابی به عملکرد میانگین $TPR=90\%$ و $FPR=4\%$ در مجموع در این پژوهش با استفاده از طبقه‌بند PCVM و روش تجزیه فرکانسی مبتنی بر فیلترهای با ضریب کیفیت ثابت در طراحی سوئیچ مغزی، به هدف استفاده از سیستم‌های BCI در خارج از آزمایشگاه با راه‌اندازی آسان و عملکرد مطمئن نزدیکتر شده‌ایم. البته با توجه به اینکه مبنای

کاربرفرمای دوحالتی یا سوئیچ مغزی در سالهای اخیر انجام شده می‌توان به سیستم ارائه شده فتوره‌چی و همکارانش [۱۱] اشاره کرد که موفق شدند حرکت انگشت اشاره دست راست را از سیگنال پس‌زمینه مغزی در دادگان ثبت شده از ۴ فرد سالم با متوسط $TPR=56\%$ و $FPR=5\%$ استخراج کنند. در این طراحی از پتانسیل وابسته به حرکت یا MPR^{49} در کنار تغییرات ریتم میو و بتا برای تشخیص بازه‌های حرکتی استفاده شد. با توجه به مطالعاتی که تاکنون انجام شده MRP در حالت تصور حرکت در سیگنال EEG دیده نمی‌شود [۴]؛ بنابراین تعمیم نتایج این سیستم به سیستم‌های مبتنی بر تصور حرکت معتبر نیست. همچنین فاز آموزش این سیستم بسیار پیچیده است و نیاز به تنظیم پارامترهای چندین طبقه‌بند SVM دارد. تعداد الکترودهای ثبت نیز برابر ۱۸ کانال ثبت دوقطبی است. کیان و همکارانش [۳۵] الگویی جدید برای سوئیچ مغزی مبتنی بر تصور حرکت انگشت مطرح کردند که در آن شخص با تکرار تصور حرکت تلاش می‌کرد سیستم را روشن کند. در این تحقیق مبنای روشن شدن سیستم، تغییرات سطح توان ERD بود و به محض آنکه این مقدار از آستانه‌ای معین عبور می‌کرد سیستم روشن می‌شد. در این سیستم معیار ارزیابی عملکرد میزان تشخیص‌های نادرست مثبت و مدت زمان پاسخ‌دهی سیستم بود که بطور متوسط برای چهار نفر بصورت روی خط برابر $FPR=0.8\%$ و $36/9$ ثانیه گزارش شد. مقدار FPR گزارش شده در این سیستم مطلوب است اما مدت زمان پاسخ‌دهی سیستم برای بسیاری از کاربردها مناسب نیست. البته شایان ذکر است که در این مقاله از روشهای پردازشی پیچیده و الگوریتم‌های یادگیری استفاده نشده است؛ به نظر می‌رسد با استفاده از روش طبقه‌بندی مناسبی عملکرد این سیستم تا حد قابل قبولی ارتقا یابد.

در تحقیق دیگری که اسکالانت^{۵۰} [۱۳] برای طراحی سوئیچ مغزی مبتنی بر حرکت پا انجام داده است با ترکیب سیستم‌های مبتنی بر هر دو پدیده ERD و ERS تلاش شده است که یک سوئیچ مغزی با دقت مناسب طراحی شود. تجزیه فرکانسی با استفاده از بانک فیلترهای با پهنای باند ثابت ۲ هرتز، روش استخراج ویژگی لگاریتم توان باند و طبقه‌بند

⁴⁹Movement related Potential

⁵⁰Escalante

سپاسگزاری

با تشکر از جناب آقای پروفیسور فورتسچلر و آقای اسکالانتی از دانشگاه گراتز اتریش به دلیل در اختیار قرار دادن دادگان حرکت پا که در این مقاله از آن استفاده شد.

ضمیمه:

- الگوریتم PCVM

در مسائل طبقه‌بندی با سرپرستی، مجموعه‌ای از دادگان آموزشی به صورت جفتهای مقدار دادگان ورودی و برچسب هر داده بصورت $\{X_i, y_i\}_{i=1}^N$ داده می‌شود که $y_i = \{-1, +1\}$ نشان‌دهنده هر یک از طبقه‌ها است. هدف در این مسائل یافتن مدل $f(X; W)$ بر اساس مجموعه دادگان آموزشی است، به نحوی که طبقه‌بند بتواند برای دادگان آزمون نیز عملکرد مناسبی داشته باشد و اصطلاحاً از قدرت تعمیم‌پذیری خوبی برخوردار باشد. این مدل توسط مقادیر نامعین وزن‌های W کنترل می‌شود. مدلی معروف و انعطاف‌پذیر برای تابع $f(X; W)$ به صورت زیر تعریف می‌شود:

$$f(X; W) = \sum_{i=1}^N w_i \phi_i(X) + b = \Phi(X)W + b \quad (5)$$

که در آن مقدار $f(X; W)$ ترکیبی خطی از N تابع پایه $\{\phi_1(X), \dots, \phi_N(X)\}$ است (که θ بردار پارامتر تابع پایه است)، $W = (w_1, \dots, w_N)^T$ بردار وزن‌ها و b مقدار بایاس است. در این تحقیق تابع پایه شعاعی گوسی یا RBF^۱ بعنوان تابع پایه انتخاب می‌شود. به منظور نگاشت خروجی‌های $f(X; W)$ به مقادیر باینری، از تابع ارتباطی پروبیت^۲ نهایت مدل به رابطه (۶) تبدیل می‌شود:

$$l(X; W, b) = \Psi\left(\sum_{i=1}^N w_i \phi_i(X) + b\right) = \Psi(\Phi(X)W + b) \quad (6)$$

توزیع پیشین هر یک از وزنهای w_i و بایاس b به ترتیب یک گوسی ناقص و یک گوسی با میانگین صفر است که به صورت رابطه (۷) تعریف می‌شود:

آشکارسازی حرکت پا در این مقاله پدیده ERS است - که همیشه پس از اجرای حرکت در سیگنال EEG ظاهر می‌شود - همواره آشکارسازی این حرکت با تأخیر نسبت به زمان شروع حرکت توسط کاربر همراه است؛ اما این میزان تأخیر بین ۱ تا ۳/۵ ثانیه برای بسیاری از کاربردهای کنترلی ساده و طراحی سوئیچ‌های روشن و خاموش قابل قبول است.

۵- نتیجه‌گیری

در این مقاله الگوریتم جدیدی برای طراحی سوئیچ مغزی مبتنی بر حرکت پا با استفاده از بانک فیلترهای با ضریب کیفیت ثابت و طبقه‌بند PCVM معرفی شد. به منظور استخراج موفق‌تر پدیده ERS از سیگنال پس‌زمینه مغزی و آشکارسازی بازه‌های رخداد حرکت پا، تجزیه فرکانسی سیگنال در باند فرکانسی وسیع ۶ تا ۳۶ هرتز (محدوده ریتم‌های میو و بتا) با استفاده از فیلترهای با ضریب کیفیت ثابت Q انجام شد. افزایش قدرت تفکیک زمانی در فرکانس‌های مرکزی بیشتر و افزایش قدرت تفکیک فرکانسی در فرکانس‌های مرکزی کمتر از مهمترین ویژگی‌های استفاده از این نوع فیلترها است که موجب کاهش خواص غیر ایستانی سیگنال EEG می‌شود و در نتیجه بهبود قابل ملاحظه‌ای در عملکرد سیستم در تشخیص بازه‌های وقوع حرکت در مقایسه با روشهای تجزیه فرکانسی با استفاده از فیلترهای با پهنای باند ثابت بوجود می‌آید. بعلاوه در این مقاله برای اولین بار در محث BCI از یک الگوریتم احتمالاتی به نام PCVM برای طبقه‌بندی الگوهای وابسته به حرکت از سیگنال پس‌زمینه EEG استفاده شد. با توجه به مزایای استفاده از روش طبقه‌بندی PCVM به نظر می‌رسد این الگوریتم در سیستم‌های BCI کاربرفرما می‌تواند جایگزینی مناسب برای طبقه‌بند SVM باشد. در این مقاله نشان دادیم که PCVM نه تنها می‌تواند ضعف‌های SVM را از بین ببرد بلکه در بسیاری از موارد به مراتب بهتر از SVM قادر به طبقه‌بندی سیگنال‌های EEG است. مقایسه نتایج حاصل از اعمال الگوریتم پیشنهادی در این مقاله با نتایج منبع [۱۳] - که در آن از همین مجموعه دادگان استفاده شده است - بهبود TPR معادل ۱۶ درصد و FPR معادل ۲ درصد را نشان می‌دهد.

¹Radial Basis Function

²Probit

- adaptive brain interface project; IEEE Trans. Neural Syst. Rehabil. Eng., 2003; 11: 159-161.
- [9] Mason S.G., Birch G.E., A brain-controlled switch for asynchronous control applications; IEEE Trans. Biomed. Eng., 2000; 47: 1297-1307.
- [10] Bashashati A., Mason S., Ward R.K., Birch G.E., An improved asynchronous brain interface: making use of the temporal history of the LF-ASD feature vectors; J. Neural. Eng., 2006; 3: 87-94.
- [11] Fatourehchi M., Ward R.K., Birch G.E.A., self-paced brain-computer interface system with a low false positive rate; J. Neural Eng., 2008; 5: 9-23.
- [12] Gala'n F., Oliva F., Guardia J., Using mental tasks transitions detection to improve spontaneous mental activity classification; J. Med. Biol. Eng Comput., 2007; 45(6): 603-612.
- [13] Solis-Escalante T., Muller-Putz G.R., Pfurtscheller G., Overt foot movement detection in one single Laplacian EEG derivation; J. Neurosci. Methods, 2008; 175: 148-153.
- [14] Pfurtscheller G., Solis-Escalante T., Could the beta rebound in the EEG be suitable to realize a "brain switch"?; Clin. Neurophysiol., 2009; 120: 24-29.
- [15] Pfurtscheller G., Solis-Escalante T., Ortner R., Linortner P., Müller-Putz G.R., Self-Paced Operation of an SSVEP-Based Orthosis With and Without an Imagery-Based "Brain Switch:." A Feasibility Study Towards a Hybrid BCI; IEEE Trans. Neural Syst. Rehabil. Eng., 2010; 18(4): 409-414.
- [16] Yong X., Fatourehchi M., Ward R.K., Birch G.E., The Design of a Point-and-Click System by Integrating a Self-Paced Brain-Computer Interface With an Eye-Tracker; IEEE J. Emerg. & selected topics in circuits and syst., 2011; 1(4): 590-602.
- [17] Yong X., Fatourehchi M., Ward R.K., Birch G.E., Automatic artifact removal in a self-paced hybrid brain-computer interface system; J. of NeuroEng. and Rehab., 2012; 9:50.
- [18] Chen H., Ti'no P., Yao X., Probabilistic Classification Vector Machines; IEEE Trans. Neural Net., 2009; 20: 901-914.
- [19] Leeb R., Friedman D., Müller-Putz G.R., Scherer R., Slater M., Pfurtscheller G., Self-Paced (Asynchronous) BCI Control of a Wheelchair in Virtual Environments: A Case Study with a Tetraplegic, Computational Intelligence and Neuroscience, 2007; Article ID 79642, 8 pages, 2007. doi:10.1155/2007/79642.
- [20] Leeb R., Friedman D., Scherer R., Slater M., Pfurtscheller G., EEGbased "walking" of a tetraplegic in virtual reality In Maia Brain Computer Interfaces; Workshop-Challenging Brain Computer Interfaces: Neural Eng. Meets Clin. Needs in Neurorehabil., 2006; 43-44.
- [21] Lotte F., Renard Y., Lécuyer A., Self-Paced Brain-Computer interaction with virtual worlds: A quantitative and qualitative study 'Out-Of-The-Lab' Proc; 4th Int'l Brain-Computer Interface Workshop and Training Course, 2008.

$$p(W | \alpha) = \prod_{i=1}^N p(w_i | \alpha_i) = \prod_{i=1}^N N_r(w_i | 0, \alpha_i^{-1}) \quad (V)$$

$$p(b | \beta) = N(b | 0, \beta^{-1})$$

در رابطه (V)، تابع گوسی ناقص، α_i و β به ترتیب نشان‌دهنده عکس ماتریس کواریانس توزیع‌های گوسی مربوط به هر یک از وزنها w_i و b هستند. وقتی $y_i = +1$ توزیع پیشین یک تابع غیرمنفی (گوسی ناقص از سمت چپ) و در حالتی که $y_i = -1$ توزیع پیشین غیر مثبت (گوسی ناقص از سمت راست) است. [شکل (۴)] این مسأله در رابطه (۸) فرمول‌بندی شده است:

$$p(w_i | \alpha_i) = \begin{cases} 2N(w_i | 0, \alpha_i^{-1}), & \text{if } y_i w_i \geq 0 \\ 0, & \text{if } y_i w_i < 0 \end{cases} \quad (۸)$$

برای پارامترهای α و β نیز توزیع پیشین گاما در نظر گرفته می‌شود. از الگوریتم EM^{۵۳} برای تعیین پارامترهایی مانند بایاس b ، W و پارامترهای کرنل θ استفاده می‌شود. به منظور مطالعه جزئیات تئوری بیشتر از الگوریتم EM در تعیین پارامترهای PCVM مطالعه مرجع [۱۸] توصیه می‌شود.

۶- مراجع

- [1] Wolpaw J.R., Birbaumer N., McFarland D.J., Pfurtscheller G., Vaughan T.M., Brain-computer interfaces for communication and control; Clin. Neurophysiol., 2002; 131: 767-791.
- [2] Scherer R., Schloegl A., Lee F., Bischof H., Jansa J., Pfurtscheller G., The self-paced Graz brain-computer interface: methods and applications; Comput. Intell. Neurosci., 2007; 7982.
- [3] Mason S.G., Birch G.E. A brain-controlled switch for asynchronous control applications; IEEE Trans. Biomed. Eng., 2000; 47: 1297-1307.
- [4] Pfurtscheller G., Lopes da Silva F.H., Event-related EEG/MEG synchronization and desynchronization: basic principles; Clin Neurophysiol., 1999; 110: 1842-1857.
- [5] Kosslyn S.M., Ganis G., Thompson W.L., Neural foundations of imagery; Nat Rev Neurosci., 2001; 2(9): 635-642.
- [6] Pfurtscheller G., Neuper C., Motor imagery activates primary sensorimotor area in humans; Neuroscience Letters, 1997; 239: 65-68.
- [7] Hasan B.A.S., Gan J.Q., Unsupervised movement onset detection from EEG recorded during self-paced real hand movement; Med. Biol. Eng. Comput., 2010; 48: 245-253.
- [8] Millan J. del R., Mourino J., Asynchronous BCI and local neural classifiers: An overview of the

⁵³Expectation-Maximization

- [29] Tipping M.E., sparse Bayesian learning and the relevance vector machine; *J. Mach. Learn. Res.*, 2001; 1: 211–244.
- [30] Rätsch G., Onoda T., Müller K.R., Soft margins for adaboost; *Mach. Learn.*, 2001; 42(3): 287–320.
- [31] <http://www.cs.bham.ac.uk/~hxc/>
- [32] Townsend G., Graimann B., Pfurtscheller G., Continuous EEG classification during motor imagery-simulation of an asynchronous BCI; *IEEE Trans. Neural Syst. Rehabil. Eng.*, 2004; 12: 258–265.
- [33] Chang C.C., Lin C.J., 2001 LIBSVM: a library for support vector machines. Software available at <<http://www.csie.ntu.edu.tw/~cjlin/libsvm>>.
- [34] Mohammadi R., Mahloojifar A., Onset foot movement detection using 1-channel EEG in self-paced Brain Computer Interface; 20th Iranian Conference on Biomedical Engineering, Tehran, Iran, 2011.
- [35] Qian K., Nikolov P., Huang D., Fei D., Chen X., Bai O., A motor imagery-based online interactive brain-controlled switch: Paradigm development and preliminary test; *Clin Neurophysiol*, 2010; 121: 1304-1313.
- [36] Mohammadi R., Mahlooji A., Chen H., Coyle D., EEG Based Foot Movement Onset Detection with the Probabilistic Classification Vector Machine; *ICONIP 2012; Part IV, LNCS 7666*, 356–363.
- [22] Mohammadi R., Mahloojifar A., Coyle D A Combination of Pre- and Postprocessing Techniques to Enhance Self-Paced BCIs Advances in Human-Computer Interaction; 2012; Article ID 185320, 10 pages, 2012. doi:10.1155/2012/185320
- [23] Bello J., Daudet L., Abdallah S., Duxbury C., Davies M., Sandler M, A tutorial on onset detection in musical signals; *IEEE Trans. Speech and Audio Proc.*, 2005; 13: 1035–1047.
- [24] Belankertz B., “Constant-Q transform” <http://www.user.tu-berlin.de/blanker/drafts.html>
- [25] Wang T., Deng J., He B Classifying EEG-based motor imagery tasks by means of time-frequency synthesized spatial patterns; *Clin. Neurophysiol.*, 2004; 115: 2744-2753.
- [26] Graimann B., Huggins J.E., Levine S.P., Pfurtscheller G., Visualization of Significant ERD/ERS patterns in multichannel EEG and ECoG data; *Clin. Neurophysiol*, 2002; 113: 43-47.
- [27] Lotte F., Congedo M., Lecuyer A., Lamarche F., Arnaldi B., A review of classification algorithms for EEG-based brain-computer interfaces; *J. Neural Eng.*, 2007; 4: 1-13.
- [28] Platt J., Probabilistic outputs for support vector machines and comparison to regularize likelihood methods; in *Advances in Large Margin Classifiers*, A.J. Smola, P. Bartlett, B. Schoelkopf, and D. Schuurmans, Eds. Cambridge, MA: MIT Press, 2000; pp. 61–74.

