

رسالة محمد



دانشگاه صنعتی شاهرود

دانشکده برق و رباتیک

گروه الکترونیک

کلاس‌بندی سیگنال‌های EEG ناشی از تصور حرکتی در کاربردهای

BCI بکمک ویژگی‌های حوزه زمان و فرکانس

حبیبه قاهری

استاد راهنما:

دکتر علیرضا احمدی فرد

استاد مشاور:

دکتر هادی گرایلو

پایان نامه ارشد جهت اخذ درجه کارشناسی ارشد

بهمن ۱۳۹۰

دانشگاه صنعتي شاهرود

دانشکده :

گروه :

پایان نامه کارشناسي ارشد آقاي/ خاتم

تحت عنوان:

در تاريخ توسط کمیته تخصصي زیر جهت اخذ مدرک کارشناسي ارشد
مورد ارزیابي و با درجه مورد پذیرش قرار گرفت.

امضاء	اساتید مشاور	امضاء	اساتید راهنما
	نام و نام خانوادگی :		نام و نام خانوادگی :
	نام و نام خانوادگی :		نام و نام خانوادگی :

امضاء	نماینده تحصیلات تکمیلی	امضاء	اساتید داور
	نام و نام خانوادگی :		نام و نام خانوادگی :
			نام و نام خانوادگی :
			نام و نام خانوادگی :
			نام و نام خانوادگی :

تقديم با تمام وجود

به پدر و مادرم

سپاس

خداوند عالَمیان را

که اوست هدایتگر بی‌هِمتا

تشکر فراوان از

آقای دکتر احمدی‌فرد

به خاطر زحمات و راهنمایی‌های بی‌دریغشان

و

تمامی آنهایی که مرا راهنمای زندگی بوده‌اند

تعهد نامه

اینجانب دانشجوی دوره کارشناسی ارشد رشته
دانشکده..... دانشگاه صنعتی شاهرود نویسنده پایان نامه
.....تحت راهنمایی.....متعهد می شوم.

- تحقیقات در این پایان نامه توسط اینجانب انجام شده است و از صحت و اصالت برخوردار است .
- در استفاده از نتایج پژوهشهای محققان دیگر به مرجع مورد استفاده استناد شده است .
- مطالب مندرج در پایان نامه تاکنون توسط خود یا فرد دیگری برای دریافت هیچ نوع مدرک یا امتیازی در هیچ جا ارائه نشده است .
- کلیه حقوق معنوی این اثر متعلق به دانشگاه صنعتی شاهرود می باشد و مقالات مستخرج با نام « دانشگاه صنعتی شاهرود » و یا « Shahrood University of Technology » به چاپ خواهد رسید .
- حقوق معنوی تمام افرادی که در به دست آمدن نتایج اصلی پایان نامه تأثیرگذار بوده اند در مقالات مستخرج از پایان نامه رعایت می گردد.
- در کلیه مراحل انجام این پایان نامه ، در مواردی که از موجود زنده (یا بافتهای آنها) استفاده شده است ضوابط و اصول اخلاقی رعایت شده است .
- در کلیه مراحل انجام این پایان نامه، در مواردی که به حوزه اطلاعات شخصی افراد دسترسی یافته یا استفاده شده است اصل رازداری ، ضوابط و اصول اخلاق انسانی رعایت شده است .

تاریخ

امضای دانشجو

مالکیت نتایج و حق نشر

- کلیه حقوق معنوی این اثر و محصولات آن (مقالات مستخرج ، کتاب ، برنامه های رایانه ای ، نرم افزار ها و تجهیزات ساخته شده است) متعلق به دانشگاه صنعتی شاهرود می باشد . این مطلب باید به نحو مقتضی در تولیدات علمی مربوطه ذکر شود .
- استفاده از اطلاعات و نتایج موجود در پایان نامه بدون ذکر مرجع مجاز نمی باشد.

* متن این صفحه نیز باید در ابتدای نسخه های تکثیر شده پایان نامه وجود داشته باشد .

چکیده

یکی از موضوعاتی که در سال‌های اخیر مورد توجه بسیاری از محققین قرار گرفته است، سیستم‌های واسط مغز و رایانه^۱ (BCI) می‌باشد. BCI سیستمی است که به کمک سیگنال‌های مغزی نظیر الکتروانسفالوگرام (EEG)، ارتباط بین شخص و وسایل جانبی مثل دست مصنوعی را برقرار نماید. در BCI مبتنی بر تصور حرکتی از شخص خواسته می‌شود تا تصور کند که بخشی از بدن خود را حرکت می‌دهد. در نتیجه تصور حرکت رخدادهایی در مغز اتفاق می‌افتد. وظیفه سیستم BCI این است که این رخدادهای را از سیگنال‌های EEG استخراج نموده و براساس آنها نوع حرکت را تشخیص دهد.

هدف از این پایان‌نامه کلاسه‌بندی داده‌های EEG ناشی از چهار نوع تصور حرکتی دست چپ، دست راست، دو پا و زبان در مغز می‌باشد. در این پایان‌نامه از مجموعه 2a از پایگاه داده مسابقه چهارم BCI که در سال ۲۰۰۸ برگزار شده استفاده شده است. در این پایان‌نامه چهار روش برای کلاسه‌بندی داده‌های این مجموعه داده پیشنهاد شده است.

یکی از موفق‌ترین روش‌ها در تشخیص تصور حرکتی روش CSP^۲ می‌باشد. این روش به کمک ماتریس کواریانس داده‌ها در کلاس‌های مختلف فیلترهای فضایی استخراج می‌کند تا داده‌های ورودی را کلاسه‌بندی نماید. مشکل CSP این است که ساختار زمانی سیگنال‌های EEG را در نظر نمی‌گیرد. از طرفی نویز یک نمونه زمانی می‌تواند تأثیر مخربی بر نتیجه این روش داشته باشد. روش بهبود یافته LTCSP^۳ ساختار زمانی داده‌ها را در نظر گرفته و تأثیر نویز در نتیجه آن کمتر از CSP است. این روش اولین بار برای کلاسه‌بندی داده‌های دو کلاسه مطرح شده که در این پایان‌نامه توسط تکنیک OVR^۴ به مسئله چهار کلاسه تعمیم یافته است.

^۱ Brain Computer Interface

^۲ Common Spatial Pattern

^۳ Local Temporal Common Spatial Pattern

^۴ One Versus the Rest

همچنین ما در این پایان‌نامه روشی به نام SEG-CSP-Var پیشنهاد داده‌ایم که در آن ابتدا سیگنال‌های EEG به قطعات زمانی شکسته شده و سپس بر روی هر قطعه زمانی روش CSP اعمال می‌شود. این روش پیشنهادی بطور متوسط نتایج بهتری از روش CSP دارد. نتایج این روش نشان می‌دهد که اهمیت کانال‌ها برای جداسازی کلاس‌ها در قطعات زمانی مختلف متفاوت است.

در روش پیشنهادی دیگر با نام SEG-CSP-BP به جای ویژگی واریانس از توان در باندهای فرکانسی متفاوت به عنوان ویژگی استفاده می‌شود. در این روش از تکنیک گسسته‌سازی چند بازه‌ای به عنوان کلاسه‌بند و از تکنیک رتبه‌بندی ویژگی‌ها به منظور کاهش ابعاد بردار ویژگی استفاده شده است.

عملکرد بهتر روش OVR-SEG-CSP-BP نسبت به روش OVR-CSP، OVR-LTCSP، OVR-SEG-CSP-Var و حتی برنده مسابقه ۲۰۰۸ در کلاسه‌بندی داده‌های EEG چهار کلاسه حاکی از آن است که استفاده از ویژگی‌های حوزه زمان و حوزه فرکانس در کنار هم می‌تواند منجر به نتایج مطلوبی شود. بنابراین در انتهای پایان‌نامه روشی پیشنهاد داده‌ایم که در آن از توزیع زمان-فرکانس کانال‌ها در روش CSP استفاده می‌شود. در این روش تابع چگالی احتمال مؤلفه‌ها در حوزه زمان-فرکانس توسط مخلوط توابع گوسی بدست می‌آید. این روش نیز نتایج بهتری نسبت به روش CSP داشته است.

کلمات کلیدی: واسط مغز و رایانه، سیگنال‌های الکتروآنسفالوگرام، روش CSP، روش LTCSP، الگوریتم OVR، قطعه‌بندی زمانی، گسسته‌سازی چند بازه‌ای در داده‌های با مقادیر پیوسته، تکنیک رتبه‌بندی ویژگی‌ها، مدل مخلوط توابع گوسی.

لیست مقالات مستخرج از پایان نامه

۱. قاهری ح و احمدی فرد ع.ر، (۱۳۹۰)، "توسعه الگوریتم LTCSP جهت کلاسه‌بندی داده‌های

EEG ناشی از تصور حرکتی چهار کلاسه"، هفتمین کنفرانس ماشین بینایی و پردازش تصویر

ایران، ۱۳۹۰، ایران، تهران.

2. H. Ghaheri and A.R. Ahmadyfard, (2011), "Local Temporal Common Spatial Patterns for Multi-Class Motor Imagery Classification", SIP 2011, korea. Jeju Island.

فهرست مطالب

فصل اول: مقدمه	۱
۱-۱- پیشگفتار	۲
۲-۱- مختصری از ساختار مغز و سیستم اعصاب	۴
۱-۲-۱- نورون	۷
۲-۲-۱- ساختار مغز	۸
۳-۲-۱- امواج مغز در فعالیت‌های طبیعی	۱۴
۴-۲-۱- سیستم ۱۰-۲۰	۱۶
۳-۱- سیستم‌های BCI	۱۸
۱-۳-۱- قسمت‌های مختلف یک سیستم BCI	۱۸
۱-۳-۱-۱- بدست آوردن سیگنال	۱۸
۲-۳-۱-۱- استخراج ویژگی	۱۹
۳-۳-۱-۱- کلاسه‌بندی ویژگی‌ها	۲۰
۴-۳-۱-۱- وسایل خروجی	۲۲
۵-۳-۱-۱- پروتکل‌های کاربردی	۲۲
۲-۳-۱-۲- BCI های موجود	۲۳
۱-۳-۱-۲-۱- پتانسیل‌های رخداد بینایی	۲۳
۲-۳-۱-۲-۱- پتانسیل‌های آرام کرتکس (SCP)	۲۳
۳-۳-۱-۲-۱- پتانسیل رخداد P300	۲۴
۴-۳-۱-۲-۱- امواج میو و بتا و سایر فعالیت‌های کرتکس حسی- حرکتی	۲۵
۵-۳-۱-۲-۱- نورون‌های کرتکس	۲۸
۴-۱- موضوع تحقیق	۲۹

فصل دوم: مروری بر روش‌های انجام شده.....	۳۴
۱-۲- نگاهی به BCI به عنوان یک سیستم شناسایی الگو.....	۳۵
۱-۱-۲- استخراج ویژگی.....	۳۶
۲-۱-۲- کلاسه‌بندی.....	۳۷
۱-۲-۱-۲- کدام کلاسه‌بندها برای کلاسه‌بندی داده‌های EEG مناسبند؟.....	۳۷
۲-۲- مروری بر مهمترین تحقیقات انجام شده.....	۴۱
۱-۲-۲- استفاده از ویژگی‌های حوزه زمان.....	۴۱
۱-۱-۲-۲- روش CSP.....	۴۲
۲-۱-۲-۲- تعمیم CSP به مسئله چند کلاسه.....	۴۶
۳-۱-۲-۲- روش LTCSP.....	۵۰
۲-۲-۲- استفاده از ویژگی‌های حوزه فرکانس.....	۵۵
۳-۲-۲- استفاده از تلفیق ویژگی‌های حوزه زمان و فرکانس.....	۶۱
فصل سوم: پایگاه داده و روش‌های انجام شده بر روی این داده‌ها.....	۶۵
۱-۳- پایگاه داده.....	۶۶
۲-۳- معیار ارزیابی.....	۶۹
۳-۳- روش و نتایج دو گروه برتر مسابقه.....	۷۰
۱-۳-۳- گروه برتر مسابقه.....	۷۰
۲-۳-۳- گروه دوم مسابقه.....	۷۱
۳-۳-۳- بعد از سال ۲۰۰۸.....	۷۲
۴-۳- پردازش اولیه داده‌ها.....	۷۴
۵-۳- کلاسه‌بند مورد استفاده در روش‌های پیشنهادی.....	۷۵
۶-۳- اجرای روش CSP متداول بر روی پایگاه داده.....	۷۶

فصل چهارم: روش‌های پیشنهادی با استفاده از ویژگی‌های حوزه زمان ۷۸

۱-۴- روش پیشنهادی اول: تعمیم روش LTCSP به مسائل چهار کلاسه ۷۹

۱-۱-۴- OVR-LTCSP ۸۰

۱-۱-۴- روند اجرای روش OVR-LTCSP ۸۰

۱-۱-۴-۲- نتایج روش OVR-LTCSP ۸۲

۲-۴- روش پیشنهادی دوم: استفاده از قطعه‌بندی زمانی در روش CSP ۸۵

۱-۲-۴- روش قطعه‌بندی زمانی در CSP برای مسائل دو کلاسه ۸۸

۱-۲-۴- مرحله آموزش ۸۸

۲-۲-۴- مرحله ارزیابی ۹۰

۲-۲-۴- نتایج روش SEG-CSP-Var برای جداسازی دو کلاس تصور حرکتی دست چپ و

دست راست ۹۱

۳-۲-۴- مقایسه نتایج روش SEG-CSP-Var روش CSP معمول ۹۵

۴-۲-۴- تعمیم قطعه‌بندی زمانی در روش CSP به مسائل چهار کلاسه ۹۹

۵-۲-۴- نتایج روش OVR-SEG-CSP-Var در حل مسئله چهار کلاسه ۱۰۰

فصل پنجم: روش‌های پیشنهادی با استفاده از ویژگی‌های حوزه زمان-فرکانس ۱۰۷

۱-۵- روش اول: استفاده از الگوریتم گسسته‌سازی چند بازه‌ای و تکنیک رتبه‌بندی ویژگی‌ها... ۱۰۹

۱-۱-۵- گسسته‌سازی چند بازه‌ای برای داده‌های پیوسته ۱۱۰

۲-۱-۵- رتبه‌بندی ویژگی‌ها ۱۱۲

۳-۱-۵- استفاده از تکنیک گسسته‌سازی چند بازه‌ای و رتبه‌بندی ویژگی‌ها برای کلاسه‌بندی

دو کلاس تصور حرکتی ۱۱۳

۱-۳-۱-۵- مرحله آموزش ۱۱۴

۲-۳-۱-۵- مرحله ارزیابی ۱۱۶

۴-۱-۵- نتایج روش SEG-CSP-BP برای کلاسه‌بندی دو کلاس تصور حرکتی دست چپ و

راست ۱۱۶

۱۱۹.....	۵-۱-۴- تعمیم روش SEG-CSP-BP به مسئله چهار کلاسه
۱۲۰.....	۵-۱-۵- نتایج روش OVR-SEG-CSP-BP برای مسئله چهار کلاسه
۱۲۳.....	۵-۲- استفاده از مدل مخلوط توابع گوسی (GMM) برای تشخیص داده‌های EEG ناشی از تصور حرکتی
۱۲۴.....	۵-۲-۱- مدل مخلوط توابع گوسی (GMM)
۱۲۶.....	۵-۲-۲- روش CSP-GMM برای کلاسه‌بندی داده‌های EEG دو کلاسه
۱۲۶.....	۵-۲-۲-۱- مرحله آموزش
۱۳۳.....	۵-۲-۲-۲- مرحله ارزیابی
۱۳۴.....	۵-۲-۲-۳- نتیجه کلاسه‌بندی دو کلاس تصور حرکتی دست چپ و دست راست
۱۳۸.....	فصل ششم: نتیجه‌گیری و پیشنهادات برای کارهای آینده
۱۳۹.....	نتیجه‌گیری و پیشنهادات برای کارهای آینده
۱۴۶.....	۶-۱- پیشنهاد کارهای آینده
۱۴۸.....	مراجع

فهرست شکل‌ها

فصل اول: مقدمه

- شکل (۱-۱): ساختار نورون [۳]..... ۷
- شکل (۲-۱): سه قسمت اصلی مغز انسان ۹
- شکل (۳-۱): لایه های مخ ۱۰
- شکل (۴-۱): مسئولیت نواحی مختلف کر تکس حسی - حرکتی [۳]..... ۱۱
- شکل (۵-۱): لب‌های مخ [۳]..... ۱۲
- شکل (۶-۱): نواحی مختلف کر تکس [۳]..... ۱۳
- شکل (۷-۱): سیستم ۱۰-۲۰ [۴]..... ۱۷
- شکل (۸-۱): سیستم ۱۰-۱۰ [۴]..... ۱۷
- شکل (۹-۱): سیستم BCI [۴] ۱۸
- شکل (۱۰-۱): نمایشی از پتانسیل‌های SCP برای انتخاب دو حالت [۴]..... ۲۴
- شکل (۱۱-۱) شکل (۱۱-۱): نمونه‌ای از ماتریس حروف در سیستم BCI مبتنی بر P300 [۴]..... ۲۵
- شکل (۱۲-۱): نمونه ای از کاربرد باندهای میو و بتا در حرکت مکان‌نما به دو جهت بالا و پایین [۴]..... ۲۶
- شکل (۱۳-۱): متوسط توزیع زمان فرکانس کانال‌های C3، C4 و Cz در طول چند آزمایش از یک شخص مربوط به ۴ نوع تصور حرکتی دست چپ، دست راست، دو پا و زبان [۷]..... ۲۷

فصل دوم: مروری بر روش‌های انجام شده

- شکل (۱-۲): نمونه‌ای از فیلترهای فضایی در روش CSP..... ۴۴
- شکل (۲-۲): مرحله ارزیابی در روش SBCSP [۲۵] ۵۶
- شکل (۳-۲): مراحل انجام روش FBCSP [۲۶]..... ۵۷

فصل سوم: پایگاه داده و روش‌های انجام شده بر روی این داده‌ها

- شکل (۱=۳): (الف) مکان الکترودهای کانال‌های EOG (ب) مکان الکترودهای EEG در پایگاه داده 2a از مسابقه ۲۰۰۸ ۶۷
- شکل (۲-۳): روند اجرای آزمایشات در مجموعه داده 2a از مسابقه ۲۰۰۸ در زمینه BCI [۹] ۶۸
- شکل (۳-۳): داده‌های EEG مربوط به تصور حرکتی دست چپ شخص ۱ ۶۸

فصل چهارم: روش‌های پیشنهادی با استفاده از ویژگی‌های حوزه زمان

- شکل (۱-۴): روند اجرای مرحله آموزش در روش OVR-LTCSP ۸۱
- شکل (۲-۴): روند اجرای مرحله ارزیابی در روش OVR-LTCSP ۸۲
- شکل شکل (۳-۴): مقایسه نتایج روش OVR-LTCSP، OVR-CSP و نفرات اول مسابقه چهارم BCI ۸۴
- شکل (۴-۴): اسپکتوگرام دو کانال C3 و C4 در سه آزمایش تصور حرکتی دست چپ مربوط به شخص ۱ ۸۶
- شکل (۵-۴): (الف) روندنمای اجرای روش SEG-CSP-Var (الف) مرحله آموزش (ب) مرحله ارزیابی ۸۸
- شکل (۶-۴): طریقه قطعه‌بندی زمانی در روش SEG-CSP-Var ۸۹
- شکل (۷-۴): طریقه بدست آوردن بردار ویژگی برای هر داده EEG در روش SEG-CSP-Var ۹۰
- شکل (۸-۴): مقایسه روش SEG-CSP-Var و روش CSP در کلاسه‌بندی داده‌های تصور حرکتی دست چپ و دست راست ۹۷
- شکل (۹-۴): دو فیلتر فضایی اول و آخر مربوط به ۴ قطعه متوالی مرتبط با شخص ۱ در روش قطعه‌بندی زمانی در مسئله دو کلاسه. هر ستون مربوط به یک قطعه است. سطر بالا فیلتر اول و سطر پایین فیلتر دوم مربوط به قطعات است. ۹۸
- شکل (۱۰-۴): مقایسه نتایج روش OVR-SEG-CSP-Var، OVR-CSP و دو نفر برتر مسابقه در حل مسئله چهار کلاسه ۱۰۴

فصل پنجم: روش‌های پیشنهادی با استفاده از ویژگی‌های حوزه زمان و فرکانس

- شکل (۱-۵): مثالی از گسسته‌سازی چند بازه‌ای برای یک ویژگی ۱۱۲
- شکل (۲-۵): روند اجرای مرحله آموزش در روش SEG-CSP-BP ۱۱۵

- شکل (۳-۵): مقایسه نتایج روش CSP، SEG-CSP-Var و SEG-CSP-BP در کلاسه‌بندی تصور حرکتی دست چپ و دست راست ۱۱۸
- شکل (۴-۵): مقایسه نتایج روش‌های OVR-CSP، OVR-SEG-CSP-Var، OVR-SEG-CSP-BP و دو نفر برتر مسابقه ۲۰۰۸ در کلاسه‌بندی داده‌های EEG ناشی از تصور حرکتی چهار کلاسه ۱۲۲
- شکل (۵-۵): TFD یک کانال فیلتر شده توسط فیلترهای فضایی مربوط به تصور حرکتی دست چپ شخص ۱ ۱۲۷
- شکل (۶-۵): TFD یک کانال فیلتر شده توسط فیلترهای فضایی مربوط به تصور حرکتی دست چپ شخص ۱ بعد از کاهش تعداد نمونه‌های زمانی ۱۲۸
- شکل (۷-۵): (الف) نمونه‌ای از ماتریس P مربوط به تصور حرکتی دست چپ (ب) شکل (الف) در دو سطح باینری (ج) شکل (الف) در ۵ سطح ۱۲۹
- شکل (۸-۵): روند اجرای مرحله آموزش روش CSP-GMM ۱۳۱
- شکل (۹-۵): (الف) PDF تخمین زده شده توسط روش GMM با تعداد ۸ گوسی مربوط به کل داده‌های آموزشی تصور حرکتی دست راست برای شخص ۱. (ب) کانتور شکل (الف) ۱۳۲
- شکل (۱۰-۵): (الف) PDF تخمین زده شده توسط روش GMM با تعداد ۸ گوسی مربوط به کل داده‌های آموزشی تصور حرکتی دست راست برای شخص ۱. (ب) کانتور شکل (الف) ۱۳۲
- شکل (۱۱-۵): نتایج روش CSP-GMM، CSP-BP و CSP در کلاسه‌بندی داده‌های EEG دو کلاس تصور حرکتی دست چپ و دست راست ۱۳۶

فهرست جدول‌ها

فصل سوم: پایگاه داده و روش‌های انجام شده بر روی این داده‌ها

- جدول (۱-۳): ضریب کاپا بدست آمده توسط نفرات برتر مجموعه داده 2a از مسابقه چهارم BCI..... ۷۰
- جدول (۲-۳): نتایج روش پیشنهاد شده در مرجع [۵۳] و مقایسه با نتایج برتر مسابقه..... ۷۳
- جدول (۳-۳): نتایج روش OVR-CSP متداول در مسئله چهار کلاسه..... ۷۷

فصل چهارم: روش‌های پیشنهادی با استفاده از ویژگی‌های حوزه زمان

- جدول (۱-۴): ضرایب کاپا حاصل از روش LTCSP به ازای m , τ و c متغیر مربوط به شخص ۱..... ۸۴
- جدول (۲-۴): ضریب کاپا ناشی از روش OVR-LTCSP به همراه مقادیر بهینه (m و τ و c)..... ۸۵
- جدول (۳-۴): نتایج روش بازه‌بندی زمانی در CSP به منظور کلاسه‌بندی تصور حرکتی دست چپ و راست..... ۹۳
- جدول (۴-۴): بهترین نتایج برحسب درصد درستی در کلاسه‌بندی به روش قطعه‌بندی زمانی در CSP..... ۹۶
- جدول (۵-۴): نتایج کلاسه‌بندی تصور حرکتی دست چپ و راست مربوط به ۹ شخص به ازای طول بازه ۰/۵..... ۹۷
- ثانیه m متغیر در روش CSP..... ۹۷
- جدول (۶-۴): نتایج روش CSP معمول برحسب درصد درستی به ازای طول بازه و m متغیر..... ۹۷
- جدول (۷-۴): نتایج قطعه‌بندی زمانی در روش CSP در مسئله چهار کلاسه..... ۱۰۲
- جدول (۸-۴): بهترین نتایج بدست آمده از قطعه‌بندی زمانی در روش CSP به همراه پارامترهای بهینه آن در کلاسه‌بندی چهار کلاس تصور حرکتی..... ۱۰۵

فصل پنجم: روش‌های پیشنهادی با استفاده از ویژگی‌های حوزه زمان و فرکانس

- جدول (۱-۵): جدول (۱-۵): نتایج روش SEG-CSP-BP به ازای طول بازه‌های متفاوت در کلاسه‌بندی تصور حرکتی دست چپ و دست راست..... ۱۱۷
- جدول (۲-۵): نتایج سه روش CSP، SEG-CSP-BP، SEG-CSP-Var در کلاسه‌بندی دو کلاس تصور حرکتی دست چپ و دست راست..... ۱۱۸
- جدول (۳-۵): نتایج روش OVR-SEG-CSP-BP به ازای طول بازه‌های متفاوت در کلاسه‌بندی داده‌های چهار کلاس تصور حرکتی..... ۱۲۱

- جدول (۴-۵): بهترین نتایج بدست آمده از روش OVR-SEG-CSP-BP به همراه طول بازه مربوطه در کلاسه-
 بندی چهار کلاس تصور حرکتی ۱۲۱
- جدول (۵-۵): نتایج روش CSP-GMM به ازای تعداد تابع گوسی متغیر (K) در کلاسه‌بندی داده‌های EEG دو
 کلاس تصور حرکتی دست چپ و دست راست ۱۳۵
- جدول (۶-۵): نتایج روش CSP-GMM، CSP-BP و CSP در کلاسه‌بندی داده‌های EEG دو کلاس تصور
 حرکتی دست چپ و دست راست ۱۳۶

لغات و اصطلاحات

AAR	Linear Adaptive Autoregressive
ALS	Amyotrophic Lateral Sclerosis; a form of motor neuron disease
AR	Autoregressive
BCI	Brain Computer Interface
CSP	Common Spatial Pattern
EEG	Electroencephalography; measurement of electrical brain activity
EMG	Electromyography; measurement of electrical muscle activity
EOG	Electrooculargraphy; measurement of electrical ocular activity
ERD	Event Related Desynchronization
ERS	Event Related Synchronization
FBCSP	Filter Bank Common Spatial Pattern
GMM	Gaussian Mixture Models
HMM	Hidden Markov Model
JAD	Joint Approximate Diagonalization
LDA	Linear discriminant analysis
LTCSP	Local Temporal Common Spatial Pattern
MI	Motor Imagery
MIBIF	Mutual Information based Best Individual Feature
MLP	Multi-Layer Perceptron
MSJAD	Multisegment JAD
NBPW	Naïve Bayesian Parzen Window
NMF	Nonnegative Matrix Factorization
OVR	One Versus the Rest
SVM	Support Vector Machine
TFD	Time Frequency distribution
TDNN	Time Delay Neural Network

فصل اول

مقدمه

فصل اول

مقدمه

۱-۱- پیشگفتار

یکی از موضوعاتی که در حدود چهار دهه اخیر مورد توجه بسیاری از محققین قرار گرفته است، پژوهش در زمینه سیستم‌های واسط مغز و رایانه^۱ (BCI) می‌باشد. واسط مغز و رایانه سیستمی است که مفاهیم ذهن را مستقیماً به دستوراتی برای ارتباط با جهان اطراف تبدیل می‌کند. چنین سیستمی می‌تواند به افراد ناتوان حرکتی کمک کند تا توسط سیگنال‌های مغزی مانند سیگنال‌های الکتروانسفالوگرام^۲ (EEG) بتوانند با محیط اطراف خود ارتباط برقرار کنند و یا یک وسیله خارجی را کنترل نمایند. واسط مغز و رایانه حتی می‌تواند برای افراد سالم نیز مسیری اضافی برای ارتباط با محیط اطراف و بهره‌گیری مضاعف از آن فراهم سازد.

¹Brain Computer Interface

²Electroencephalogram

یکی از روش‌های کنترلی در تحقیقات BCI استفاده از تصور حرکتی^۱ (MI) است. در BCI مبتنی بر MI شخص در ذهن خود تصور می‌کند که در حال حرکت دادن یکی از اعضای بدن خود می‌باشد. این تصور باعث به وجود آمدن الگو^۲هایی در سیگنال‌های مغزی می‌شود. با استخراج این الگوها در سیگنال‌های مغزی و با استفاده از روش‌های تشخیص الگو^۳ و کلاسه‌بندی^۴، می‌توان به نوع حرکتی که شخص تصور نموده است پی برد. سیستم BCI هر نوع تصور حرکتی را متناظر با یک دستور خاص دانسته و این دستور را به منظور کنترل مستقیماً برای یک وسیله خارجی می‌فرستد.

مثالی از یک سیستم ساده BCI مبتنی بر EEG به این صورت است که بخواهیم در یک صفحه نمایش، مکان‌نما^۵ را به سمت چپ و یا راست حرکت دهیم. در این سیستم برای حرکت به سمت راست، شخص باید منظور خود را بدون اینکه عملاً این حرکت را انجام دهد، توسط تصور حرکت دست راست در ذهن خود، بیان دارد. با بررسی سیگنال‌های الکتریکی ثبت شده از بالای سر شخص، سیستم نوع تصور حرکتی را تشخیص داده و می‌فهمد که منظور شخص حرکت مکان‌نما به سمت راست می‌باشد. سیستم BCI این مفهوم را توسط دستورات قابل فهم برای کامپیوتر می‌فرستد و به اصطلاح مفاهیم ذهن شخص را برای کامپیوتر ترجمه می‌نماید.

لازم به ذکر است که خروجی BCI تنها کامپیوتر نیست بلکه می‌تواند هر وسیله دیگر مانند اعضای مصنوعی، ویلچر، ربات و یا هر وسیله هوشمند یا غیر هوشمند دیگر باشد که در کل با عنوان رایانه یا کامپیوتر مطرح می‌شود. البته ناگفته نماند که سیستم BCI با عناوین دیگری چون واسط مغز و ماشین^۶ و واسط مستقیم عصبی^۷ نیز شناخته می‌شود.

¹Motor Imagery

² pattern

³Pattern Recognition

⁴Classification

⁵cursor

⁶Brain Machine Interface

⁷Direct Neural Interface

در ادامه این فصل مختصری از سیستم اعصاب و ساختار مغز انسان و بعد برای آشنایی بیشتر توضیحاتی راجع به سیستم‌های BCI و انواع آن آورده می‌شود و نهایتاً ارتباط موضوع تحقیق با سیستم‌های BCI بیان خواهد شد.

۱-۲- مختصری از ساختار مغز و سیستم اعصاب

سیستم عصبی-عضلانی سیستمی است که مغز از طریق آن قادر به ایجاد ارتباط و اعمال کنترل به محیط خارج است. بیماری‌هایی از قبیل ALS^۱، آسیب به ساقه مغز و آسیب‌های مغزی-نخاعی، مثال‌هایی از انواع بیماری‌هایی هستند که مسیر عصبی کنترل عضلات در آنها آسیب می‌بیند. در شرایط حاد بیماری، فرد مبتلا ممکن است تمام حرکات ارادی خود را از دست بدهد. حتی ممکن است حرکات چشم و تنفس که اعمالی غیر ارادی هستند نیز امکان پذیر نباشد. در غیاب روش‌هایی برای جبران فیزیولوژیکی آسیب‌های وارده در اثر این بیماری‌ها، سه انتخاب برای بازآفرینی عملکرد طبیعی بیماران وجود دارد:

- افزایش قابلیت‌های مسیرهای عصبی - عضلانی باقیمانده: مثلاً افرادی با آسیب دیدگی ساقه مغز می‌توانند از حرکت چشم برای پاسخ به سؤال و یا رساندن مفاهیم کوچک استفاده کنند و یا افراد با نارسایی عضوی در صحبت کردن، می‌توانند از حرکت دست‌ها برای رساندن منظور خود استفاده کنند.
- بازسازی عملکرد از دست رفته توسط عبور از مناطق آسیب دیده در مسیر عصبی: مثلاً در افراد با آسیب دیدگی نخاعی، با استفاده از سیگنال‌های الکترومایوگرام^۲ (EMG) از روی ماهیچه‌ها در قسمت‌های آسیب دیده در مسیر عصبی، می‌توان سیگنال خاص را دریافته و بازسازی کرده و به مقصد رساند.

^۱ Amyotrophic Lateral Sclerosis

^۲ Electromyogram

▪ فراهم آوردن مسیر ارتباطی جدید و غیرماه‌یچه‌ای برای مغز که از طریق آن بتواند مستقیماً پیام‌ها و دستورالعمل‌های کنترلی را به محیط خارج ارسال نماید، مانند یک رابط مغز و رایانه.

خصوصیتی که این رابط‌های مغز و رایانه را از سایر وسایل ارتباطی مجزا می‌کند، عدم نیاز به حرکتی آشکار در بدن به منظور انتقال اطلاعات می‌باشد. بدین ترتیب در حالت ایده‌آل، شخص باید بتواند بی‌حرکت در جای خود نشسته و با تمرکز بر برخی افکار و تولید امواج مغزی مناسب منظور خود را بیان کند. با توجه به عدم امکان تحرک در برخی بیماران، اهمیت این موضوع بیشتر نمایان می‌شود [۱].

فعالیت‌های عصبی باعث ایجاد سیگنال‌های الکتریکی در سر می‌شوند و همچنین تغییرات در جریان اکسیژن خون نیز با میزان فعالیت‌های عصبی ارتباط دارد. زمانی که سلول‌های عصبی فعال هستند اکسیژنی که توسط هموگلوبین خون حمل می‌شود را مصرف می‌کنند. پاسخ محلی به این کاهش اکسیژن، افزایش جریان خون در ناحیه‌هایی است که فعالیت‌های عصبی زیاد است. از طرف دیگر در اثر فعالیت‌های عصبی و انتقال پیام‌های عصبی جریان الکتریکی تولید می‌شود که این جریان الکتریکی یک میدان مغناطیسی را تولید می‌کند. با توجه به این مطالب روش‌های مختلفی برای اندازه‌گیری فعالیت‌های مغزی وجود دارد. روش‌هایی مانند ¹PET، ²FMRI و عکس‌برداری نوری، میزان جریان خون مغز را اندازه‌گیری می‌کنند. روش ³MEG سیگنال‌های مغناطیسی مغز را اندازه‌گیری می‌کند. روش EEG، سیگنال‌های الکتریکی تولید شده توسط مغز را اندازه‌گیری می‌نماید. با وجود این که دقت مکانی EEG پایین است، اما دقت زمانی آن بالا و کمتر از چند میلی ثانیه می‌باشد. همچنین این روش نسبت به بقیه روش‌ها ارزان‌تر و استفاده از آن نیز آسان‌تر می‌باشد. به دلیل این خصوصیات، اکثر سیستم‌های BCI از این روش برای ثبت فعالیت‌های مغز استفاده می‌کنند [۱].

¹Positron Emission Tomography

²Functional Magnetic Resonance Imaging

³Magneto Encephalography

در دهه هفتم قرن بیستم میلادی بعد از مقاله Hans Berger [۲] در سال ۱۹۲۹، EEG به طور اساسی برای بررسی اختلالات نورولوژی در کلینیک‌ها و برای تشخیص فعالیت‌های مغزی در آزمایشگاه‌ها به کار برده شد و محققان بسیاری کاربرد درمانی آن را کشف کردند. در این فاصله، محققان به این نتیجه رسیدند که شاید EEG یک کاربرد دیگری نیز داشته باشد! شاید بتوان با استفاده از آن، به تفکرات آدمی پی برد. شاید به وسیله آن، اشخاص بتوانند مستقیماً با استفاده از مغز و بدون استفاده از کانال‌های طبیعی یا اعصاب محیطی و ماهیچه‌ها، با دیگران ارتباط برقرار کنند و یا وسایلی را کنترل نمایند. تا این زمان، این ایده به صورت خیال و دروغین بود، مانند فیلمی که در سال ۱۹۷۷ ساخته شد و در آن هواپیمایی توسط سیگنال‌های EEG مغز خلبان کنترل می‌شد [۱].

ارتباطات مبتنی بر EEG به چند دلیل علمی، کمتر به منظور ارتباطات مورد توجه قرار می‌گرفت: به دلیل فعالیت‌های غیر ارادی مغز، هندسه فضایی و پیچیده مغز و عدم هماهنگی فعالیت‌های مختلف مغز از یک آزمایش به آزمایش دیگر^۱، رزولوشن و واقعی بودن اطلاعات ارادی مغز تغییر می‌کند. در نتیجه احتمال تشخیص یک پیام یا دستور در میان این پیچیدگی، اعوجاج و اختلافات، دور از دسترس به نظر می‌رسید. ارتباطات مبتنی بر EEG نیاز به تحلیل سیگنال‌های چند کاناله به صورت زنده^۲ دارد که این تکنولوژی یا وجود نداشت و یا خیلی سخت بود.

رخدادهای علمی و تکنولوژی‌های اخیر، این شرایط را تغییر داده است. اول اینکه، تحقیقات آزمایشگاهی به اطلاعات جزئی سیگنال‌های EEG دست یافتند و دیری نپایید که محل و مکانیزم شروع امواج اصلی و پتانسیل‌های رخداد^۳ EEG و ارتباط آنها با فعالیت‌های مغزی آشکار شد و مطالعات مختلفی، همبستگی بین سیگنال‌های EEG و حرکات‌های تصویری یا واقعی و فعالیت‌های ذهنی را بررسی نمودند. در این زمان سیگنال‌های EEG به عنوان وسیله‌ای برای ارتباطات و کنترل در نظر گرفته شد. ثانیاً پیشرفت سریع و پیوسته سخت افزار و نرم افزار کامپیوتری و کاهش قیمت

^۱ trial-to-trial


^۲ online

^۳ Event Potentials

آنها، تحلیل سیگنال‌های چند کاناله مغز را حمایت می‌نمود. ثالثاً تشخیص نیازها و پتانسیل‌های اشخاص با اختلالات شدید عصبی - عضلانی مثل آسیب نخاعی یا فلج مغزی، تلاش برای بهبود تکنولوژی ارتباطات و کنترل را بیشتر می‌کرد و در نتیجه پیشرفت در چنین تکنولوژی‌هایی، انگیزه برای تحقیقات BCI را بیشتر می‌نمود [۱]. در بخش بعد برای فهم چگونگی ایجاد سیگنال‌های الکتریکی مختصری راجع به نورون (سلول عصبی) آورده شده است.

۱-۲-۱- نورون

نورون یک سلول است که واکنش‌های زیستی - شیمیایی^۱ بدن را استفاده می‌کند تا بتواند اطلاعات را دریافت کرده و آنها را تحلیل نماید و انتقال دهد. این سلول دارای یک تنه^۲ می‌باشد که درون آن هسته^۳ سلول قرار دارد. هر نورون دارای یک آکسون میله ای شکل است که ارتباط سلول با سایر نورون‌ها را برقرار می‌کند. تنه سلول نیز به شاخه‌هایی به نام دندریت^۴ ختم می‌شود که آنها نیز ارتباط سلول با سایر نورون‌ها را برقرار می‌سازند. در حقیقت آکسون‌ها ارتباط فیزیکی با نورون‌های دیگر ندارند بلکه یک شکاف کوچک به نام گاف سیناپسی^۵ در محل تماس آنها وجود دارد که در آنجا پالس‌های الکتریکی انتقال می‌یابند. شکل (۱-۱) ساختار نورون را نشان می‌دهد [۱].



شکل (۱-۱): ساختار نورون [۳]

^۱biomedical

^۲Body cell

^۳nucleus

^۴denrite

^۵Synaptic gap

زمانی که یک نورون تحریک می‌شود سیگنال‌هایی را به نورون‌هایی می‌فرستد که دندریت این نورون‌ها با آکسون این نورون ارتباط دارد. دندریت‌ها می‌توانند به هزاران آکسون متصل شوند. سیگنال‌های رسیده به یک نورون (از طریق دندریت‌ها) می‌توانند به صورت فضایی و زمانی با هم جمع شوند. اگر مجموع آنها از یک مقدار آستانه بیشتر باشد، به اصطلاح نورون آتش شده^۱ و سیگنال برآیند را از طریق آکسون‌ها می‌فرستد. سیگنال آمده از یک نورون خیلی ضعیف است. در حالت عادی برای تشکیل یک فعالیت خاص، نورون‌های بسیاری در مغز فعال هستند. به نظر می‌رسد که اندازه-گیری فعالیت هر نورون به تنهایی امکان‌پذیر نباشد اما فعالیت گروهی از نورون‌ها را می‌توان اندازه گرفت. برای اینکه سیگنال‌های ایجاد شده توسط نورون‌ها از بالای پوست سر قابل اندازه‌گیری باشد، مجموعه‌ای از شرایط نیاز است مثلاً اینکه فعالیت نورون‌ها باید عمود بر پوست سر باشد تا بتواند در جهت میدان ناشی از دستگاه اندازه‌گیری‌کننده حرکت کند و همچنین تعداد زیادی از نورون‌ها باید به طور موازی با هم آتش شوند تا سیگنال آنها همدیگر را خنثی نکنند. به دلیل وجود این شرایط خاص، فعالیت مجموعه بزرگی از نورون‌ها در اندازه‌گیری EEG نادیده گرفته می‌شود [۱].

۱-۲-۲- ساختار مغز

بافت عصبی به دو بخش اصلی تقسیم می‌شود: سیستم اعصاب مرکزی^۲ و سیستم اعصاب محیطی (PNS)^۳. سیستم اعصاب مرکزی شامل مغز^۴ و نخاع^۵ بوده و سیستم اعصاب محیطی شامل اعصاب آوران (اعصابی که احساسات را از اندام‌های حسی به مغز می‌آورد) و وایران (اعصابی که سیگنال‌های حرکتی را از مغز به اندام‌های می‌برند) است که به خارج از مغز و نخاع ادامه می‌یابد. مجموعه‌ای از صد بلیون نورون، مغز انسان را تشکیل می‌دهد. مغز قطعاً یک فوق کامپیوتر است که تمامی اعمال بدن را کنترل می‌کند، به احساسات جامعیت می‌بخشد و به تحریکات پاسخ می‌دهد.

^۱ Trigger

^۲ Central Nervous System

^۳ Peripheral Nervous System


^۴ Brain

^۵ Spinal Cord

مغز استدلال کرده و عواطف را تولید می‌کند. از دیدگاه آناتومی، مغز به سه قسمت مخ^۱، مخچه^۲ و ساقه مغز^۳ تقسیم می‌شود. در شکل (۱-۲) این سه قسمت نشان داده شده است.

مخچه: نقش مهمی در کنترل حرکتی دارد و همچنین شامل فعالیت‌های شناختی مانند هوشیاری و درک زبان و احتمالاً برخی فعالیت‌های ذهنی مانند ترس و لذت می‌باشد. شروع حرکت با این قسمت نیست اما در هماهنگی، تصمیم‌گیری و زمان‌بندی در طول حرکت، شرکت دارد. این قسمت اطلاعات را از سیستم‌های حسی و بقیه قسمت‌ها و مغز دریافت نموده و با فعالیت‌های حرکتی تلفیق می‌نماید تا یک حرکت صحیح و هماهنگ انجام شود.

ساقه مغز: قسمت عقبی مغز بوده و از لحاظ ساختاری، در ادامه آن نخاع قرار گرفته است. این قسمت تحریک عصبی حسی و حرکتی را به صورت و گردن می‌رساند و یک قسمت اساسی از مغز بوده و به عنوان رابط سیستم‌های حسی و حرکتی از قسمت‌های مهم مغز به اعضای بدن می‌باشد. ساقه مغز فعالیت‌های غیر ارادی مانند تنفس، تنظیمات قلب، فعالیت‌های هورمونی و اساساً چرخه زیستی را کنترل می‌نماید.



شکل (۱-۲): سه قسمت اصلی مغز انسان

¹Cerebrum


²Cerebellum

³Braistem

مخ: شامل مناطقی برای شروع حرکت، احساس هوشیاری، آنالیز پیچیده، فشارهای روانی و حرکتی می‌باشد، حرکت‌های ارادی ماهیچه‌ها را هماهنگ ساخته و تعادل برقرار می‌سازد.

مخ از دو نوع بافت عصبی ساخته شده است: ماده خاکستری^۱ و ماده سفید^۲. لایه نازکی از ماده خاکستری سطح خارجی مخ را می‌پوشاند که به کرتکس مخ^۳ معروف است. زیر ماده خاکستری، ماده سفید قرار دارد که عمده‌ترین بخش مخ را تشکیل می‌دهد (شکل (۱-۳)).

ناحیه کرتکس، محلی است که برای سیستم‌های BCI خیلی قابل توجه می‌باشد. این قسمت مسئول فعالیت‌های شناختی^۴ بوده و نزدیک سطح پوست سر است. لازم به ذکر است که فعالیت‌های مغز به صورت محلی می‌باشند و هر قسمت از کرتکس مسئول ایجاد یک فعالیت خاص است. اندازه ناحیه متناسب با اهمیت و پیچیدگی فعالیت آن قسمت خاص از بدن دارد.



شکل (۱-۳): لایه های مخ

^۱Gray Matter


^۲White Matter

^۳Cerebral Cortex

^۴Cognitive Tasks

در شکل (۴-۱) مسئولیت هر قسمت از ناحیه حسی-حرکتی کرتکس نشان داده شده است. قسمت مخ بزرگترین بخش مغز بوده و شامل نیمکره‌های^۱ های چپ و راست است. نیمکره چپ، تشخیص احساسات و کنترل نیمه راست بدن را به عهده دارد و بالعکس. به طور خاص می‌توان گفت کرتکس حسی - حرکتی^۲ برای تحقیقات BCI از اهمیت ویژه‌ای برخوردار است. این قسمت مسئول فعالیت تمام بدن است. احساسات از اندام‌ها، از طریق اعصاب آوران به کرتکس حسی آورده می‌شوند و همچنین دستورات حرکتی از کرتکس حرکتی و از طریق اعصاب وایران به اندام‌ها انتقال می‌یابند.

در تحقیقات BCI این مهم است که بدانیم کدام ناحیه از کرتکس مربوط به فعالیت مورد تحقیق است و چه تغییراتی در سیگنال نورون‌های آن قسمت خاص نسبت به حالت عادی بدن ایجاد می‌شود.



شکل (۴-۱): مسئولیت نواحی مختلف کرتکس حسی - حرکتی [۳]

^۱ hemispheres

^۲ Sensorimotor cortex


لب‌های مخ، مغز را به چندین ناحیه تقسیم کرده و عملکرد آنها را توصیف می‌کنند. اسامی این لب‌ها برگرفته از استخوان‌های جمجمه است. در شکل (۵-۱) لب‌های مخ آورده شده است.

لب‌های پیشانی^۱: شامل نواحی است که انقباض عضلات ارادی، پردازش فکر در شرایط بحرانی (استدلال) و کنترل حرکتی صحبت کردن را اداره می‌کنند.

لب‌های آهیانه‌ای^۲: نواحی هستند که در آنجا اطلاعات حسی دریافت شده و کلمات و مفاهیم زبان درک می‌شود. حس بساوایی، ادراک فضایی، ادراک دیداری، بازشناسی اندازه‌ها، رنگ و اشکال از یکدیگر از وظایف این قسمت می‌باشد.

لب‌های گیجگاهی^۳: نواحی هستند که در آنجا اطلاعات حسی تفسیر شده و در حافظه ذخیره می‌شود.

لب‌های پس سری^۴: کنترل بصری و پردازش اطلاعات بینایی از وظایف این نواحی است.




شکل (۵-۱): لب‌های مخ [۳]

^۱ frontal lobes

^۲ parietal lobes

^۳ temporal lobes

^۴ occipital lobes



شکل (۱-۶): نواحی مختلف کرکس [۳]

در بخش زیر به بررسی نواحی از مغز که در پاسخ به تحریکات حسی و در حرکت اعضا مهم هستند، می‌پردازیم. این نواحی در شکل (۱-۶) مشخص شده‌اند.

Primary Motor Cortex (M1): در لب پیشانی بوده و برای حرکت اعضای بدن به کار می‌رود. M1 شامل نورون‌های بزرگی است که آکسون‌های طولی را به سمت نخاع می‌فرستد تا به نورون‌های حرکتی آلفا که به ماهیچه‌ها متصل هستند، فرمان دهند. نواحی M1 در برنامه‌ریزی و تصحیح حرکت‌ها و در پاسخ به ورودی‌های حسی شرکت دارند.

Motor Association Cortex: در لب پیشانی بوده و پیام‌های آمده از نواحی M1 را دریافت نموده و در حین حرکت، اعضای بدن را کنترل می‌نماید.

Speech Cortex (Broca's Area): قسمتی از لب پیشانی بوده و کنترل نورون‌های حرکتی صورت در هنگام صحبت به عهده این قسمت می‌باشد.

Primary Somatosensory Cortex (S1): در لب آهیانه‌ای بوده و شامل پردازش اولیه تحریکات حسی لامسه و تحریکات درونی اعضاست.

Sensory Association Cortex: در لب آهیانه‌ای بوده و پیام‌های آمده از S1 را دریافت می‌کند.

درک احساسات مربوط به مکان و جهت یابی بدن در فضا، از وظایف این ناحیه است.

Primery Visual Cortex: قسمتی از لب پس‌سری بوده و برای پاسخ اولیه به روشنایی به‌کار

می‌رود و همچنین اندازه، رنگ، شدت روشنایی، حرکت و ابعاد جسم را تشخیص می‌دهد.

Visual Association Area: قسمتی از لب پس‌سری بوده و اطلاعات به دست آمده از Primery

Visual Cortex را تفسیر می‌کند.

Audiotory Cortex: قسمتی از لب گیجگاهی بوده و پاسخ اولیه به شنیده‌ها توسط مغز در این

قسمت انجام می‌شود. در این قسمت تنها اطلاعات پایه‌ای صوت مانند pitch و بلندی آن تحلیل می‌شود.

Audiotory Association Area: قسمتی از لب گیجگاهی بوده و اطلاعات آمده از Audiotory

Cortex را تفسیر می‌کند. همچنین درک کامل صدا در این نواحی انجام می‌گیرد.

Wernicke's Area: در قسمت لب گیجگاهی بوده و درک زبان در این قسمت صورت می‌پذیرد

[۳].

۱-۲-۳- امواج مغز در فعالیت‌های طبیعی

EEG اساساً با دو نوع فعالیت تعریف می‌شود: فعالیت‌های متناوب^۱ و فعالیت‌های گذرا^۲. فعالیت-

های متناوب در حوزه فرکانس به چند باند فرکانسی تقسیم می‌شوند که هر باند فرکانسی دارای یک نام خاص بوده و وجود آنها در پوسته سر نمایانگر یک فعالیت خاص در مغز می‌باشد.

¹Rhythmic Activity

²Transients Activity

فرکانس بیشتر سیگنال‌های مخ در رنج 1-40 Hz بوده و خارج این محدوده را نویز در نظر می‌گیرند. باید توجه نمود که در اینجا تعریف عمومی این باندها در نظر گرفته شده و تعریف‌های مختلفی برای آنها وجود دارد.

در بزرگسالان سالم، دامنه و فرکانس این سیگنال‌ها، در یک حالت نسبت به حالت دیگر مانند خواب و بیداری متفاوت می‌باشد. مشخصات این امواج با سن تغییر می‌کند. در مغز انسان چند نوع موج متفاوت موجود می‌باشد که توسط رنج فرکانسی آنها شناخته می‌شوند. این امواج توسط این نام‌ها شناخته می‌شوند: دلتا (δ)، تتا (θ)، آلفا (α)، میو (μ)، بتا (β) و گاما (γ).

▪ **امواج دلتا:** فرکانس امواج دلتا زیر ۴ هرتز بوده و دارای دامنه زیاد می‌باشند. این امواج به‌طور طبیعی در بزرگسالان در حالت خواب عمیق وجود دارند و ممکن است در بیداری نیز وجود داشته باشند. این امواج طبیعتاً در نوزادان نیز وجود دارند. همچنین ممکن است در اثر جراحات عمیق و در بیماری‌های مغزی متابولیک وجود داشته باشند. این موج‌ها در بزرگسالان به‌طور برجسته در جلوی مغز و در کودکان در عقب مغز وجود دارند.

▪ **امواج تتا:** رنج فرکانسی این امواج، ۴ تا ۷ هرتز بوده و به‌طور طبیعی در نوجوانان وجود دارند. همچنین در هنگام خواب و یا هیجان و یا تفکر در بزرگسالان نیز به وجود می‌آیند. امواج تتای اضافی در بزرگسالان به معنای فعالیت غیر معمول مغز است. این امواج بیشتر در لب‌های گیجگاهی و آهیانه‌ای موجود می‌باشند.


▪ **امواج آلفا:** فرکانس این امواج در رنج 8-12Hz بوده و در قسمت لب‌های پس‌سری مغز وجود داشته و دارای دامنه زیاد می‌باشند. این رنج فرکانسی در هنگام بستن چشم‌ها و هنگام استراحت پدیدار شده و با بازکردن چشم‌ها و یا فشار ذهنی، کاهش می‌یابد و همچنین این امواج در قسمت‌های گیجگاهی و پیشانی نیز موجود می‌باشند.

- **امواج میو:** علاوه بر آلفای پس سری یک نوع موج دیگر در همین رنج به نام امواج میو وجود دارد که در نواحی کرتکس حسی-حرکتی وجود داشته و در هنگامی که دست‌ها و بازوها بیکار هستند زیاد می‌شوند.
- **امواج بتا:** در محدوده 12-30Hz بوده و معمولاً در هردو طرف به صورت متقارن موجود بوده و بیشتر در لب‌های پیشانی مشهود می‌باشند. این امواج وابسته به فعالیت‌های حرکتی بوده و به طور عموم در طول حرکت‌های شدید کاهش می‌یابند. دامنه این موج‌ها کم است و اغلب به صورت هارمونیکی و در هنگام تفکر شدید و در اثر تأثیر داروها نیز ظاهر می‌شوند.
- **امواج گاما:** فرکانس این امواج در حدود 30-100Hz بوده و به نظر می‌رسد که ناشی از فعالیت شبکه‌ای از نورون‌ها با هم در هنگام فعالیت شناختی یا حرکتی باشند. این امواج در مناطق حسی-حرکتی وجود داشته و هنگام مشغولیت شدید ذهنی شناختی، مانند پردازش بر روی نور و صدا و در هنگام درگیری‌های حافظه به وجود می‌آیند [۱].


۱-۲-۴- سیستم ۲۰-۱۰

در اندازه‌گیری EEG، کلاهی بر روی سر انسان قرار داده می‌شود که شامل تعدادی الکتروود است. سیستم ۲۰-۱۰ یک سیستم استاندارد است که شامل ۱۹ الکتروود می‌باشد. در این سیستم، هر الکتروود دارای یک نام است که بر اساس موقعیت آن الکتروود (لب گیجگاهی، آهیانه‌ای، پیشانی و پس-سری) در یک نیمکره انتخاب شده است. هر الکتروود دارای یک شماره است که بیان‌گر نیمکره مربوطه می‌باشد. شماره‌های زوج در رنج یک تا هشت مربوط به نیمکره راست و شماره‌های فرد مربوط به نیمکره چپ می‌باشند. عبارت ۲۰-۱۰ اشاره به فاصله (به درصد) بین الکتروودها دارد که مثلاً ۲۰ درصد دور سر می‌باشد. در این سیستم یک مرجع ولتاژ و یک زمین نیاز است و آن جایی است که در طول فعالیت‌های مختلف ثابت بماند، مانند لاله گوش و یا استخوان پشت گوش. سیستم ۲۰-۱۰ در

شکل (۷-۱) نشان داده شده است و همچنین سیستم استاندارد دیگری به نام ۱۰-۱۰ نیز وجود دارد که در شکل (۸-۱) آورده شده است [۱].



شکل (۷-۱): سیستم ۱۰-۲۰ [۲۱]



شکل (۸-۱): سیستم ۱۰-۱۰ [۲۱]


۳-۱- سیستم‌های BCI

۱-۳-۱- قسمت‌های مختلف یک سیستم BCI

مانند هر سیستم کنترلی یا ارتباطی دیگر، BCI نیز دارای ورودی (یعنی فعالیت الکتروفیزیولوژیکی کاربر)، خروجی (دستورات به دنیای بیرون)، اجزایی که ورودی را به خروجی تبدیل می‌کند و پروتکلی که آغاز، پایان و زمان انجام کار را تعیین می‌نماید، می‌باشد که در این بخش توضیح مختصری راجع به هر کدام از آنها آورده شده است. شکل (۱-۹) این عناصر و تعامل بین آنها را نشان می‌دهد.

۱-۱-۳-۱- بدست آوردن سیگنال

در یک سیستم BCI، ورودی‌ها همان سیگنال‌های الکتریکی ثبت شده از روی پوست سر و یا از داخل مغز می‌باشند. سیستم‌های BCI را می‌توان به دو دسته نیازمند به عمل جراحی و بدون نیاز به عمل جراحی (مانند BCI مبتنی بر EEG) تقسیم نمود. همچنین می‌توان آنها را برحسب اینکه



شکل (۱-۹): سیستم BCI [۴]

ورودی آنها برای تشکیل شدن، نیاز به تحریکات حسی دارد (مانند P300 به وجود آمده از تحریکات حسی) یا نه (مانند امواج ناشی از تصور حرکتی)، تقسیم نمود. یعنی با توجه به نوع مفاهیم ذهن و مکانی از کرتکس که اطلاعات مفیدتری دارند، می توان کانال های مورد نیاز را انتخاب نمود. در هر صورت بعد از به وجود آمدن سیگنال ها، باید آنها را توسط الکترودهایی ثبت کرده و سپس تقویت نموده و آنگاه به صورت دیجیتالی ذخیره کرد تا آماده پردازش توسط کامپیوتر باشند.

۱-۳-۱- استخراج ویژگی

سیگنال های دیجیتالی بدست آمده از مغز، وارد فرایندهایی برای استخراج ویژگی از جمله فیلترینگ زمانی، اندازه گیری دامنه ولتاژ در یک لحظه زمانی خاص، آنالیز طیفی و غیره می شود. سیستم BCI می تواند از ویژگی های حوزه زمان یا حوزه فرکانس و یا توأم از هر دو حوزه استفاده نمایند. به طور کلی ویژگی های سیگنالی مورد استفاده در یک سیستم BCI دو گونه هستند: ویژگی های گذرا یا پتانسیل های مغزی مرتبط با وقوع یک رخداد خاص و ویژگی های ریتمیک و سنکرون شده سیناپسی. اطلاع راجع به این رخدادهای می تواند به پیشرفت BCI کمک کند. موقعیت و نوع کار ناحیه ای از مغز که ریتم ها یا پتانسیل های رخداد را می سازد، می تواند چگونگی ثبت آن، چگونگی کنترل دامنه آن توسط کاربر و چگونگی تشخیص و حذف اثر اغتشاشات را تعیین نماید. در مورد انتخاب ویژگی های مفید برای کلاسه بندی باید دقت نمود که ویژگی ها توسط اغتشاشاتی مانند سیگنال های الکتریکی حرکت چشم^۱ (EOG) و سیگنال های الکتریکی فعالیت ماهیچه های صورت^۲ (EMG) یا بقیه اغتشاشات غیر فعالیت عصبی، تأثیرپذیر نباشند.

لازم به ذکر است که در سیستم های BCI استخراج ویژگی جهت آموزش سیستم، باید برای هر فرد به طور جدا انجام شود چراکه سیگنال های EEG برای هر فرد متفاوت بوده و با توجه به سن و جنس و سایر خصوصیات فردی، متفاوت خواهد بود [۱].

^۱Electrooculogram

^۲Electromyogram

۳-۱-۳-۱ کلاسه‌بندی ویژگی‌ها

در این قسمت، ویژگی‌های به دست آمده از سیگنال‌های EEG مغز برای شناسایی وارد کلاسه‌بند شده و نتیجه شناسایی برای کنترل وسایل خارجی مورد استفاده قرار می‌گیرد. این کلاسه‌بند می‌تواند از روش‌های خطی (مثل آنالیز کلاسیک آماری) و یا غیرخطی (مانند شبکه عصبی) استفاده نماید. یک سیستم BCI می‌تواند برای عملکرد بهتر در سه سطح با کاربر تطبیق یابد. در سطح اول برای اولین بار سیستم BCI متناسب با ویژگی‌های استخراج شده از سیگنال‌های مغزی کاربر مورد نظر تنظیم می‌شود. BCI هایی که فقط این مرحله از تطبیق با کاربر را دارا می‌باشند، تنها زمانی موفق هستند که مشخصات سیگنال‌های EEG استخراج شده از مغز کاربر خیلی پایدار باشد. اما در حقیقت EEG و سایر سیگنال‌های الکتروفیزیولوژیکی، دارای تغییرات کوتاه مدت و بلندمدت می‌باشند که این تغییرات وابسته به زمان، سطح هورمونی، تجهیزات ثبت، حوادث اتفاق افتاده اخیر برای فرد، خستگی، بیماری، سن و سایر فاکتورها می‌باشند. بنابراین یک سیستم BCI کارا، باید دارای سطح دومی از تطبیق سازی باشد یعنی تنظیم متوالی در طول زمان که تأثیر این عوامل غیرارادی را کاهش دهد.

هرچند که در سطوح ۱ و ۲، تعامل بین کاربر و BCI وجود دارد، سطح سوم، تطبیق‌سازی و تقویت توانایی‌های وفقی مغز می‌باشد. در این سطح ویژگی‌های سیگنال ورودی در BCI به عنوان خروجی، به دستوراتی برای وسایل تبدیل می‌شوند که مشاهده نتایج این دستورات می‌تواند ویژگی-های سیگنال ورودی را تحت تأثیر قرار دهد یعنی از خروجی به ورودی فیدبک داریم. در موارد مطلوب، مغز کاربر، ویژگی‌های سیگنال را برای عملکرد بهتر BCI تغییر می‌دهد. از طرف دیگر، تطبیق بیش اندازه و نامناسب نیز می‌تواند به عملکرد سیستم آسیب برساند چراکه کاربر همیشه در شرایط مساعد نمی‌باشد تا بتواند سیگنال‌های ایده‌آل را ایجاد کند. این سطح شامل تعامل بین مغز و کامپیوتر است و یکی از مشکلات اساسی برای محققان BCI می‌باشد [۴].

عملکرد موفق سیگنال‌های خروجی عصبی-عضلانی معمول مغز که در افراد سالم مستقیماً از مغز به اندام‌ها می‌روند، بستگی به فیدبک دارد. خروجی‌های معمول مغز مانند صحبت کردن یا راه رفتن و بیشتر خروجی‌های خاص مانند آواز خواندن، نیاز به فراگیری اولیه و حفظ تنظیمات پیوسته براساس اشتباهات حین و پایان کار دارد. یعنی شخص نتیجه عمل خود را می‌بیند و اگر حرکت اشتباهی انجام داده باشد، حرکت خود را اصلاح می‌کند، یعنی در واقع از خروجی به ورودی فیدبک داریم. هنگامی که از همان ابتدا فیدبک وجود ندارد، مهارت‌های حرکتی به طور مناسب بهبود نمی‌یابد، و نیز اگر فیدبک در حین فعالیت برداشته شود، نتیجه مطلوبی نخواهیم داشت.

عملکرد یک سیستم BCI نیز مانند کانال‌های خروجی معمول عصبی-عضلانی، وابسته به فیدبک و متناسب‌سازی فعالیت مغزی بر حسب فیدبک است. بنابراین یک سیستم BCI باید دارای فیدبک بوده و بر اساس این فیدبک، فعالیت‌های مغز متناسب شوند. بنابراین در این‌گونه سیستم‌ها دو کنترلر وفقی وجود دارد: مغز کاربر که سیگنال‌های اندازه‌گیری شده توسط BCI را می‌سازد و خود BCI که این سیگنال‌ها را به دستورات خاص تبدیل می‌نماید [۴].

در اکثر سیستم‌های BCI بخش‌های فیدبک‌دار وجود ندارند. یعنی فرد مورد آزمایش از کیفیت سیگنال‌های ایجاد شده ناشی از تصور حرکتی خود اطلاعی ندارد و فقط از او خواسته می‌شود تا حرکت خاصی را انجام دهد. این صورت طی چند ماه و در چند روز مختلف، انجام شده می‌شوند. بخشی از آزمایشات به عنوان داده آموزشی^۱ برای آموزش سیستم در نظر گرفته می‌شوند و برخی به عنوان داده ارزیابی^۲ بکار می‌روند. یعنی تنها تطبیق‌سازی در سطوح اول و دوم وجود دارد که البته تطبیق‌سازی سطح دوم نیز در یک بازه زمانی کوتاه مدت انجام می‌شود و بنابراین BCI ساخته شده ممکن است در بلند مدت عملکرد مطلوبی نداشته باشد چراکه همانطور که گفته شد کیفیت سیگنال-های مغز در طول زمان و با تغییر حالات، سن و غیره تغییر خواهد کرد [۱].

¹Training data

²Test data

۱-۳-۴- وسایل خروجی

برای بیشتر سیستم‌های BCI، خروجی، صفحه نمایشگر کامپیوتر می‌باشد اما هر وسیله دیگری مانند ویلچر و اعضای مصنوعی و یا یک ربات نیز می‌تواند به عنوان خروجی باشند. وقتی خروجی صفحه نمایشگر است، هدف اصلی انتخاب یک حرف یا آیکون‌های موجود روی صفحه می‌باشد. در شخص آسیب دیده سیگنال‌های حرکتی در مغز تولید می‌شوند و قرار است که از راه نخاع به اندام مربوطه برسند اما متأسفانه چون نخاع آسیب دیده است، این پیام‌های عصبی به اعضای بدن نمی‌رسد. در این کاربردهای BCI، سیگنال‌های مغزی جمع‌آوری شده و توسط سیستم تفسیرگر، نوع حرکت مورد نظر شخص تشخیص داده شده و توسط یک سیستم کنترلی منجر به حرکت اندام مربوطه و یا عضو مصنوعی می‌شود [۴].

۱-۳-۵- پروتکل‌های کاربردی

برای هر سیستم BCI پروتکلی وجود دارد است که عملکرد آن را هدایت می‌کند. این پروتکل مشخص می‌کند که چگونه یک سیستم خاموش یا روشن شود، آیا تبدیل پیام‌ها توسط سیستم تریگر می‌شود یا کاربر، توالی و سرعت تعامل بین کاربر و سیستم چگونه است و اینکه آیا فیدبک وجود دارد و اگر وجود دارد خروجی فیدبک چیست.

بیشتر پروتکل‌های BCI، کاملاً منطبق بر اهداف کاربردی BCI نیستند و نمی‌توانند نیازهای یک فرد ناتوان را برآورده سازند. اکثر آزمایشگاه‌ها به کاربر کنترل خاموش – روشن کردن دستگاه را نداده و این کار به عهده فرد محقق می‌باشد. به دلیل اینکه محققان می‌خواهند تا سرعت و دقت روش‌های پیشنهادی را بسنجند، از کاربر می‌خواهند تا پیام دلخواه آنها را بفرستد در صورتی که در دنیای واقعی، کاربر پیام‌ها را انتخاب می‌کند. این تفاوت در پروتکل‌ها می‌تواند گذر از تحقیق تا کاربرد را پیچیده سازد [۴].

۱-۳-۲ BCI های موجود

سیستم‌های BCI با توجه به نوع سیگنال الکتروفیزیولوژیکی مورد استفاده آنها به ۵ دسته تقسیم می‌شوند که در ادامه آورده شده‌اند.

۱-۳-۲-۱ پتانسیل‌های رخداده بینایی

Middendorf و همکارانش [۵] در سال ۲۰۰۰ روشی را در تحقیقات BCI پیشنهاد دادند که بعد از آن مورد استفاده بسیاری از محققان قرار گرفت. در این روش بر روی صفحه نمایش چند مربع نمایش داده می‌شود که به طور متناوب هر مربع با فرکانس خاصی خاموش و روشن می‌شود. در ابتدا مربع‌ها خاموش هستند و شخص به مربع مورد نظر خیره می‌شود و سپس مربع‌ها، شروع به فلش-خوردن می‌کنند، البته هر کدام با یک فرکانس خاص و به طور متناوب. نگاه به هر کدام از مربع‌ها سبب تشدید فرکانس فلش خوردن آن در سیگنال‌های مغزی در ناحیه کرتکس بینایی می‌شود. با تشخیص این فرکانس، می‌توان به مربع مربوطه پی‌برد [۴].

۱-۳-۲-۲ پتانسیل‌های آرام کرتکس^۱ (SCP)

از جمله ویژگی‌های فرکانس پایین سیگنال‌های EEG، جابه‌جایی پتانسیلی آرام می‌باشد که SCP نام دارند. SCP های منفی مربوط به حرکت و دیگر فعالیت‌های کرتکس می‌باشند، درحالی که SCP های مثبت مربوط به حالت استراحت بعد از فعالیت‌های کرتکس می‌باشند. در مطالعات نشان داده شده که کاربر می‌تواند کنترل SCP را یاد بگیرد. کاربر می‌تواند با افزایش یا کاهش سطح ولتاژ از یک مقدار بحرانی، مفهوم باینری (دو حالتی یا بله و خیر) خود را بیان کند. مرحله آموزش در این نوع BCI وقت-گیر است. این نوع BCI می‌تواند برای بیماران ALS با درجه زیاد به کار رود.


^۱ Slow Cortical Potential

یک پروتکل جدید دسترسی به اینترنت را برای افراد ناتوان فراهم ساخته است. این روش به کاربر که کلاهی را ۲۴ ساعته پوشیده، اجازه می‌دهد تا با سلسله‌ای از SCP های مثبت و منفی، آیکون‌هایی را انتخاب نمایند [۴]. نمونه‌ای از پتانسیل‌های SCP در دو حرکت در شکل (۱-۱۰) نشان داده شده است.

۱-۳-۲-۳- پتانسیل رخداد P300^۱

یک تحریک حسی، بصری یا شنوایی غیرمعمول، در صورتی که فرد تحت تأثیر تحریکات دیگر نباشد، بعد از 300ms در سیگنال‌های کرتکس پیشانی، یک پیک مثبت ایجاد خواهد نمود. برای مثال کاربر روبروی یک ماتریس از حروف، اعداد یا بقیه سمبل‌ها قرار گرفته است. در ابتدا صفحه تاریک است و بعد از آن، هر 125ms یک سطر یا ستون فلش می‌خورد. هر دفعه که سمبل خاموش است یک رویداد معمول داریم و بعد از فلش خوردن سمبل یک رویداد غیرمعمول اتفاق افتاده و بعد از 300ms پتانسیل P300 ایجاد می‌شود.

در شکل (۱-۱۱) نمونه‌ای از پتانسیل P300 ایجاد شده در کانال Pz ناشی از فلش خوردن یک سمبل نشان داده شده است. اگر شخص بخواهد مثلاً حرف K را انتخاب کند، باید به این حرف خیره




شکل (۱-۱۰): نمایشی از پتانسیل‌های SCP برای انتخاب دو حالت [۴]

^۱ P300 Evokeked Potential

شود. در هر بار فلش خوردن سطر و ستونی که شامل این حرف است، یک رویداد غیر معمول در مغز ایجاد شده و P300 به وجود می‌آید که مشخصات آن با P300 ناشی از بقیه حروف متفاوت است. چون پتانسیل‌های ایجاد شده در مغز کوچک هستند، برای اندازه‌گیری مجموع پتانسیل‌های ایجاد شده در مغز در تمامی مواردی که حرف مورد نظر روشن می‌شود بدست می‌آید. سیستم BCI مبتنی بر P300 یک مزیت دارد و آن این است که نیازی به آموزش کاربر ندارد چراکه پتانسیل P300، در هر اتفاق غیر معمول در مغز ایجاد می‌شود. مشخصات P300 نیز با زمان قابل تغییر بوده و بنابراین در این نوع از BCI نیز وقتی سازی در دو سطح ۱ و ۲ لازم است [۴].


۱-۳-۲-۴- امواج میو و بتا و سایر فعالیت‌های کرتکس حسی - حرکتی

در افراد هوشیار، در زمان استراحت، یعنی زمانی که سیگنالی از طریق اعصاب حسی از اندام‌ها به مغز آورده نمی‌شود و یا سیگنالی از مغز به طرف اندام‌ها ارسال نمی‌شود، در نواحی کرتکس حسی- حرکتی، مؤلفه‌های فرکانسی در محدوده ۸ تا ۱۲ هرتز وجود دارد که امواج میو نامیده می‌شوند. این امواج در اکثر افراد بزرگسال وجود دارند. امواج میو با امواج بتا در محدوده ۱۸ تا ۲۶ هرتز همراه هستند. در واقع رنج فرکانسی بتا هارمونیک‌های امواج میو می‌باشند.



شکل (۱-۱۱): نمونه‌ای از ماتریس حروف در سیستم BCI مبتنی بر P300 [۴]

حرکت هر یک از اعضای بدن (مانند دست و پا) باعث به وجود آمدن الگوهای فرکانسی خاصی در کرتکس حرکتی مغز می‌شود. این الگوها به صورت کاهش برخی امواج مانند میو و بتا در کرتکس حرکتی در نیمکره مخالف مغز ظهور می‌کند که این رویداد ^۱ERD نام دارد. در برخی افراد به طور همزمان، افزایش این امواج در همان نیمکره در کرتکس حرکتی وجود دارد که ^۲ERS نامیده می‌شود. تحقیقات نشان داده است که تصور حرکتی نیز مانند خود حرکت باعث به وجود آمدن چنین الگوهایی در مغز خواهد شد [۱، ۴ و ۶]. بنابراین این رویدادهای طبیعی در مغز محققان را بر آن داشته تا از تشخیص چنین الگوهایی برای ساخت سیستم‌های BCI مبتنی بر تصور حرکتی برای استفاده افراد ناتوان حرکتی استفاده کنند. شکل (۱-۱۲) نمونه ای از متوسط دامنه در باندهای فرکانسی ۴ هرتزی را در یک کانال مغزی در دو تصور حرکتی دست چپ و راست نشان می‌دهد. دست چپ متناظر با حرکت مکان‌نما به سمت بالا و دست چپ متناظر با حرکت به سمت پایین در صفحه نمایش در نظر گرفته شده است [۴].




شکل (۱-۱۲): نمونه ای از کاربرد باندهای میو و بتا در حرکت مکان‌نما به دو جهت بالا و پایین [۴]

^۱ Event Related Desynchronization

^۲ Event Related Synchronization

برای روشن تر شدن موضوع شکل (۱-۱۳) از مرجع [۷] آورده شده است. در این شکل توزیع زمان-فرکانس سه کانال C3، C4 و Cz در استاندارد ۲۰-۱۰ در طول ۴ ثانیه تصور حرکتی آورده شده است. این توزیع‌ها متوسط توزیع زمان-فرکانس در چند آزمایش از چهار نوع تصور حرکتی یعنی دست چپ، دست راست، دو پا و زبان مربوط به یک شخص هستند. کانال C3 در نیمکره چپ و کانال C4 در نیمکره راست مغز و هر دو بر روی ناحیه مربوط به دست در کرتکس اولیه حرکتی^۱ می‌باشند. کانال Cz در مرکز سر قرار دارد (به شکل (۱-۴) توجه شود). طیف قرمز رنگ انرژی بیشتر و طیف



شکل (۱-۱۳): متوسط توزیع زمان فرکانس کانال‌های C3، C4 و Cz در طول چند آزمایش از یک شخص مربوط به ۴ نوع تصور حرکتی دست چپ، دست راست، دو پا و زبان [۷]

^۱ Primary Motor cortex

آبی رنگ انرژی کمتر را نشان می‌دهد.

همانطور که مشاهده می‌شود در تصور حرکتی دست چپ در کانال C3 باند میو (طیف حدود ۸ تا ۱۲ هرتز) قبل از تصور وجود داشته و تا پایان تصور ادامه دارد، اما در کانال C4 این باند فرکانسی قبل از تصور وجود داشته و بعد از حدود ۰/۶ ثانیه محو می‌شود، یعنی اصطلاحاً در طول تصور حرکتی دست چپ، در نیمکره راست مغز ERD اتفاق افتاده است. همانطور که مشاهده می‌شود در باند بتا (حدود ۱۸ تا ۲۶ هرتز) نیز ERD رخ داده است که البته قبل از تصور حرکتی این باند فرکانسی انرژی کمی داشته است.

در تصور حرکتی دست راست نیز در باندهای میو و بتا در کانال C3، ERD وجود داشته است. در کانال Cz در تصور حرکتی دست راست و چپ تغییرات خاصی در این باندهای فرکانسی مشاهده نمی‌شود و در هر دو نوع تصور حرکتی توزیع فرکانسی این کانال یکسان است. با توجه به تفاوت‌های مشاهده شده در کانال‌های C3 و C4 در طول تصور حرکتی دست چپ و راست، در بسیاری از تحقیقات از همین دو کانال برای جداسازی دو کلاس این دو نوع تصور استفاده می‌شود [۱۲ و ۱۹]. در تصور حرکتی دو پا به طور همزمان و تصور حرکتی زبان، توزیع انرژی هر سه کانال C3، C4 و Cz شده مانند هم بوده و نمی‌توان برای جداسازی آنها از این سه کانال استفاده کرد.

۱-۳-۲-۵- نوروهای کرتکس^۱

در سال ۱۹۶۰، محققان توانستند با قرار دادن الکترودهای فلزی بر روی تک تک نوروهای کرتکس، پتانسیل ایجاد شده در هر یک از نوروها را اندازه بگیرند. چندین مقاله نشان داد که میمون‌ها می‌توانند تخلیه نوروهای تنها در کرتکس حرکتی را یاد بگیرند. در نتیجه انتظار می‌رود که افراد با ناتوانایی‌های حرکتی نیز بتوانند کنترل مشابهی داشته باشند بطوریکه برای کاربردهای BCI می‌تواند مفید باشد. بررسی این احتمال با وجود کمبود الکترودهای مناسب برای استفاده انسان و توانایی ثبت‌های طولانی مدت از نوروهای تنها، این کار را به تعویق انداخت. تحقیقات در این زمینه

¹ Critical Neurons

نیاز به عمل جراحی دارد. الکترودهای قدیمی باعث جراحت در بافت‌ها می‌شد و یا اینکه نسبت به یک نورون حرکت می‌کرد. در سال ۱۹۸۹ الکترودهایی ساخته شد که این مشکلات را برطرف کرد. با استفاده از این روش برای BCI، سیستم‌هایی با دقت و سرعت بالا ساخته می‌شود. اما چون نیاز به عمل جراحی دارد، در افراد با ناتوانی‌های زیاد مورد استفاده قرار می‌گیرد [۴].

۱-۴- موضوع تحقیق

در بخش‌های قبل گفتیم که مغز می‌تواند با دنیای بیرون ارتباط برقرار کند، اما هنوز نتوانسته به خیالات جامه عمل بپوشاند. BCI ها هنوز نتوانسته‌اند هواپیما را به پرواز درآورند و نمی‌توانند در هر زمانی استفاده شوند، چون یک طرف این سیستم‌ها انسان است و تولید داده‌های اولیه آنها وابسته به اوست.

تحقیقات BCI هنوز در مراحل اولیه است. هنوز روشن نیست که BCI تا کجا پیش خواهد رفت. تنها چیزی که روشن است این است که پیشرفت این سیستم‌ها وابسته به چند عامل است: ناهمبستگی سیستم BCI از کانال‌های ارتباطی عصبی-عضلانی معمول و وابستگی بر جنبه‌های درونی فعالیت‌های طبیعی مغز، انتخاب روش‌های جمع‌آوری سیگنال‌های مغز، ویژگی‌های استخراج شده از سیگنال‌ها، روش‌های استخراج ویژگی، الگوریتم‌های ترجمه مفاهیم مغز به دستورات کنترلی و پروتکل‌های عملکردی در این سیستم‌ها [۴].

همانطور که از قسمت‌های قبل پیداست، تحقیقات BCI بیشتر به صورت آزمایشگاهی می‌باشند، بطوریکه هر سیستم BCI منحصر به فرد بوده و متناسب با نیازهای شخص مورد آزمایش ساخته می‌شود. مرحله آموزش اگر به طور مداوم انجام گیرد، شخص مورد آزمایش خسته شده و سیگنال‌های مغزی مناسب جمع‌آوری نمی‌شوند. فرد باید چند ماه به طور متوالی مورد آموزش قرار گیرد تا سیگنال‌های مغزی او در شرایط متفاوت جمع‌آوری گردد و از طرف دیگر فیدبک‌های لازم به او داده شود تا بتواند پتانسیل‌ها و یا ریتم‌های مورد نیاز را هر چه بهتر در مغز ایجاد نماید.

بعد از ثبت داده‌های مورد نیاز، می‌توان به سیستم BCI به عنوان یک سیستم شناسایی الگو نگریست. همانطور که بیان شد، روش‌های زیادی برای استخراج ویژگی در گزارشات آمده است که برخی از آنها تنها از ویژگی‌های حوزه زمان استفاده می‌کنند و برخی ویژگی‌های حوزه فرکانس را مورد آنالیز قرار می‌دهند. تعدادی از روش‌ها تلفیقی از ویژگی‌های هر دو حوزه را بکار می‌برند.

طبق مرجع [۸] به دلیل مشکلات زیاد، کمتر بر روی مسائل کلاسه‌بندی تصور حرکتی به صورت زنده^۱ تحقیقات صورت گرفته است. در بسیاری از مقالات از سیگنال‌های مغزی جمع‌آوری شده در پایگاه‌های داده موجود برای مطالعه این موضوع استفاده می‌شود. طی چند دهه اخیر کنگره‌ها و کنفرانس‌های زیادی برای تبادل اطلاعات در زمینه تحقیقات BCI، به منظور پیشرفت هر چه بیشتر در این حوزه، صورت گرفته است. همچنین در سال‌های ۲۰۰۰، ۲۰۰۳، ۲۰۰۵ و ۲۰۰۸ مسابقاتی به صورت جهانی در این زمینه انجام شده است.

در اکثر مقالات گزارش شده [۸] تنها کلاسه‌بندی دو کلاس تصور حرکتی مورد تحقیق قرار گرفته است و کمتر به مسائل چند کلاسه پرداخته شده است، چراکه پیچیدگی مسئله با افزایش تعداد کلاس‌های تصور حرکتی بیشتر می‌شود.

در این تحقیق کلاسه‌بندی سیگنال‌های EEG ناشی از تصور حرکتی چهار کلاس حرکت دست چپ، دست راست، پا و زبان مورد نظر است. برای این منظور از داده‌های 2a از پایگاه داده مسابقه ۴ در زمینه BCI که در سال ۲۰۰۸ انجام گرفته است [۹]، استفاده کرده‌ایم که توضیحات راجع به این پایگاه داده در فصل سوم آورده شده است.

همانطور که در قسمت‌های قبل بیان شد، تصور حرکت نیز مانند خود حرکت باعث ایجاد ERD/ERS در مغز می‌شود. به دلیل بافت استخوانی مجسمه، اتفاق‌های مورد نظر که از لحاظ تئوری انتظار داریم، به طور دقیق رخ نمی‌دهند. در واقع سیگنال‌های به وجود آمده در کرتکس که در زیر مجسمه است تا به پوست سر برسد با سیگنال‌های زیادی تداخل می‌کنند و در نتیجه این مسئله

¹ Online

تشخیص ERD/ERS را مشکل می سازد. از طرف دیگر حتی ممکن است کانال مناسب برای کلاسه-بندی تصور حرکتی متفاوت از کانال پیشنهاد شده در تئوری باشد. همچنین با توجه به نوع آسیب-دیدگی فرد مورد آزمایش ممکن است برخی کانال‌های مناسب برای جداسازی کلاس‌ها عملکرد خوبی نداشته باشند و در نتیجه باید از سایر کانال‌ها برای تشخیص تصور حرکتی استفاده نمود. بنابراین انتخاب کانال‌های مناسب برای هر فرد باید به طور خودکار و منحصر به فرد صورت پذیرد.

تحقیقات در زمینه BCI مبتنی بر تصور حرکتی که داده‌های آن به روش EEG از روی پوست سر جمع‌آوری می‌شوند، شخص محقق را با تعداد زیادی کانال EEG روبرو می‌کند. ازدیاد تعداد کانال‌ها از لحاظ محاسباتی مسئله را پیچیده می‌سازد. قطعاً تمامی کانال‌ها دارای اطلاعات مفید برای کلاسه‌بندی داده‌های ناشی از تصور حرکتی نمی‌باشند. بنابراین باز هم باید به دنبال کانال‌هایی بود که برای جداسازی کلاس‌ها دارای اطلاعات مفیدتری هستند.

از طرف دیگر محدوده فرکانسی امواج میو و بتا و سایر باندهای فرکانسی که در قسمت‌های قبل آورده شد، بصورت متعارف برای تمام افراد بیان شد. در عمل برای هر شخص این محدوده‌های فرکانسی ممکن است با شخص دیگر کمی متفاوت باشد [۶]. این موضوع نیاز به استفاده از روش‌های خودکار برای انتخاب بازه فرکانسی مناسب را برای هر فرد روشن‌تر می‌سازد.

در تحقیقات انجام شده روش‌های مختلفی برای کلاسه‌بندی داده‌های EEG ناشی از تصور حرکتی ذکر شده است که برخی از روش‌ها در فصل دوم به طور مختصر توضیح داده شده‌اند.

در فصل سوم راجع به پایگاه داده مورد استفاده در این پایان‌نامه توضیحات مختصری داده شده است. در این فصل روش برنده مسابقه ۲۰۰۸ و یکی از مقالاتی که بر روی این پایگاه داده تحقیق انجام داده است، به همراه نتایج آنها برای مقایسه با نتایج روش پیشنهادی ما آورده شده است.

این مجموعه داده شامل داده‌های EEG ناشی از چهار نوع تصور حرکتی دست چپ، دست راست، دو پا و زبان مربوط به ۹ شخص می‌باشد. در این پایان‌نامه چهار روش برای کلاسه‌بندی داده‌های این مجموعه داده پیشنهاد شده است.

یکی از موفق‌ترین روش‌ها در زمینه BCI مبتنی بر تصور حرکتی روش CSP¹ می‌باشد. روش‌های زیادی در مقالات برای بهبود روش CSP ارائه شده است که اکثر این روش‌ها سعی در یافتن باندهای فرکانسی مناسب برای هر فرد مورد آزمایش در این روش داشته‌اند.

روش CSP مبتنی بر ماتریس کواریانس داده‌ها بوده و ساختار زمانی داده‌ها را در نظر نمی‌گیرد. همچنین نویز در یک نقطه زمانی می‌تواند تأثیر زیادی بر نتیجه این روش داشته باشد.

یکی از روش‌هایی که برای بهبود روش CSP گزارش شده است روش LTCSP است. این روش ساختار زمانی داده‌ها را در نظر گرفته و تأثیر نویز در نتیجه آن خیلی کم است. این روش اولین بار برای کلاسه‌بندی داده‌های دو کلاسه مطرح شده که در فصل چهارم این پایان‌نامه توسط تکنیک OVR به مسئله چهار کلاسه تعمیم یافته است.

بهبود عملکرد روش LTCSP نسبت به روش CSP معمول به دلیل این است که روش LTCSP ساختار زمانی داده‌ها را در نظر می‌گیرد. بنابراین ما در ادامه فصل چهارم این پایان‌نامه روشی به نام SEG-CSP-Var پیشنهاد دادیم که در آن از قطعه‌بندی زمانی در روش CSP استفاده شده است. این روش پیشنهادی بطور متوسط نتایج بهتری از روش CSP داشته است. با اجرای این روش متوجه شدیم که اهمیت کانال‌ها برای جداسازی کلاس‌ها در قطعات زمانی مختلف متفاوت است. همچنین اطلاعات تمامی قطعات زمانی در کنار هم می‌تواند به بهبود نتایج حاصل از تک تک قطعات کمک کند. این روش را توسط الگوریتم OVR به مسئله چهار کلاسه تعمیم داده و OVR-SEG-CSP-Var نامیده‌ایم.

برای بهبود نتایج روش SEG-CSP-Var در فص پنجم روشی دیگر با نام SEG-CSP-BP پیشنهاد داده‌ایم که در آن به جای ویژگی واریانس از توان در باندهای فرکانسی متفاوت به عنوان ویژگی استفاده می‌شود. در این روش از تکنیک گسسته‌سازی چند بازه‌ای به عنوان کلاسه‌بند و از

¹ Common Spatial Pattern

تکنیک رتبه‌بندی ویژگی‌ها به منظور کاهش ابعاد بردار ویژگی استفاده شده است. این روش را نیز توسط الگوریتم OVR به مسئله چهار کلاسه تعمیم داده و OVR-SEG-CSP-BP نامیده‌ایم.

عملکرد بهتر روش OVR-SEG-CSP-BP نسبت به روش OVR-CSP، OVR-LTCSP، OVR-SEG-CSP-Var و حتی برنده مسابقه ۲۰۰۸ حاکی از آن است که استفاده از ویژگی‌های حوزه زمان و حوزه فرکانس در کنار هم می‌تواند منجر به نتایج مطلوبی شود. بنابراین در انتهای فصل پنجم روشی پیشنهاد دادیم که در آن از توزیع زمان-فرکانس کانال‌ها در روش CSP استفاده می‌شود. در این روش تابع چگالی احتمال مؤلفه‌ها در حوزه زمان-فرکانس توسط مخلوط توابع گوسی^۱ (GMM) بدست می‌آید. این روش که آن را CSP-GMM نامیده‌ایم، نتایج بهتری نسبت به روش CSP داشته است. همچنین برای مقایسه با روش CSP-GMM روش SEG-CSP-BP را در کل بازه تصور حرکتی اجرا کرده و به این نتیجه رسیدیم که روش CSP-GMM نتایج بهتری دارد. در حقیقت با روش SEG-CSP-BP ویژگی‌ها از نوع توان در باندهای فرکانسی مختلف هستند که بدون در نظر گرفتن اطلاعات زمانی در کل بازه ۳ ثانیه مورد بررسی بدست می‌آیند. برتری CSP-GMM نسبت به این روش بیانگر این مطلب است که اطلاعات زمانی در کنار اطلاعات فرکانسی منجر به نتایج بهتری در کلاسه‌بندی سیگنال‌های EEG ناشی از تصور حرکتی خواهد شد.

در فصل ششم نتیجه‌گیری و پیشنهادات برای کارهای آتی آورده شده است.

^۱ Gaussian Mixture Models

فصل دوم

مروری بر روش‌های انجام شده

فصل دوم

مروری بر روش‌های انجام شده

۲-۱- نگاهی به BCI به عنوان یک سیستم شناسایی الگو^۱

هدف اصلی BCI این است که فعالیت‌های مغزی را به دستوراتی برای کنترل وسایل خارجی تبدیل نماید. برای رسیدن به این منظور ابتدا باید ویژگی‌های مناسبی از سیگنال‌های مغزی استخراج نمود و سپس بر مبنای این ویژگی‌ها و توسط الگوریتم‌های کلاسه‌بندی، نوع تصور حرکتی را مشخص کرد. یعنی در واقع BCI یک سیستم شناسایی الگوست که رابطه بین مغز انسان و وسایل خارجی را برقرار می‌کند.

عملکرد هر سیستم شناسایی الگو وابسته به ویژگی‌های داده شده به آن و الگوریتم‌های کلاسه‌بندی استفاده شده است. در ادامه به توضیح خصوصیات ویژگی‌های BCI و کلاسه‌بندهای مورد نیاز برای هر کدام از ویژگی‌ها خواهیم پرداخت.

^۱Pattern recognition

۲-۱-۱- استخراج ویژگی

در سیستم‌های BCI مبتنی بر تصور حرکتی، از ویژگی‌ها در هر سه حوزه‌ی زمان، فرکانس و زمان-فرکانس استفاده شده است. بعضی از مشخصات ویژگی‌های بکار رفته در طراحی یک سیستم BCI به صورت زیر می‌باشند:

نویز و اغتشاشات خارجی^۱: همانطور که در فصل قبل گفته شد، به دلیل بافت استخوانی جمجمه، و وجود آرتیفکت‌هایی مانند EOG و EMG، سیگنال‌های EEG نسبت سیگنال به نویز ضعیفی دارند. در نتیجه ویژگی‌های BCI نویزی بوده و دارای اغتشاشات خارجی می‌باشند.

ابعاد زیاد: در سیستم‌های BCI، بردارهای ویژگی اغلب دارای ابعاد زیاد می‌باشند. در واقع، ممکن است چندین ویژگی از کانال‌های مختلف و از بازه‌های زمانی مختلف استخراج شوند.

اطلاعات زمانی: توالی زمانی داده‌های EEG باید در نظر گرفته شود، چراکه در هر لحظه از زمان رویدادهای خاصی در سیگنال‌های EEG در کانال‌های مختلف رخ خواهد داد که ممکن است اطلاعات آنها در کنار هم برای کلاسه‌بندی مفید واقع شوند.

ناایستا بودن^۲: ویژگی‌های BCI ناایستا می‌باشند چراکه سیگنال‌های EEG می‌توانند در طول زمان به سرعت تغییر نمایند.

تعداد آزمایشات محدود: بدست آوردن مجموعه داده‌های آموزشی وقت‌گیر بوده و برای افراد مورد آزمایش، خسته کننده می‌باشد. به همین دلیل مرحله آموزش برای استفاده BCI در روزها و ماه‌های مختلف انجام می‌گیرد و تعداد آزمایشات خیلی نمی‌تواند باشد [۸].

¹outlier
²artifact
³ Non-stationary

۲-۱-۲- کلاسه‌بندی

بیشتر الگوهای فعالیت‌های مغزی برای استفاده در BCI، مربوط به تغییرات سیگنال‌های EEG در زمان‌های خاص بوده که احتمالاً در باندهای فرکانسی خاصی صورت می‌گیرند. بنابراین توالی زمانی EEG باید در استخراج ویژگی در نظر گرفته شود. برای استفاده از این اطلاعات زمانی، سه روش اساسی پیشنهاد می‌شود:

تلفیق ویژگی‌های بازه‌های زمانی مختلف: این روش شامل استخراج ویژگی از چندین بازه زمانی و پیوستن آنها در یک بردار ویژگی واحد می‌باشد.

ترکیب کلاسه‌بندی بازه‌های زمانی مختلف: این روش شامل انجام مراحل استخراج ویژگی و کلاسه‌بندی در بازه‌های زمانی مختلف و سپس ترکیب نتایج آنها می‌باشد.

کلاسه‌بندی دینامیک: این روش شامل استخراج ویژگی از بازه‌های زمانی مختلف است تا یک دنباله زمانی از بردارهای ویژگی داشته باشیم، به طوریکه این دنباله توسط یک کلاسه‌بند دینامیک می‌تواند، کلاسه‌بندی شود.

در استخراج ویژگی روش اول بیشتر مورد استفاده قرار می‌گیرد و بنابراین از اینجا می‌توان فهمید که چرا بردارهای ویژگی دارای ابعاد زیاد می‌باشند [۸].

۲-۱-۲- کدام کلاسه‌بندها برای کلاسه‌بندی داده‌های EEG مناسبند؟

F. Lotte و همکارانش در [۸] دسته‌بندی خاصی برای انواع کلاسه‌بندها در نظر گرفته‌اند که به شرح زیر است:

تولیدکننده^۱ - جداکننده^۲: کلاسه‌بندهای تولیدکننده (که همچنین به عنوان کلاسه‌بندهای آمورنده^۱ شناخته می‌شوند) مانند بیزین درجه دو^۲، مدل آماری کلاس‌ها^۳ را به دست می‌آورند. برای

^۱generative
^۲discriminative

دسته‌بندی بردارهای ویژگی، این کلاسه‌بندها پیشامد^۴ هر کلاس را محاسبه نموده و محتملترین پیشامد را در نظر می‌گیرند. کلاسه‌بندهای جداکننده مانند SVM^۵ روشی را برای کلاسه‌بندی مستقیم بردارهای ویژگی جستجو می‌نمایند.

استاتیک^۶-دینامیک: کلاسه‌بندهای استاتیک مانند MLP^۷ ها، هنگام کلاسه‌بندی یک بردار ویژگی، توالی زمانی ویژگی‌ها و رخدادها را نمی‌توانند در نظر بگیرند و در مقابل کلاسه‌بندهای دینامیک مثل HMM^۸ و TDNN^۹ می‌توانند سلسله بردارهای ویژگی را کلاسه‌بندی نموده و بنابراین به دینامیک زمانی داده‌ها دست یابند.

پایدار یا ناپایدار بودن: کلاسه‌بندهای پایدار مانند LDA^{۱۰} پیچیدگی کمی دارند. پایداری آنها به این صورت است که یک تغییر کوچک در داده‌های آموزشی، تأثیر چشم‌گیری در عملکرد آنها نخواهد داشت. در مقابل کلاسه‌بندهای ناپایدار مانند MLP پیچیدگی زیاد داشته و تغییر کمی در داده‌های آموزشی منجر به تغییر چشم‌گیری در عملکرد آنها خواهد شد.

تنظیم شدگی^{۱۱}: شامل کنترل پیچیدگی یک کلاسه‌بند برای کاهش نیاز به داده‌های آموزشی^{۱۲} فراوان می‌باشد. یک کلاسه‌بند تنظیم شده مانند SVM، عمومیت^{۱۳} خوبی داشته و نسبت به اغتشاشات خارجی مقاوم می‌باشد.

¹informative

²Bayes quadratic

³Class models

⁴likelihood

⁵Support Vector Machine

⁶static

⁷Multi-Layer Perceptron

⁸Hidden Markov Model

⁹Time Delay Neural Network

¹⁰Linear Discriminant Analysis

¹¹Regularized

¹²Overtraining

¹³Generalization

متأسفانه به دلیل اینکه ماهیت داده‌های مورد ارزیابی در مقالات مختلف است، به طور دقیق نمی‌توان روش‌های کلاسه‌بندی را با هم مقایسه کرد، اما در مرجع [۸] کلاسه‌بندها بر اساس توانایی آنها در رفع مشکلات خاص ویژگی‌های BCI مقایسه می‌شوند که خلاصه‌ای از آن به شرح زیر است:

نویز و اغتشاشات: به نظر می‌رسد کلاسه‌بندهای تنظیم شده مانند SVM در مواجهه با اغتشاشات، عملکرد خوبی داشته باشند و همچنین استدلال می‌شود که کلاسه‌بندهای جداکننده، نتایج بهتری از انواع تولیدکننده در وجود نویز یا اغتشاشات دارند.

ابعاد زیاد: SVM احتمالاً مناسب‌ترین کلاسه‌بند برای کلاسه‌بندی ویژگی‌ها با ابعاد زیاد می‌باشد. اگر ابعاد زیاد مربوط به استفاده از تعداد زیادی بازه زمانی باشد، می‌توان به جای استفاده از یک بردار ویژگی با تعداد ابعاد زیاد، از زنجیره‌ای از بردارهای ویژگی و کلاسه‌بند دینامیک استفاده نمود. برای مثال، SVM و کلاسه‌بندهای دینامیک مانند HMM می‌توانند داده‌های EEG را به خوبی کلاسه‌بندی نمایند. در مقابل KNN^۱ها نمی‌توانند در زمینه BCI استفاده شوند چراکه به افزایش ابعاد بردارهای ویژگی بسیار حساس بوده و در نتیجه برای ابعاد کم پیشنهاد می‌شوند. بنابراین لازم است تا قبل از اینکه از این نوع کلاسه‌بندها استفاده شود، از روش‌های کاهش ابعاد و یا انتخاب ویژگی استفاده نمود.

اطلاعات زمانی: به نظر می‌رسد که برای آزمایشات سنکرون که به صورت offline انجام می‌شوند، کلاسه‌بندهای دینامیک روش‌های کارآمدتری برای استفاده از توالی زمانی موجود در ویژگی‌ها باشند.

ناایستا بودن^۲: ممکن است ترکیبی از کلاسه‌بندها بتوانند مسئله پایداری را حل نماید و همچنین کلاسه‌بندهای پایدارمانند LDA یا SVM نیز می‌توانند در این مورد استفاده شوند اما ترکیب آنها نتایج بهتری خواهد داشت.

^۱K-nearest neighbor

^۲Non-stationary

داده‌های آموزشی کم: اگر داده‌های آموزشی کم باشند، مناسب‌تر است تا روش‌های ساده با

پارامترهای کم مانند LDA استفاده شوند.

همانطور که بیان شد داده‌های EEG برای هر شخص با توجه به ویژگی‌های فردی شناختی، سن، روحیات و از همه مهمتر نوع و میزان آسیب‌دیدگی، متفاوت بوده و منحصر به فرد می‌باشد. در نتیجه میزان نسبت سیگنال به نویز و نوع ویژگی‌های بدست آمده برای افراد مختلف، متفاوت است.

ممکن است یک شخص نتواند در شرایط برابر نسبت به شخص دیگر، ریتم‌های خاصی را در مغز ایجاد کند و در نتیجه یک نوع ویژگی برای دو شخص در شرایط یکسان و با یک نوع کلاسه‌بند نتایج را نسبت به نوع دیگر ویژگی، برای یک شخص بهبود بخشد و برای شخص دیگر بالعکس. در نتیجه ممکن است نوع خاصی از ویژگی برای یک شخص نویز زیادی نداشته باشد و با کلاسه‌بند پیچیده‌تر نتایج بهتری داشته باشیم و برای شخص با نویز بیشتر کلاسه‌بندهای ساده‌تر بهتر جواب دهند. همچنین ممکن است نسبت سیگنال به نویز بالا باشد اما پراکندگی بردارهای ویژگی زیاد باشد و در نتیجه نیاز به کلاسه‌بند ساده‌تر داشته باشیم. در هر صورت خلاصه مطلب اینکه تحقیقات BCI مختص به فرد¹ است یعنی برای هر شخص باید با توجه به سیگنال‌های ثبت شده از بالای سر، نوع ویژگی‌ها را انتخاب کرده و با توجه به نوع ویژگی و مشاهده‌ی خصوصیات ویژگی‌ها مانند میزان پراکندگی، نوع کلاسه‌بند را انتخاب نمود. بدین دلیل همانطوریکه در مقالات مشاهده می‌شود یک روش خاص نسبت به روش دیگر، برای برخی افراد نتایج بهتری دارد و برای برخی بالعکس.

از آنجا که تحقیقات BCI از نوع کلینیکی می‌باشد، در مقالات از داده‌های متفاوت از افراد با شرایط آزمایشگاهی متفاوت، استفاده شده است و در نتیجه مقایسه روش‌ها دشوار می‌باشد. در ادامه فصل برخی از مقالات اخیر در زمینه BCI مبتنی بر MI را به طور مختصر بررسی می‌کنیم.

¹Subject specific

۲-۲- مروری بر مهمترین تحقیقات انجام شده

آنچه از قسمت‌های قبل فهمیده می‌شود این است که نوع ویژگی تعیین کننده نوع کلاسه‌بند می‌باشد. همانطور که بیان شد در تحقیقات BCI مبتنی بر MI، از هر سه حوزه زمان، فرکانس و زمان-فرکانس برای استخراج ویژگی استفاده شده است که در این بخش برخی مقالات منتشر شده در سال‌های اخیر را به تفکیک این سه حوزه مرور نموده‌ایم.

۲-۲-۱- استفاده از ویژگی‌های حوزه زمان

از آنجایی که نسبت سیگنال به نویز داده‌ها در BCI مبتنی بر سیگنال‌های EEG پایین است، تشخیص ERD و ERS ها در کانال‌های EEG مشکل می‌باشد. در حقیقت به خاطر بافت استخوانی جمجمه، رزولوشن مکانی سیگنال‌های EEG به دست آمده از بالای سر پایین بوده و در نتیجه سیگنال به دست آمده از هر کانال EEG از بالای سر مجموع چند سیگنال از منابع اصلی آنها از زیر جمجمه است. در نتیجه تشخیص کانال‌های مفید برای جداسازی کلاس‌ها و همچنین استخراج رخدادهای مهم ناشی از تصور حرکتی در این کانال‌ها، مشکل است [۱].

یکی از روش‌های موفق برای کاهش کانال در کاربردهای BCI مبتنی بر تصور حرکتی، روش CSP^۱ می‌باشد. CSP یک روش تجزیه‌سازی^۲ بوده و اولین بار در سال ۱۹۹۱ توسط Koles [۱۰] در یک مسئله دو کلاسه برای تشخیص وجود بیماری یا عدم وجود آن مطرح شد. در این روش سیگنال‌های به دست آمده از بالای سر به دو ماتریس تجزیه می‌شوند که یکی از آنها سیگنال‌های منبع را دارا می‌باشد و دیگری وزن‌هایی است که به نمونه‌های این سیگنال‌های ثانویه داده می‌شود تا سیگنال‌های به دست آمده از بالای سر ساخته شوند. در واقع ستون‌های ماتریس وزن‌ها، فیلترهای فضایی^۳ هستند که توسط این فیلترهای فضایی، ماتریس کواریانس دو مجموعه به طور همزمان قطری می‌شود. در

^۱Common Spatial Pattern

^۲Decomposition method

^۳Spatial filters

حقیقت این فیلترها، بردارهای ویژه متناظر با مقادیر ویژه ماتریس کواریانس کل داده های دو کلاس است که به ترتیب در یک ماتریس قرار گرفته اند. در این روش هر نقطه در زمان که شامل تمامی کانال هاست، به عنوان یک نمونه در نظر گرفته شده و به فضایی نگاشت داده می شود که مبتنی بر این فیلترهای فضایی می باشد. سطرهای بالای ماتریس سیگنال های ثانویه به وجود آمده (سیگنال های منبع)، که متناظر با مقادیر ویژه بزرگتر هستند، برای یک کلاس دارای واریانس بیشتر بوده و برای کلاس دیگر دارای واریانس کمتر می باشند و سطرهای پایین بالعکس. به این ترتیب می توان گفت فعالیت های مغزی مناسب برای جداسازی دو کلاس یا همان ERD/ERS ها در قالب این سیگنال های ثانویه به دست می آیند [۱۱].

۲-۱-۲-۱- روش CSP

هدف از روش CSP یافتن فیلترهایی است که پس از اعمال آنها بر روی سیگنال های EEG بتوان بیشترین اختلاف از لحاظ واریانس را برای سیگنال های دو کلاس مختلف ایجاد نمود. در این رابطه سیگنال های EEG دو کلاس ناشی از تصور حرکتی یک شخص را R_1 و R_2 می نامیم. برای هر شخص، هر کلاس شامل چند آزمایش^۱ است که خروجی هر آزمایش در مسئله دو کلاسه، سیگنال های EEG ناشی از یک تصور حرکتی خاص مربوط به آن کلاس (مثلاً دست چپ یا راست) می باشد. برای هر آزمایش سیگنال های EEG توسط یک ماتریس $K \times N$ ، به نام X بیان می شوند بطوریکه $X = [x_1, x_2, \dots, x_N]$ است. K تعداد کانال های EEG و N تعداد نمونه های زمانی هر کانال می باشد. در نتیجه در این ماتریس $x_i (i \in 1, 2, \dots, N)$ یک بردار ستونی با ابعاد $K \times 1$ می باشد که به عنوان یک نمونه^۲ زمانی در نظر گرفته می شود. باید توجه نمود که میانگین زمانی سیگنال هر کانال در طول N نمونه زمانی باید صفر باشد که البته با فیلتر کردن در مبحث پردازش اولیه داده ها، این خواسته تحقق می یابد.

¹trial

²Sample

تخمین ماتریس کواریانس متوسط نرمال شده برای هر کلاس به صورت رابطه (۲-۱) به دست می‌آید که در این رابطه T_i تعداد آزمایشات برای تصور حرکتی i امین کلاس است (مثلاً حرکت دست راست). در این گزارش از بالانویس T به منزله ترانهاده ماتریس استفاده شده است.

$$\bar{C}_i = \frac{1}{T_i} \sum_{j \in T_i} \frac{X_j X_j^T}{\text{trace}(X_j X_j^T)}, \quad i=1,2 \quad (2-1)$$

$\bar{C}_i$ ها ماتریسی با ابعاد $K \times K$ می‌باشند که توسط آنها، ماتریس کواریانس مرکب برای دو کلاس، از رابطه (۲-۲) بدست می‌آید.

$$\bar{C} = \bar{C}_1 + \bar{C}_2 \quad (2-2)$$

$\bar{C}$ می‌تواند به صورت $\bar{C} = U^T \Lambda U$ تجزیه شود به گونه‌ای که ستون‌های U را بردارهای ویژه تشکیل می‌دهند و Λ ماتریس قطری از مقادیر ویژه مربوطه می‌باشد. مقادیر ویژه بر روی قطر Λ به صورت نزولی مرتب شده‌اند [۱۲].

چنانچه ماتریس سفیدکننده P بصورت $P = U \Lambda^{-1/2}$ تعریف گردد، این تبدیل می‌تواند نمونه‌ها را به فضایی با بردارهای پایه U نگاشت دهد، به گونه‌ای که تمام مقادیر ویژه $P^T \bar{C} P$ برابر با یک شوند. یعنی:

$$P^T \bar{C} P = I \quad \text{یا} \quad P^T (\bar{C}_1 + \bar{C}_2) P = I \quad (2-3)$$

لازم به ذکر است که I در رابطه (۲-۳) ماتریس همانی^۱ است.

حال اگر بخواهیم سیگنال‌های EEG هر کلاس را توسط ماتریس سفید کننده P ، سفید کنیم، ماتریس‌های کواریانس مربوط به این دو کلاس مختلف بصورت $S_1 = P^T \bar{C}_1 P$ و $S_2 = P^T \bar{C}_2 P$ بدست می‌آیند [۱۲]. ماتریس S_1 به کمک ماتریس بردارهای ویژه و ماتریس قطری مقادیر ویژه بصورت $S_1 = B^T \Lambda_1 B$ تجزیه می‌شود. بطور مشابه برای کلاس دیگر داریم $S_2 = B^T \Lambda_2 B$ بطوریکه $\Lambda_1 + \Lambda_2 = I$ است. در این رابطه Λ_1 و Λ_2 ماتریس‌های قطری $K \times K$ هستند که به ترتیب مربوط به مقادیر ویژه


^۱Identity

داده‌های سفید شده در کلاس‌های ۱ و ۲ می‌باشند. این به معنای آن است که مقادیر و بردارهای ویژه S_1 و S_2 یکسان است، با این تفاوت که بردارهای ویژه متناظر با بزرگترین مقادیر ویژه S_1 ، متناظر با کوچکترین مقادیر ویژه S_2 است و بالعکس [۱۲].

بنابراین تصویر نمونه‌های سفید شده در فضای مبتنی بر بردارهای ویژه متناظر با بزرگترین و کوچکترین مقادیر ویژه S_1 و S_2 سری‌های زمانی جدیدی است که برای کلاسه‌بندی دو کلاس متناسب می‌باشند. با در نظر گرفتن ماتریس $W=PB$ ، نگاشت ماتریس داده‌های X به صورت رابطه (۲-۴) بدست می‌آید.

$$Z=W^T X \quad (۴-۲)$$

درواقع ستون‌های معکوس ماتریس W^T همان فیلترهای فضایی هستند، به طوریکه سمت چپ-ترین آنها، متناظر با بزرگترین مقدار ویژه S_1 می‌باشد. در واقع هر ستون از این ماتریس یک بردار است که به سیگنال‌های منبع هر کانال (سطرهای ماتریس Z) یک وزن می‌دهد تا سطرهای ماتریس X را بسازد، که همان سیگنال‌های ثبت شده از بالای پوست سر می‌باشند. وزن‌های داده شده به کانال‌ها در یک فیلتر فضایی را پس از درونیابی می‌توان به صورت شکل (۲-۱) نمایش داد. هر یک از دایره‌های کوچک در این شکل مکان استخراج سیگنال مربوط به یک کانال EEG از پوست سر را مشخص می‌کند. طیف قرمز وزن‌های بزرگتر را نشان می‌دهد و طیف آبی رنگ نماینده وزن‌های کمتر است.



شکل (۲-۱): نمونه‌ای از فیلترهای فضایی در روش CSP

سطرهای بالای Z متناظر با بزرگترین مقادیر ویژه می‌باشند و برای کلاس R_1 دارای واریانس بیشتر و برای کلاس R_2 دارای واریانس کمتر هستند و سطرهای پایین بالعکس.

با برداشتن m سیگنال از سطرهای بالا و m سیگنال از سطرهای پایین ماتریس Z ، بردار ویژگی با $2m$ عنصر بدست می‌آید که این عناصر مطابق رابطه (۵-۲) محاسبه می‌شوند [۱۲].

$$f_p = \log \left(\frac{\text{var}(Z_p)}{\sum_{i=1}^{2m} \text{var}(Z_i)} \right), \quad p=1,2,\dots,2m \quad (5-2)$$

مرحله آموزش^۱:

آزمایشات استفاده شده برای بدست آوردن ماتریس W با نام آزمایشات کالیبره‌سازی شناخته می‌شوند که توسط همان داده‌ها کلاسه‌بند را باید آموزش داد. یعنی بعد از به‌دست آمدن ماتریس W ، از همان داده‌ها دوباره استفاده کرده و در ترانهاده ماتریس W ضرب نموده و از ماتریس Z به دست آمده، ویژگی‌ها را توسط فرمول (۵-۲) برای هر کلاس به دست می‌آوریم و کلاسه‌بند مناسب را آموزش می‌دهیم.

مرحله ارزیابی^۲:

در مرحله ارزیابی، سیگنال‌های EEG مربوط به تصور حرکتی مشخص در اختیار سیستم گذاشته می‌شود. کافی است این داده‌ها (ماتریس‌های X) را در ترانهاده ماتریس W که از مرحله آموزش به دست آمده، ضرب کرده و ویژگی‌های سیگنال را به دست آورد و آنها را برای دسته‌بندی به کلاسه‌بند داد.

Ramoser و همکارانش در مرجع [۱۲] برای کلاسه‌بندی سیگنال‌های EEG در ۵۶ کانال ناشی از دو کلاس تصور حرکت دست چپ و دست راست، از روش CSP استفاده کردند. داده‌ها از یک فیلتر

¹Training Phase

²Test Phase

میانگذر 8-30Hz عبور داده شدند تا سیگنال‌ها شامل باندهای میو و بتا باشند. در این مقاله، برای هر فرد، داده‌ها از شروع آزمایش به پنجره‌های ۱/۵ ثانیه بدون تداخل تقسیم شده و برای هر پنجره به روش Cross-Validation، ۲۰ بار کلاسه‌بندی انجام شده و هر بازه‌ای که به طور متوسط بهترین نتیجه را داشت به عنوان بهترین پنجره زمانی انتخاب می‌شود. برای کلاسه‌بندی از روش LDA استفاده شده است و پارامتر m در رابطه (۲-۵) دو انتخاب شده است.

در این مقاله، برای مقایسه با کل باند فرکانسی 8-30Hz، سیگنال‌ها را به زیر باندهای ۴ هرتزی فیلتر نموده و بعد روش CSP اجرا می‌شود. نتایج گزارش شده نشان می‌دهد که اعمال CSP بر روی کل بازه فرکانسی کارایی بهتری دارد.

در این مقاله ذکر شده است که برای به دست آوردن دو کانال مهمتر، می‌توان از الگوهای فضایی استفاده نمود. در ستون اول و آخر ماتریس فیلترهای فضایی، دو کانالی که بیشترین ضریب را از لحاظ قدرمطلق داشتند، در نظر گرفته و برای کلاسه‌بندی مستقیماً از واریانس همین کانال‌ها استفاده شده است. نتایج گزارش شده از این دو کانال تفاوت چندانی با نتایج روش CSP ندارد. بعد از رسم دو فیلتر مهمتر برای چند شخص، مشاهده شده است که در یک فیلتر در اطراف کانال C3 ماکزیمم ضرایب وجود دارد و در فیلتر دیگر در اطراف C4 مینیمم ضرایب وجود دارد. اما در تمامی افراد دقیقاً در این دو کانال ماکزیمم ضریب از لحاظ قدر مطلق وجود ندارد. این همان چیزی است که در فصل قبل به آن اشاره شد، یعنی در عمل ممکن است کانال‌های مهمتر با کانال‌هایی که از لحاظ تئوری انتظار داریم یکی نباشد و دیگر اینکه، مهمترین کانال‌ها برای جداسازی دو کلاس برای هر شخص با دیگری متفاوت است.

۲-۱-۲-۲- تعمیم CSP به مسئله چند کلاسه

یکی از محدودیت‌های روش CSP این است که این روش برای کلاسه‌بندی مسائل دوکلاسه مطرح شده است. به همین منظور تلاش‌های زیادی برای تعمیم این روش به مسائل چند کلاسه انجام

شده است [۱۳ و ۱۴]. در اکثر روش‌های مطرح شده، یک مسئله چند کلاس به چند مسئله دو کلاس شکسته می‌شود. یکی از این روش‌ها، روش PW^۱ می‌باشد که در این روش، کلاس‌ها به صورت دو به دو بررسی می‌شوند و برای هر کلاس نسبت به کلاس دیگر یک ماتریس W بدست می‌آید. در نتیجه در یک مسئله C کلاس به تعداد $\binom{C}{2}$ کلاس‌بند وجود دارد. داده تست ورودی توسط تمامی کلاس‌بندها دسته‌بندی شده و نهایتاً داده ورودی متعلق به کلاسی است که بیشترین رأی را دارد [۱۳].

در روش DC^۲ به اندازه یکی کمتر از تعداد کلاس‌ها، ماتریس فیلترهای فضایی داریم. مثلاً در یک مسئله‌ی سه کلاس، دو کلاس-بند طراحی می‌شود. یک کلاس‌بند کلاس ۱ را از ترکیب کلاس‌های ۲ و ۳ متمایز می‌کند. برای این منظور ماتریس W₁ طراحی می‌گردد. کلاس‌بند دیگر کلاس ۲ را از کلاس ۳ متمایز می‌کند بطوریکه ماتریس W₂ ویژگی‌های مربوطه را ایجاد می‌کند. داده تست ورودی ابتدا توسط کلاس‌بند اول دسته‌بندی می‌شود. اگر داده در کلاس ۱ قرار گرفت، کلاس آن معلوم می‌شود، اما اگر جزء بقیه کلاس‌ها بود، باید وارد کلاس‌بند دوم شود تا محتملترین کلاس از بین کلاس ۲ و ۳ انتخاب شود [۱۳].

روش کلاس‌بندی یک کلاس نسبت به سایر کلاس‌ها (OVR)^۳، ویژگی‌های استخراج شده از یک کلاس را نسبت به ویژگی‌های بقیه کلاس‌ها مقایسه می‌کند. بنابراین برای حل یک مسئله ۴ کلاس توسط این روش، نیاز به ۴ کلاس‌بند داریم که هر کلاس‌بند ویژگی‌های یک کلاس را نسبت به بقیه کلاس‌ها کلاس‌بندی می‌کند. در نتیجه در رابطه (۲-۱)، ماتریس کواریانس متوسط کلاس دو برابر با جمع ماتریس کواریانس سه کلاس دیگر است [۱۴].

مثلاً در مسئله‌ای که کلاس‌بندی ۴ کلاس تصور حرکتی R₁، R₂، R₃ و R₄ مطرح است، بر اساس روش OVR، هر داده تست ورودی توسط ۴ کلاس‌بند بررسی می‌شود. کلاس‌بند اول احتمال تعلق

¹Pair-Wise

²Divide-and-Conquer

³One Versus the Rest

داده ورودی به کلاس یک یا سایر کلاس‌ها را توسط ماتریس W_1 محاسبه می‌کند. حال اگر فرض کنیم که $\bar{R}_i$ ماتریس کواریانس متوسط کلاس i ام است آنگاه در رابطه (۲-۱) در روش OVR داریم [۱۴]:

$$\bar{C}_1 = \bar{R}_1, \quad \bar{C}_2 = \bar{R}_2 + \bar{R}_3 + \bar{R}_4 \quad (۲-۶)$$

W_2 ماتریسی است که کلاس R_2 را نسبت به بقیه کلاس‌ها جدا می‌کند یعنی:

$$\bar{C}_1 = \bar{R}_2, \quad \bar{C}_2 = \bar{R}_1 + \bar{R}_3 + \bar{R}_4 \quad (۲-۷)$$

در نتیجه کلاسه‌بندی داده تست ورودی در کلاسه‌بند دوم که بر اساس W_2 انجام می‌پذیرد، بیان می‌دارد که این داده در کلاس ۲ است یا عضوی از بقیه کلاس‌هاست. به همین ترتیب کلاسه‌بند سوم و چهارم نیز به ترتیب بر اساس W_3 و W_4 داده ورودی را کلاسه‌بندی می‌کنند.

در نتیجه در روش OVR، هر داده تست ورودی با ۴ کلاسه‌بند روبرو است که هر کلاسه‌بند با یک احتمال این داده را عضو یک کلاس خاص می‌داند یا عضو بقیه کلاس‌ها. در نهایت به کمک یکی از روش‌های تصمیم‌گیری کلاس نهایی داده تعیین می‌گردد. مثلاً این تصمیم‌گیری می‌تواند بر اساس احتمال تعلق داده ورودی به هر کلاس انجام شده و محتملترین کلاس انتخاب شود [۱۵].

همانطور که بیان شد CSP در ابتدا برای مسائل دو کلاسه مطرح شده بود که توسط روش‌هایی مانند OVR، PW و DC به مسائل چند کلاسه تعمیم یافت که در این روش‌ها یک مسئله چند کلاسه به چندین مسئله دو کلاسه شکسته می‌شود. G. Dornhege و همکارانش در [۱۴] روشی به نام JAD^۱ مطرح کردند که در آن در یک مسئله چند کلاسه تمامی کلاس‌ها به طور مستقیم دسته‌بندی می‌شوند. در روش JAD که تعمیمی از روش CSP است فیلترهای فضایی بدست می‌آیند که می‌توانند به طور همزمان ماتریس کواریانس تمام کلاس‌ها را قطری کنند بطوریکه مجموع مقادیر ویژه تمامی کلاس‌ها بعد از نگاشت به فضای جدید برابر با یک شوند. اگر ماتریس کواریانس متوسط کلاس i ام

^۱joint approximate diagonalization

برابر با C_i باشد تحت ماتریس W رابطه (۸-۲) باید برقرار شود [۱۳ و ۱۴]. به دست آوردن ماتریس W مناسب توسط روش‌هایی مانند مرجع [۱۶] انجام می‌شود.

$$W^T C_i W = D_i, \sum_{i=1}^M D_i = I \quad (۸-۲)$$

در روش CSP فیلترهای فضایی مهمتر، بردارهای ویژه متناظر با بزرگترین و کوچکترین مقادیر ویژه در هر کلاس هستند (مقادیر ویژه بزرگتر در یک کلاس متناظر با مقادیر ویژه کوچکتر در کلاس دیگر هستند). در روش JAD برای بدست آوردن فیلترهای فضایی مهمتر، مقادیر ویژه ماتریس کواریانس هر کلاس را بعد از نگاشت (مقادیر روی قطر D_i ها) بر حسب رابطه (۹-۲) رتبه‌بندی کرده و بردارهای ویژه متناظر با آنهایی که بیشترین رتبه را دارند به عنوان فیلتر فضایی انتخاب می‌شوند.

$$\text{score}(\lambda) = \frac{1}{1 + \lambda(M-1)^2 / (1-\lambda)} \quad (۹-۲)$$

مثلاً اگر بخواهیم L فیلتر فضایی مهمتر را به بدست آوریم لازم است تا در یک مسئله M کلاسه، به تعداد $\frac{L}{M}$ از بردارهای ویژه متناظر با مقادیر ویژه با رتبه بیشتر در هر کلاس برداشته شوند. از آنجایی که بردارهای ویژه برای تمامی کلاس‌ها مشترک هستند، هر بردار باید یک بار انتخاب شود.

روش JAD از لحاظ محاسباتی پیچیده‌تر از روش CSP است. نتایج مراجع [۱۳] و [۱۴] نشان می‌دهد که روش JAD نتایج بهتری از روش OVR-CSP در حل مسئله چهار کلاسه نداشته است. C. Guger و همکارانش [۱۷] روش CSP را در کاربردهای بلادرنگ به کار بردند. در این تحقیق برای بازه‌های مختلف زمانی Cross-Validation انجام شده و بهترین قطعه زمانی توسط کلاسه‌بندی LDA انتخاب شد. نتایج گزارش شده نشان می‌دهد که هرچه طول بازه‌های زمانی بیشتر باشد، نتایج کلاسه‌بندی بهتر است، اما سرعت پاسخ‌دهی کاهش می‌یابد.

در روش CSP برای بدست آوردن فیلترهای فضایی، از ماتریس کواریانس سیگنال‌های EEG استفاده می‌نماید و بنابراین نویز و اغتشاشات می‌توانند بر روی نتیجه این روش تأثیرگذار باشند. همچنین این روش یک روش مستقل از زمان بوده و در تخمین ماتریس کواریانس، ساختار زمانی سیگنال‌ها را به طور محلی در نظر نگرفته و هر نقطه زمانی در راستای کانال، به صورت کاملاً مجزا

عضوی از مجموعه نمونه‌های یک کلاس در نظر گرفته شده و تمامی نقاط دور و نزدیک از لحاظ زمانی همسایه می‌باشند، در نتیجه نویز در یک نقطه زمانی بر روی تخمین کواریانس متوسط تأثیر زیادی خواهد داشت.

در مرجع [۱۸] روشی به نام LTCSP^۱ پیشنهاد شده است که می‌توان گفت دو مشکل اشاره شده را تا حدودی برطرف ساخته است. روش ذکر شده در این مقاله تعمیمی از روش CSP است که توسط یک ماتریس همسایگی، ساختار محلی سیگنال‌های زمانی EEG را در تخمین کواریانس در نظر می‌گیرد. در نتیجه می‌توان ادعا نمود که نویز در یک منطقه زمانی، تأثیر کمتری بر روی نتیجه نهایی خواهد داشت.

همانند روش CSP، روش LTCSP نیز روشی ساده است که از لحاظ محاسباتی پیچیدگی ندارد اما می‌توان گفت این روش، از روش CSP پایداری بیشتری در برابر اغتشاش و نویز دارد.

در مقایسه با روش CSP، در روش LTCSP، اختلاف مقدار واریانس سیگنال‌ها در سطرها و ستون‌ها متناسب با پایین ماتریس سیگنال‌های فیلتر شده، بیشتر می‌باشد [۱۸].

چون در روش‌های پیشنهادی از روش LTCSP استفاده شده است، در بخش بعد به توضیح این روش می‌پردازیم.

۲-۲-۱-۳ روش LTCSP

همانطور که بیان شد، CSP روشی است که در یک مسئله دو کلاسه، به دنبال فیلترهایی است که واریانس سیگنال‌های فیلتر شده را برای یک کلاس ماکزیمم و برای کلاس دیگر مینیمم نمایند. بنابراین می‌توان به این روش به عنوان یک مسئله بهینه سازی نگریست که به صورت کسر (۶) بیان می‌شود.

¹Local Temporal Common Spatial Pattern

$$\max \frac{\text{trace}(W^T \bar{C}_1 W)}{\text{trace}(W^T \bar{C}_2 W)} \quad (10-2)$$

در واقع برای ماکزیمم سازی کسر (۱۰-۲)، ماتریس W باید صورت کسر را ماکزیمم و مخرج کسر را مینیمم سازد، البته همانطور که در بخش قبل بیان شد باید شرط $W^T(\bar{C}_1 + \bar{C}_2)W = I$ برقرار شود. این مسئله بهینه سازی، یک مسئله بردار ویژگی است که با حل آن، ماتریس W برابر است با بردارهای ویژگی ماتریس $(\bar{C}_2)^{-1} \bar{C}_1$ [۱۸].

اما می توان از نقطه نظر دیگری به مسئله نگریسته و رابطه (۱۰-۲) را به صورت رابطه (۱۱-۲) گسترش داد [۱۸]:

$$\frac{\frac{1}{T_1} \sum_{i=1}^{T_1} \sum_{j=1}^K (w_j^T X_i X_i^T w_j) / \text{trace}(X_i X_i^T)}{\frac{1}{T_2} \sum_{i=1}^{T_2} \sum_{j=1}^K (w_j^T X_i X_i^T w_j) / \text{trace}(X_i X_i^T)} \quad (11-2)$$

در رابطه (۱۱-۲)، T_1 و T_2 تعداد آزمایشات در هر کلاس بوده و زیرنویس i نشان دهنده i امین آزمایش هر کلاس می باشد. w_j ، ستون j ام ماتریس W است.

با حذف زیرنویس های i و j می توان عبارت $w^T X X^T w$ را در رابطه (۱۱-۲) به شکل رابطه (۱۲-۲) گسترش داد. در حقیقت از این رابطه می توان فهمید که ماتریس کواریانس سیگنال های فیلترشده توسط W ، از جمع مجذور فاصله دوتایی بین نمونه های فیلترشده (یعنی $w^T X_i$ ، $i = 1, 2, \dots, N$) بدست می آید.

$$w^T X X^T w = \frac{1}{2N} \sum_{l=1}^N \sum_{m=1}^N (w^T X_l - w^T X_m)^2 \quad (12-2)$$

در [۱۸]، برای هر نمونه X_l و X_m ضربی با عنوان H_{lm}^X در نظر گرفته شده است که این ضریب نماینده میزان همسایگی زمانی این دو نمونه می باشد و در رابطه (۱۳-۲) آورده شده است.

$$w^T X X^T w = \frac{1}{2N} \sum_{l=1}^N \sum_{m=1}^N (w^T X_l - w^T X_m)^2 H_{lm}^X \quad (13-2)$$

با افزایش فاصله زمانی دو نمونه، باید این ضریب کاهش یابد، بنابراین در مرجع [۱۸]، ماتریس H به صورت رابطه (۲-۱۴) تعریف شده است. بطوریکه تمامی عناصر این ماتریس مقداری بین صفر و یک دارند. در رابطه (۲-۱۴) و در ادامه مقاله، بالانویس X نشان دهنده این است که ماتریس مربوطه باید برای هر آزمایش به طور جداگانه محاسبه شود.

$$H_{lm}^X = \begin{cases} \exp\left(-\|x_l - x_m\|^2 / \sigma\right), & |l-m| < \tau \\ 0, & \text{otherwise} \end{cases} \quad (2-14)$$

ماتریس H یک ماتریس متقارن است که ماتریس همسایگی نامیده می شود. در رابطه (۲-۱۴)، علامت $\|\cdot\|$ اندازه فاصله اقلیدسی دو نمونه x_l و x_m می باشد و همانطور که گفته شد هر نمونه دارای ابعاد $K \times 1$ می باشد. τ محدوده همسایگی زمانی را تعریف می کند، به طوریکه در خارج از محدوده τ ، مقدار همسایگی یعنی H_{lm}^X صفر است.

پارامتر σ به صورت $\sigma = c\sigma_0$ تعریف می شود به طوریکه σ_0 انحراف معیار مجذور اندازه نمونه های دو کلاس در مرحله آموزش می باشد و همانطور که در قسمت های قبل بیان شد، نمونه های هر کلاس بردارهای ستونی ماتریس های داده EEG تمامی آزمایشات آن کلاس در مرحله آموزش می باشند. در حقیقت روش CSP حالت خاصی از روش LTCSP است و این قضیه هنگامی محقق می شود که $\tau = N$ و $c = +\infty$ باشد، در این صورت تمامی عناصر H^X یک می باشند. در این حالت تمامی نمونه ها در همسایگی یکدیگر بوده و میزان این همسایگی برای تمامی نقاط دور و نزدیک زمانی، یکسان است. بنابراین نویز در نمونه های دورتر نیز می تواند سایر نقاط را تحت تأثیر قرار داده و تأثیر زیادی بر محاسبه ماتریس کواریانس سیگنال های فیلتر شده داشته باشد. در صورتی که در روش LTCSP با تعریف این همسایگی ها، این نقص برطرف شده است.

بعد از انجام یکسری محاسبات، ماتریس کواریانس محلی به صورت رابطه (۲-۱۵) به دست می آید.

$$\tilde{C}_i = \frac{1}{T_i} \sum_{j \in T_i} \frac{X_j L^X X_j^T}{\text{trace}(X_j L^X X_j^T)}, \quad i=1,2 \quad (2-15)$$

در رابطه (۱۵-۲) ماتریس $L^X = D^X - H^X$ ، ماتریس لاپلاسیان است که یک ماتریس مثبت معین بوده و می‌تواند به صورت $L^X = L^{X^{1/2}} \times L^{X^{1/2}}$ تجزیه شود. D^X یک ماتریس قطری است که درایه‌های روی قطر آن، جمع سطرهای ماتریس H^X می‌باشند، یعنی $D_{ii}^X = \sum_{m=1}^N H_{im}^X$. همانند روش CSP، روش LTCSP نیز یک مسئله بهینه‌سازی است و هدف از آن یافتن ماتریس W به منظور ماکزیمم‌سازی رابطه (۱۶-۲) می‌باشد.

$$\max \frac{\text{trace}(W^T \tilde{C}_1 W)}{\text{trace}(W^T \tilde{C}_2 W)} \quad (16-2)$$

با انجام محاسباتی که جزئیات بیشتر آن در [۱۸] آورده شده‌است، رابطه (۱۷-۲) بدست می‌آید. در این رابطه $\tilde{U}$ ماتریسی از بردارهای ویژه ماتریس $\tilde{C}_1 + \tilde{C}_2$ و $\tilde{D}$ ماتریسی قطری از مقادیر ویژه متناظر با این بردارها می‌باشد. $\tilde{V}$ ماتریسی از بردارهای ویژه ماتریس $\tilde{D}^{-1/2} \tilde{U}^T \tilde{C}_1 \tilde{U} \tilde{D}^{-1/2}$ است.

$$\tilde{W} = \tilde{U} \tilde{D}^{-1/2} \tilde{V} \quad (17-2)$$

سرانجام سیگنال‌های جدید بعد از فیلتر نمودن سیگنال‌های اولیه ماتریس X ، توسط رابطه (۲-۱۸) به دست می‌آیند.

$$\tilde{Z} = \tilde{W}^T X L^{X^{1/2}} \quad (18-2)$$

در روش LTCSP نیز m سطر بالا و m سطر پایین از $\tilde{Z}$ ، سیگنال‌های مناسب برای کلاسه‌بندی می‌باشند و مانند فرمول (۵-۲) ویژگی‌ها برابرند با:

$$\tilde{f}_p = \log \left(\frac{\text{var}(\tilde{Z}_p)}{\sum_{i=1}^{2m} \text{var}(\tilde{Z}_i)} \right), \quad p=1,2,\dots,2m \quad (19-2)$$

در ادامه به روش‌های ارائه شده در سایر مقالات می‌پردازیم.

D. Coyle و همکارانش در مرجع [۱۹] از دو کانال C3 و C4 برای کلاسه‌بندی دو کلاس تصور حرکتی دست چپ و دست راست استفاده کردند. در این مقاله در مرحله آموزش ۴ شبکه عصبی MLP برای هر دو کلاس و هر دو کانال آموزش دیده است. در مرحله ارزیابی برای هر داده تست سری‌های زمانی پیش‌بینی شده از سیگنال‌های دو کانال C3 و C4 توسط شبکه‌های عصبی آموزش

دیده مربوطه بدست آمده است. یعنی برای کانال C3 دو سری توسط شبکه عصبی آموزش دیده مربوط به دست چپ و دست راست بدست می‌آید. برای کانال C4 هم به همین ترتیب دو سری زمانی پیش بینی می‌شود. نهایتاً ۴ سری زمانی بدست می‌آید که توان آنها به عنوان ویژگی در یک بردار قرار داده می‌شود. برای کلاسه‌بندی ویژگی‌ها از روش LDA استفاده شده است. در این مقاله به جای شبکه عصبی از ضرایب AAR^۱ برای تخمین سری‌های زمانی نیز استفاده شده است. آزمایشات این مقاله نشان می‌دهد که روش MLP نتایج بهتری داشته است.

در مقاله [۲۰] روشی سریع و دقیق برای کلاسه‌بندی دو کلاس تصور حرکت دست راست و چپ پیشنهاد شده است. در این مقاله بر روی تنها یک کانال (C4) یک منحنی درجه ۲ اعمال شده و ضرایب آن به عنوان ویژگی در نظر گرفته شده است. برای کلاسه‌بندی، از روش KNN^۲ استفاده شده است که نسبت به روش SVM و MLP سریعتر و نتایج بهتری دارد.

D. Coyle در [۲۱] روشی به نام EED^۳ مانند CSP مبتنی بر بردارهای ویژه برای استخراج فیلترهای فضایی به کار برده شده و بعد از به دست آوردن کمترین و بیشترین مقادیر ویژه برای ماتریس‌های کواریانس، این فیلترها به دست می‌آیند. بعد از اعمال این فیلترها به سیگنال‌های اصلی، سیگنال‌های منبع استخراج و واریانس آنها به دست می‌آید. کلاسه‌بند مورد استفاده در این مقاله، SVM می‌باشد که بررسی‌های انجام شده در این مقاله نشان می‌دهد که در بعضی مواقع این روش، بهتر از روش CSP ها نتیجه داده است. البته با ترکیب ویژگی‌های این دو روش نیز می‌توان به نتایج خوبی رسید.

در مرجع [۱۵] از ۲۲ کانال برای کلاسه‌بندی چهار کلاس تصور حرکتی استفاده شده است. در این مقاله ۳ نمونه ICA^۴ یعنی Infomax، Fast ICA و SOBI با روش CSP مقایسه شده تا نشان دهد کدام روش برای انتخاب فیلترهای مناسب در کلاسه‌بندی موفق‌تر عمل می‌کند. CSP اولین بار

^۱ Linear Adaptive Autoregressive

^۲ K-Nearest Neighbor

^۳ Extreme Energy Difference

^۴ Independent Components Analysis

برای جداسازی دو کلاس مطرح شده بود که برای تعمیم به ۴ کلاس باید مسئله چهار کلاسه را به چندین مسئله دو کلاسه شکست، اما ICA را می‌توان مستقیماً برای چهار کلاس استفاده کرد. در نتیجه‌گیری این مقاله نشان داده شده است که روش Infomax از دو روش دیگر ICA و از CSP بهتر بوده است. همچنین استفاده از روش PCA^۱ قبل از ICA نتایج Fast ICA را بهبود بخشیده و نتایج Infomax را بدتر نموده است.

۲-۲-۲- استفاده از ویژگی‌های حوزه فرکانس

نتایج CSP خیلی وابسته به فیلترینگ فرکانسی اولیه داده‌ها است و اگر باند فرکانسی مناسب انتخاب نشود نتایج مطلوبی نخواهیم داشت [۱۲]. برای رفع این مشکل S. Lemm و همکارانش [۲۲] روشی به نام CSSP^۲ پیشنهاد داده‌اند و آن هم استفاده از فیلترهای FIR^۳ می‌باشد که به طور انحصاری برای هر فرد بدست می‌آیند. اساس ساخت این فیلترها مبتنی بر یک مقدار ثابت جابه‌جایی زمانی داده‌ها می‌باشد. در این روش فیلترهای فضایی همزمان با فیلترهای فرکانسی بدست می‌آیند. از آنجایی که در تصور حرکتی، بیشتر دو باند فرکانسی میو و بتا مطرح می‌باشد و سایر اغتشاشات مانند سیگنال‌های EOG و EMG در باندهای دیگر اتفاق می‌افتند، بهتر است باندهای فرکانسی محدود شوند. از طرف دیگر از آنجایی که برای افراد مختلف، تمرکز بر روی باندهای فرکانسی متفاوت است، در این روش می‌تون با سعی و خطا و با تغییر دادن یک پارامتر به نام τ ، بهترین فیلتر را برای هر فرد انتخاب کرد. آزمایشات انجام شده در این مقاله نشان می‌دهد که روش CSSP به طور متوسط نتایج بهتری از روش CSP داشته است.

در روش CSSP [۲۲] شکل فیلترها انعطاف پذیر نمی‌باشد. G. Dornhege و همکاران [۲۳] روشی مطرح کردند که در آن فیلتر FIR برای هر شخص به طور منحصر به فرد بدست می‌آید به

^۱ Principle Component Analysis


^۲ Common Spatio-Spectral Pattern

^۳ Finite Impulse Response

صورتی که هر شکلی می‌تواند داشته باشد. استفاده از این روش با نام CSSSP^۱، جواب‌های بهتری از روش‌های CSP و CSSP بدست داده است.

روش CSSSP از لحاظ محاسباتی، پیچیده است اما نتایج خوبی دارد، که برای رفع این مشکل پیچیدگی محاسباتی و برای داشتن درصد‌های بالا مانند این روش، در مقاله [۲۴] از روش ISSPL^۲ استفاده شده است. روش ISSPL مانند روش CSSSP فیلترهای مناسب برای هر فرد را می‌یابد که این فیلترها می‌توانند هر شکلی داشته باشند. این روش که به طور تکرارپذیر مناسب‌ترین فیلتر را انتخاب می‌کند نسبت به CSSSP ساده‌تر است.

Q. Novi و همکارانش [۲۵] یک روش دیگر با نام SBCSP^۳ برای یافتن باندهای فرکانسی مناسب برای هر فرد مورد آزمایش ارائه دادند. در این روش سیگنال تمامی کانال‌ها توسط فیلترهای IIR در باندهای فرکانسی ۴ هرتزی بدون تداخل در فاصله ۴ تا ۴۰ هرتز فیلتر می‌شوند. در مرحله آموزش، CSP در هر زیرباند اجرا شده و توسط روش LDA کلاسه‌بندی در هر زیرباند انجام می‌شود. زیرباندی که بالاترین نتیجه کلاسه‌بندی را دارند به عنوان زیرباندهای بهینه انتخاب شده و در مرحله ارزیابی از آنها استفاده می‌شود. در مرحله ارزیابی باید نتایج کلاسه‌بندی ناشی از تمامی زیرباندها در نظر گرفته شود. در شکل (۲-۲) روند انجام این روش در مرحله ارزیابی مشاهده می‌شود.



شکل (۲-۲): مرحله ارزیابی در روش SBCSP [۲۵]


^۱Common Sparse Spectral Spatial Pattern

^۲Iterative Spatio-Spectral Patterns Learning

^۳Sub-band Common Spatial Pattern

در مقاله [۲۵] روش SBCSP و روش‌های CSSP، CSSSP و روش CSP معمول بر روی یک مجموعه داده آزمایش شده است. نتایج آزمایشات نشان می‌دهد که به طور متوسط سه روش CSSP، CSSSP و SBCSP نتایج بهتری از روش CSP معمول دارند و همچنین به طور متوسط SBCSP از تمامی روش‌ها موفق‌تر عمل کرده است. برای برخی اشخاص مورد آزمایش روش CSP نتایج بهتری از سه روش دیگر داشته است.

در روش SBCSP برای کلاسه‌بندی لازم است تا نتیجه کلاسه‌بندی تمامی زیرباندها در نظر گرفته شود. روش‌های مختلفی برای ترکیب نتایج حاصل از تمامی کلاسه‌بندی‌ها وجود دارد که می‌تواند انتخاب زیرباندهای بهینه را تحت تأثیر قرار دهد. برای رفع این نقص K. K. Ang و همکارانش [۲۶] روشی به نام FBCSP^۱ پیشنهاد دادند. در این روش نیز بعد از فیلتر کردن تمامی کانال‌ها توسط فیلترهای چبی‌شف درجه ۲ با باندهای ۴ هرتزی بین ۸ تا ۴۰ هرتز، CSP در هر زیرباند اجرا شده و ویژگی‌ها در هر زیرباند بدست می‌آیند. از تمامی ویژگی‌های بدست آمده تعدادی ویژگی انتخاب شده و در کلاسه‌بندی استفاده می‌شوند. روند اجرای روش FBCSP در شکل (۲-۳) مشاهده می‌شود. در این مقاله الگوریتم MIBIF^۲، MINBPW^۳، MIFS^۴ چند الگوریتم دیگر به منظور کاهش ویژگی استفاده شده است. روش‌های SVM، NBPW^۵، KNN و چند روش دیگر نیز برای کلاسه‌بندی مورد



شکل (۲-۳): مراحل انجام روش FBCSP [۲۶]

^۱Filter Bank Common Spatial Pattern

^۲Mutual Information based Best Individual Feature

^۳Mutual Information-based Naïve Bayesian ParzenWindow

^۴MutualInformation based feature selection

^۵Naïve Bayesian Parzen Window

استفاده قرار گرفته‌اند. نتایج نشان دادند که ترکیب الگوریتم انتخاب ویژگی MIBIF4 با کلاسه‌بند SVM و NBPW درصد‌های مطلوب‌تری دارند. در همین مقاله روش FBCSP با روش SBCSP مقایسه شد که در اکثر موارد و به طور متوسط، روش FBCSP نتایج بهتری از روش SBCSP و CSP معمول داشته است.

FBCSP نیز روشی دو کلاسه است که Z. Y. Chin و همکارانش [۲۷] از روش‌های تعمیم روش CSP به ۴ کلاس مانند OVR، PW و DC استفاده کرده و روش FBCSP را برای کلاسه‌بندی ۴ کلاس تصور حرکتی دست چپ، دست راست، پا و زبان به کار برده‌اند. در این مقاله از الگوریتم MIBIF4 برای کاهش ویژگی و از روش NBPW برای کلاسه‌بندی استفاده شده است.

در مرجع [۲۸] از تصور حرکت دست چپ و راست برای حرکت کرسر به بالا و پایین استفاده شده است. در این مقاله دوسؤال مطرح است: کدام روش برای کلاسه‌بندی مناسب‌تر است و تعداد ویژگی‌ها چه تأثیری بر عملکرد کلاسه‌بند دارد. در این مقاله از ۱۵ کانال استفاده شده که توان سیگنال‌ها در باندهای ۳ هرتزی بین ۸ تا ۲۷ هرتز به عنوان ویژگی در نظر گرفته می‌شود. در نتیجه ۱۰۵ ویژگی برای هر داده EEG وجود دارد که به روش SFS^۱ [۲۹] مرتب شده و تنها ۳۰ ویژگی اول برای کلاسه‌بندی در نظر گرفته می‌شوند. برای کلاسه‌بندی از روش‌های مختلف آستانه گذاری با توابع خطی و غیر خطی استفاده شده است. در نهایت تمامی روش‌های کلاسه‌بندی بهترین نتیجه خود را در ۲۰-۱۰ ویژگی داشتند و روش‌های یک بعدی خطی از روش‌های دو بعدی خطی و روش‌های یک بعدی غیرخطی بهترند.

یکی از روش‌های کاهش نویز در کانال‌های EEG استفاده از روش لاپلاسیان سطحی^۲ می‌باشد. در این روش سیگنال بدون نویز هر کانال برابر است با سیگنال با نویز منهای متوسط n همسایه نزدیک این کانال، بطوریکه n معمولاً برابر با ۴ یا ۸ است.

^۱Sequential Forward Selection

^۲surface Laplacian

$$V_j^{Lap} = V_j - \frac{1}{n} \sum_{k=1:n} V_k \quad (20-2)$$

در مقاله [۳۰] ابتدا تمامی سیگنال‌ها توسط روش لاپلاسیین سطحی حذف نویز شده و ۹ کانال روی کر تکس حسی-حرکتی را انتخاب شده است. سپس توسط فیلتر باترورث هر کانال به ۱۳ باند فرکانسی تقسیم می‌شود و بعد از تبدیل هیلبرت گرفتن هر باند، پوش آن بدست می‌آید و تمامی پوش‌ها برای ۹ کانال در یک بردار ۱۱۷ تایی قرار داده می‌شود. در کلاسه‌بندی از تابع همبستگی برای دو کلاس استفاده می‌شود. در مقاله [۳۱] نیز از همین روش استفاده شده است.

در مرجع [۳۲] از دو کانال C3 و C4 برای کلاسه‌بندی دو کلاس تصور حرکتی دست چپ و دست راست استفاده شده است. در این مقاله توان باند آلفا و بتا در دو کانال به عنوان ویژگی بکار برده شده است. علاوه بر کلاسه‌بند فازی، سه کلاسه‌بند SVM غیرخطی، MLP و LC^۱ استفاده شده که روش فازی از همه بهتر گزارش شده است.

D. Coyle [۳۳] از روش NTSP^۲ استفاده کرده و سری‌های زمانی پیش بینی شده داده‌ها را بدست آورده است. آنگاه توسط روش CSP تعداد این سری‌های زمانی کاهش داده است. در این مقاله نیز برای تأکید بیشتر بر روی باندهای میو و بتا از فیلترهایی با پهنای باند 8-12Hz ، 8-16Hz ، 8-20Hz و 8-24Hz قبل از کلاسه CSP استفاده شده و نتایج آنها به طور مجزا بررسی شده است. با توجه به نتایج این تحقیق پهنای باند بزرگتر یعنی ۸ تا ۲۴ هرتز نتایج بهتری داشته است. البته این روش نیز تنها بر روی دو کلاس تصور حرکتی دست چپ و راست بحث می‌کند و برای کلاسه بندی از چهار روش LDA، SVM، MDA^۳ و GDBC^۴ استفاده شده که نتایج روش‌های LDA و SVM از بقیه روش‌ها بهتر می‌باشد.

^۱ linear classifier

^۲ neural-time-series-prediction preprocessing

^۳ Mahalanobis distance analysis classifier

^۴ generalized distance based classifier

در مرجع [۳۴] از ضرایب ویولت گسسته برای یافتن ویژگی‌ها استفاده شده است. این مقاله نیز مبتنی بر استفاده از باندهای میو (۸ تا ۱۲ هرتز) و بتا (۱۸ تا ۲۴ هرتز) بوده و متوسط و واریانس ضرایب در این زیرباندها به عنوان ویژگی استفاده شده است. در این مقاله تنها از کانال‌های C3، C4 و Cz برای کلاسه‌بندی دو کلاس تصور حرکتی دست چپ و راست استفاده شده است. کلاسه‌بند مورد استفاده در این تحقیق SVM فازی می‌باشد.

در مقاله [۳۵] تعریف جدیدی از ERD و ERS ارائه شده است. در این مقاله نیز از دو کانال C3 و C4 استفاده شده و بعد از محاسبه FFT بر روی این دو کانال باند فرکانسی ۲ تا ۳۳ هرتز به فاصله‌های ۴ هرتزی تقسیم شده و به جای اندازه در هر نقطه از فاز تبدیل فوریه در این باندهای فرکانسی استفاده شده است. برای کلاسه‌بندی از روش محاسبه ضریب همبستگی برای دو کلاس استفاده شده است. در این روش برای برخی افراد، نتایج بهتری نسبت به استفاده از اندازه در هر نقطه زمانی بدست آمده است.

روش‌های مبتنی بر WPD^۱ که تا سال ۲۰۰۷ وجود دارد، انرژی زیرباندها را به عنوان ویژگی در نظر می‌گیرند. این روش‌ها وفقی^۲ نیستند بنابراین نمی‌توانند بهترین زیر باندها را برای هر شخص انتخاب کنند. این زیر باندها باید بر اساس اطلاعات اولیه نوروفیزیولوژی، انتخاب شوند. هدف از مقاله [۳۶] یافتن بهترین زیر باندها برای هر فرد از طریق محاسباتی ساده و تکرارپذیر می‌باشد. بعد از انتخاب زیر باندها، توان آنها به عنوان ویژگی در نظر گرفته می‌شود. کلاسه‌بند مورد استفاده در این تحقیق، PNN^۳ می‌باشد. لازم به ذکر است که این روش تنها برای یک کانال بهترین زیرباندها را انتخاب می‌کند. بهترین کانال برای جداسازی کلاس‌ها با دیدن نتایج کلاسه‌بندی توسط زیرباندهای انتخابی هر کانال انتخاب می‌شود.

^۱Wavelet Packet Decomposition

^۲Adaptive

^۳Probabilistic Neural Network

در مرجع [۳۷] کلاسه‌بندی ۴ کلاس تصور حرکت دست چپ و دست راست و پا و زبان بررسی شده است. در این مقاله توان ۱۰ باند فرکانسی ۴ هرتزی بین ۰ تا ۴۰ هرتز از ۱۴ کانال به عنوان ویژگی استفاده شده است. برای کاهش ویژگی از روش فاصله bhattacharyya [۳۸] استفاده و سپس از بین این ویژگی‌های انتخابی ۱۰ ویژگی مناسب براس جداسازی دو کلاس با استفاده از الگوریتم ژنتیک انتخاب شده است. در این مقاله برای کلاسه‌بندی ویژگی‌ها از روش SVM استفاده شده که درصدهای کلاسه‌بندی زیر ۵۰ بوده است.

۲-۲-۳- استفاده از تلفیق ویژگی‌های حوزه زمان و فرکانس

S. Lemm و همکارانش در [۳۹] برای کلاسه‌بندی دو کلاس تصور حرکتی دست چپ و راست از حوزه زمان- فرکانس استفاده کردند. آنها برای این منظور از دو کانال C3 و C4 استفاده نموده و توسط موجک پیوسته با تابع مادر مارلت توزیع زمان-فرکانس این دو کانال را به دست آوردند. ویژگی‌ها در هر نمونه زمانی برابر با توان باندهای میو و بتا در توزیع بدست آمده برای هر دو کانال می‌باشند. در نتیجه برای هر نمونه زمانی چهار ویژگی بدست آمده است. برای کلاسه‌بندی از کل زمان تصور حرکتی استفاده شده و هر نمونه زمانی به طور جدا کلاسه‌بندی شده است. در مرحله آموزش برای هر نمونه زمانی در هر کلاس، مدل گوسی ۴ بعدی بدست آمده و در مرحله تست هر نقطه زمانی توسط مدل گوسی مربوط به آن نقطه زمانی دسته‌بندی شده و دارای یک احتمال در هر کلاس می‌باشد. نهایتاً تلفیقی از احتمالات تمامی نقاط زمانی در هر کلاس، احتمال کل بازه زمانی برای تعلق به دو کلاس بدست می‌آید که هر کدام بیشتر بود این داده تست مربوط به همان کلاس است.

در مقاله [۴۰] ویژگی‌های سیگنال توسط تخمین انرژی در حوزه‌های فرکانس، $t-f$ ^۱ و $t-s$ ^۲ بدست آمده است. در این مقاله از روش‌های چگالی طیف توان^۳ (PSD)، تجزیه اتمی^۴ مانند روش تبدیل

^۱ time-frequency domain

^۲ time-scale domain

^۳ power spectral density (PSD) techniques

^۴ atomic decompositions

فوریه زمان کوتاه^۱، توزیع‌های انرژی در حوزه زمان-فرکانس^۲ مانند توزیع‌های Wigner Ville، RID، Born-Jordan، Choi-Williams و Zhao-Atlas-Marks و همچنین از تبدیل موجک گسسته و پیوسته برای به دست آوردن انرژی باندهای فرکانسی میو (8-12Hz) و (18-25Hz) در دو کانال C3 و C4 برای کلاسه‌بندی دو کلاس تصور حرکتی دست چپ و راست استفاده شده است. در این مقاله روش‌های LDA و SVM خطی و غیرخطی برای کلاسه‌بندی به کار برده شده و نتایج نشان می‌دهد استفاده از روش PSD در تمامی انواع کلاسه‌بندها، از بقیه روش‌ها موفق‌تر بوده است.

همانطور که گفته شد روش CSP خیلی وابسته به بازه زمان و فرکانس انتخاب شده دارد. در [۴۱] همزمان با یافتن فیلترهای فضایی، فیلترهای فرکانس و فیلترهای زمان نیز بدست می‌آیند. در حقیقت فرکانس‌هایی که در کانال‌های مهمتر برای جداسازی مفید هستند و زمان وقوع آنها مشخص می‌شود. در این روش نیازی به اطلاعات اولیه نوروفیزیولوژی مغز نمی‌باشد. در این مقاله از روش مبتنی بر تنسور^۳ درجه ۳ [۴۲] استفاده شده است که برای این منظور توزیعی سه بعدی از زمان-فرکانس-کانال را با استفاده از تبدیل موجک کانال‌ها به دست آورده و سپس توسط یک الگوریتم تکرارپذیر، فیلترهای فضایی، فرکانسی و زمانی یافته می‌شود. این روش در این مقاله برای کلاسه‌بندی دو کلاس تصور حرکت دست چپ و راست مطرح شده که نتایج این روش نسبت به روش CSP بهتر می‌باشد.

مقاله [۴۳] نیز یک مسئله دو کلاسه برای تصور حرکت دست چپ و راست می‌باشد. در این مقاله ابتدا به روش ANFIS^۴ سری زمانی پیش بینی شده از سیگنال EEG بدست آمده و بعد از آن توزیع زمان-فرکانس سیگنال اصلی و سری پیش‌بینی شده توسط تبدیل موجک پیوسته به دست آمده است. سپس ویژگی‌های فضای فرکتال از تبدیل موجک داده‌های اصلی و پیش‌بینی شده از هم

¹ short time fourier transform(STFT)

² time-frequency(t-f) energy distributions

³ Tensor

⁴ Adaptive Neuro-Fuzzy Inference System

کم شده و به عنوان ویژگی‌های اصلی بکار برده شده‌اند. کلاسه‌بند مورد استفاده در این مقاله LDA می‌باشد که نتایج خوبی داشته است.

در مقاله [۴۴] از ترکیبی از ویژگی‌های حوزه زمان و فرکانس توأم با هم استفاده شده است. در این تحقیق برای کلاسه‌بندی دو کلاس تصور حرکت دست چپ و راست از دو کانال C3 و C4 استفاده شده است. روش پیشنهادی در این مقاله به این صورت است که ابتدا cumulant درجه ۳، که به صورت $C_{3x} = E[x(k)x(k+m)x(k+n)]$ برای سیگنال x تعریف می‌شود، از سیگنال این دو کانال به دست آمده و سپس بر روی سری بدست آمده تبدیل فوریه درجه دو^۱ اعمال می‌شود. در این مقاله، ترکیبی از ویژگی‌های حوزه زمان و حوزه فرکانس به عنوان ویژگی در نظر گرفته شده‌اند که عبارتند از: ۴ ضریب از ضرایب AR سیگنال، ۴ ویژگی مربوط به PSD سیگنال و ۴ ویژگی آماری از bispectrum به دست آمده. در نتیجه، نهایتاً از دو کانال مورد استفاده ۲۴ ویژگی به دست آمده است. روش NMF^۲ یک روش مفید برای خوشه‌بندی^۳ داده‌ها بوده و در زمینه تشخیص الگو در داده‌های مثبتی مانند تصویر و توزیع STFT^۴ به کار برده می‌شود [۴۵ و ۴۶]. همانطور که گفته شد ERD/ERS ها ممکن است برای هر شخص در باندهای فرکانسی متفاوتی رخ دهند که پیش بینی آنها ممکن نیست [۶]. روش NMF یک روش مفید در یافتن بردارهای پایه در حوزه فرکانس در زمینه BCI می‌باشد [۴۷ و ۴۸]. در واقع این روش، ماتریس داده X را که تمامی داده‌های آن مثبت هستند به دو ماتریس U و V تجزیه می‌کند بطوریکه $X=UV^T$ ، $U \geq 0$ و $V \geq 0$.

Hyekyoung Lee و همکارانش [۴۹] روشی به نام KNMF^۵ پیشنهاد دادند. در تحقیق آنها ابتدا توسط ویولت پیوسته، نمایش زمان-فرکانس تمامی کانال‌ها به دست آمده و با کنار هم قرار دادن این توزیع‌ها ماتریس X ساخته شده است. سپس این ماتریس به دو ماتریس U و V تجزیه می‌شود که ستون‌های ماتریس V بردارهای پایه‌ای هستند که مشخصات طیفی را برمی‌گردانند و سطرهای

¹ bispectrum

² Nonnegative Matrix Factorization

³ Clustering

⁴ Short Time Fourier Transform

⁵ Kernel Nonnegative Matrix Factorization

ماتریس U ویژگی‌های مورد استفاده می‌باشند. در این مقاله روش KNMF و NMF برای کلاسه‌بندی دو کلاس تصور حرکتی دست چپ و راست مقایسه شده‌اند که نتایج KNMF بهتر است.

در واقع در روش‌های مبتنی بر NMF تعداد ویژگی‌ها که به تعداد کانال در فرکانس می‌باشد، به تعداد بردارهای پایه یعنی r کاهش می‌یابد. بعد از یافتن مقادیر U در داده‌های تست، هر نقطه زمانی باید کلاسه‌بندی شده و نهایتاً بر اساس نتایج تمامی نقاط تصمیم‌گیری انجام شود. در اکثر مقالات مبتنی بر NMF از روش Gaussian probabilistic model-based [۳۹] استفاده می‌شود.

در مرجع [۴۹] نیز نیازی به اطلاعات اولیه راجع به باندهای فرکانسی مرتبط با تصور حرکتی و کانال‌های لازم برای شناسایی کلاس‌ها نمی‌باشد. در این تحقیق سیگنال‌ها را توسط local cosin packet به سگمنت‌های زمانی تقسیم نموده و سپس زیر باندهای فرکانسی لازم برای کلاسه‌بندی را توسط الگوریتم‌های خوشه‌بندی یافته‌اند. سرانجام این ویژگی‌ها توسط روش discriminant power مرتب شده و به منظور کاهش ابعاد k تای اول آنها برداشته می‌شود و سپس از روش SVM برای کلاسه‌بندی استفاده می‌شود.

در مقاله [۵۱] از دو کانال C3 و C4 برای کلاسه‌بندی دو کلاس تصور حرکت دست راست و چپ استفاده شده است. در این تحقیق ابتدا توسط روش NTSP^۱ سری زمانی پیش بینی شده را برای سیگنال‌های EEG به دست آمده از این دو کانال به دست آورده و سپس ویژگی‌های زمانی، فرکانسی و زمان-فرکانس از این سری‌ها بدست آمده است. مثلاً برای به دست آوردن ویژگی‌های حوزه زمان از متوسط مجذور تفاضل سری به دست آمده از مقادیر اصلی سیگنال‌ها استفاده شده است. برای به دست آوردن ویژگی‌های حوزه فرکانس از تبدیل فوریه بر روی این سری‌ها و برای به دست آوردن ویژگی‌های حوزه زمان-فرکانس از تبدیل فوریه زمان کوتاه (STFT) بر روی سری‌های به دست آمده استفاده شده است. در انتها نیز از روش LDA برای کلاسه‌بندی ویژگی‌های به دست آمده، استفاده شده است.

^۱ Neural-time-series-predictionprocessing

فصل سوم

پایگاه داده و روش‌های انجام شده بر روی این داده‌ها

فصل سوم

پایگاه داده و روش‌های انجام شده بر روی این داده‌ها

در این فصل ابتدا مختصری راجع به پایگاه داده مورد استفاده آورده شده و سپس روش‌های انجام گرفته بر روی این مجموعه داده بررسی شده است. بعد از آن عملیات پیش پردازش داده‌ها و کلاسه‌بند مورد استفاده در روش‌های پیشنهادی فصول بعد توضیح داده خواهند شد. در انتهای فصل نتایج روش CSP متداول بر روی این پایگاه داده ارائه خواهد شد.


۳-۱- پایگاه داده

در این تحقیق آزمایشات انجام شده بر روی پایگاه داده 2a از مسابقه چهارم^۱ BCI که در سال ۲۰۰۸ برگزار شده، صورت گرفته است. این مجموعه داده توسط دانشگاه Graz بدست آمده و توضیحات کامل آن از مرجع [۹] قابل دسترسی می‌باشد. در این قسمت به طور مختصر توضیحاتی راجع به این پایگاه داده آورده شده است.


^۱BCI competition IV

این مجموعه داده شامل داده‌های EEG مربوط به ۴ تصور حرکتی دست چپ، دست راست، هردو پا و زبان، مربوط به نه شخص می‌باشد. سیگنال‌های EEG در این مجموعه داده، شامل ۲۲ کانال می‌باشند که با فرکانس ۲۵۰ هرتز نمونه‌برداری شده‌اند. برای هر شخص، داده‌ها در دو مجموعه آموزش و تست دسته‌بندی شده‌اند که هر مجموعه شامل ۲۸۸ آزمایش (۷۲ آزمایش از هر کلاس) است. در واقع هر آزمایش شامل ۲۵ کانال است که سه کانال آن مربوط به سیگنال‌های حرکت چشم (EOG) می‌باشد. مکان الکترودهای ۲۲ کانال EEG و مکان الکترودهای EOG در شکل (۱-۳) مشاهده می‌شوند.

با بررسی سیگنال‌های مربوط به کانال‌های EOG در آزمایشگاه، اگر در حین اجرای یک آزمایش شخص چشم خود را حرکت داده باشد، نسبت به حالت بدون حرکت، تغییراتی در این سیگنال‌ها اتفاق می‌افتد که توسط متخصص آن آزمایش به عنوان یک آزمایش با آرتیفکت در مشخصات این مجموعه داده، معین می‌گردد و در حین اجرای روش‌های تشخیص الگو می‌تواند کنار گذاشته شود. در این پایان‌نامه نیز آزمایشات با آرتیفکت کنار گذاشته شده‌اند.




(ب)




(الف)

شکل (۱=۳): (الف) مکان الکترودهای کانال‌های EOG [۹] (ب) مکان الکترودهای EEG در پایگاه داده 2a از مسابقه ۲۰۰۸ [۳۳]

در هر آزمایش، شخص در مقابل یک مانیتور نشسته و بعد از شنیدن یک صدای هشداردهنده، یک علامت + بر روی مانیتور نمایش داده می‌شود و بعد از دو ثانیه این علامت محو شده و یک نشانه دیگر که به سمت بالا، پایین، چپ یا راست است، نشان داده می‌شود که به ترتیب نماینده تصور حرکت دست چپ، دست راست، دو پا و زبان می‌باشند. در ثانیه سوم از شخص خواسته می‌شود تا تصور حرکتی مربوطه را انجام دهد که این تصور تا ثانیه ۶ ادامه خواهد داشت. روند اجرای هر آزمایش در شکل‌های (۳-۲) داده شده است. نمونه‌ای از آزمایشات مربوط به تصور حرکتی دست چپ شخص ۱ در شکل (۳-۳) آورده شده است.



شکل (۳-۲): روند اجرای آزمایشات در مجموعه داده 2a از مسابقه ۲۰۰۸ در زمینه BCI [۹]



شکل (۳-۳): داده‌های EEG مربوط به یک آزمایش از تصور حرکتی دست چپ شخص ۱

۳-۲- معیار ارزیابی

از آنجایی که در این تحقیق داده‌های مسابقه ۲۰۰۸ در زمینه BCI به کار برده شده است و در این مسابقه برای انتخاب بهترین روش از معیاری به نام کاپا^۱ استفاده شده است، ما نیز برای مقایسه نتایج عملکرد روش‌های پیشنهادی خود با برنده مسابقه، نتایج خود را بر حسب این معیار بیان نمودیم.

در حقیقت معیار کاپا سازگاری بین نتایج به دست آمده از کلاسه‌بندی و نتایج واقعی را اندازه می‌گیرد و به صورت زیر تعریف می‌شود [۵۲]:

$$\kappa = \frac{p_0 - p_e}{1 - p_e} \quad (۱-۳)$$

p_0 و p_e از روی ماتریس پراکندگی^۲ بدست می‌آیند. ماتریس پراکندگی، در یک مسئله با M کلاس، دارای ابعاد $M \times M$ است بطوریکه عنصر n_{ij} تعداد آزمایشاتی از کلاس i ام است که در کلاس j ام دسته‌بندی شده‌اند. $n_{i:}$ و $n_{:i}$ به ترتیب بردارهای سطر و ستون i ام از این ماتریس است و تعداد کل آزمایشات برابر است با $N = \sum_{i=1}^M \sum_{j=1}^M n_{ij}$. p_0 سازگاری کلی^۳ نامیده می‌شود که همان معیار درستی^۴ است و p_e احتمال سازگاری^۵ است. این دو پارامتر به صورت روابط (۲-۳) و (۳-۳) تعریف می‌شوند:

$$p_0 = \frac{\sum_{i=1}^4 n_{ii}}{N} \quad (۲-۳)$$

$$p_e = \frac{\sum_{i=1}^4 n_{:i} n_{i:}}{N^2} \quad (۳-۳)$$

اگر تمام آزمایشات به درستی کلاسه‌بندی شوند، کاپا برابر با یک می‌شود، بنابراین هر چه مقدار آن به یک نزدیکتر باشد، کلاسه‌بند عملکرد بهتری دارد.

^۱ Kappa

^۲ Confusion Matrix

^۳ Overall agreement

^۴ Accuracy

^۵ Chance agreement

۳-۳- روش و نتایج دو گروه برتر مسابقه

این مسابقه دارای ۵ شرکت کننده در قسمت مربوط به این مجموعه داده بوده است. مسابقه از این قرار بوده که مجموعه داده های آموزشی و تست برای هر ۹ شخص بر روی سایت مذکور قرار گرفته اما تنها برچسب کلاس های داده های آموزشی در دسترس بوده است. هر شرکت کننده می بایست روش خود را بر روی این مجموعه داده اعمال نموده و برچسب داده های تست را به همراه کد برنامه نویسی خود ارسال نماید. بهترین نتیجه برای این ۹ مورد آزمایشی، به طور متوسط، به عنوان برنده مسابقه اعلام شده و برچسب صحیح داده های تست بعد از اعلام نتایج بر روی سایت قرار گرفته است.

نتایج قرار گرفته بر روی سایت نشان می دهد که معیار کاپا برای گروه اول و دوم بالای ۰/۵ و برای گروه های بعد حدود ۰/۳ است. در این قسمت مختصری از روش مورد استفاده دو گروه برتر آورده شده است که نتایج آنها در جدول (۳-۱) مشاهده می شود.

۳-۳-۱- گروه برتر مسابقه

این گروه الگوریتمی پیشنهاد دادند که مشتمل بر سه بخش پیش پردازش، استخراج ویژگی و کلاسه بندی داده ها می باشد. مختصری از هر بخش به شرح زیر است:

جدول (۳-۱): ضریب کاپا بدست آمده توسط نفرات برتر مجموعه داده 2a از مسابقه چهارم BCI [۹]

ضریب کاپا برای اشخاص مورد آزمایش									
متوسط	۹	۸	۷	۶	۵	۴	۳	۲	۱
نفر اول	۰/۵۷	۰/۶۱	۰/۷۵	۰/۷۷	۰/۲۷	۰/۴۰	۰/۴۸	۰/۷۵	۰/۴۲
نفر دوم	۰/۵۲	۰/۶۹	۰/۷۳	۰/۶۶	۰/۲۱	۰/۱۶	۰/۴۴	۰/۷۱	۰/۳۴

- **پیش پردازش:** حذف آرتیفک‌ها توسط فیلتر کردن با استفاده از فیلتر میان‌گذر با باند عبور صفر تا ۴۰ هرتز و جداکردن بازه زمانی ۲ ثانیه، از نیم ثانیه قبل از تصور حرکتی تا ۱/۵ ثانیه بعد از آن.
- **استخراج ویژگی:** برای بدست آوردن ویژگی‌ها از روش FBCSP [۲۶] با استفاده از تکنیک OVR استفاده شده است (جزئیات بیشتر این روش در فصل دوم آورده شد). برای کاهش ویژگی در هر کلاسه‌بند روش OVR، روش MIMIF4 بکار رفته است.
- **کلاسه‌بندی:** تمامی کلاسه‌بندهای مورد استفاده در روش OVR از نوع NBPW بوده و برچسب نهایی توسط ماکزیمم احتمالی که از چهار کلاسه‌بند بدست می‌آید، انتخاب می‌شود.

۳-۳-۲- گروه دوم مسابقه

روش ارائه شده توسط نفر دوم مسابقه شامل موارد زیر بوده است:

- **پیش پردازش:** حذف آرتیفک‌ها توسط فیلتر کردن با استفاده از فیلتر میان‌گذر با باند عبور ۸ تا ۳۰ هرتز و جداکردن بازه زمانی ۳ ثانیه از ابتدا تا انتهای بازه تصور حرکتی.
- **استخراج ویژگی:** برای بدست آوردن ویژگی‌ها CSP به روش PW اجرا شده است که در نتیجه آن ۶ ماتریس فیلترهای فضایی به وجود می‌آید. برای هر داده از سیگنال‌های EEG، ۸ ویژگی مهمتر ناشی از تمامی ۶ ماتریس W حاصله بدست آمده و در یک بردار قرار داده می‌شود. بنابراین بردارهای ویژگی با ابعاد $6 \times 8 = 48$ بدست می‌آید. ابعاد ویژگی‌ها توسط روش LDA به ۳ کاهش داده می‌شود.
- **کلاسه‌بندی:** این گروه از کلاسه‌بند بیزین برای کلاسه‌بندی بردارهای ویژگی با ابعاد ۳ بین ۴ کلاس استفاده کرده‌اند.

۳-۳-۳- بعد از سال ۲۰۰۸

بعد از اعلام نتایج مسابقه در سال ۲۰۰۸ نیز تحقیقاتی در این زمینه بر روی این مجموعه داده انجام گرفته است که مهمترین آنها، مقاله [۵۳] می باشد.

همانطور که در فصل دو بیان شد، JAD [۱۴] تعمیمی از روش CSP به مسائل چند کلاسه است که بدون شکستن مسئله به مسائل دو کلاسه، مستقیماً تمامی کلاس‌ها را دسته‌بندی می‌کند. C. Gouy-Pailler و همکارانش در مرجع [۵۳] بیان داشتند که انرژی باندهای فرکانسی در تمام بازه تصور حرکتی ثابت نبوده و با زمان تغییر می‌کند. در حقیقت انرژی یک باند در طول زمان فعال و غیر فعال^۱ می‌شود. آنها به منظور در نظر گرفتن توالی زمانی داده‌های EEG از بازه‌بندی زمانی در روش JAD استفاده کرده و آن روش را MSJAD^۲ نامیدند. آنها در این مقاله بازه زمانی ۴ ثانیه از شروع تصور حرکتی تا یک ثانیه بعد از آن را در نظر گرفته و به پنجره‌های یک ثانیه‌ای بدون تداخل تقسیم کردند. آنگاه روش JAD را در کل این پنجره‌های زمانی و برای تمام کلاس‌ها اجرا کردند. آنها توسط روش ارائه شده در مرجع [۵۴] ماتریس W ای یافتند که بتواند به طور همزمان ماتریس کواریانس تمامی کلاس‌ها را در تمامی پنجره‌های زمانی قطری سازد به طوریکه مجموع مقادیر ویژه تمامی آنها یک شود (رابطه (۳-۴)). در این رابطه J تعداد پنجره‌ها و M تعداد کلاس‌ها است.

$$W^T C_{ij} W = D_{ij} \quad , i=1, \dots, M, j=1, 2, \dots, J \quad (4-3)$$
$$\sum_{i=1}^M \sum_{j=1}^J D_{ij} = I$$

در روش MSJAD نیز مانند روش JAD طبق رابطه (۲-۹) L فیلتر مهمتر در ۴ کلاس برگزیده می‌شوند که توضیحات بیشتر در فصل دوم آورده شد. در این مقاله L=8 در نظر گرفته شده است. بعد از فیلتر کردن داده‌های EEG برای بدست آوردن ویژگی‌ها در این مقاله توان باندهای فرکانسی دو هرتزی در فاصله ۵ تا ۳۵ هرتز بدون تداخل محاسبه می‌شود که در کل ۱۲۰ ویژگی به دست می‌آید که توسط روش logistic regression [۵۵] به یکی از ۴ کلاس دسته‌بندی می‌شود.

^۱ activations/deactivations
^۲ Multisegment JAD

در این مقاله برای مقایسه روش MSJAD با روش CSP و JAD، در این دو روش نیز بعد از فیلترکردن داده‌های EEG از بازه‌بندی زمانی در سیگنال‌های فیلتر شده استفاده کردند. در روش CSP که توسط الگوریتم OVR به ۴ کلاس تعمیم یافته است، دو فیلتر مهمتر از هر ۴ کلاسه‌بند روش OVR انتخاب شده و در یک ماتریس قرار داده شد که در نتیجه ۸ فیلتر فضایی به دست می‌آید.

بعد از فیلتر کردن داده‌های EEG توسط این ۸ فیلتر، سیگنال‌های EEG در ۳ ثانیه تصور حرکتی به ۵ پنجره زمانی ۱ ثانیه‌ای با تداخل ۸۰٪ تقسیم شده و توان باندهای دو هرتزی در تمامی پنجره‌ها محاسبه می‌شود. در نتیجه در هر پنجره ۱۲۰ ویژگی و در کل ۱۲۰۰ ویژگی برای هر داده EEG بدست می‌آید. در روش JAD نیز به همین ترتیب ویژگی‌ها را بدست آورده و به روش logistic regression کلاسه‌بندی می‌شوند. در جدول (۲-۳) نتایج هر سه روش و نفرات برتر مسابقه بر حسب کاپا آورده شده و ماکزیمم مقدار در هر ۴ روش برای هر شخص به صورت پررنگ‌تر مشخص شده است. همانطور که مشاهده می‌شود روش پیشنهادی مرجع [۵۳] به طور متوسط نتایج بهتری از روش دو نفر برتر مسابقه ندارد اما در برخی موارد روش MSJAD نتایج بهتری از نفرات برتر داشته است. همچنین به طور متوسط روش MSJAD نتایج را نسبت به روش CSP خیلی بهبود نمی‌بخشد.

جدول (۲-۳): نتایج روش پیشنهاد شده در مرجع [۵۳] و مقایسه با نتایج برتر مسابقه

ضریب کاپا برای اشخاص مورد آزمایش									
متوسط	۹	۸	۷	۶	۵	۴	۳	۲	۱
CSP	.۱۶۵	.۱۴۰	.۱۷۵	.۱۵۰	.۱۴۴	.۱۱۹	.۱۲۵	.۱۷۲	.۱۵۰
JAD	.۱۵۲	.۱۳۹	.۱۶۷	.۱۵۰	.۱۴۹	.۱۱۸	.۱۲۶	.۱۵۷	.۱۴۰
MSJAD	.۱۶۶	.۱۴۲	.۱۷۷	.۱۵۱	.۱۵۰	.۱۲۱	.۱۳۰	.۱۶۹	.۱۴۶
نفر اول	.۱۶۸	.۱۴۲	.۱۷۵	.۱۴۸	.۱۴۰	.۱۲۷	.۱۷۷	.۱۷۵	.۱۶۱
نفر دوم	.۱۶۹	.۱۳۴	.۱۷۱	.۱۴۴	.۱۱۶	.۱۲۱	.۱۶۶	.۱۷۳	.۱۶۹

در بخش بعد پردازش اولیه بر روی داده‌ها توضیح داده خواهد شد. عملیات پیش پردازش در تمامی روش‌های پیشنهادی فصول بعد اجرا خواهد شد.

۳-۴- پردازش اولیه داده‌ها

قبل از اجرای روش‌های انجام شده در این فصل نرخ نمونه‌برداری سیگنال‌های EEG هرکانال به ۱۰۰ هرتز کاهش داده شده است. سپس این سیگنال‌ها توسط یک فیلتر میانگذر FIR پیش‌رونده/عقب‌رونده با فاز صفر^۱ و با باند عبور ۸ تا ۳۰ هرتز، فیلتر می‌شوند [۱۲]. باند فرکانسی مذکور با این هدف انتخاب شده است که اولاً شامل باندهای فرکانسی امواج میو (۱۲ - ۸ هرتز) و بتا (۳۰ - ۱۳ هرتز) می‌باشد، چراکه این امواج برای کلاسه‌بندی داده‌های تصور حرکتی مناسب می‌باشند [۱، ۶ و ۵۶]، ثانیاً از آنجایی که فرکانس آرتیفکتهایی مانند سیگنال‌های الکتریکی حرکت چشم (EOG) و سیگنال‌های الکتریکی ناشی از حرکت ماهیچه‌های صورت (EMG) خارج از این محدوده است، این آرتیفکته‌ها توسط این فیلتر حذف خواهد شد. فعالیت‌های EOG در فرکانس‌های زیر ۴ هرتز و فعالیت‌های EMG در فرکانس‌های بالای ۳۰ هرتز اتفاق می‌افتند [۵۷].

در اکثر مقالات مربوط به BCI از این بازه‌ی فرکانسی برای فیلتر کردن سیگنال استفاده شده است. در مرجع [۱۲] سیگنال‌های EEG از فیلترهایی در بازه‌های مختلف فرکانسی عبور داده می‌شوند. فیلتر نمودن در باند عبور ۸ تا ۳۰ هرتز بهترین کارایی را بدنبال داشته است.

به دلیل اینکه ERD/ERS قبل و یا در طول تصور حرکتی رخ دهد [۶]، فاصله زمانی ۰/۵ ثانیه قبل از شروع تصور تا ۲/۵ ثانیه بعد از آن، یعنی در مجموع ۳ ثانیه از لحظه ۲/۵ تا ۵/۵ ثانیه برای استخراج ویژگی مورد مطالعه قرار گرفته است. نفر اول مسابقه نیز از ۰/۵ ثانیه قبل از تصور حرکتی تا ۱/۵ ثانیه بعد از آن استفاده کرده است که البته چون در این پایان‌نامه نرخ نمونه‌برداری داده‌ها کاهش داده شده است ما طول بازه زمانی را به ۳ ثانیه افزایش داده‌ایم.

^۱ Zero-phase forward/backward FIR filter

۳-۵- کلاسه‌بند مورد استفاده در روش‌های پیشنهادی

همانطور که در فصل دوم بیان شد، به طور کلی می‌توان گفت اگر داده‌های آموزشی کم باشند، روش‌های ساده با پارامترهای کم می‌توانند استفاده شوند. همچنین در داده‌های نایستایی مانند داده‌های EEG، کلاسه‌بندهای پایداری مانند LDA و SVM می‌توانند نتایج خوبی داشته باشند. در داده‌های با نسبت سیگنال به نویز ضعیف که شامل نویز و اغتشاشات می‌باشند، کلاسه‌بندهای جداکننده که یک مرز جدایی برای دو کلاس رسم می‌کنند می‌توانند عملکرد خوبی داشته باشند و در بیشتر موارد کرنل خطی بهتراست. SVM برای ویژگی‌های با ابعاد زیاد می‌تواند بسیار خوب عمل کند، اما زمان بیشتری برای آموزش می‌خواهد و کمی پیچیده‌تر است [۸]. شاید به همین دلایل است که در تحقیقات BCI، از روش‌های LDA و SVM مخصوصاً از نوع خطی آنها بیشتر استفاده می‌شود.

در این تحقیق، از روش OVR برای تعمیم روش CSP به چهار کلاس استفاده شده است. در الگوریتم OVR در مسئله ۴ کلاسه، ۴ کلاسه‌بند وجود دارد که هر کدام یکی از کلاها را نسبت به بقیه کلاس‌ها کلاسه‌بندی می‌کند. در مرحله ارزیابی هر داده تست با ۴ کلاسه‌بند روبروست و در نهایت ۴ نتیجه کلاسه‌بندی بدست می‌آید که باید بر حسب آنها کلاس نهایی را انتخاب کرد. در مرجع [۱۵] در تمامی کلاسه‌بندهای روش OVR از روش LDA استفاده شده است. خروجی هر کدام از کلاسه‌بندها احتمالی است که به یکی از کلاس‌ها یا به بقیه داده می‌شود. نهایتاً کلاسی که ماکزیمم احتمال را داشت، به عنوان برچسب داده تست ورودی در نظر گرفته می‌شود.

در این پایان‌نامه برای تعمیم روش‌های پیشنهادی به چهار کلاس از روش OVR استفاده کرده‌ایم. ما نیز مانند مرجع [۱۵] بر حسب ماکزیمم احتمال کلاس‌ها برچسب نهایی را انتخاب کردیم. بنابراین و بنابر آنچه در بند یک این بخش آورده شد، از روش LDA با کرنل خطی برای کلاسه‌بندی داده‌ها در فصل چهارم استفاده نموده‌ایم.

۳-۶- اجرای روش CSP متداول بر روی پایگاه داده

روش CSP [۱۲] از موفق‌ترین روش‌ها در زمینه BCI مبتنی بر تصور حرکتی می‌باشد [۸] و روش‌های زیادی برای بهبود آن گزارش شده‌اند [۱۸ و ۲۶-۲۲].

با مشاهده روش‌های اجرا شده در تمامی مسابقات BCI [۹] متوجه می‌شویم که اکثر روش‌های مطرح شده توسط شرکت‌کنندگان مسابقات از روش‌های مبتنی بر روش CSP برای جداسازی داده‌های EEG ناشی از تصور حرکتی استفاده کرده‌اند [۸].

ما در این پایان‌نامه در دو فصل بعد سه روش را برای بهبود CSP پیشنهاد داده‌ایم. در این تحقیق برای بررسی میزان موفقیت روش پیشنهادی خود، روش CSP متداول به همراه الگوریتم OVR (OVR-CSP) را بر روی مجموعه داده در دسترس اجرا کردیم. نتایج این روش در جدول (۳-۳) مشاهده می‌شود. برای روش OVR-CSP متداول تمامی مراحل پیش پردازش مطابق آنچه در بخش ۳-۴ آورده شد انجام گرفته است. ۴ کلاس به بند مورد استفاده در الگوریتم OVR روش LDA می‌باشند بطوریکه نتیجه نهایی بر حسب ماکزیمم احتمالی که از ۴ کلاس به دست می‌آید انتخاب می‌شود.

از آنجایی که به سیستم‌های BCI برای هر فرد بطور منحصر بفرد آموزش می‌یابند [۶]، در روش CSP به ازای m از یک تا ۸ در رابطه (۲-۵) کلاس‌بندی بر روی داده‌های تست انجام شده و ماکزیمم نتیجه به همراه m ای که به ازای آن این نتیجه ماکزیمم به دست آمده است برای تمامی اشخاص در جدول (۳-۳) آورده شده است. با مقایسه نتایج این جدول با جدول (۳-۱) مشاهده می‌شود که بطور متوسط نتایج ما از نتایج نفر دوم مسابقه بهتر بوده است. ما برای تعمیم CSP به مسئله ۴ کلاس از روش OVR استفاده کردیم اما آنها از روش PW استفاده نموده‌اند [۹].

جدول (۳-۳): نتایج روش OVR-CSP متداول در مسئله چهار کلاس

شخص ۱	شخص ۲	شخص ۳	شخص ۴	شخص ۵	شخص ۶	شخص ۷	شخص ۸	شخص ۹	متوسط
۰/۷۴ (۵)	۰/۳۴ (۴)	۰/۷۶ (۴)	۰/۵۱ (۳)	۰/۲۲ (۵)	۰/۲۷ (۳)	۰/۶۹ (۳)	۰/۶۲ (۵)	۰/۷۹ (۳)	۰/۵۵

فصل چهارم

روش‌های پیشنهادی با استفاده از

ویژگی‌های حوزه زمان

فصل چهارم

روش‌های پیشنهادی با استفاده از ویژگی‌های حوزه زمان

در این فصل دو روش پیشنهاد شده که در آنها تنها از ویژگی‌های حوزه زمان استفاده شده است. روش پیشنهادی اول تعمیم روش LTCSP به مسئله چهار کلاسه می‌باشد. روش LTCSP در سال ۲۰۰۸ توسط H. Wang و W. Zheng [۱۸] برای حل مسئله دو کلاسه تصور حرکتی دست چپ و دست راست مطرح شده و موفقیت بیشتری نسبت به روش CSP در جداسازی دو کلاس داشته است. روش CSP معمول ساختار زمانی داده‌ها را در نظر نمی‌گیرد. روش LTCSP بر خلاف روش CSP ساختار زمانی داده‌های EEG را در نظر گرفته و همچنین نسبت به نویز پایدارتر است. ما در این پایان‌نامه این روش را توسط الگوریتم OVR [۱۴] به مسئله چهار کلاسه تعمیم داده‌ایم. LTCSP ساختار زمانی داده‌ها را در نظر می‌گیرد. ما نیز برای در نظر گرفتن توالی زمانی اطلاعات سیگنال‌های EEG، روش دوم را پیشنهاد داده‌ایم. در این روش سیگنال‌ها به قطعات زمانی مختلف با تداخل تقسیم شده، CSP در هر قطعه اجرا شده و ویژگی‌های بدست آمده از تمامی قطعات در کنار هم قرار داده می‌شوند. می‌توان گفت روش پیشنهادی ما نیز نسبت به نویز از روش CSP متداول پایدارتر است.

۴-۱- روش پیشنهادی اول: تعمیم روش LTCSP به مسائل چهار

کلاسه

همانطور که در فصل قبل بیان شد CSP یکی از موفق‌ترین روش‌ها در زمینه BCI مبتنی بر MI است که روش‌های زیادی برای بهبود عملکرد آن گزارش شده است. روش CSP نمی‌تواند ساختار زمانی داده‌های EEG را در نظر بگیرد [۱۸]. CSP به هر نقطه زمانی در همه کانال‌ها به عنوان یک نمونه در فضای ویژگی نگریسته و آنها را به فضای جدیدی مبتنی بر ماتریس کواریانس این ویژگی‌ها نگاشت می‌دهد.

تاکنون چندین روش مانند CSSP [۲۲]، CSSSP [۲۳]، ISSPL [۲۴] و SBCSP [۲۵]، FBCSP [۲۶] و سایر روش‌ها برای بهبود ایده اولیه CSP ارائه شده است. تلاش این روش‌ها در یافتن بازه‌های فرکانسی مناسب برای فیلتر کردن کانال‌های EEG می‌باشد. در تمامی این روش‌ها مشکل CSP که تمام سیگنال را در محاسبه واریانس بدون در نظر گرفتن همسایگی زمانی بکار می‌برد همچنان باقی می‌ماند. لذا نویز کانال‌های EEG در یک لحظه می‌تواند واریانس هر کانال و نتیجتاً موفقیت CSP را تحت تأثیر زیادی قرار دهد.

H. Wang و W. Zheng [۱۸] روشی به نام LTCSP پیشنهاد دادند که می‌توان گفت مشکل اشاره شده را تا حدودی برطرف ساخته و از طرف دیگر نتایج بهتری از روش CSP معمول داشته است. این روش تعمیم یافته روش CSP است که توسط یک ماتریس همسایگی، ساختار محلی سیگنال‌های زمانی EEG را در تخمین ماتریس کواریانس در نظر می‌گیرد. در نتیجه نویز یک بازه زمانی، تأثیری بر روی واریانس محاسبه شده در بازه‌های زمانی دور نخواهد داشت. همانند روش CSP، پیچیدگی محاسباتی روش LTCSP کم است اما LTCSP از روش CSP پایداری بیشتری در برابر اغتشاش و نویز دارد [۱۸]. روش LTCSP نیز مانند روش CSP برای مسائل دو کلاسه مطرح شده است.

در این پایان‌نامه سعی شده است تا روش LTCSP را برای کلاسه‌بندی داده‌های EEG تصور حرکتی ناشی از چهار تصور حرکتی به کار ببریم.

۴-۱-۱-OVR-LTCSP

همان‌طور که بیان شد، LTCSP تعمیمی از روش CSP بوده و مانند این روش، برای مسائل دو کلاسه بیان شده است. بنابراین می‌توان روش‌های تعمیم روش CSP را به مسائل چندکلاسه [۱۳] و [۱۴] برای این روش نیز به کار برد.

در این پایان‌نامه، برای استفاده از روش LTCSP در یک مسئله ۴ کلاسه از تصور حرکتی در زمینه BCI، از الگوریتم OVR [۱۴] استفاده نموده‌ایم. الگوریتم OVR مسئله ۴ کلاسه را به ۴ مسئله دو کلاسه می‌شکند. هر مسئله دو کلاسه، یک کلاس تصور حرکتی را نسبت به بقیه کلاس‌ها کلاسه‌بندی می‌کند. برای این منظور از چهار کلاسه‌بند LDA استفاده شده است تا ویژگی‌های بدست آمده برای هر کلاس را نسبت به بقیه کلاس‌ها کلاسه‌بندی نماییم. کلاس داده‌های ورودی را آن کلاسه‌بند که در آن فاصله داده‌ها از مرز جداسازی بیشتر است، تعیین می‌نماید.

۴-۱-۱-۱-روند اجرای روش OVR-LTCSP

مختصری از روند اجرای روش OVR-LTCSP در زیر آورده شده است.


- پردازش اولیه: مطابق آنچه در بخش ۳-۴ توضیح داده شد صورت می‌گیرد.
- کاهش تعداد کانال: در این تحقیق، برای کاهش کانال از روش LTCSP استفاده شده است.
- برای تعمیم این روش به مسئله چهار کلاسه از الگوریتم OVR استفاده نموده‌ایم. بنابراین ۴ کلاسه‌بند مورد نیاز است که هر کدام از کلاسه‌بندها یک کلاس را نسبت به بقیه کلاس‌ها مطابق با روش LTCSP دو کلاسه [۱۸] جداسازی می‌کند. در روش OVR-LTCSP نیز مانند روش OVR-CSP برای هر کلاسه‌بند یک ماتریس فیلترهای فضایی وجود دارد که بعد از

نگاشت توسط این فیلترها، سیگنال‌های ثانویه بدست می‌آیند (رابطه (۲-۱۸)). با برداشتن m سطر از بالا و پایین ماتریس سیگنال‌های ثانویه، سیگنال‌های لازم برای جداسازی دو مجموعه مربوط به هر کلاسه‌بند بدست می‌آید.


▪ **استخراج ویژگی:** در این تحقیق بعد از کاهش کانال در هر کلاسه‌بند از همان ویژگی‌های واریانس نرمال شده (رابطه (۲-۱۹)) استفاده می‌شود.

▪ **کلاسه‌بندی:** در روش ۴ کلاسه، در مرحله آموزش هر کلاسه‌بند باید به طور جدا آموزش داده شود به طوریکه هر کدام، یک کلاس را نسبت به بقیه کلاس‌ها دسته‌بندی می‌کند. بنابراین هر کلاسه‌بند یک مسئله دو کلاسه است که طریقه آموزش آن در فصل دوم توضیح داده شد [۱۶]. در مرحله ارزیابی، هر داده تست با چهار کلاسه‌بند روبروست که بعد از مراحل پردازش اولیه، توسط ماتریس‌های W در هر کلاسه‌بند، بردار ویژگی مربوط به آن کلاسه‌بند به دست آمده و دسته‌بندی می‌شود. نهایتاً ۴ نتیجه کلاسه‌بندی داریم که داده تست را با ۴ احتمال جزء کلاس ۱ تا ۴ قرار می‌دهد. کلاس نهایی مربوط به نتیجه‌ای است که احتمال بیشتری دارد [۱۵]. در این تحقیق هر چهار کلاسه‌بند از نوع LDA می‌باشند.

روند اجرای مراحل آموزش و تست به ترتیب در شکل‌های (۴-۱) و (۴-۲) مشاهده می‌شوند.



شکل (۴-۱): روند اجرای مرحله آموزش در روش OVR-LTCS



شکل (۲-۴): روند اجرای مرحله ارزیابی در روش OVR-LTCSP

۴-۱-۱-۲- نتایج روش OVR-LTCSP

مانند مرجع [۱۸] ما نیز روش LTCSP را به ازای $m \in \{1, \dots, 5\}$ و $\tau \in \{2, \dots, 5\}$ و $c \in \{1, 2, \dots, 10\}$ برای هر ۹ شخص در پایگاه داده انجام دادیم.

همانطور که در بخش ۲ بیان شد، $\sigma = c\sigma_0$ است و σ_0 انحراف معیار مجذور اندازه نمونه‌های آموزشی است که در روش OVR، یکبار در ازای هر ۴ کلاس محاسبه شده و برای هر ۴ کلاسه‌بند استفاده می‌شود. لازم به ذکر است که بقیه پارامترها یعنی m ، c و τ نیز برای هر ۴ کلاسه‌بند ثابت در نظر گرفته می‌شوند.

مقادیر بدست آمده بر حسب ضریب کاپا برای شخص ۱ در جدول (۱-۴) آورده شده و ماکزیمم مقدار آن در جدول مشخص شده است. ماکزیمم مقدار کاپا برابر با ۰/۷۷ است که در $m=5$ ، $\tau=4$ و $c=5$ اتفاق افتاده است.

به همین ترتیب چنین جدولی برای ۸ شخص دیگر نیز بدست آوردیم. ماکزیمم مقدار کاپا به همراه پارامترهای مربوطه، به عنوان مقادیر بهینه پارامترها به صورت ترکیب سه‌تایی (m, τ, c) ، برای هر ۹ شخص در جدول (۲-۴) آورده شده است.


جدول (۱-۴): ضرایب کاپا حاصل از روش LTCSP به ازای m ، τ و c متغیر مربوط به شخص ۱

τ	$C=1$	$C=2$	$C=3$	$C=4$	$C=5$	$C=6$	$C=7$	$C=8$	$C=9$	$C=10$
$m=1$										
۲	۰/۶۹	۰/۶۹	۰/۷۰	۰/۷۰	۰/۷۰	۰/۶۹	۰/۶۹	۰/۶۸	۰/۶۸	۰/۶۸
۳	۰/۶۹	۰/۶۹	۰/۷۰	۰/۷۰	۰/۷۲	۰/۷۱	۰/۷۱	۰/۷۱	۰/۷۰	۰/۷۰
۴	۰/۷۱	۰/۷۱	۰/۷۱	۰/۷۲	۰/۷۲	۰/۷۲	۰/۷۲	۰/۷۱	۰/۷۱	۰/۷۱
۵	۰/۷۰	۰/۷۰	۰/۷۰	۰/۷۱	۰/۷۱	۰/۷۱	۰/۷۱	۰/۷۰	۰/۷۰	۰/۷۰
$m=2$										
۲	۰/۶۹	۰/۶۹	۰/۶۹	۰/۷۰	۰/۷۰	۰/۷۰	۰/۷۰	۰/۷۰	۰/۶۹	۰/۶۹
۳	۰/۷۰	۰/۷۰	۰/۷۰	۰/۷۲	۰/۷۱	۰/۷۱	۰/۷۱	۰/۷۰	۰/۷۰	۰/۷۰
۴	۰/۷۱	۰/۷۱	۰/۷۱	۰/۷۲	۰/۷۲	۰/۷۲	۰/۷۲	۰/۷۲	۰/۷۲	۰/۷۲
۵	۰/۷۱	۰/۷۱	۰/۷۱	۰/۷۱	۰/۷۲	۰/۷۲	۰/۷۲	۰/۷۳	۰/۷۳	۰/۷۳
$m=3$										
۲	۰/۶۸	۰/۶۸	۰/۶۹	۰/۶۹	۰/۶۹	۰/۶۹	۰/۶۹	۰/۷۰	۰/۷۰	۰/۷۰
۳	۰/۶۹	۰/۶۹	۰/۷۰	۰/۷۰	۰/۷۱	۰/۷۱	۰/۷۰	۰/۷۰	۰/۶۹	۰/۶۹
۴	۰/۷۱	۰/۷۱	۰/۷۱	۰/۷۲	۰/۷۲	۰/۷۲	۰/۷۲	۰/۷۳	۰/۷۳	۰/۷۲
۵	۰/۷۲	۰/۷۲	۰/۷۲	۰/۷۳	۰/۷۳	۰/۷۳	۰/۷۳	۰/۷۲	۰/۷۲	۰/۷۲
$m=4$										
۲	۰/۷۰	۰/۷۰	۰/۷۰	۰/۷۲	۰/۷۲	۰/۷۲	۰/۷۳	۰/۷۳	۰/۷۳	۰/۷۲
۳	۰/۷۱	۰/۷۱	۰/۷۱	۰/۷۴	۰/۷۴	۰/۷۴	۰/۷۳	۰/۷۳	۰/۷۲	۰/۷۱
۴	۰/۷۱	۰/۷۱	۰/۷۱	۰/۷۴	۰/۷۴	۰/۷۴	۰/۷۳	۰/۷۳	۰/۷۲	۰/۷۲
۵	۰/۷۳	۰/۷۳	۰/۷۳	۰/۷۲	۰/۷۲	۰/۷۲	۰/۷۲	۰/۷۱	۰/۷۱	۰/۷۱
$m=5$										
۲	۰/۷۲	۰/۷۱	۰/۷۲	۰/۷۲	۰/۷۳	۰/۷۴	۰/۷۴	۰/۷۴	۰/۷۳	۰/۷۳
۳	۰/۷۱	۰/۷۵	۰/۷۶	۰/۷۶	۰/۷۶	۰/۷۶	۰/۷۵	۰/۷۴	۰/۷۴	۰/۷۴
۴	۰/۷۱	۰/۷۴	۰/۷۴	۰/۷۴	۰/۷۷	۰/۷۶	۰/۷۶	۰/۷۵	۰/۷۵	۰/۷۵
۵	۰/۷۴	۰/۷۲	۰/۷۳	۰/۷۵	۰/۷۵	۰/۷۳	۰/۷۲	۰/۷۲	۰/۷۲	۰/۷۲

جدول (۴-۲): ضریب کاپا ناشی از روش OVR-LTCSP به همراه مقادیر بهینه (m و τ و c)

متوسط	۹	۸	۷	۶	۵	۴	۳	۲	۱
. / ۶۱	. / ۸۰ (۳ و ۵ و ۷)	. / ۷۴ (۸ و ۳ و ۵)	. / ۷۵ (۲ و ۵ و ۳)	. / ۳۷ (۲ و ۵ و ۳)	. / ۳۱ (۸ و ۲ و ۵)	. / ۶۰ (۱۰ و ۲ و ۳)	. / ۸۰ (۳ و ۴ و ۲)	. / ۳۵ (۹ و ۵ و ۴)	. / ۷۷ (۵ و ۴ و ۵)

با مقایسه جدول (۴-۱) و جدول (۳-۳) مشاهده می‌شود، نتایج روش LTCSP در همه موارد مورد آزمایش، از نتایج روش CSP بهتر است. با توجه به جدول (۳-۱) مشاهده می‌شود روش LTCSP در ۵ مورد از ۹ مورد، عملکرد بهتری از برنده مسابقه داشته است که به طور متوسط نیز نتیجه بهتری دارد. نتایج روش OVR-LTCSP، OVR-CSP و دو نفر برتر مسابقه در نمودار میله‌ای زیر مشاهده می‌شود.




شکل (۴-۳): مقایسه نتایج روش OVR-LTCSP، OVR-CSP و نفرات اول مسابقه چهارم BCI

۴-۲- روش دوم: استفاده از قطعه‌بندی زمانی در روش CSP

در شکل (۱-۱۳) از فصل اول مشاهده کردیم در تصور حرکتی دست چپ در کانال C3 باند میو (طیف حدود ۸ تا ۱۲ هرتز) قبل از تصور وجود داشته و تا پایان تصور ادامه دارد، اما در کانال C4 این باند فرکانسی قبل از تصور وجود داشته و بعد از حدود $0/6$ ثانیه محو می‌شود و تا پایان تصور حرکتی دوباره به وجود نمی‌آید. یعنی اصطلاحاً در طول تصور حرکتی دست چپ، در نیمکره راست مغز ERD اتفاق افتاده است. توزیع‌های زمان-فرکانس موجود در شکل (۱-۱۳) مربوط به یک آزمایش نیستند. در واقع توزیع زمان-فرکانس چند آزمایش از هر نوع تصور حرکتی بدست آمده و برای هر نوع تصور متوسط‌گیری و رسم شده است.

در حقیقت در یک آزمایش تنها، این روند مشاهده نمی‌شود و اصطلاحاً باندهای فرکانسی در طول تصور حرکتی فعال و غیر فعال می‌شوند. یعنی یک باند فرکانسی در یک لحظه از زمان در سیگنال یک کانال به وجود آمده و بعد از مدت کوتاهی محو می‌شود و دوباره بعد از مدتی به وجود می‌آید و ممکن است تا پایان تصور حرکتی ادامه نیابد [۵۳].

در شکل (۴-۴) اسپکتوگرام کانال‌های C3 و C4 مربوط به ۳ آزمایش تصور حرکتی دست چپ برای یک شخص آورده شده است. در این شکل نواحی با طیف رنگی نارنجی-قرمز مربوط به مؤلفه‌های فرکانسی با توان بالا می‌باشند. در مقابل طیف رنگ آبی مربوط به مؤلفه‌های فرکانسی با توان کمتر هستند. لکه‌های نارنجی-قرمز به معنای تولید مؤلفه فرکانسی مشخص در بازه زمانی خاص می‌باشد. همانطور که از این شکل مشاهده می‌شود، مؤلفه‌های فرکانسی به وجود آمده در طول زمان تصور حرکتی پایدار نیستند. به نظر می‌رسد برخی از مؤلفه‌های فرکانسی برای سه آزمایش در یک بازه‌ی زمانی خاص تکرار شده‌اند. برخی از این مؤلفه‌های فرکانسی در شکل مذکور برای دو بازه زمانی با کادر دایره و مربع مشخص شده‌اند.



شکل (۴-۴): اسپکتوگرام دو کانال C3 و C4 در سه آزمایش تصور حرکتی دست چپ مربوط به شخص ۱

این مشاهدات انگیزه اصلی ما برای قطعه‌بندی سیگنال‌های EEG و استخراج ویژگی از هر قطعه است. در برخی تحقیقات گزارش شده در بعضی مراجع [۸ و ۵۸] نیز از کلاسه‌بندهای دینامیکی مانند HMM و TDNN که توالی وقایع زمانی در نظر گرفته می‌شود نیز استفاده شده است که نتایج خوبی در زمینه BCI مبتنی بر تصور حرکتی داشته‌اند.

همانطور که در فصل سوم بیان شد در مرجع [۵۳] ابتدا داده‌های EEG توسط فیلترهای فضایی بدست آمده از روش CSP و JAD فیلتر شده و سپس ۳ ثانیه تصور حرکتی به پنجره‌های زمانی ۱ ثانیه با تداخل ۸۰٪ تقسیم می‌شود. آنگاه ویژگی‌های تمامی بازه‌ها در یک بردار قرار داده شده و کلاسه‌بندی صورت می‌گیرد. با توجه به جدول (۳-۲) روش مورد استفاده آنها نتایج خوبی نسبت به نفر برتر مسابقه نداشته است.

در این پایان نامه برخلاف مرجع [۵۳] ابتدا قطعه‌بندی زمانی انجام گرفته و بعد روش CSP در هر قطعه زمانی اجرا شده و فیلترهای فضایی در هر قطعه بدست می‌آید.

روش CSP مبتنی بر ماتریس کواریانس داده‌ها می‌باشد و بنابراین نویز در یک ناحیه زمانی تأثیر زیادی بر تخمین ماتریس کواریانس داشته و در نتیجه فیلترهای فضایی مناسب استخراج نخواهند شد. در این صورت تمامی ویژگی‌ها تحت تأثیر خواهند گرفت.

در روش پیشنهادی ما ابتدا بر روی سیگنال‌های EEG قطعه‌بندی زمانی انجام شده و بعد در هر قطعه زمانی روش CSP اجرا می‌شود. بنابراین برای هر قطعه زمانی فیلترهای فضایی به طور مجزا بدست می‌آیند. بعد از استخراج ویژگی‌ها از هر قطعه زمانی، بردارهای ویژگی بدست آمده در کنار هم قرار گرفته و بردار ویژگی نهایی بدست می‌آید. بنابراین نویز در هر قطعه زمانی تنها ماتریس کواریانس همان قطعه و در نتیجه فیلترهای فضایی و ویژگی‌های همان قطعه را تحت تأثیر قرار می‌دهد. بنابراین تأثیر نویز بر کل بردار ویژگی کاهش می‌یابد.

در ادامه این بخش به توضیح روش پیشنهادی می‌پردازیم.


۴-۲-۱- روش قطعه‌بندی زمانی در CSP برای مسائل دو کلاسه

روش پیشنهادی که آن را SEG-CSP-Var نامیده‌ایم، دارای دو مرحله آموزش و ارزیابی می‌باشد که در ادامه به توضیح آن می‌پردازیم. روندنمای اجرای مراحل آموزش و ارزیابی در شکل (۴-۵) نشان داده شده است.

۴-۲-۱-۱- مرحله آموزش


این مرحله شامل گام‌های زیر است:

- پردازش اولیه داده‌های آموزشی: مطابق آنچه در بخش ۳-۴ آورده شد.



شکل (۴-۵): (الف) روندنمای اجرای روش SEG-CSP-Var (الف) مرحله آموزش (ب) مرحله ارزیابی

▪ **قطعه‌بندی زمانی:** بعد از پردازش اولیه داده‌های EEG، لازم است تا بازه مورد نظر برای رخ دادن سیگنال‌های تصور حرکتی را به پنجره‌های زمانی مساوی با لحاظ همپوشانی مناسب، تقسیم نماییم. از آنجایی که ممکن است مناسب‌ترین طول برای هر قطعه زمانی برای اشخاص مختلف متفاوت باشد، طول قطعه را یک پارامتر متغیر در نظر می‌گیریم. نتایج کلاسه‌بندی را به ازای مقادیر مختلف این پارامتر در نظر گرفته و طولی که بهترین نتیجه کلاسه‌بندی را برای شخص به وجود آورد، به عنوان طول بهینه برای آن شخص برمی‌گزینیم.



شکل (۴-۶): طریقه قطعه‌بندی زمانی در روش SEG-CSP-Var

در شکل (۴-۶) طریقه قطعه‌بندی زمانی با طول T ثانیه و شیفت ΔT ثانیه نشان داده شده است. کل بازه مورد نظر در شکل از ثانیه‌ی $2/5$ تا 6 ثانیه می‌باشد.

▪ **بدست آوردن فیلترهای فضایی:** در این مرحله روش CSP را در هر قطعه زمانی سیگنال-های EEG اجرا کرده و فیلترهای فضایی را در هر قطعه بدست می‌آوریم. در نتیجه به تعداد قطعات زمانی ماتریس‌های W داریم. اگر تعداد قطعه‌ها را S در نظر بگیریم، این ماتریس‌ها را به ترتیب $W_1, W_2, \dots, W_S$ می‌نامیم.


▪ **به دست آوردن ویژگی‌های مرحله آموزش:** ویژگی‌های مرحله آموزش را مطابق روابط (۴-۱) و (۴-۲) بدست می‌آوریم. ویژگی‌های بدست آمده از قطعه‌ی i ام را با بردار ویژگی F^i نمایش می‌دهیم.

$$F^i = [f_1^i \ f_2^i \ \dots \ f_m^i \ \dots \ f_{2m-1}^i \ \dots \ f_{2m}^i] \ , i = 1, 2, \dots, S \quad (۴-۱)$$

نهایتاً بردار ویژگی تصور حرکتی برای یک آزمایش برابر است با بردار F :

$$F = [F^1 \ F^2 \ \dots \ F^S] \quad (۴-۲)$$

طریقه بدست آوردن بردار ویژگی برای هر داده EEG در شکل (۴-۷) نشان داده شده است.



شکل (۴-۷): طریقه بدست آوردن بردار ویژگی برای هر داده EEG در روش SEG-CSP-Var

- آموزش کلاسه‌بند: توسط بردارهای ویژگی بدست آمده برای دو کلاس، کلاسه‌بند مورد نظر را آموزش می‌دهیم. کلاسه‌بند مورد استفاده از نوع LDA می‌باشد.

۴-۲-۱-۲- مرحله ارزیابی

- در مرحله ارزیابی برای ماتریس EEG مورد آزمون از یک تصور حرکتی گام‌های زیر اجرا می‌شود:
 - پردازش اولیه داده‌ها مانند مرحله آموزش
 - قطعه‌بندی زمانی مانند مرحله آموزش با طول قطعه بهینه بدست آمده از مرحله آموزش.
 - اعمال ماتریس نگاشت دهنده W_i به قطعه i ام از سیگنال‌های EEG و بدست آوردن ویژگی‌های این قطعه.
 - قرار دادن ویژگی‌های تمامی قطعات ($i=1,2,\dots,S$) در یک بردار و اعمال آن به کلاسه‌بند آموزش یافته.

۴-۲-۲- نتایج روش SEG-CSP-Var برای جداسازی دو کلاس تصور حرکتی

دست چپ و دست راست

برای بررسی توانایی روش پیشنهادی در کلاسه‌بندی، ابتدا این روش را برای دسته‌بندی دو کلاس تصور حرکتی دست چپ و دست راست برای هر ۹ شخص امتحان کرده و نتایج کلاسه‌بندی داده‌های ارزیابی را برحسب درصد درستی به دست آوردیم.

همانطور که بیان شد، کل بازه مورد بررسی، از نیم ثانیه قبل از تصور حرکتی تا ۲/۵ ثانیه بعد از آن در نظر گرفته شده است. از آنجایی که آزمایشات BCI منحصر به فرد است [۶]، برای هر شخص باید طول قطعه مناسب در فرایند قطعه بندی را بدست آوردیم. برای این منظور طول قطعه‌های زمانی ۰/۵، ۱، ۱/۵، ۲، ۲/۵ و ۳ ثانیه برای هر شخص مورد مطالعه قرار گرفته است. میزان شیفت قطعات زمانی متوالی نسبت به هم، ۰/۵ ثانیه در نظر گرفته شده است.

همانند روش CSP متداول، انتخاب m (نصف تعداد فیلترهای فضایی) مهم است. برای این منظور به ازای هر طول برای قطعه‌های زمانی، مقدار m را نیز از ۱ تا ۸ تغییر داده و توسط داده‌های تست کلاسه‌بندی انجام می‌گیرد و نتایج کلاسه‌بندی بر حسب درصد تشخیص درستی به دست می‌آید.

نتایج کلاسه‌بندی به ازای طول بازه‌ها و m متغیر در جدول (۴-۳) آورده شده و ماکزیمم نتیجه برای هر شخص در جدول به صورت پررنگ‌تر نشان داده شده است.

بهترین نتیجه برای هر شخص پارامترهای آن یعنی طول بازه‌ها و m مخصوص به این نتیجه ماکزیمم در پرانتز در جدول (۴-۴) آورده شده است.

جدول (۳-۴): نتایج روش بازه‌بندی زمانی در CSP به منظور کلاسه‌بندی تصور حرکتی دست چپ و راست

(الف): درصد درستی برای اشخاص مورد آزمایش به ازای بازه‌بندی ۰/۵ ثانیه‌ای

m	شخص ۱	شخص ۲	شخص ۳	شخص ۴	شخص ۵	شخص ۶	شخص ۷	شخص ۸	شخص ۹
۱	۹۰/۰۷	۵۷/۰۴	۹۷/۰۷	۶۲/۹۳	۵۵/۵۶	۷۰/۳۷	۷۵/۷۱	۹۸/۵۱	۸۳/۸۵
۲	۸۰/۸۵	۶۶/۱۷	۹۲/۷۱	۵۶/۷۶	۵۸/۵۲	۶۷/۵۹	۷۲/۸۶	۹۷/۸۶	۸۴/۶۲
۳	۸۰/۸۵	۶۰/۵۶	۸۹/۷۸	۵۹/۴۸	۵۱/۱۱	۶۰/۱۹	۶۷/۸۶	۹۷/۷۶	۸۲/۳۱
۴	۸۴/۴۰	۵۹/۱۵	۸۹/۰۵	۵۷/۷۶	۵۴/۸۱	۶۰/۱۹	۷۵/۰۰	۹۷/۰۱	۸۰/۷۷
۵	۷۸/۷۲	۵۷/۷۵	۹۰/۵۱	۵۸/۶۲	۵۰/۳۷	۶۲/۰۴	۶۵	۹۴/۰۳	۷۹/۲۳
۶	۸۰/۸۵	۶۱/۲۷	۹۳/۴۳	۶۰/۳۴	۵۰/۳۷	۵۸/۳۳	۶۰/۷۱	۹۴/۷۸	۷۶/۱۵
۷	۷۸/۷۲	۵۶/۳۴	۹۰/۵۱	۶۸/۱۰	۴۸/۸۹	۴۷/۲۲	۶۰/۷۱	۹۴/۷۸	۷۴/۶۲
۸	۷۴/۴۵	۵۱/۴۱	۸۱/۰۲	۵۲/۵۹	۵۱/۱۱	۷۷/۲۱	۶۲/۸۶	۹۲/۵۴	۵۴/۶۲

(ب): درصد درستی برای اشخاص مورد آزمایش به ازای بازه‌بندی ۱ ثانیه‌ای

m	شخص ۱	شخص ۲	شخص ۳	شخص ۴	شخص ۵	شخص ۶	شخص ۷	شخص ۸	شخص ۹
۱	۹۲/۲۰	۵۷/۷۵	۹۵/۶۲	۷۲/۴۱	۵۶/۳۰	۶۵/۷۴	۷۷/۱۴	۹۷/۰۱	۸۴/۶۲
۲	۸۵/۸۲	۶۲/۶۸	۹۵/۶۲	۶۲/۹۳	۵۳/۳۳	۶۵/۷۴	۷۴/۲۹	۹۵/۵۲	۸۵/۳۸
۳	۹۰/۰۷	۶۲/۶۸	۹۱/۲۴	۵۸/۶۲	۶۳/۷۰	۶۵/۷۴	۷۷/۱۴	۹۵/۵۲	۸۳/۸۵
۴	۸۰/۱۴	۶۰/۵۶	۹۱/۲۴	۵۸/۶۲	۵۷/۷۸	۶۲/۹۶	۷۵/۰۰	۹۷/۷۶	۸۸/۴۶
۵	۸۰/۱۴	۶۱/۹۷	۹۱/۹۷	۶۶/۳۸	۵۸/۰۴	۶۱/۱۱	۷۱/۴۳	۹۴/۰۳	۸۵/۳۸
۶	۷۷/۳۰	۶۰/۵۶	۸۴/۶۷	۶۳/۷۹	۵۴/۰۷	۵۶/۴۸	۷۰/۰۰	۹۰/۳۰	۸۱/۵۴
۷	۷۶/۶۰	۵۲/۸۲	۷۷/۳۷	۶۱/۲۱	۵۷/۰۴	۶۲/۰۴	۶۰/۷۱	۸۹/۵۵	۸۳/۸۵
۸	۷۲/۳۴	۵۲/۸۲	۷۸/۸۳	۶۲/۹۳	۵۵/۱۱	۶۰/۱۹	۶۲/۸۶	۸۶/۵۷	۷۳/۸۵

(ج): درصد درستی برای اشخاص مورد آزمایش به ازای بازه‌بندی ۱/۵ ثانیه‌ای

m	شخص ۱	شخص ۲	شخص ۳	شخص ۴	شخص ۵	شخص ۶	شخص ۷	شخص ۸	شخص ۹
۱	۹۳/۶۲	۵۲/۸۲	۹۶/۳۵	۷۴/۱۴	۵۴/۰۷	۶۴/۸۱	۷۲/۱۴	۹۷/۷۶	۹۲/۵۴
۲	۸۴/۴۰	۵۸/۴۵	۹۷/۰۸	۶۴/۶۶	۵۱/۸۱	۶۵/۷۴	۸۲/۱۴	۹۷/۰۱	۸۲/۳۱
۳	۸۸/۶۵	۶۷/۶۱	۹۵/۶۲	۶۰/۳۴	۵۴/۵۶	۶۲/۰۴	۸۷/۱۴	۹۶/۲۷	۸۶/۹۲
۴	۹۰/۰۷	۵۹/۸۶	۹۵/۶۲	۶۰/۳۴	۴۸/۱۵	۶۲/۰۴	۸۴/۲۹	۹۷/۰۱	۸۶/۱۵
۵	۸۵/۸۲	۶۰/۵۶	۹۲/۷۰	۶۲/۹۳	۴۵/۱۹	۶۰/۱۹	۸۰/۰۰	۹۷/۰۱	۸۷/۶۹
۶	۸۱/۵۶	۵۹/۱۵	۸۳/۹۴	۶۱/۲۱	۴۷/۴۱	۶۰/۳۳	۷۶/۴۳	۹۶/۲۷	۸۵/۳۴
۷	۸۲/۹۸	۵۴/۲۳	۷۷/۳۷	۵۹/۴۸	۴۶/۶۷	۵۲/۷۸	۷۵/۰۰	۹۶/۲۷	۸۳/۰۸
۸	۸۵/۸۲	۵۲/۸۲	۷۷/۳۷	۶۰/۳۴	۴۷/۴۱	۵۸/۳۳	۷۵/۰۰	۹۶/۲۶	۸۳/۰۸

(د): درصد درستی برای اشخاص مورد آزمایش به ازای بازه‌بندی ۲ ثانیه‌ای

m	شخص ۱	شخص ۲	شخص ۳	شخص ۴	شخص ۵	شخص ۶	شخص ۷	شخص ۸	شخص ۹
۱	۸۶/۶۵	۵۱/۴۱	۹۵/۶۲	۶۸/۱۰	۵۴/۰۷	۶۶/۶۷	۷۷/۸۶	۹۷/۷۶	۹۱/۵۴
۲	۸۵/۱۱	۵۲/۱۱	۹۴/۸۹	۷۱/۵۵	۵۶/۳۰	۶۳/۸۹	۸۴/۲۹	۹۴/۰۳	۸۷/۶۹
۳	۸۶/۵۲	۵۷/۰۴	۹۵/۶۲	۶۴/۶۶	۵۱/۸۵	۶۰/۱۹	۸۲/۱۴	۹۱/۷۹	۸۸/۴۶
۴	۹۲/۲۰	۶۱/۹۷	۹۶/۳۵	۶۳/۷۹	۵۲/۵۹	۶۴/۸۱	۸۲/۸۶	۹۶/۲۷	۸۶/۱۵
۵	۸۷/۲۳	۵۵/۶۳	۹۶/۳۵	۶۲/۰۷	۵۹/۲۶	۶۴/۸۱	۸۲/۱۴	۹۹/۲۵	۸۵/۱۵
۶	۸۸/۶۵	۵۷/۰۴	۹۳/۴۳	۶۴/۶۶	۴۹/۶۳	۶۷/۵۹	۷۵/۰۰	۹۷/۰۱	۸۱/۵۴
۷	۸۸/۵۲	۵۴/۲۳	۹۴/۱۶	۷۰/۶۹	۵۷/۰۴	۵۹/۲۶	۷۴/۲۹	۹۷/۰۱	۸۵/۳۸
۸	۸۵/۸۲	۵۵/۵۳	۹۰/۵۱	۶۷/۲۴	۵۵/۵۶	۵۹/۲۶	۷۰/۰۰	۹۴/۰۳	۸۶/۹۲

(ه): درصد درستی برای اشخاص مورد آزمایش به ازای بازه‌بندی ۲/۵ ثانیه‌ای

m	شخص ۱	شخص ۲	شخص ۳	شخص ۴	شخص ۵	شخص ۶	شخص ۷	شخص ۸	شخص ۹
۱	۹۲/۴۱	۶۰/۵۶	۹۵/۶۲	۶۳/۷۹	۵۶/۰۷	۶۶/۶۷	۷۶/۴۳	۹۷/۰۱	۹۴/۷۴
۲	۸۶/۲۶	۵۷/۷۵	۹۶/۳۵	۶۶/۳۸	۵۰/۳۷	۶۲/۰۷	۸۰/۰۰	۹۷/۰۱	۹۰/۷۷
۳	۸۵/۸۱	۶۰/۵۶	۹۶/۳۵	۷۰/۶۹	۵۴/۰۷	۶۲/۰۷	۸۲/۸۶	۹۴/۷۶	۹۰/۰۰
۴	۸۶/۵۲	۵۷/۰۴	۹۵/۶۶	۶۵/۵۲	۵۵/۵۶	۶۲/۰۷	۸۳/۶۳	۹۷/۷۶	۸۸/۴۶
۵	۸۳/۶۹	۵۵/۶۳	۹۷/۶۱	۶۴/۶۶	۵۵/۵۶	۶۲/۰۷	۸۰/۰۰	۹۸/۵۱	۹۰/۷۷
۶	۸۳/۸۹	۵۲/۸۲	۹۴/۸۹	۶۲/۹۳	۵۸/۵۲	۵۲/۴۸	۷۷/۸۶	۹۸/۵۱	۹۰/۰۰
۷	۸۱/۵۶	۵۳/۵۲	۹۴/۸۹	۶۲/۹۳	۵۴/۳۳	۵۶/۴۸	۸۰/۰۰	۹۵/۵۲	۹۰/۰۰
۸	۸۱/۵۶	۵۴/۹۳	۸۶/۱۳	۵۴/۰۷	۵۹/۶۳	۵۴/۶۳	۸۲/۸۴	۹۵/۵۲	۸۶/۱۵

(ر): درصد درستی برای اشخاص مورد آزمایش به ازای بازه‌بندی ۳ ثانیه‌ای

m	شخص ۱	شخص ۲	شخص ۳	شخص ۴	شخص ۵	شخص ۶	شخص ۷	شخص ۸	شخص ۹
۱	۸۷/۹۴	۵۷/۰۴	۹۳/۴۳	۷۱/۵۲	۵۳/۳۳	۶۲/۰۴	۷۶/۴۳	۷۳/۸۸	۹۷/۰۸
۲	۸۸/۶۵	۵۶/۳۴	۹۴/۸۹	۷۷/۵۹	۵۳/۳۳	۵۶/۴۸	۷۷/۱۴	۷۳/۸۸	۸۹/۲۳
۳	۹۰/۷۸	۵۴/۹۳	۹۵/۶۲	۶۸/۱۰	۵۲/۵۹	۶۲/۹۶	۸۶/۴۳	۹۸/۵۱	۸۶/۱۵
۴	۸۹/۳۶	۵۴/۳۶	۹۴/۶۲	۶۶/۶۴	۵۲/۵۹	۶۲/۹۶	۸۶/۴۳	۹۷/۷۶	۹۰/۰۰
۵	۸۷/۹۴	۵۷/۷۵	۹۷/۸۱	۶۶/۶۴	۵۳/۳۳	۶۰/۱۹	۸۳/۵۷	۹۷/۰۱	۸۶/۹۲
۶	۸۶/۵۲	۵۲/۸۲	۹۵/۳۶	۷۵/۶۶	۵۴/۸۱	۶۰/۱۹	۷۹/۲۹	۹۶/۲۷	۸۴/۶۲
۷	۸۵/۱۱	۵۲/۸۲	۹۶/۳۵	۶۷/۲۴	۵۴/۰۷	۵۶/۴۸	۷۰/۰۰	۹۶/۲۷	۸۳/۰۸
۸	۸۴/۴۰	۵۰/۰۰	۹۶/۳۵	۶۷/۲۴	۵۳/۳۳	۶۰/۱۹	۶۶/۴۳	۹۶/۲۷	۸۲/۳۱

جدول (۴-۴): بهترین نتایج برحسب درصد درستی در کلاسه‌بندی به روش قطعه‌بندی زمانی در CSP

شخص ۱	شخص ۲	شخص ۳	شخص ۴	شخص ۵	شخص ۶	شخص ۷	شخص ۸	شخص ۹	
۹۳/۶۲	۶۷/۶۱	۹۷/۸۱	۷۷/۵۹	۶۳/۷۰	۷۷/۲۱	۸۷/۱۴	۹۹/۲۵	۹۷/۰۸	درصد
(۱ و ۵)	(۳ و ۵)	(۵ و ۳)	(۲ و ۳)	(۳ و ۱)	(۸ و ۵)	(۳ و ۵)	(۵ و ۲)	(۱ و ۳)	(بازه و m)
۸۴/۵۶									متوسط

۴-۲-۳- مقایسه نتایج روش SEG-CSP-Var روش CSP معمول

ممکن است این سؤال پیش آید که شاید بازه‌ای پیدا شود که اطلاعات آن بازه به تنهایی برای کلاسه‌بندی مفید واقع شود و قرار دادن اطلاعات قطعات زمانی مختلف به طور پشت سر هم، نه تنها نتیجه را بهبود نبخشد بلکه نرخ کلاسه‌بندی را کاهش دهد. برای این منظور و مقایسه روش پیشنهادی با روش CSP معمول و صحت این ادعا که روش پیشنهادی از روش CSP معمول نتایج بهتری دارد، روش CSP را به ازای طول بازه‌ها و m های مختلف برای هر ۹ شخص بدون پنجره‌بندی زمانی اجرا کردیم. در این بررسی‌ها نیز میزان شیفت زمانی را $۰/۵$ ثانیه و محدوده مورد نظر را همان بازه زمانی $۰/۵$ ثانیه قبل از تصور حرکتی تا $۲/۵$ ثانیه بعد از آن یعنی زمان $۲/۵$ تا $۵/۵$ ثانیه در نظر گرفتیم.

مثلاً برای طول قطعه انتخاب شده $۰/۵$ ثانیه، CSP در فاصله $۲/۵$ تا ۳ ثانیه به ازای m های مختلف بدست آمد. دوباره در بازه ۳ تا $۳/۵$ این روش را اجرا کرده و نتایج کلاسه‌بندی به ازای m های مختلف تنها در همین فاصله زمانی، بدست آمد و به همین ترتیب این کار را تا پایان ثانیه $۵/۵$ انجام دادیم که نتایج آن به ازای این طول بازه به ازای m از ۱ تا ۸ برای شخص ۱ در جدول (۴-۵) آورده شده است.

جدول (۵-۴): نتایج روش SEG-CSP-Var در کلاسه‌بندی تصور حرکتی دست چپ و راست مربوط به ۹ شخص به ازای طول بازه ۰/۵ ثانیه و m متغیر در روش CSP


m	۲/۵-۳ ثانیه	۳-۳/۵ ثانیه	۳/۵-۴ ثانیه	۴-۴/۵ ثانیه	۴/۵-۵ ثانیه	۵-۵/۵ ثانیه	۵/۵-۶ ثانیه
۱	۸۰/۱	۷۹/۴	۸۰/۹	۷۳/۱	۷۰/۹	۷۱/۶	۷۲/۳
۲	۷۹/۴	۷۸/۰	۷۴/۵	۷۴/۵	۷۲/۳	۷۰/۹	۶۵/۲
۳	۷۶/۶	۷۵/۹	۷۶/۶	۷۵/۲	۷۵/۲	۶۵/۲	۷۰/۲
۴	۸۱/۶	۷۵/۲	۷۵/۲	۷۵/۲	۷۷/۳	۶۰/۹	۶۵/۲
۵	۷۳/۱	۷۳/۸	۷۵/۲	۷۲/۳	۷۷/۳	۶۵/۹	۶۵/۲
۶	۷۶/۶	۷۶/۶	۷۶/۶	۷۳/۸	۷۷/۳	۶۶/۷	۶۵/۹
۷	۷۲/۳	۷۳/۸	۷۸/۰	۷۸/۰	۷۵/۲	۷۶/۴	۶۵/۲
۸	۷۰/۹	۷۰/۹	۷۴/۵	۷۴/۵	۷۷/۳	۶۸/۱	۶۵/۹

به همین ترتیب برای طول بازه‌های ۱، ۱/۵، ۲، ۲/۵ و ۳ ثانیه با همان شیفت زمانی ۰/۵ ثانیه چنین جدولی بدست آوردیم. سپس بهترین درصد درستی را از کل نتایج به همراه فاصله زمانی و m آن برگزیدیم. بهترین نتایج برای هر ۹ شخص به همراه بازه زمانی و m آن در جدول (۶-۴) آورده شده است.

برای مقایسه نتایج روش پیشنهادی و روش CSP متداول، نتایج جداول (۴-۴) و (۶-۴) در نمودار میله‌ای شکل (۸-۴) در کنار هم آورده شده است.

جدول (۶-۴): نتایج روش CSP معمول برحسب درصد درستی به ازای طول بازه و m متغیر


شخص ۱	شخص ۲	شخص ۳	شخص ۴	شخص ۵	شخص ۶	شخص ۷	شخص ۸	شخص ۹	
۹۱/۴۹ ۲/۵-۵/۵ ۱	۶۵/۴۹ ۳-۳/۵ ۸	۹۷/۸۱ ۳/۵-۴/۵ ۴	۷۶/۷۲ ۲/۵-۵/۵ ۱	۶۵/۹۳ ۲/۵-۵ ۵	۷۲/۲۲ ۲/۵-۴ ۵	۸۶/۴۳ ۳-۴/۵ ۲	۹۹/۲۵ ۲/۵-۳ ۶	۹۱/۵۴ ۲/۵-۵/۵ ۱	درصد طول بازه (s) m
۸۲/۹۹									متوسط



شکل (۸-۴): مقایسه روش SEG-CSP-Var و روش CSP در کلاسه‌بندی داده‌های تصور حرکتی دست چپ و دست راست

در شکل (۸-۴) مشاهده می‌شود که با روش پیشنهادی در ۶ مورد افزایش درصد داشته‌ایم و در دو مورد نتایج بدون تغییر است (در موارد بالای ۹۷ درصد). تنها در مورد شخص ۵ کاهش درصد داشته‌ایم. به طور متوسط روش پیشنهادی نتایج بهتری از روش CSP معمول داشته است. موفقیت روش پیشنهادی به معنای آن است که به طور متوسط، سلسله اطلاعات به صورت پشت سر هم برای کلاسه‌بندی دو کلاس مفیدتر از اطلاعات هر کدام از قطعات زمانی است.

همانطور که در جدول (۴-۴) مشاهده می‌شود بهترین نتیجه روش پیشنهادی برای شخص ۱ در روش پیشنهادی، در طول بازه ۱/۵ ثانیه و $m=1$ بدست می‌آید. یعنی در فاصله زمانی ۲/۵ تا ۵/۵ ثانیه، ۴ قطعه ۱/۵ ثانیه‌ای با جابه‌جایی زمانی ۰/۵ ثانیه وجود دارد. در شکل (۹-۴) دو فیلتر فضایی اول و آخر هر قطعه، یعنی ستون اول و آخر ماتریس معکوس W_i مربوط به هر قطعه برای هر ۴ قطعه نشان داده شده است.



شکل (۹-۴): دو فیلتر فضایی اول و آخر مربوط به ۴ قطعه متوالی مرتبط با شخص ۱ در روش SEG-CSP-Var در مسئله دو کلاسه. هر ستون مربوط به یک قطعه است. سطر بالا فیلتر اول و سطر پایین فیلتر دوم مربوط به قطعات است.

همانطور که در شکل (۹-۴) مشاهده می‌شود فیلترهای قطعات زمانی متوالی با هم متفاوت هستند. تفاوت آنها نشانه این است که اهمیت کانال‌ها برای جداسازی دو کلاس در هر قطعه متفاوت از دیگری است. در روش CSP تنها یک ماتریس از فیلترهای فضایی بدست می‌آید و این به معنای آن است که در کل فاصله زمانی مورد نظر از $2/5$ تا $5/5$ ثانیه اهمیت کانال‌ها برای جداسازی یکسان است.

بهبود نتایج در روش پیشنهادی نسبت به روش CSP حاکی از این حقیقت است که اطلاعات تمامی قطعات زمانی در کنار هم مفید است، چراکه با توجه به شکل (۹-۴) در هر قطعه الگوهای فرکانسی خاصی وجود دارد که در سایر نواحی وجود ندارد. ممکن است در هر قطعه باند فرکانسی خاصی در یک کانال از یک کلاس به وجود آید که در کانال دیگر به وجود نیاید و به این ترتیب اهمیت کانال‌ها در هر قطعه با قطعه دیگر متفاوت است. با اجرای CSP در هر قطعه زمانی، ERD/ERS ها در قالب سیگنال‌های ثانویه استخراج می‌شوند که با کنار هم قرار دادن اطلاعات این سیگنال‌های ثانویه، می‌توان به اطلاعات مفیدتری از تک تک اطلاعات هر قطعه دست یافت.

۴-۲-۴- تعمیم قطعه‌بندی زمانی در روش CSP به مسائل چهار کلاسه

روش پیشنهادی مبتنی بر روش CSP می‌باشد. روش CSP ابتدا برای مسائل دو کلاسه مطرح شده و تعدادی الگوریتم برای تعمیم آن به مسائل چند کلاسه مطرح شده است [۱۳ و ۱۴]. ما در این تحقیق از الگوریتم OVR برای تعمیم روش CSP و روش پیشنهادی خود به مسئله چهار کلاسه استفاده می‌کنیم.

برای تعمیم روش بازه‌بندی زمانی به چهار کلاس نیز مانند روش متداول OVR-CSP، لازم است تا چهار کلاسه‌بند وجود داشته باشد. هر کدام از کلاسه‌بندها یک کلاس را نسبت به بقیه کلاس‌ها دسته‌بندی می‌کند. همانطور که در توضیحات بخش ۴-۲-۱ آورده شد، هر کلاسه‌بند دو کلاسه در این روش به تعداد قطعه‌های زمانی، ماتریس برای فیلترهای فضایی و متناظر با آن، ماتریس W دارد. اگر تعداد قطعه‌های زمانی S باشد ماتریس‌های W در کلاسه‌بند i ام را با نام‌های $W_1^i, W_2^i, \dots, W_S^i$ می‌شناسیم به طوریکه $i=1,2,3,4$.

در روش چهار کلاسه، هر کلاسه‌بند باید به طور جدا آموزش داده شود به طوریکه هر کدام، یک کلاس را نسبت به بقیه کلاس‌ها دسته‌بندی می‌کند. مثلاً کلاسه‌بند اول، کلاس ۱ را نسبت به بقیه کلاس‌ها جداسازی می‌کند. در هر قطعه زمانی باید روش OVR اجرا شود. در نتیجه مانند روش OVR-CSP ماتریس کواریانس متوسط کلاس دوم در هر قطعه زمانی برابر است با مجموع ماتریس کواریانس بقیه کلاس‌ها در همان قطعه (رابطه (۲-۱)). طریقه بدست آوردن ویژگی‌ها در شکل (۴-۷) آورده شده است. تنها تفاوت روش پیشنهادی با روش CSP متداول این است که در روش پیشنهادی بردارهای ویژگی بدست آمده از تمامی قطعات زمانی باید در کنار هم قرار گرفته و بردار ویژگی نهایی ساخته شود. کلاسه‌بند باید بر اساس بردارهای نهایی آموزش ببیند.

در این قسمت نیز قبل از هر کاری باید پردازش اولیه بر روی داده‌های آموزشی صورت گیرد.

در مرحله ارزیابی، هر داده تست با چهار کلاسه‌بند روبروست که بعد از مراحل پردازش اولیه و قطعه‌بندی، توسط ماتریس‌های W در هر کلاسه‌بند، بردار ویژگی مربوط به آن کلاسه‌بند به دست آمده و دسته‌بندی می‌شود. نهایتاً ۴ نتیجه کلاسه‌بندی داریم که داده تست را با ۴ احتمال جزء کلاس ۱ تا ۴ قرار می‌دهد. کلاس نهایی مربوط به نتیجه‌ای است که احتمال بیشتری دارد [۱۵]. در این تحقیق هر ۴ کلاسه‌بند از نوع LDA می‌باشند.

۴-۲-۵- نتایج روش OVR-SEG-CSP-Var در حل مسئله چهار کلاسه

کل بازه انتخابی، از نیم ثانیه قبل از تصور حرکتی تا ۲/۵ ثانیه بعد از آن در نظر گرفته شده است. از آنجایی که آزمایشات BCI منحصر به فرد است، برای هر شخص باید بازه مناسب را بدست می‌آوریم. برای این منظور بازه‌های زمانی ۰/۵، ۱، ۱/۵، ۲، ۲/۵ و ۳ برای هر شخص مورد مطالعه قرار گرفت. میزان جابه‌جایی شروع پنجره‌های متوالی نیز ۰/۵ ثانیه در نظر گرفته شده است. در این روش نیز مانند روش CSP متداول، انتخاب m مهم است. برای این منظور به ازای هر طول برای پنجره‌های زمانی، مقدار m را نیز از ۱ تا ۸ تغییر داده و توسط داده‌های تست کلاسه‌بندی انجام می‌گیرد. هر m که بیشترین مقدار کاپا را داشت، به عنوان m بهینه در آن بازه‌بندی در نظر گرفته می‌شود.

روش پیشنهادی را OVR-SEG-CSP-Var نامیده‌ایم. نتایج کلاسه‌بندی به ازای طول بازه‌ها و m متغیر در جدول (۷-۴) آورده شده و ماکزیمم نتیجه برای هر شخص در جدول به صورت پررنگ‌تر نشان داده شده است.

در جدول (۸-۴) بهترین نتیجه برای هر شخص آورده شده و در پرانتز پارامترهای آن یعنی طول بازه و m مخصوص به این نتیجه ماکزیمم آورده شده است.

جدول (۴-۷): نتایج قطعه‌بندی زمانی در روش CSP در مسئله چهار کلاسه

(الف): ضریب کاپا برای اشخاص مورد آزمایش به ازای بازه‌بندی ۰/۵ و ۱ ثانیه‌ای

m	شخص ۱	شخص ۲	شخص ۳	شخص ۴	شخص ۵	شخص ۶	شخص ۷	شخص ۸	شخص ۹
ضریب کاپا برای اشخاص مورد آزمایش به ازای بازه‌بندی ۰/۵ ثانیه‌ای									
۱	۰/۶۹	۰/۳۹	۰/۷۶	۰/۴۶	۰/۱۶	۰/۲۸	۰/۶۴	۰/۶۹	۰/۶۳
۲	۰/۶۳	۰/۳۹	۰/۷۸	۰/۴۹	۰/۲۶	۰/۳۶	۰/۷۰	۰/۷۵	۰/۶۸
۳	۰/۶۵	۰/۳۸	۰/۷۶	۰/۴۱	۰/۲۷	۰/۳۶	۰/۶۹	۰/۶۴	۰/۷۱
۴	۰/۶۵	۰/۳۹	۰/۷۲	۰/۴۱	۰/۲۸	۰/۳۲	۰/۶۲	۰/۶۵	۰/۷۲
۵	۰/۶۳	۰/۳۸	۰/۷۱	۰/۴۶	۰/۲۲	۰/۲۷	۰/۵۷	۰/۶۷	۰/۶۷
۶	۰/۵۳	۰/۳۶	۰/۷۴	۰/۴۱	۰/۲۰	۰/۳۲	۰/۵۲	۰/۶۴	۰/۶۸
۷	۰/۵۳	۰/۳۶	۰/۷۰	۰/۴۰	۰/۱۹	۰/۳۲	۰/۵۲	۰/۵۹	۰/۶۴
۸	۰/۴۹	۰/۳۵	۰/۷۱	۰/۳۸	۰/۱۹	۰/۲۸	۰/۴۹	۰/۵۴	۰/۵۸
ضریب کاپا برای اشخاص مورد آزمایش به ازای بازه‌بندی ۱ ثانیه‌ای									
۱	۰/۶۲	۰/۳۸	۰/۷۸	۰/۵۱	۰/۲۵	۰/۳۸	۰/۶۴	۰/۶۶	۰/۵۹
۲	۰/۶۵	۰/۳۸	۰/۷۹	۰/۴۶	۰/۳۰	۰/۳۴	۰/۷۳	۰/۷۴	۰/۷۰
۳	۰/۶۷	۰/۴۲	۰/۷۷	۰/۴۷	۰/۲۶	۰/۳۳	۰/۶۹	۰/۷۱	۰/۷۰
۴	۰/۶۲	۰/۳۹	۰/۷۲	۰/۴۳	۰/۲۳	۰/۲۷	۰/۶۶	۰/۶۲	۰/۷۰
۵	۰/۶۲	۰/۳۶	۰/۷۰	۰/۴۱	۰/۲۸	۰/۱۶	۰/۶۲	۰/۵۸	۰/۷۲
۶	۰/۶۰	۰/۳۶	۰/۷۰	۰/۴۰	۰/۲۷	۰/۳۲	۰/۶۲	۰/۵۷	۰/۷۲
۷	۰/۶۱	۰/۳۸	۰/۷۰	۰/۳۸	۰/۲۳	۰/۳۰	۰/۶۱	۰/۶۲	۰/۶۷
۸	۰/۵۹	۰/۳۵	۰/۶۹	۰/۳۸	۰/۲۰	۰/۲۶	۰/۵۹	۰/۶۰	۰/۶۶

(ب): ضریب کاپا برای اشخاص مورد آزمایش به ازای بازه‌بندی ۱/۵ ثانیه‌ای

شخص ۱	شخص ۲	شخص ۳	شخص ۴	شخص ۵	شخص ۶	شخص ۷	شخص ۸	شخص ۹	m
۰/۷۰	۰/۳۰	۰/۷۸	۰/۵۱	۰/۱۲	۰/۳۱	۰/۶۵	۰/۶۸	۰/۶۳	۱
۰/۶۹	۰/۴۰	۰/۷۸	۰/۴۸	۰/۲۷	۰/۲۸	۰/۷۵	۰/۷۳	۰/۷۱	۲
۰/۷۲	۰/۳۹	۰/۷۵	۰/۴۸	۰/۲۵	۰/۳۳	۰/۷۰	۰/۶۸	۰/۷۲	۳
۰/۶۸	۰/۴۰	۰/۷۸	۰/۴۰	۰/۲۳	۰/۳۰	۰/۷۱	۰/۶۹	۰/۷۷	۴
۰/۷۲	۰/۴۱	۰/۷۵	۰/۳۶	۰/۲۱	۰/۲۸	۰/۶۷	۰/۷۰	۰/۷۰	۵
۰/۶۸	۰/۴۳	۰/۷۴	۰/۳۶	۰/۱۷	۰/۳۱	۰/۶۸	۰/۶۷	۰/۷۱	۶
۰/۶۸	۰/۳۹	۰/۷۱	۰/۳۶	۰/۱۷	۰/۲۸	۰/۷۱	۰/۷۵	۰/۶۹	۷
۰/۶۵	۰/۳۸	۰/۷۱	۰/۳۶	۰/۱۸	۰/۲۸	۰/۷۰	۰/۷۲	۰/۶۸	۸

(ج): ضریب کاپا برای اشخاص مورد آزمایش به ازای بازه‌بندی ۲ ثانیه‌ای

شخص ۱	شخص ۲	شخص ۳	شخص ۴	شخص ۵	شخص ۶	شخص ۷	شخص ۸	شخص ۹	m
۰/۶۷	۰/۲۸	۰/۷۶	۰/۵۴	۰/۱۷	۰/۳۳	۰/۶۳	۰/۶۷	۰/۳۰	۱
۰/۶۷	۰/۳۹	۰/۸۰	۰/۵۷	۰/۲۳	۰/۳۰	۰/۷۶	۰/۷۱	۰/۶۰	۲
۰/۷۱	۰/۳۵	۰/۷۴	۰/۵۳	۰/۲۸	۰/۳۶	۰/۷۰	۰/۷۲	۰/۶۹	۳
۰/۷۱	۰/۳۴	۰/۷۳	۰/۴۵	۰/۳۱	۰/۳۲	۰/۷۱	۰/۷۱	۰/۷۵	۴
۰/۷۲	۰/۳۵	۰/۷۳	۰/۴۷	۰/۲۲	۰/۲۶	۰/۷۲	۰/۶۶	۰/۷۲	۵
۰/۷۰	۰/۳۰	۰/۷۳	۰/۴۴	۰/۲۵	۰/۲۲	۰/۷۳	۰/۶۴	۰/۷۳	۶
۰/۶۹	۰/۳۰	۰/۷۴	۰/۴۴	۰/۲۹	۰/۲۲	۰/۷۳	۰/۶۱	۰/۷۱	۷
۰/۶۶	۰/۳۱	۰/۷۳	۰/۴۷	۰/۲۸	۰/۲۱	۰/۷۲	۰/۶۲	۰/۶۸	۸

(د): ضریب کاپا برای اشخاص مورد آزمایش به ازای بازه‌بندی ۲/۵ ثانیه‌ای

شخص ۱	شخص ۲	شخص ۳	شخص ۴	شخص ۵	شخص ۶	شخص ۷	شخص ۸	شخص ۹	M
۰/۶۹	۰/۳۲	۰/۷۸	۰/۵۴	۰/۲۱	۰/۲۹	۰/۶۶	۰/۴۷	۰/۳۰	۱
۰/۶۷	۰/۴۳	۰/۷۸	۰/۵۷	۰/۳۱	۰/۳۴	۰/۷۴	۰/۶۰	۰/۸۰	۲
۰/۷۲	۰/۳۸	۰/۷۵	۰/۵۰	۰/۲۴	۰/۳۰	۰/۷۰	۰/۷۱	۰/۶۶	۳
۰/۷۲	۰/۳۶	۰/۷۸	۰/۴۴	۰/۲۰	۰/۳۱	۰/۷۰	۰/۷۴	۰/۷۶	۴
۰/۷۰	۰/۳۸	۰/۷۵	۰/۴۱	۰/۲۸	۰/۳۱	۰/۶۷	۰/۷۴	۰/۷۴	۵
۰/۶۹	۰/۳۸	۰/۷۴	۰/۴۱	۰/۲۷	۰/۲۷	۰/۶۹	۰/۷۴	۰/۷۶	۶
۰/۶۸	۰/۳۶	۰/۷۱	۰/۴۰	۰/۲۷	۰/۲۸	۰/۷۱	۰/۶۷	۰/۶۷	۷
۰/۶۴	۰/۳۶	۰/۷۱	۰/۴۲	۰/۲۶	۰/۲۷	۰/۷۰	۰/۶۳	۰/۷۰	۸


(ه): ضریب کاپا برای اشخاص مورد آزمایش به ازای بازه‌بندی ۳ ثانیه‌ای

شخص ۱	شخص ۲	شخص ۳	شخص ۴	شخص ۵	شخص ۶	شخص ۷	شخص ۸	شخص ۹	M
۰/۶۶	۰/۲۹	۰/۷۵	۰/۴۳	۰/۲۷	۰/۳۰	۰/۶۷	۰/۶۲	۰/۷۰	۱
۰/۶۸	۰/۳۵	۰/۷۵	۰/۴۲	۰/۲۸	۰/۳۰	۰/۶۸	۰/۶۲	۰/۷۱	۲
۰/۷۱	۰/۳۲	۰/۷۵	۰/۴۰	۰/۲۷	۰/۲۹	۰/۶۸	۰/۶۵	۰/۷۱	۳
۰/۷۰	۰/۳۶	۰/۷۱	۰/۴۵	۰/۲۷	۰/۲۹	۰/۶۹	۰/۶۵	۰/۷۲	۴
۰/۷۴	۰/۳۴	۰/۷۱	۰/۵۰	۰/۳۰	۰/۲۸	۰/۷۰	۰/۶۳	۰/۷۲	۵
۰/۶۷	۰/۳۰	۰/۷۰	۰/۵۰	۰/۲۶	۰/۲۸	۰/۷۰	۰/۶۳	۰/۷۳	۶
۰/۶۶	۰/۳۶	۰/۶۹	۰/۴۱	۰/۲۶	۰/۲۷	۰/۶۹	۰/۷۰	۰/۷۵	۷
۰/۶۸	۰/۳۹	۰/۶۸	۰/۴۲	۰/۲۶	۰/۲۷	۰/۶۹	۰/۷۰	۰/۷۵	۸

جدول (۴-۸): بهترین نتایج بدست آمده از روش OVR-SEG-CSP-Var به همراه پارامترهای بهینه آن در کلاسه‌بندی چهار کلاس تصور حرکتی

شخص ۱	شخص ۲	شخص ۳	شخص ۴	شخص ۵	شخص ۶	شخص ۷	شخص ۸	شخص ۹	
۰/۷۴	۰/۴۳	۰/۸۰	۰/۵۷	۰/۳۱	۰/۳۸	۰/۷۶	۰/۷۵	۰/۸۰	کاپا
(۵ و ۳)	(۶ و ۲/۵)	(۲ و ۲)	(۲ و ۲)	(۲ و ۲/۵)	(۱ و ۱)	(۲ و ۲)	(۷ و ۱/۵)	(۲ و ۲/۵)	(بازهم)
۰/۶۱									متوسط

نتایج روش OVR-SEG-CSP-Var به همراه نتایج روش OVR-CSP و دو نفر برتر مسابقه در نمودار میله‌ای شکل (۴-۱۰) مشاهده می‌شود.



شکل (۴-۱۰): مقایسه نتایج روش OVR-CSP، OVR-SEG-CSP-Var و دو نفر برتر مسابقه در حل مسئله چهار کلاسه

در جدول (۴-۱۰) مشاهده می‌شود که در روش OVR-SEG-CSP-Var نسبت به روش OVR-CSP در تمامی موارد به جز شخص ۱ ضریب کاپا افزایش داشته است. در بدترین مورد یعنی برای شخص روش OVR-SEG-CSP-Var و OVR-CSP عملکرد یکسانی داشته‌اند. در این مورد طول بازه برابر با ۳ ثانیه بدست آمده است، یعنی در فاصله مورد نظر تنها یک بازه زمانی وجود دارد در نتیجه دو روش یکی می‌شوند. OVR-CSP در طول بازه ۳ ثانیه حالت خاصی از OVR-SEG-CSP-Var است. می‌توان گفت به طور متوسط روش پیشنهادی نتایج بهتری از روش CSP معمول دارد. موفقیت روش پیشنهادی به معنای آن است که به طور متوسط، سلسله اطلاعات به صورت پشت سر هم برای کلاسه‌بندی دو کلاس مفیدتر از اطلاعات هر کدام از قطعات زمانی است. همچنین با توجه به نمودار نتایج روش در ۶ مورد از نتایج نفر برتر مسابقه بهتر بوده است و به طور متوسط نیز نتایج بهتری دارد. لازم به ذکر است که نتایج روش پیشنهادی ما از نتایج مرجع [۵۳] در بهترین حالت، بهتر بوده است. در این روش توانستیم با ویژگی‌های ساده مانند واریانس و کلاسه‌بند ساده مانند LDA به نتایج خوبی دست یابیم. طول بردار ویژگی در بدترین حالت (طول بازه ۰/۵ ثانیه) برابر با ۹۶ می‌باشد.

فصل پنجم

روش‌های پیشنهادی با استفاده از ویژگی‌های

حوزه زمان و فرکانس

فصل پنجم

روش‌های پیشنهادی با استفاده از ویژگی‌های

حوزه زمان و فرکانس

در این فصل دو روش پیشنهاد شده است که در آنها از ویژگی‌های حوزه زمان و فرکانس توأماً استفاده شده است.

در مقاله [۵۳] که دسته‌بندی مجموعه داده مورد استفاده ما مورد مطالعه قرار گرفته است، از این حقیقت استفاده شده که الگوهای فرکانسی ایجاد شده از ابتدا تا انتهای فاصله فرکانسی ثابت نبوده و فعال و غیر فعال می‌شوند. در این مقاله از بازه‌بندی زمانی در روش JAD و CSP استفاده شده است. در این مقاله ابتدا روش JAD و CSP در کل بازه تصور حرکتی اجرا و بعد سیگنال فیلتر شده توسط فیلترهای فضایی در این بازه به چند قطعه زمانی با تداخل تقسیم شده و از توان در باندهای فرکانسی دو هرتزی به عنوان ویژگی استفاده شده است. تمامی ویژگی‌های بدست آمده برای جداسازی کلاس‌ها بکار برده شده‌اند.

ما بر خلاف مرجع [۵۳] در روش SEG-CSP-Var ابتدا بازه‌بندی زمانی انجام داده و سپس CSP را اجرا کردیم. با مقایسه جدول (۲-۳) و (۴-۸) مشاهده می‌شود که با ویژگی‌های ساده مانند واریانس و کلاسه‌بند ساده مانند LDA توانستیم به نتایج بهتری نسبت به روش مطرح شده در [۵۳] دست یابیم.

به نظر رسید که شاید بتوانیم با استفاده از ویژگی‌های حوزه فرکانس به جای واریانس نتایج روش پیشنهادی خود را بهبود دهیم. به همین دلیل روشی با نام SEG-CSP-BP پیشنهاد دادیم که در بخش ۵-۱ به توضیح آن خواهیم پرداخت.

در برخی مقالات [۲۸، ۳۲، ۳۷، ۳۹ و ۴۰] توان در باندهای فرکانسی مختلف به عنوان ویژگی استفاده شده است. در این مقالات توان باندهای فرکانسی در کل بازه تصور حرکتی بدست می‌آید. در واقع با اینکار اطلاعات زمانی نادیده گرفته می‌شود.

در این پایان‌نامه با نتایج مطلوب‌تر در استفاده از ویژگی‌های حوزه فرکانس به جای واریانس در قطعه‌بندی زمانی در روش CSP، به این نتیجه رسیدیم که اطلاعات زمان در کنار اطلاعات فرکانس می‌تواند در بهبود نتایج مؤثر باشد. به همین دلیل تصمیم گرفتیم تا بطور جزئی‌تر به باندهای فرکانسی مختلف نگاه کنیم. برای این منظور روشی پیشنهاد دادیم که در آن تابع چگالی احتمال^۱ (PDF) مؤلفه‌ها در توزیع زمان فرکانس داده‌های EEG توسط مدل GMM^۲ بدست می‌آید. در این روش برای کاهش تعداد کانال‌ها و یافتن مناسب‌ترین کانال‌ها برای جداسازی کلاس‌ها از روش CSP استفاده شده است. در بخش ۵-۲ به توضیح بیشتر این روش می‌پردازیم.

^۱ Probability density function

^۲ Gaussian Mixture Models

۵-۱- روش اول: استفاده از الگوریتم گسسته‌سازی چند بازه‌ای و

تکنیک رتبه‌بندی ویژگی‌ها

همانطور که در مرجع [۵۳] بیان شده و در شکل (۱-۱۳) مشاهده نمودیم، انرژی باندهای فرکانسی مختلف در کل بازه زمانی تصور حرکتی ثابت نبوده و هر باند فرکانسی اصطلاحاً در طول زمان فعال و غیر فعال می‌شود. به منظور در نظر گرفتن توالی زمانی رخداد های ناشی از تصور حرکتی در داده‌های EEG، در مقاله [۵۳] از بازه‌بندی زمانی استفاده شده است. در این مرجع بعد از اعمال فیلترهای فضایی بدست آمده از روش CSP و JAD کل ۳ ثانیه تصور حرکتی به بازه‌های زمانی ۱ ثانیه‌ای با تداخل ۸۰٪ تقسیم شده و بعد انرژی باندهای فرکانسی ۲ هرتزی بدون تداخل در فاصله ۵ تا ۳۵ هرتز از هر پنجره زمانی استخراج شده است. ویژگی‌های بدست آمده از تمامی پنجره‌های زمانی در یک بردار کنار هم قرار داده می‌شوند. ابعاد این بردار ۱۲۰۰ می‌باشد که به روش logistic regression [۵۵] کلاسه‌بندی شده است.

ما در فصل دوم روشی مطرح کردیم که در آن ابتدا پنجره‌بندی زمانی انجام شده و سپس توسط روش OVR-CSP ماتریس‌های فضایی هر پنجره را بدست آوردیم. بعد از پنجره بندی و اعمال 2m فیلتر مهم‌تر در هر پنجره زمانی، واریانس نرمالایز شده (رابطه (۲-۵)) سیگنال‌های فیلتر شده در هر پنجره به عنوان ویژگی‌های آن پنجره در نظر گرفته شده‌اند. در نهایت ویژگی‌های تمامی پنجره‌های زمانی در یک بردار قرار داده شده و به روش LDA کلاسه‌بندی می‌شود.

به منظور بهبود نتایج روش پیشنهادی مذکور و برای مقایسه با روش ارائه شده در مرجع [۵۳] تصمیم گرفتیم تا در روش بازه‌بندی زمانی برای استخراج ویژگی از هر بازه زمانی به جای ویژگی واریانس از ویژگی‌های حوزه فرکانس مانند توان باندهای فرکانسی مختلف استفاده کنیم. اما زمانی که طول بازه‌های زمانی کوچک است تعداد بازه‌ها و به طبع آن ابعاد بردار ویژگی زیاد خواهد بود. در این

صورت چنانچه مانند روش قبل از کلاسه‌بند LDA استفاده کنیم بدلیل ابعاد زیاد بردار ویژگی نتایج مطلوبی حاصل نخواهد شد. به همین دلیل باید از روش‌های کاهش ویژگی استفاده نماییم. روش‌های زیادی به منظور کاهش ویژگی در مقالات گزارش شده است. مثلاً در مقاله [۲۸] از روش SFS و در مقاله [۳۷] از روش الگوریتم ژنتیک به منظور کاهش ویژگی استفاده شده است. اما این روش‌ها ممکن است در دام مینیمم‌های محلی افتاده و همچنین از سرعت بالایی برخوردار نیستند.

روش گسسته‌سازی چند بازه‌ای برای داده‌های پیوسته^۱ [۵۹] به همراه تکنیک رتبه‌بندی ویژگی‌ها^۲ [۶۰] در مرجع [۶۱] برای تشخیص زبان گفتاری به کمک ضرایب تبدیل موجک استفاده شده و نتایج خوبی داشته است. ما در این تحقیق از این روش به منظور کاهش ابعاد ویژگی و کلاسه‌بندی داده‌های EEG ناشی از تصور حرکتی استفاده کرده‌ایم. ابتدا این روش را برای کلاسه‌بندی دو کلاس تصور حرکتی دست چپ و دست راست به کار برده و سپس به چهار کلاس تعمیم می‌دهیم. در ادامه تکنیک گسسته‌سازی چند بازه‌ای و الگوریتم رتبه‌بندی ویژگی‌ها توضیح داده خواهد شد.

۵-۱-۱- گسسته‌سازی چند بازه‌ای برای داده‌های پیوسته

روش گسسته‌سازی چند بازه‌ای اولین بار توسط Fayyad و Irani [۵۹] برای ویژگی‌های با مقادیر پیوسته مطرح شده و بعدها در مباحث داده‌کاوی استفاده شد [۶۰]. گسسته‌سازی چند بازه‌ای برای هر ویژگی به طور جدا صورت می‌پذیرد. برای هر ویژگی مقادیر تمامی داده‌های آموزشی را در نظر گرفته و آن را به صورت صعودی مرتب کرده و مجموعه S می‌نامیم. آنتروپی مجموعه S توسط رابطه زیر محاسبه می‌شود:

$$\text{Ent}(S) = \sum_{i=1}^k P(C_i, S) \log_2 (P(C_i, S)) \quad (1-5)$$

^۱ Multi interval Discretisation of Continuous-Valued Attributes

^۲ Benchmarking attribute selection techniques

به طوریکه k نشان دهنده تعداد کلاس‌ها و $P(C_i, S)$ احتمال وجود نمونه‌های کلاس C_i را در مجموعه S بیان می‌دارد. در مجموعه S میانگین هر دو ضریب متوالی نابرابر از دو کلاس متفاوت را به عنوان یک کاندیدای نقطه قطع در نظر می‌گیریم. هر نقطه قطع مجموعه S را به دو زیرمجموعه S_1 و S_2 تقسیم می‌کند به طوریکه آنتروپی این دو مجموعه نیز مانند رابطه (۵-۱) محاسبه می‌شود. بعد از یافتن تمامی نقاط قطع آنتروپی اطلاعات کلاسی حاصل از هر نقطه قطع توسط رابطه (۵-۲) محاسبه می‌شود [۵۹].

$$E(A, T; S) = \frac{|S_1|}{N} \text{Ent}(S_1) + \frac{|S_2|}{N} \text{Ent}(S_2) \quad (۲-۵)$$

N تعداد اعضای مجموعه S بوده و علامت $|.$ نمایانگر تعداد اعضای مجموعه می‌باشد.

پس از آنکه برای تمامی نقاط قطع آنتروپی اطلاعات کلاسی را محاسبه نمودیم، نقطه قطعی که آنتروپی اطلاعات آن از همه کمتر باشد را در نظر گرفته و زیر مجموعه‌های حاصل از آن (S_1 و S_2) و آنتروپی حاصل از آنها و مجموعه S ذخیره می‌شود، اما تنها هنگامی می‌توان آن را به عنوان نقطه قطع حقیقی پذیرفت که در شرط MDLPC^۱ [۵۹] صدق کند (رابطه (۵-۳))

$$\text{Gain}(A, T; S) > \frac{\log_2(N-1)}{N} + \frac{\Delta(A, T; S)}{N} \quad (۳-۵)$$

به طوریکه:

$$\text{Gain}(A, T; S) = \text{Ent}(S) - \frac{|S_1|}{N} \text{Ent}(S_1) - \frac{|S_2|}{N} \text{Ent}(S_2) \quad (۴-۵)$$


$$\Delta(A, T; S) = \log_2(3^k - 2) - [k \text{Ent}(S) - k_1 \text{Ent}(S_1) - k_2 \text{Ent}(S_2)] \quad (۵-۵)$$

k_1 ، k_2 و k به ترتیب بیانگر تعداد کلاس‌های متمایز موجود در مجموعه S_1 ، S_2 و S می‌باشند.

هر نقطه قطع مجموعه S را به دو زیر مجموعه S_1 و S_2 تفکیک می‌کند و در ادامه هر یک از این زیر مجموعه‌ها خود یک مجموعه جدید S در نظر گرفته شده و روال فوق به صورت بازگشتی بر روی آن‌ها اجرا می‌شود تا جایی که دیگر نتوانیم نقطه قطع جدیدی برای این ستون ویژگی بیابیم. آنگاه نقاط قطع (T ها) هر ستون ویژگی را ذخیره می‌کنیم. برای تمامی ستون‌های ویژگی به همین روش

^۱ Minimum Description Length Principle

عمل می‌کنیم. نقاط قطع هر ستون ویژگی را به تعدادی دسته تقسیم بندی کرده و بر اساس احتمال وجود هر کلاس در دسته‌ها، می‌توان آنها را به نام کلاسی که بیشترین احتمال را دارد نامگذاری کرد [۶۲]. برای مثال در شکل زیر سه نقطه قطع بدست آمده است که در نتیجه ۴ دسته وجود دارد که احتمال کلاس‌های ۱ و ۲ در هر دسته با P_1 و P_2 مشخص شده‌اند. مثلاً در دسته اول $P_1=0.3$ و $P_2=0.7$ است. در نتیجه $P_2 > P_1$ بوده و بنابراین این دسته را کلاس ۲ می‌نامیم.



شکل (۵-۱): مثالی از گسسته‌سازی چند بازه‌ای برای یک ویژگی

۵-۱-۲- رتبه‌بندی ویژگی‌ها

برای کلاسه‌بندی هر داده EEG توسط گسسته‌سازی چند بازه‌ای لازم است تا هر ویژگی بدست آمده برای این داده را با نقاط قطع بدست آمده برای همان ویژگی مقایسه نموده و در یکی از دسته‌ها دسته‌بندی کرده و احتمال کلاس‌ها را برای هر ویژگی بدست آورد. در نهایت احتمال هر کلاس برای این داده برابر با حاصلضرب احتمالات بدست آمده از هر کدام از ویژگی‌ها برای آن کلاس می‌باشد. همانطور که بیان شد در این روش تعداد ویژگی‌ها زیاد بوده و بدلیل همبستگی بین ویژگی‌ها تمامی آنها اطلاعات مفید برای جداسازی دو کلاس نخواهند داشت. بنابراین لازم است تا ویژگی‌ها پالایش شوند.

برای تعیین مناسب‌ترین ویژگی‌ها برای کلاسه‌بندی کلاس‌ها می‌توان از روشی که توسط M. Hall و G. Holmes در مرجع [۶۰] ارائه شد استفاده کرد. این روش پیشنهادی به این صورت است که ابتدا توسط داده‌های آموزشی دسته دوم و با استفاده از نقاط قطعی که در مرحله گسسته‌سازی

چند بازه‌ای بدست آوردیم، درصد صحت کلاسه‌بندی را برای هر ویژگی به تنهایی محاسبه نماییم. ویژگی که ماکزیمم نتیجه را داشت رتبه یک می‌گیرد.

برای بهبود درصد صحت تشخیص می‌توان از سایر ویژگی‌ها به صورت ترکیبی با ویژگی دارای رتبه یک بهره برد. برای این منظور ترکیب دوتایی هر یک از ویژگی‌ها را با ویژگی رتبه یک در نظر گرفته و درصد صحت تشخیص زبان را برای هر کدام بدست می‌آوریم. به ویژگی که به ازای آن ماکزیمم نتیجه بدست آمد رتبه دو داده می‌شود. ماکزیمم نتیجه را با درصد صحت حاصل از ویژگی یک به تنهایی مقایسه کرده اگر تلفیق ویژگی رتبه یک و دو نتیجه بهتری داشت ویژگی رتبه دو را به عنوان ویژگی مناسب می‌پذیریم و در غیر این صورت به ویژگی رتبه یک اکتفا می‌کنیم. این روند را با تلفیق سه تایی و بیشتر ویژگی‌ها ادامه می‌دهیم تا جایی که دیگر درصد صحت تشخیص نسبت به حالت قبل بهبود نیابد. با این روند بهترین مجموعه ویژگی‌ها برای کلاسه‌بندی کلاس‌ها یافته می‌شوند [۶۲].

این روش کاهش ویژگی از سرعت بالایی برخوردار بوده، اما متأسفانه این روش نیز مانند بسیاری از روش‌های کاهش ویژگی ممکن است در دام مینییم‌های محلی بیفتد.

۵-۱-۳- استفاده از تکنیک گسسته‌سازی چند بازه‌ای و رتبه‌بندی ویژگی‌ها

برای کلاسه‌بندی دو کلاس تصور حرکتی

این روش نیز مانند تمامی روش‌های تشخیص الگو شامل دو مرحله آموزش و تست می‌باشد که در این بخش هر کدام از آنها توضیح داده خواهد شد. در این روش برای مرحله آموزش به دو دسته داده نیاز داریم. بنابراین کل داده‌های آموزشی و تست مجموعه داده 2a را به سه قسمت مساوی تقسیم نموده و دو مجموعه را برای آموزش و یک مجموعه را برای تست به کار می‌بریم. از دو مجموعه آموزش برای اجرای CSP و بدست آوردن فیلترهای فضایی استفاده می‌کنیم. دوباره از مجموعه اول برای گسسته‌سازی چند بازه‌ای و بدست آوردن نقاط قطع استفاده می‌شود. مجموعه دوم را برای رتبه-


بندی ویژگی‌ها و یافتن ویژگی‌های مناسب برای کلاسه‌بندی کلاس‌ها استفاده می‌کنیم. در ادامه بخش به توضیح روند مراحل آموزش و تست خواهیم پرداخت. روش پیشنهادی در این قسمت را SEG-CSP-BP نامیده‌ایم.

۵-۱-۳-۱- مرحله آموزش

همانطور که در قسمت قبل بیان شد در این روش دو مجموعه داده آموزشی مورد نیاز است. روند اجرای مرحله آموزش در شکل (۵-۲) مشاهده می‌شود.

مرحله آموزش این روش شامل گام‌های زیر است:

- پیش پردازش داده‌های آموزشی: مطابق آنچه در بخش ۳-۴ آورده شد انجام می‌پذیرد.
- اجرای روش CSP: از هر دو مجموعه داده آموزشی اول و دوم برای اجرای روش CSP و به منظور کاهش تعداد کانال استفاده می‌شود. در این مرحله از روش قطعه‌بندی زمانی در روش



شکل (۵-۲): روند اجرای مرحله آموزش در روش SEG-CSP-BP

CSP (روش پیشنهادی در فصل چهارم که SEG-CSPVar نامیده شد) استفاده شده است.

در اینجا $m=8$ در نظر گرفته شده اما طول بازه‌ها متغیر بوده و مقدار بهینه آن برای هر شخص با توجه به ماکزیمم نتیجه کلاسه‌بندی بدست می‌آید.

▪ **به دست آوردن ویژگی‌ها از مجموعه داده اول:** برای بدست آوردن ویژگی‌ها مانند روش SEG-CSP-Var، که در بخش ۴-۲-۱ توضیح داده شد، عمل می‌کنیم. در اینجا به جای واریانس نرمالایز شده از توان باندهای فرکانسی ۲، ۴، ۸ و ۱۶ هرتزی به عنوان ویژگی در هر بازه زمانی استفاده می‌کنیم (مانند مرجع [۱۵]).

▪ **اعمال معیار فیشر^۱ بر روی ویژگی‌ها:** بعد از بدست آوردن ویژگی‌ها معیار فاصله فیشر بر روی آنها اعمال می‌شود. ۲۰۰ ویژگی دارای که دارای بیشترین مقدار فاصله فیشر می‌باشند انتخاب شده و به مرحله بعد راه می‌یابند. فاصله فیشر برای هر ویژگی در دو کلاس طبق رابطه (۵-۶) محاسبه می‌شود [۶۳]. در این رابطه μ_i و σ_i به ترتیب میانگین و واریانس ویژگی در کلاس i هستند.

$$F = \frac{(\mu_1 - \mu_2)^2}{\sigma_1^2 + \sigma_2^2} \quad \text{▪} \quad (۵-۶)$$

▪ **اجرای گسسته سازی چند بازه‌ای:** این الگوریتم بر روی ویژگی‌های بدست آمده از مرحله قبل اجرا می‌شود.

▪ **رتبه‌بندی و انتخاب ویژگی‌ها:** در این مرحله ویژگی‌های مناسب برای جداسازی کلاس‌ها توسط مجموعه داده آموزشی دوم مطابق با بخش ۵-۱-۲ انتخاب می‌گردند.

¹ Fisher discriminant analysis

۵-۱-۳-۲- مرحله ارزیابی

▪ پردازش اولیه داده تست: مطابق با آنچه در مرحله آموزش انجام شده است صورت می-پذیرد.

▪ بازه‌بندی زمانی و اعمال فیلترهای فضایی: فیلترهای فضایی مربوطه، به هر بازه اعمال شده و ویژگی‌ها از هر بازه زمانی استخراج می‌شود. بردار ویژگی نهایی مطابق آنچه در بخش ۴-۱-۲-۲ آورده شد بدست می‌آید.

▪ کلاسه‌بندی بردار ویژگی: برای کلاسه‌بندی ویژگی‌ها تنها از همان ویژگی‌های مشخص شده در مرحله رتبه‌بندی داده‌ها استفاده می‌شود. برای کلاسه‌بندی هر داده EEG توسط گسسته‌سازی چند بازه‌ای لازم است تا ویژگی‌های مشخص شده را با نقاط قطع بدست آمده برای همان ویژگی مقایسه نموده و در یکی از دسته‌ها دسته‌بندی کرده و احتمال کلاس‌ها را برای هر ویژگی بدست آورد. در نهایت احتمال هر کلاس برای این داده برابر با حاصلضرب احتمالات بدست آمده از هر کدام از ویژگی‌ها برای آن کلاس می‌باشد. برچسب داده برابر است با کلاسی که احتمال آن بیشتر است.

۵-۱-۴- نتایج روش SEG-CSP-BP برای کلاسه‌بندی دو کلاس تصور حرکتی

دست چپ و راست

در این بخش نیز مانند روش بازه‌بندی زمانی در CSP (SEG-CSP-Var) روش مطرح شده در این قسمت را برای طول بازه‌های ۱، ۱/۵، ۲، ۲/۵ و ۳ ثانیه اجرا کرده و جابه‌جایی زمانی برای پنجره-های زمانی متوالی را ۰/۵ ثانیه در نظر می‌گیریم (شکل (۴-۶)). در این قسمت $m=8$ در نظر گرفته شده است.

نتایج روش SEG-CSP-BP در کلاسه‌بندی دو کلاس تصور حرکتی دست چپ و دست راست به ازای طول بازه‌های متفاوت برای هر ۹ شخص در جدول (۵-۱) مشاهده می‌شود.

در جدول (۵-۲) بهترین نتیجه برای هر شخص روش SEG-CSP-BP به همراه نتایج روش SEG-CSP-Var از جدول (۴-۶) مقایسه شده‌اند.


برای مقایسه روش پیشنهادی خود با این دو روش، CSP متداول را با شرایط یکسان یعنی با همان پیش پردازش و بازه زمانی ۲/۵ تا ۵/۵ ثانیه و کلاسه‌بند LDA برای کلاسه‌بندی دو کلاس تصور حرکت دست چپ و دست راست اجرا کردیم. در روش CSP متغیر m را برای هر شخص از ۱ تا ۸ تغییر داده و m ای را که به ازای آن ماکزیمم نتیجه بدست آمد برگزیدیم.

جدول (۵-۱): نتایج روش SEG-CSP-BP به ازای طول بازه‌های متفاوت در کلاسه‌بندی تصور حرکتی دست چپ و دست راست

۱ ثانیه	۱/۵ ثانیه	۲ ثانیه	۲/۵ ثانیه	۳ ثانیه	
۹۱/۴۹	۸۷/۷۳	۹۴/۷۰	۸۷/۱۳	۸۳/۱۷	شخص ۱
۶۶/۰۰	۷۹/۵۸	۷۳/۲۴	۷۰/۰۰	۶۲/۰۰	شخص ۲
۹۳/۰۰	۹۴/۰۰	۹۶/۷۰	۹۸/۸۶	۹۷/۰۰	شخص ۳
۷۵/۰۰	۷۹/۱۴	۷۱/۰۵	۷۶/۴۵	۷۱/۰۵	شخص ۴
۵۴/۵۵	۶۴/۰۰	۶۱/۶۷	۶۶/۰۰	۶۵/۶۶	شخص ۵
۶۲/۰۰	۶۵/۰۰	۷۱/۰۰	۷۰/۰۰	۷۹/۰۰	شخص ۶
۸۳/۰۰	۸۴/۰۰	۸۷/۰۰	۷۵/۰۰	۸۱/۰۰	شخص ۷
۹۴/۰۰	۹۶/۰۰	۹۹/۲۵	۹۷/۶۷	۹۶/۰۰	شخص ۸
۹۲/۰۰	۹۵/۰۰	۹۵/۰۰	۹۶/۰۰	۹۴/۰۰	شخص ۹

جدول (۵-۲): نتایج سه روش CSP, SEG-CSP-BP, SEG-CSP-Var در کلاسه‌بندی دو کلاس تصور حرکتی دست چپ و دست راست

روش شخص	CSP (m)	SEG-CSP-Var (طول قطعه و m)	SEG-CSP-BP (طول قطعه)
شخص ۱	۹۱/۴۸ (۱)	۹۳/۶۳ (۱/۵ S و ۱)	۹۴/۷۰ (۲ S)
شخص ۲	۵۴/۹۲ (۲)	۶۷/۶۱ (۱/۵ S و ۳)	۷۹/۵۸ (۱/۵ S)
شخص ۳	۹۷/۰۸ (۲)	۹۷/۸۱ (۳ S و ۵)	۹۸/۸۶ (۲/۵ S)
شخص ۴	۷۳/۲۸ (۲)	۷۷/۵۹ (۲ S و ۳)	۷۹/۱۴ (۱/۵ S)
شخص ۵	۵۹/۲۶ (۸)	۶۳/۷۰ (۱ S و ۳)	۶۶/۰۰ (۲/۵ S)
شخص ۶	۶۹/۴۴ (۴)	۷۷/۲۱ (۸ S و ۰/۵)	۷۹/۰۰ (۳ S)
شخص ۷	۷۷/۱۴ (۳)	۸۷/۱۴ (۱/۵ S و ۳)	۸۷/۰۰ (۲ S)
شخص ۸	۹۸/۵۰ (۳)	۹۹/۲۵ (۲ S و ۵)	۹۹/۲۵ (۲ S)
شخص ۹	۹۰/۷۶ (۴)	۹۷/۰۸ (۱ S و ۳)	۹۶/۸۰ (۲/۵ S)
متوسط	۷۹/۱۰	۸۴/۵۶	۸۶/۷۰



شکل (۵-۳): مقایسه نتایج روش CSP, SEG-CSP-Var و SEG-CSP-BP در کلاسه‌بندی تصور حرکتی دست چپ و دست راست

نتایج سه روش جدول (۵-۲) در نمودار میله‌ای شکل (۵-۳) در کنار هم آورده شده است. همانطور که در این نمودار مشاهده می‌شود هر دو روش SEG-CSP-Var و SEG-CSP-BP در همه موارد از روش CSP متداول جواب‌های بهتری داشته‌اند. همچنین روش SEG-CSP-BP به طور متوسط نتایج بهتری از روش CSP و SEG-CSP-Var دارد.

۵-۱-۴- تعمیم روش SEG-CSP-BP به مسئله چهار کلاس

برای تعمیم این روش به مسئله با تعداد کلاس‌های بیشتر از دو می‌توان از روش‌های مربوط به CSP استفاده کرد. ما برای این منظور نیز از روش OVR [۱۴] استفاده نموده و روش پیشنهادی را OVR-SEG-CSP-BP نامیده‌ایم.

در این قسمت نیز قبل از هر کاری باید پردازش اولیه بر روی داده‌های آموزشی صورت گیرد. برای تعمیم روش پیشنهادی به چهار کلاس نیز مانند روش متداول OVR-CSP، لازم است تا چهار کلاس‌بند وجود داشته باشد. هر کدام از کلاس‌بندها یک کلاس را نسبت به بقیه کلاس‌ها دسته‌بندی می‌کند. در روش چهار کلاس، هر کلاس‌بند باید به طور جدا آموزش داده شود. هر کلاس‌بند یک مسئله دو کلاس است که طریقه آموزش آن در قسمت ۵-۱-۳ توضیح داده شد. مثلاً کلاس‌بند اول، کلاس ۱ را نسبت به بقیه کلاس‌ها جداسازی می‌کند. در نتیجه مانند روش OVR-CSP ماتریس کواریانس متوسط کلاس دوم در هر قطعه زمانی برابر با مجموع ماتریس کواریانس بقیه کلاس‌ها در همان قطعه است (رابطه (۲-۱)).

برای هر کلاس‌بند لازم است تا مراحل گسسته‌سازی چند بازه‌ای و رتبه‌بندی ویژگی‌ها به طور جدا انجام گیرد. نقاط قطع و مجموعه ویژگی‌های لازم برای جداسازی هر کلاس نسبت به بقیه برای هر کلاس‌بند در مرحله آموزش بدست آمده و ذخیره می‌شود.

در مرحله ارزیابی، هر داده تست با چهار کلاس‌بند روبروست که بعد از مراحل پردازش اولیه و قطعه‌بندی، بردار ویژگی مربوط به آن کلاس‌بند توسط ماتریس‌های W در هر کلاس‌بند به دست می‌-

آید. ویژگی‌های دارای رتبه بالاتر مربوط به این کلاسه‌بند برداشته شده و توسط نقاط قطع مربوط به هر کدام، کلاس نهایی و احتمال آن ثبت می‌شود.

نهایتاً چهار نتیجه کلاسه‌بندی داریم که داده تست را با ۴ احتمال جزء کلاس ۱ تا ۴ قرار می‌دهد. کلاس نهایی مربوط به نتیجه‌ای است که احتمال بیشتری دارد [۱۵].

۵-۱-۵- نتایج روش OVR-SEG-CSP-BP برای مسئله چهار کلاسه

کل بازه انتخابی، از نیم ثانیه قبل از تصور حرکتی تا ۲/۵ ثانیه بعد از آن در نظر گرفته شده است. از آنجایی که آزمایشات BCI منحصر به فرد است، برای هر شخص باید بازه مناسب را بدست می‌آوریم. برای این منظور بازه‌های زمانی ۱، ۱/۵، ۲، ۲/۵ و ۳ برای هر شخص مورد مطالعه قرار گرفت. میزان جابه‌جایی شروع پنجره‌های متوالی نیز ۰/۵ ثانیه در نظر گرفته شده است.

در این قسمت $m=8$ در نظر گرفته شده است یعنی در تمام قطعات زمانی به تعداد ۱۶ فیلتر فضایی انتخاب می‌شود. نتایج روش پیشنهادی به ازای طول بازه‌های مختلف برای هر ۹ شخص در جدول (۳-۵) آورده شده است.

از جدول (۳-۵) مشهود است که بهترین نتیجه برای تمامی موارد در طول بازه‌های ۲/۵ و ۳ ثانیه بدست آمده است.

ماکزیمم نتایج به همراه طول بازه مربوط به آن به عنوان طول بازه بهینه برای هر شخص در جدول (۴-۵) با نام روش OVR-SEG-CSP-BP آورده شده است.

نتایج روش OVR-SEG-CSP-BP به همراه نتایج روش OVR-SEG-CSP-Var از جدول (۴-۴)

۸، روش OVR-CSP از جدول (۳-۳) و دونفر برتر مسابقه ۲۰۰۸ از جدول (۱-۳) در شکل (۴-۵) مقایسه شده‌اند.

جدول (۳-۵): نتایج روش OVR-SEG-CSP-BP به ازای طول بازه‌های متفاوت در کلاسه‌بندی داده‌های چهار کلاس تصور حرکتی


	۱ ثانیه	۱/۵ ثانیه	۲ ثانیه	۲/۵ ثانیه	۳ ثانیه
شخص ۱	۰/۶۸	۰/۷۸	۰/۷۸	۰/۷۸	۰/۷۵
شخص ۲	۰/۳۴	۰/۳۴	۰/۳۶	۰/۴۰	۰/۴۲
شخص ۳	۰/۷۸	۰/۷۸	۰/۸۳	۰/۷۸	۰/۸۹
شخص ۴	۰/۵۳	۰/۴۶	۰/۵۳	۰/۵۶	۰/۵۹
شخص ۵	۰/۲۵	۰/۲۵	۰/۲۹	۰/۳۱	۰/۳۵
شخص ۶	۰/۳۳	۰/۳۳	۰/۳۴	۰/۳۸	۰/۳۴
شخص ۷	۰/۶۰	۰/۶۹	۰/۶۷	۰/۶۵	۰/۷۲
شخص ۸	۰/۷۲	۰/۷۱	۰/۷۰	۰/۶۳	۰/۷۷
شخص ۹	۰/۶۷	۰/۶۷	۰/۶۹	۰/۷۲	۰/۷۵

جدول (۴-۵): بهترین نتایج بدست آمده از روش OVR-SEG-CSP-BP به همراه طول بازه مربوطه در کلاسه‌بندی چهار کلاس تصور حرکتی

	شخص ۱	شخص ۲	شخص ۳	شخص ۴	شخص ۵	شخص ۶	شخص ۷	شخص ۸	شخص ۹
کاپا	۰/۷۸	۰/۴۲	۰/۸۹	۰/۵۹	۰/۳۵	۰/۳۸	۰/۷۲	۰/۷۷	۰/۷۵
طول بازه	۲/۵ s	۳ s	۳ s	۳ s	۳ s	۲/۵ s	۳ s	۳ s	۳ s
متوسط	۰/۶۳								

همانطور که از شکل (۴-۵) پیداست روش OVR-SEG-CSP-BP در ۶ مورد جواب بهتری از روش OVR-SEG-CSP-Var داشته است. این روش در تمامی موارد از روش CSP متداول نتایج بهتری داشته است.

OVR-SEG-CSP-BP به طور متوسط از بقیه روش‌ها موفقیت بیشتری در کلاسه‌بندی داده‌های EEG ناشی از تصور حرکتی در مسئله چهار کلاسه داشته است.



شکل (۴-۵): مقایسه نتایج روش‌های OVR-SEG-CSP-BP, OVR-SEG-CSP-Var, OVR-CSP و دو نفر برتر مسابقه در کلاسه‌بندی داده‌های EEG ناشی از تصور حرکتی چهار کلاسه

۵-۲- استفاده از مدل مخلوط توابع گوسی (GMM) برای تشخیص

داده‌های EEG ناشی از تصور حرکتی

همانطور که در فصل‌های قبل بیان شد انرژی باندهای فرکانسی مختلف در طول تصور حرکتی پایدار نبوده و در طول زمان تغییر می‌کند. در فصل چهارم روش قطعه‌بندی زمانی در روش CSP مطرح شد که نتایج آن به طور متوسط از نتایج CSP متداول بهتر بود. در بخش ۵-۱ نیز روشی دیگر پیشنهاد دادیم که در آن به جای ویژگی واریانس از ویژگی‌های فرکانس استفاده کردیم. در این روش از توان باندهای فرکانسی مختلف در پنجره‌های زمانی استفاده شده و سپس تعداد کمی از ویژگی‌ها به عنوان ویژگی‌های مناسب برای کلاسه‌بندی انتخاب شد. نتایج این روش به طور متوسط از روش مبتنی بر ویژگی واریانس بهتر می‌باشد. با مشاهده نتایج خوب این روش به این نتیجه رسیدیم که اطلاعات حوزه زمان در کنار اطلاعات حوزه فرکانس می‌تواند در بهبود نتایج مؤثر واقع شود. بنابراین به فکر افتادیم تا از توزیع زمان-فرکانس سیگنال‌های EEG استفاده کنیم اما سؤال مطرح شده این است که چه نوع ویژگی باید از این توزیع‌ها استخراج شود؟

در اکثر مقالاتی که در زمینه BCI از توزیع زمان-فرکانس سیگنال‌ها استفاده کرده‌اند [۳۹ و ۴۰]، از سطح زیر نمودار توزیع زمان-فرکانس (TFD) سیگنال‌ها در باندهای فرکانسی مختلف به عنوان ویژگی استفاده شده است. با اینکار اطلاعات زمانی سیگنال‌ها نادیده گرفته می‌شود. به همین دلیل تصمیم گرفتیم تا بطور جزئی‌تر به باندهای فرکانسی مختلف نگاه کرده و اطلاعات زمانی را در کنار اطلاعات فرکانسی در نظر بگیریم و با روش مطرح شده در این مقالات مقایسه کنیم.

پیشنهاد ما به این صورت می‌باشد که توسط روش GMM مدلی برای توزیع زمان-فرکانس سیگنال‌ها در فضای دو بعدی زمان و فرکانس بدست آورده و سپس از یک معیار فاصله برای کلاسه‌بندی توابع چگالی احتمال بدست آمده برای هر داده تست ورودی استفاده کنیم. در ادامه ابتدا توضیح مختصری راجع به GMM آورده و سپس به توضیح روش پیشنهادی با نام CSP-GMM می‌پردازیم.

۵-۲-۱- مدل مخلوط توابع گوسی (GMM)

مخلوط توابع گوسی (GMM) تابع چگالی احتمال (PDF) بردارهای ویژگی را توسط ترکیبی از چند تابع گوسی وزن دار مدل می‌کند. در حقیقت GMM مجموعی از K تابع گوسی متفاوت است که هر کدام از این توابع دارای یک وزن خاص هستند. برای هر بردار ویژگی $X \in R^d$ مدل تلفیقی به صورت رابطه (۷-۵) تعریف می‌شود [۶۴].

$$f(X|\theta) = \sum_{j=1}^K \alpha_j N(X|\mu_j, \Sigma_j) \quad (۷-۵)$$

$$N(X|\mu_j, \Sigma_j) = \frac{1}{2\pi^{d/2} |\Sigma_j|^{1/2}} \exp \left\{ -\frac{1}{2} (X - \mu_j)^T \Sigma_j^{-1} (X - \mu_j) \right\} \quad (۸-۵)$$

پارامتر θ به صورت $\theta = \{\alpha_j, \mu_j, \Sigma_j\}_{j=1}^K$ تعریف می‌شود بطوریکه:

▪ $\alpha_j > 0$ وزن تابع گوسی j ام می‌باشد بطوریکه $\sum_{j=1}^K \alpha_j = 1$ است.

▪ $\mu_j \in R^d$ میانگین تابع گوسی j ام است.

▪ Σ_j ماتریس کواریانس تابع گوسی j ام است که دارای ابعاد $d \times d$ می‌باشد.

برای مجموعه‌ای از بردارهای ویژگی $X_1, X_2, \dots, X_n$ و تخمین ماکزیمم احتمال^۱ از پارامترهای

مجهول θ برای تابع احتمال $L(\cdot)$ برابر است با:

$$\theta_{ML} = \operatorname{argmax}_{\theta} L(\theta|X_1, X_2, \dots, X_n) = \operatorname{argmax}_{\theta} \sum_{i=1}^n \log f(X_i, \theta) \quad (۹-۵)$$

الگوریتم‌های زیادی برای تخمین پارامترهای مدل GMM یعنی θ_{ML} وجود دارد. الگوریتمی که

بیشتر مورد استفاده قرار می‌گیرد الگوریتم EM^۲ است [۶۵]. EM یک الگوریتم بازگشتی است که از

یک مقدار اولیه برای θ شروع کرده و در هر بار تکرار این پارامتر را بروز رسانی می‌کند تا همگرا شود.

بروز رسانی پارامترها در تکرار t ام در دو مرحله پیش‌بینی^۳ (E) و ماکزیمم سازی^۴ (M) صورت می‌-

پذیرد که به صورت زیر می‌باشند [۶۴].

^۱ Maximum likelihood

^۲ Expectation Maximization

^۳ Expectation

^۴ Maximization

▪ مرحله پیش‌بینی:

در این مرحله احتمال‌های پسین^۱ W_{ij} محاسبه می‌شود. این احتمال بیان می‌دارد بردار ویژگی X_i با چه احتمالی جزئی از تابع گوسی λ ام در تکرار t ام است.

$$W_{ij} = \frac{\alpha_j^t f(X_i | \mu_j^t, \Sigma_j^t)}{\sum_{i=1}^K \alpha_i^t f(X_i | \mu_i^t, \Sigma_i^t)} \quad (۱۰-۵)$$

▪ مرحله ماکزیمم‌سازی:

در این مرحله پارامترهای تکرار $t+1$ ام مطابق روابط زیر بدست می‌آیند.

$$\alpha_j^{t+1} = \frac{1}{n} \sum_{i=1}^n W_{ij} \quad (۱۱-۵)$$

$$\mu_j^{t+1} = \frac{\sum_{i=1}^n W_{ij} X_i}{\sum_{i=1}^n W_{ij}} \quad (۱۲-۵)$$

$$\Sigma_j^{t+1} = \frac{\sum_{i=1}^n W_{ij} (X_i - \mu_j^{t+1})(X_i - \mu_j^{t+1})^T}{\sum_{i=1}^n W_{ij}} \quad (۱۳-۵)$$

ماتریس‌های کواریانس توابع می‌توانند قطری باشند. در این صورت ویژگی‌ها مستقل از هم می‌باشند [۶۳]. اگر ماتریس کواریانس‌ها را قطری در نظر بگیریم، پیچیدگی محاسباتی در روش GMM کاهش یافته و سرعت این روش بالاتر می‌رود.

در تکرار اول روش بهینه‌سازی EM نیاز به یک نقطه شروع می‌باشد. یکی از روش‌های بدست آوردن نقطه شروع استفاده از خوشه‌بندی به روش K-means است. یعنی داده‌ها به روش K-means دسته‌بندی شده و میانگین داده‌ها در هر دسته و برچسب داده‌ها استخراج می‌شود. توسط داده‌هایی که در هر دسته قرار می‌گیرند می‌توان ماتریس کواریانس ویژگی‌ها در هر دسته را بدست آورد. البته می‌توان مراکز خوشه‌ها را در شروع به روش تصادفی نیز انتخاب کرد. در این روش K بردار ویژگی به عنوان مراکز دسته‌ها در نظر گرفته می‌شوند. وزن‌های تمامی توابع بطور مساوی $\frac{1}{K}$ قرار داده می‌شوند. ماتریس کواریانس دسته‌ها برای همه یکسان و قطری در نظر گرفته می‌شود. عنصر λ ام روی قطر اصلی ماتریس کواریانس برابر با واریانس ویژگی λ ام برای تمامی داده‌های آن دسته است.

^۱ posterior probability

۵-۲-۲- روش CSP-GMM برای کلاسه‌بندی داده‌های EEG دو کلاسه

در این قسمت از دو کلاس تصور حرکتی دست چپ و دست راست برای هر نه شخص استفاده شده است. این روش نیز دارای دو مرحله آموزش و ارزیابی است که در ادامه به توضیح آن می‌پردازیم.

۵-۲-۲-۱- مرحله آموزش

قبل از اجرای روش پیشنهادی مرحله پیش پردازش را که در بخش ۳-۴ توضیح داده شد بر روی داده‌ها اجرا می‌کنیم. بعد از این مرحله ابتدا به منظور کاهش تعداد کانال‌ها و یافتن مناسب‌ترین کانال‌ها برای جداسازی دو کلاس، از روش CSP استفاده شده است. تعداد فیلترهای فضایی در این روش ۴ در نظر گرفته شده است ($m=2$). بعد از اعمال فیلترهای فضایی انتخاب شده (مطابق رابطه (۲-۵)) چهار سیگنال ثانویه مناسب برای جداسازی کلاس‌ها بدست می‌آید.

در مرحله بعد توزیع زمان-فرکانس (TFD) چهار سیگنال ثانویه را بدست می‌آوریم. برای بدست آوردن TFD سیگنال‌ها از تبدیل موجک پیوسته با تابع مادر مارلت مختلط^۱ با فرکانس مرکزی $f_c=1$ و پهنای باند $f_b=2$ استفاده شده است. این نوع موجک در تحقیقات BCI به کار رفته و نتایج خوبی در این زمینه داشته است [۴۷-۴۹]. تابع مادر موجک مارلت مختلط به صورت رابطه زیر تعریف می‌شود:

$$\psi(t) = \frac{1}{\sqrt{\pi f_b}} \exp(2\pi j f_c t) \exp\left(-\frac{t^2}{f_b}\right) \quad (۱۴-۵)$$

توزیع زمان-فرکانس سیگنال X برابر است با دامنه کانولوشن X و تابع موجک که به صورت رابطه (۱۴-۵) تعریف می‌شود. اگر سیگنال مربوط به کانال k ام را با X^k نشان دهیم، $\chi_{t,f}^k$ توزیع زمان-فرکانس آن سیگنال در زمان t و فرکانس f بوده و توسط رابطه (۱۴-۵) محاسبه می‌شود.


$$\chi_{t,f}^k = \left\| \psi_{f,t} * X_t^k \right\| \quad (۱۵-۵)$$

^۱ Complex Morlet


در این تحقیق نرخ نمونه‌برداری داده‌های EEG مور استفاده ۲۵۰ هرتز بوده که در مرحله پیش پردازش به ۱۰۰ هرتز کاهش یافت. با این اوصاف در ۳ ثانیه مورد نظر، از ۰/۵ ثانیه قبل از تصور حرکتی تا ۲/۵ ثانیه بعد از آن، ۳۰۰ نمونه زمانی وجود دارد. همچنین محدوده فرکانسی موردنظر از ۸ تا ۳۰ هرتز در نظر گرفته شده است. بنابراین به تعداد 30×300 نمونه در حوزه زمان-فرکانس وجود دارد. نمونه‌ای از TFD یکی از کانال‌ها بعد از فیلترینگ توسط فیلترهای فضایی در شکل (۵-۵) نشان آورده شده است. از آنجایی که تعداد نمونه‌ها در حوزه زمان-فرکانس زیاد است، به منظور افزایش سرعت در مراحل بعد روش پیشنهادی از کاهش نرخ نمونه برداری در حوزه زمان بعد از بدست آوردن TFD ها استفاده شده است. برای این منظور بعد از بدست آوردن TFD کانال k مطابق رابطه (۵-۱۵) از هر ۱۰ نمونه زمانی یکی را نگه می‌داریم.

$$\tilde{\chi}^k(t, f) = \chi^k(10t, f), \quad t=1, 2, \dots, 30 \quad (5-16)$$

در شکل (۵-۶) TFD کانال شکل (۵-۵) بعد از کاهش تعداد نمونه‌ها در حوزه زمان را مشاهده کنید.



شکل (۵-۵): TFD یک کانال فیلتر شده توسط فیلترهای فضایی مربوط به تصور حرکتی دست چپ شخص ۱




شکل (۵-۶): TFD یک کانال فیلتر شده توسط فیلترهای فضایی در تصور حرکتی دست چپ مربوط به شخص ۱ بعد از کاهش تعداد نمونه‌های زمانی

بعد از بدست آوردن TFD برای هر چهار سیگنال فیلتر شده توسط فیلترهای فضایی و کاهش تعداد نمونه‌های آن‌ها در حوزه زمان، تمامی آن‌ها را طبق رابطه (۵-۱۷) در کنار آن قرار داده و ماتریس P را بدست می‌آوریم. هر کدام از TFD ها دارای ابعاد 23×30 می‌باشند در نتیجه ماتریس P دارای ابعاد 23×120 می‌باشد. یک نمونه از ماتریس P برای تصور حرکتی دست چپ در یک آزمایش در شکل (۵-۷-الف) نشان داده شده است.


$$P = [\tilde{\chi}^1 \tilde{\chi}^2 \tilde{\chi}^3 \tilde{\chi}^4] \quad (۵-۱۷)$$

قرار است در این پایان‌نامه PDF ماتریس‌های P بدست آمده از تمامی داده‌های آموزشی را توسط روش GMM بدست آوریم. اما برای بدست آوردن مخلوط گوسی‌ها نیاز به بردارهای ویژگی به عنوان ورودی داریم. ما در این تحقیق به هر نقطه در صفحه زمان-فرکانس به عنوان یک الگو نگریستیم. طیف قرمز رنگ به معنای احتمال بیشتر حضور یک الگو در آن ناحیه است و طیف آبی رنگ احتمال بیشتر برای عدم حضور را نشان می‌دهد.


(الف)



(ب)



(ج)



شکل (۵-۷): (الف) نمونه‌ای از ماتریس P مربوط به تصور حرکتی دست چپ
(ب) شکل (الف) در دو سطح باینری (ج) شکل (الف) در ۵ سطح

اگر یک مقدار آستانه به اندازه متوسط بیشترین و کمترین مقدار موجود در ماتریس‌های P بدست آمده از تمامی داده‌های آموزشی در نظر بگیریم و مقادیر بالاتر این مقدار آستانه را برابر یک و مقادیر کمتر را برابر صفر قرار دهیم، تصاویر باینری نظیر شکل (۵-۷-ب) بدست می‌آید.

سطح ۱ در یک ناحیه از شکل (۵-۷-ب) به معنای وجود الگو و سطح صفر به معنای عدم حضور الگو در آن ناحیه است. ویژگی الگوها را مؤلفه‌های زمان و فرکانس (t, f) در نظر گرفتیم.

برای تخمین دقیق‌تر PDF این الگوها به جای دو سطح از ۵ سطح استفاده شده است. به این صورت که ماکزیمم مقدار را معادل عدد ۴ در نظر گرفته و بقیه ماتریس را مطابق با آن کوانتیزه می‌کنیم. در نتیجه تصویرهایی با ۵ سطح بدست می‌آید (شکل (۵-۷-ج)).

برای بدست آوردن مدل مخلوط توابع گوسی به عنوان PDF دو بعدی لازم است تا ماتریس ویژگی‌ها را به عنوان ورودی برنامه بدست آوریم. همانطور که گفتیم ویژگی‌ها مؤلفه (t, f) الگوها یعنی نقاط در فضای زمان-فرکانس می‌باشند. هر چه یک نقطه دارای مقدار بیشتر باشد یعنی احتمال حضور آن نقطه در فضای زمان-فرکانس بیشتر است بنابراین تابع چگالی احتمال باید مقدار بیشتری در آن نقطه داشته باشد. برای این منظور به تعداد مقدار هر نقطه، ویژگی‌های آن را در ماتریس ویژگی تکرار می‌کنیم. مثلاً اگر مقدار نقطه (۵ و ۱) برابر با ۴ است در ماتریس ویژگی ۴ بار (۵ و ۱) را تکرار می‌کنیم.


برای بدست آوردن مدل گوسی‌های تلفیقی به عنوان PDF دو بعدی لازم است تا ماتریس ویژگی‌ها را به عنوان ورودی برنامه بدست آوریم. همانطور که گفتیم ویژگی‌ها مؤلفه (t, f) الگوها یعنی نقاط در فضای زمان-فرکانس می‌باشند. هر چه یک نقطه دارای مقدار بیشتر باشد یعنی احتمال حضور آن نقطه در فضای زمان-فرکانس بیشتر است بنابراین تابع چگالی احتمال باید مقدار بیشتری در آن نقطه داشته باشد. برای این منظور به تعداد مقدار هر نقطه، ویژگی‌های آن را در ماتریس ویژگی تکرار می‌کنیم. مثلاً اگر مقدار نقطه (۵ و ۱) برابر با ۴ است در ماتریس ویژگی ۴ بار (۵ و ۱) را تکرار می‌کنیم.

تعداد توابع گوسی در مخلوط گوسی را نیز به عنوان ورودی به الگوریتم می‌دهیم. در این پایان-نامه این تعداد را بطور متغیر از ۱ تا ۱۰ تغییر داده و هر کدام که بهترین نتیجه کلاسه‌بندی را داشت به عنوان مخلوط گوسی بهینه در نظر می‌گیریم.


بعد از بدست آوردن ماتریس ویژگی‌ها آن را به عنوان ورودی به برنامه GMM که در نرم‌افزار متلب نوشته شده است می‌دهیم تا تابع چگالی احتمال ویژگی‌های دو بعدی را بدست آورد. نمونه‌ای از توابع چگالی احتمال و کانتور آنها برای کلاس تصور حرکتی دست چپ و دست راست مربوط به شخص ۱ در شکل‌های (۵-۹) و (۵-۱۰) نشان داده شده است. در این شکل‌ها تعداد گوسی‌ها ۸ تا در نظر گرفته شده است.

همانطور که بخش ۵-۲-۱ بیان شد، در مدل GMM ماتریس کواریانس گوسی‌ها می‌تواند قطری در نظر گرفته شود و یا اینکه بطور کلی به هر صورتی می‌تواند باشد. قطری فرض کردن ماتریس‌های کواریانس می‌تواند باعث کاهش پیچیدگی محاسباتی و افزایش سرعت در محاسبات و تخمین پارامترها در مدل گوسی شود. فرض قطری بودن ماتریس‌های کواریانس به معنای این است که ویژگی‌ها را در فضای ویژگی ناهمبسته در نظر هستند [۶۵]. همانطور که گفتیم ویژگی‌های مورد استفاده در این روش مؤلفه زمان و فرکانس نقاط TFD است بنابراین می‌توان فرض کرد که ویژگی‌ها به هم وابسته نیستند و در نتیجه ماتریس‌های کواریانس‌ها را قطری در نظر گرفتیم.


روند اجرای مرحله آموزش در شکل (۵-۸) مشاهده می‌شود.



شکل (۵-۸): روند اجرای مرحله آموزش روش CSP-GMM



شکل (۵-۹): (الف) تخمین زده شده توسط روش GMM با تعداد ۸ گوسی مربوط به کل داده‌های آموزشی تصور حرکتی دست چپ برای شخص ۱. (ب) کانتور شکل (الف)



شکل (۵-۱۰): (الف) تخمین زده شده توسط روش GMM با تعداد ۸ گوسی مربوط به کل داده‌های آموزشی تصور حرکتی دست راست برای شخص ۱. (ب) کانتور شکل (الف)

۵-۲-۲- مرحله ارزیابی

مرحله ارزیابی هر داده تست ورودی شامل مراحل زیر می‌باشد:

- پیش پردازش: مطابق آنچه در مرحله آموزش انجام شد صورت می‌پذیرد.
- فیلتر کردن داده‌ها: داده‌های تست توسط فیلترهای فضایی بدست آمده از مرحله آموزش فیلتر شده و چهار سیگنال ثانویه مهمتر برای جداسازی بدست می‌آید.
- به دست آوردن ماتریس P : این مرحله توسط بدست آوردن PDF سیگنال‌های فیلتر شده، کاهش تعداد نمونه‌های زمانی و قرار دادن آنها در کنار هم و به دست آوردن ماتریس P مطابق رابطه (۵-۱۶) انجام می‌پذیرد.
- کوانتیزه کردن: در این مرحله تصویر ۵ سطحی از ماتریس P مطابق مرحله آموزش بدست می‌آید.
- استخراج ماتریس ویژگی: ویژگی‌ها را از تصویر ۵ سطحی مطابق آنچه در مرحله آموزش بیان شد بدست می‌آوریم.
- تخمین مدل گوسی‌های تلفیقی: در این مرحله از ماتریس ویژگی بدست آمده از مرحله قبل با همان تعداد گوسی که در مرحله آموزش استفاده شد تابع چگالی احتمال را بدست می‌آوریم.
- یافتن فاصله: PDF بدست آمده با PDF هر یک از کلاس‌ها که در مرحله آموزش بدست آوردیم مقایسه می‌شود. برچسب نهایی مربوط به کلاسی است که فاصله این PDF از PDF مربوط به آن کلاس کمتر باشد.
- برای بدست آوردن فاصله از معیار Chi-Squared (χ^2) استفاده شده است. (χ^2) یک معیار فاصله هیستوگرام است که در تشخیص تصویر، دسته‌بندی اشیاء و نوع بافت، انطباق توصیفگرها، کلاسه‌بندی شکل و غیره موفق بوده است [۶۶]. برای دو PDF با نام‌های P و Q این معیار به صورت

رابطه (۵-۱۸) تعریف می‌شود. در این رابطه اندیس i به معنای نقطه i ام از فضای ویژگی است. ابعاد PDF ها به اندازه ۲۳×۱۲۰ است.

$$\chi^2(P, Q) = \frac{1}{2} \sum_i \frac{(P_i - Q_i)^2}{(P_i + Q_i)^2} \quad (۵-۱۸)$$

۵-۲-۳- نتیجه کلاسه‌بندی دو کلاس تصور حرکتی دست چپ و دست

راست

در این تحقیق روش پیشنهادی را برای کلاسه‌بندی دو کلاس تصور حرکتی دست چپ و دست راست برای هر نه شخص بکار بردیم. برای هر شخص تعداد توابع گوسی (K در رابطه (۵-۷)) را در مدل GMM باید بدست آوریم. برای این منظور این تعداد را از ۱ تا ۱۰ تغییر داده و برای هر کدام نتایج کلاسه‌بندی را بدست آورده و مقداری که به ازای آن ماکزیمم نتیجه کلاسه‌بندی را داشتیم به عنوان بهینه برای هر شخص در نظر می‌گیریم. نتایج کلاسه‌بندی برحسب درصد درستی به ازای تعداد توابع گوسی (K) متفاوت برای هر ۹ شخص در جدول (۵-۵) آورده شده است. بیشترین درصد کلاسه‌بندی برای هر شخص به صورت پر رنگ‌تر در جدول مشاهده می‌شود. نتایج ماکزیمم به همراه پارامتر آن یعنی پارامتر K به عنوان بهینه‌ترین تعداد تابع گوسی برای هر شخص در جدول (۵-۶) مشاهده می‌شود.

همانطور که بیان شد در بسیاری از مقالات [۳۷ و ۴۰] از توان باندهای فرکانسی در کل بازه زمانی سه ثانیه‌ای مورد نظر به عنوان ویژگی استفاده کرده‌اند. با اینکار اطلاعات زمانی سیگنال‌ها نادیده گرفته می‌شود. ما در روش CSP-GMM با بدست آوردن تابع چگالی مؤلفه‌های زمان-فرکانس سیگنال‌ها بطور جزئی‌تر به باندهای فرکانسی نگریسته و اطلاعات زمانی سیگنال‌ها را نیز در کنار اطلاعات فرکانسی در نظر گرفتیم.

برای مقایسه اینکه آیا توان باندهای فرکانسی در کل بازه زمانی مورد نظر بدون در نظر گرفتن اطلاعات زمانی جواب بهتری دارد و یا با در نظر گرفتن اطلاعات زمانی، روش SEG-CSP-BP را که در بخش ۵-۱ پیشنهاد دادیم اجرا کردیم. البته در این روش طول قطعه را ۳ ثانیه در نظر گرفتیم. در نتیجه تنها یک قطعه زمانی وجود خواهد داشت. SEG-CSP-BP با طول قطعه ۳ ثانیه در حقیقت قطعه‌بندی زمانی ندارد که ما در این قسمت آن را CSP-BP نامیده‌ایم.


نتایج روش CSP-BP به همراه نتایج روش CSP-GMM در جدول (۵-۶) آورده شده است. همچنین برای مقایسه روش پیشنهادی با روش CSP متداول نتایج این روش را نیز در همین جدول آورده‌ایم. برای ایجاد شرایط یکسان در روش CSP متداول و CSP-BP مانند روش CSP-GMM از ۴ فیلتر فضایی استفاده شده است. برای مقایسه بیشتر نتایج هر سه روش در نمودار شکل (۵-۱۰) مشاهده می‌شوند.

جدول (۵-۵): نتایج روش CSP-GMM به ازای تعداد تابع گوسی متغیر (K) در کلاسه‌بندی داده‌های EEG دو کلاس تصور حرکتی دست چپ و دست راست

شخص	K	۱	۲	۳	۴	۵	۶	۷	۸	۹	۱۰
شخص ۱		۸۰/۸۸	۷۶/۶۰	۵۹/۵۷	۷۶/۶۰	۷۷/۷۱	۶۸/۷۲	۸۱/۶۷	۸۷/۰۰	۸۰/۰۰	۸۲/۸۵
شخص ۲		۵۰/۰۰	۵۰/۰۰	۵۰/۷۰	۵۰/۷۰	۵۱/۰۰	۵۹/۸۶	۶۲/۶۸	۵۰/۷۰	۵۰/۷۰	۵۰/۰۰
شخص ۳		۷۹/۵۱	۸۰/۸۱	۷۶/۵۴	۷۹/۴۵	۸۵/۵۵	۸۸/۵۷	۹۳/۰۴	۹۵/۰۰	۹۰/۹۱	۸۸/۵۰
شخص ۴		۵۹/۱۴	۵۶/۶۵	۷۲/۱۵	۷۴/۱۷	۷۰/۱۴	۶۸/۱۶	۵۸/۶۲	۵۹/۱۴	۷۰/۵۶	۶۸/۶۵
شخص ۵		۵۰/۷۰	۵۱/۰۹	۵۱/۰۹	۵۴/۸۱	۵۵/۵۶	۵۶/۶۲	۵۷/۷۸	۵۹/۵۷	۵۵/۵۶	۵۷/۰۰
شخص ۶		۵۵/۵۶	۶۰/۱۹	۵۹/۷۰	۵۸/۳۳	۵۵/۵۶	۵۶/۴۸	۵۳/۷۰	۵۵/۵۶	۵۵/۹۳	۵۷/۴۱
شخص ۷		۶۵/۰۰	۵۲/۸۶	۶۲/۱۴	۶۵/۰۰	۷۰/۰۰	۷۳/۵۷	۷۲/۸۶	۶۴/۲۹	۶۵/۷۱	۶۷/۸۶
شخص ۸		۶۷/۴۶	۶۱/۴۹	۵۹/۵۶	۷۰/۷۵	۷۶/۱۶	۷۷/۱۵	۸۰/۱۴	۷۵/۱۵	۶۸/۷۵	۷۶/۱۶
شخص ۹		۶۶/۹۲	۶۵/۵۵	۷۰/۰۷	۶۱/۵۹	۸۶/۷۰	۸۷/۵۳	۷۵/۵۹	۸۱/۱۶	۸۵/۱۱	۶۹/۸۳

جدول (۵-۶): نتایج روش CSP-GMM، CSP-BP و CSP در کلاسه‌بندی داده‌های EEG دو کلاس تصور حرکتی دست چپ و دست راست

روش شخص	(K) CSP-GMM	CSP-BP	CSP
شخص ۱	۸۷/۰۰ (۸)	۸۰/۰۴	۸۶/۵۲
شخص ۲	۶۲/۸۶ (۷)	۵۲/۵۵	۵۹/۱۵
شخص ۳	۹۵/۰۰ (۸)	۹۴/۰۰	۹۴/۸۹
شخص ۴	۷۴/۱۷ (۴)	۷۳/۰۷	۷۲/۴۱
شخص ۵	۵۹/۵۷ (۸)	۵۷/۴۳	۵۱/۸۵
شخص ۶	۶۰/۱۹ (۲)	۵۱/۵۲	۵۵/۵۶
شخص ۷	۷۳/۵۷ (۶)	۶۴/۴۵	۷۲/۸۶
شخص ۸	۸۰/۱۴ (۷)	۶۹/۸۶	۷۷/۶۱
شخص ۹	۸۷/۵۳ (۶)	۸۶/۶۷	۸۳/۰۷
متوسط	۷۷/۷۸	۶۹/۹۵	۷۲/۶۳



شکل (۵-۱۱): نتایج روش CSP-GMM، CSP-BP و CSP در کلاسه‌بندی داده‌های EEG دو کلاس تصور حرکتی دست چپ و دست راست

همانطور که در نمودار شکل (۵-۱۱) مشاهده می‌شود نتایج روش CSP-BP در ۶ مورد از نتایج روش CSP متداول پایین‌تر بوده است. همچنین به طور متوسط نیز روش CSP-BP نتایج بهتری از روش CSP-BP نداشته است. این به معنای آن است که استفاده از ویژگی‌های فرکانسی به جای واریانس در بازه ۳ ثانیه از زمان ۲/۵ تا ۵/۵ در داده‌های EEG کمکی به بهبود نتایج نکرده است.

با توجه به نمودار مذکور مشاهده می‌شود که روش CSP-GMM در تمامی موارد و به طور متوسط نتایج بهتری از هر دو روش دیگر داشته است. این به معنای آن است که در نظر گرفتن اطلاعات زمانی در کنار اطلاعات فرکانسی به بهبود نتایج در کلاسه‌بندی داده‌های EEG ناشی از تصور حرکتی دو کلاس دست چپ و دست راست کمک کرده است.

سرعت اجرای الگوریتم GMM پایین بوده و با افزایش تعداد بردارهای ویژگی نیز به نسبت پایین‌تر می‌آید. به همین دلیل تنها از ۴ فیلتر فضایی مهم‌تر در این روش استفاده شده است در صورتی که در روش‌های قبلی از ۱۶ فیلتر استفاده شده بود. به همین دلیل بنظر می‌رسد که مقایسه این روش با روش‌های پیشنهادی قبل کار درستی نباشد. به دلیل نبودن مجال کافی برای اجرای این روش با $m=8$ ، در آینده این کار را انجام خواهیم داد.

لازم به ذکر است که نتایج روش CSP-GMM تنها برای مسئله دو کلاسه آورده شد. ما سعی کردیم این روش را توسط الگوریتم OVR به مسئله چهار کلاسه تعمیم دهیم. برای این منظور برای کلاسه‌بندی از همان معیار فاصله استفاده کردیم. اما نتایج حاصله خیلی پایین بود. در روش‌های قبلی از روش LDA برای کلاسه‌بندی در روش OVR استفاده شد. LDA احتمال تعلق به کلاس‌ها را به عنوان خروجی می‌دهد. برچسب نهایی داده‌های تست متعلق به کلاسی بود که احتمال بیشتری داشت. متأسفانه استفاده از معیار فاصله χ^2 نتایج خوبی نداشت. می‌توان برای تعمیم این روش به مسئله بیشتر از دو کلاس از معیار مناسب دیگری استفاده کرد. این کار را به آینده موکول می‌کنیم.

فصل ششم

نتیجه‌گیری

و

پیشنهادات برای کارهای آینده

فصل ششم

نتیجه‌گیری و پیشنهادات برای کارهای آینده

هدف از این پایان‌نامه کلاسه‌بندی سیگنال‌های EEG ناشی از تصور حرکتی در سیستم‌های BCI می‌باشد. در فصل اول این پایان‌نامه مختصری راجع به سیستم مغز و اعصاب ارائه شد. سپس به توضیح عملکرد سیستم‌های BCI پرداخته و انواع BCI را مورد مطالعه قرار دادیم. در این فصل بیان شد که در مغز انسان در حالت عادی امواج با فرکانس‌های متفاوت در قسمت‌های مختلف مغز بوجود می‌آید. با انجام یک فعالیت خاص در مغز ممکن است این سیگنال‌ها در برخی مناطق مغز کاهش یابند. همچنین ممکن است با انجام برخی فعالیت‌ها یکسری امواج در مغز بوجود آید که در حالت استراحت مغز وجود نداشته‌اند.

تصور حرکتی نیز مانند خود حرکت باعث ERD/ERS در سیگنال کانال‌های EEG خواهد شد. یعنی ممکن است در حالت بیکار مغز فرکانس‌هایی در یک کانال مغز وجود نداشته باشد و با شروع تصور حرکتی به وجود آیند (ERS) و یا بالعکس فرکانس‌هایی در حالت بیکاری مغز در سیگنال یک کانال خاص وجود داشته باشد و با شروع تصور حرکتی کاهش یابد (ERD). سیگنال‌های الکتروفیزیولوژیکی مغز از فردی به فرد دیگر متفاوت بوده و همچنین سیگنال‌های مغز یک فرد خاص

نیز با توجه به سن، شرایط روحی، خستگی، نوع آسیب‌دیدگی و برخی پارامترهای دیگر تغییر خواهد نمود. رنج فرکانسی امواج مختلف مغز مانند امواج میو و بتا در مقالات بطور تقریبی برای تمام افراد بیان می‌شود. اما در واقع این رنج‌ها برای تمامی افراد یکسان نبوده و ممکن است کمی متفاوت باشد. الگوهای ناشی از تصور حرکتی در مغز تمامی افراد یکسان نبوده و ممکن است در برخی افراد بصورت ERD و در برخی افراد به طور ERS ظهور کند. حتی باند فرکانسی که ERD/ERS در آن اتفاق می‌افتد نیز ممکن است متفاوت باشد.

در فصل دوم به مرور تحقیقات انجام شده در زمینه BCI مبتنی بر تصور حرکتی پرداختیم. این تحقیقات را بر حسب نوع ویژگی‌های بکار برده شده در آنها به سه حوزه زمان، فرکانس و زمان-فرکانس دسته‌بندی کرده و مختصری راجع به نحوه بدست آوردن ویژگی‌ها، کاهش ابعاد ویژگی و کلاسه‌بند مورد استفاده در آنها آوردیم. متأسفانه چون در مقالات گزارش شده از مجموعه داده‌های مختلف استفاده شده است نتوانستیم نتایج این روش‌ها را با هم مقایسه کنیم.

مشکل دیگری که محققان زمینه BCI با آن روبرو هستند زیاد بودن تعداد کانال‌های EEG است. یکی از موفق‌ترین روش‌ها برای کاهش تعداد کانال‌ها روش CSP است. این روش نمونه‌های زمانی سیگنال‌های EEG را به فضایی مبتنی بر بردارهای ویژه ماتریس کواریانس داده‌ها نگاشت می‌دهد. بدلیل اینکه این روش مبتنی بر ماتریس کواریانس سیگنال‌هاست، بازه زمانی مورد استفاده در این روش می‌تواند در نتیجه آن بسیار مؤثر باشد و همچنین نویز در یک بازه زمانی می‌تواند تأثیر قابل توجهی بر نتایج حاصله از این روش داشته باشد.

محدوده فرکانسی سیگنال‌های EEG نیز می‌تواند نتیجه روش CSP را تحت تأثیر قرار دهد. تاکنون روش‌های زیادی برای بهبود CSP در مقالات گزارش شده است. سعی محققان در اکثر تحقیقات گزارش شده این بوده است که بازه فرکانسی مناسب را در این روش برای هر فرد بیابند. اکثر مقالات گزارش شده برای این منظور، با اینکه در بررسی بر روی سیگنال‌های EEG چند شخص بطور متوسط نتایج بهتری از CSP داشته‌اند، نتوانسته‌اند در تمامی موارد از روش CSP پیشی بگیرند.

از دیگر مشکلات روش CSP این است که این روش ساختار زمانی داده‌های EEG را در نظر نمی‌گیرد. در مقالاتی که سعی بر بهبود فرکانسی روش CSP داشته‌اند باز هم از ماتریس کواریانس داده‌ها استفاده می‌شود و بنابراین در این روش‌ها نیز ساختار زمانی داده‌ها در نظر گرفته نمی‌شود. همچنین نویز در یک بازه زمانی می‌تواند تمامی ویژگی‌های حاصله را در این روش‌ها تحت تأثیر قرار دهد.

در روش LTCSP [۱۸] ساختار زمانی داده‌ها در نظر گرفته می‌شود و بنابراین نویز در یک نقطه زمانی تنها نزدیکترین همسایه‌های خود را تحت تأثیر قرار داده و تأثیر کمتری بر نتیجه نهایی خواهد داشت. این روش نیز مانند روش CSP پیچیدگی محاسباتی زیادی نداشته و از ویژگی‌های ساده مانند واریانس استفاده می‌کند. مشکلی که در این روش وجود دارد این است که محدوده فرکانسی سیگنال‌ها تأثیر زیادی بر نتیجه خواهد داشت.

در اکثر مقالات گزارش شده در زمینه BCI مبتنی بر تصور حرکتی کلاسه‌بندی دو کلاس تصور حرکتی دست چپ و دست راست مطرح بوده و کمتر به مسائل چند کلاسه پرداخته شده است. در این پایان‌نامه از داده‌های 2a از مسابقه چهارم BCI استفاده شده است. این مجموعه داده شامل چهار نوع تصور حرکتی دست چپ، دست راست، دو پا و زبان مربوط به ۹ شخص می‌باشد.

در فصل سوم مختصری راجع به این مجموعه داده و روش‌های ارائه شده توسط دو نفر برتر مسابقه و روش ارائه شده در یکی از مقالاتی که این مجموعه داده را مورد بررسی قرار داده است آورده شده است. روش CSP اولین بار برای حل مسئله دو کلاسه مطرح شده بود که در مقالات چندین الگوریتم برای تعمیم این روش به مسائل چهار کلاسه گزارش شده است. روش LTCSP نیز مانند روش CSP در ابتدا برای مسائل دو کلاسه مطرح شده است.

ما در ابتدای فصل چهارم روش LTCSP را توسط الگوریتم OVR به مسئله چهار کلاسه تعمیم داده و OVR-LTCSP نامیده‌ایم. در این فصل روش OVR-LTCSP برای هر ۹ شخص پایگاه داده اجرا و با روش OVR-CSP مقایسه شده است. OVR-LTCSP در تمامی موارد نتایج بهتری از روش

OVR-CSP داشته است. همچنین نتایج این روش در اکثر موارد و بطور متوسط از دو نفر برتر مسابقه ۲۰۰۸ بهتر بوده است (شکل (۴-۳)). شاید یکی از دلایلی که روش OVR-LTCSP از روش ارائه شده توسط نفر برتر مسابقه در برخی موارد نتایج بهتری نداشته است این باشد که باند فرکانسی مناسب برای جداسازی کلاس‌ها برای هر فرد به طور مناسب انتخاب نشده است.

موفقیت روش LTCSP نسبت به روش CSP به دلیل در نظر گرفتن ساختار زمانی داده‌ها می-باشد. برای در نظر گرفتن اطلاعات توالی زمانی داده‌ها در بخش دوم فصل چهارم روشی پیشنهاد دادیم که در آن از قطعه‌بندی زمانی در روش CSP استفاده کرده‌ایم. در این روش از همان ویژگی‌وارianس استفاده شده است. در این روش ابتدا بازه ۳ ثانیه مورد نظر را به قطعات زمانی با طول متغیر و تداخل ۵/۰ ثانیه تقسیم کرده و روش CSP را در هر قطعه بدست آورده‌ایم. ویژگی‌های بدست آمده از تمامی قطعات زمانی را در کنار هم قرار داده و در کلاسه‌بندی استفاده کردیم. کلاسه‌بند مورد استفاده در این روش LDA می‌باشد. این روش را برای حل مسئله دو کلاس تصور حرکتی دست چپ و دست راست برای هر ۹ شخص بکار برده و SEG-CSP-Var نامیدیم. SEG-CSP-Var در تمامی موارد نتایج بهتری از CSP در همان سه ثانیه داشته است (شکل (۵-۵)).

روش قطعه‌بندی زمانی را برای توسط الگوریتم OVR به مسئله چهار کلاسه تعمیم داده و OVR-SEG-CSP-Var نامیدیم. نتایج این روش را با نتایج روش OVR-CSP و دو نفر برتر مسابقه مقایسه نموده‌ایم (شکل (۴-۱۰)). روش پیشنهادی در ۸ مورد نتایج بهتری از روش CSP داشته و تنها در یک مورد نتایج یکسانی با روش CSP متداول داشته است. پس روش OVR-SEG-CSP-Var بطور متوسط موفقیت بیشتری از روش OVR-CSP در حل مسئله چهار کلاسه داشته است.

موفقیت قطعه بندی زمانی در روش CSP به معنای آن است که در کنار هم قرار دادن اطلاعات قطعات زمانی سیگنال‌های EEG به بهبود نتایج کمک کرده است. با قطعه‌بندی زمانی و اجرای روش CSP در هر قطعه زمانی در شکل (۴-۹) مشاهده کردیم که فیلترهای فضایی قطعات مختلف زمانی با هم متفاوت است. این به معنای آن است که اهمیت کانال‌ها در جداسازی کلاس‌ها در قطعات زمانی

مختلف متفاوت می‌باشد، یعنی ممکن است در یک بازه زمانی کانال‌های خاصی برای جداسازی اهمیت داشته باشند که در قطعات زمانی دیگر این کانال‌ها مهم نبوده و کانال‌های دیگری از اهمیت بیشتر برای جداسازی کلاس‌ها برخوردار باشند.

در مرجع [۵۳] که بر روی مجموعه داده مورد استفاده ما تحقیقاتی صورت گرفته است روشی به نام MSJAD ارائه شده که در آن از قطعه‌بندی زمانی در روش JAD استفاده شده است. در این مقاله برای مقایسه نتایج روش پیشنهادی خود با روش JAD و CSP ابتدا این روش‌ها را اجرا کرده و بعد از اعمال فیلترهای بدست آمده از این روش‌ها سیگنال فیلتر شده را به بازه‌های زمانی با تداخل تقسیم کرده‌اند. توان باندهای فرکانسی ۲ هرتزی در هر قطعه به عنوان ویژگی بدست آمده است. ویژگی‌های بدست آمده از تمامی قطعات در کنار هم قرار داده گرفته و از تمامی آنها برای کلاسه‌بندی استفاده شده است. نتایج گزارش شده در این مرجع به طور متوسط نسبت به نفرات برتر مسابقه کمتر می‌باشد (جدول (۲-۳)).

ما در بخش ۵-۱ این پایان‌نامه روشی به نام SEG-CSP-BP پیشنهاد دادیم. این روش همان روش SEG-CSP-Var است که به جای واریانس از ویژگی توان در باندهای فرکانسی استفاده شده است. بعد از بدست آوردن ویژگی‌ها از روش گسسته‌سازی چند بازه‌ای و رتبه‌بندی ویژگی‌ها به منظور انتخاب ویژگی و کلاسه‌بندی استفاده شده است. این روش را برای کلاسه‌بندی دو کلاس تصور حرکتی دست چپ و دست راست بکار برده و مشاهده نمودیم که نتایج حاصله از این روش از روش CSP متداول و روش SEG-CSP-Var بهتر بوده است (شکل (۳-۵)).

روش SEG-CSP-BP را نیز توسط الگوریتم OVR به مسئله چهار کلاسه تعمیم داده و OVR-SEG-CSP-BP نامیدیم. در شکل (۴-۵) مشاهده می‌شود که روش OVR-SEG-CSP-BP بطور متوسط عملکرد مطلوبتری از روش OVR-CSP، OVR-SEG-CSP-Var و دو نفر برتر مسابقه داشته است.

با مقایسه جداول (۲-۳) و (۸-۴) مشاهده می‌شود که بطور متوسط نتایج روش پیشنهادی ما (OVR-SEG-CSP-BP) از بهترین نتیجه در مقاله [۵۳] بیشتر بوده است. یکی از دلایل این موضوع این است که در این مقاله ابتدا سیگنال‌ها فیلتر شده و بعد قطعه‌بندی شده‌اند اما در روش پیشنهادی ما ابتدا سیگنال‌ها را از لحاظ زمانی قطعه‌بندی نموده و سپس فیلتر می‌کنیم. از دیگر دلایل موفقیت روش پیشنهادی می‌تواند توان باندهای فرکانسی ۲، ۴، ۸ و ۱۶ هرتزی به جای تنها باندهای ۲ هرتزی باشد. همچنین کاهش ابعاد بردارهای ویژگی نیز کمک شایانی به بهبود نتایج کرده است.

روش گسسته‌سازی چند بازه‌ای و تکنیک رتبه‌بندی ویژگی‌ها هیچ کدام در زمینه تحقیقات BCI استفاده نشده بودند. ما در این مقاله از تلفیق این دو روش استفاده نموده و به نتایج مطلوبی دست یافتیم.

با بدست آوردن نتایج بهتر روش SEG-CSP-BP نسبت به سایر روش‌های مورد بررسی به این نتیجه رسیدیم که اطلاعات زمانی در کنار اطلاعات فرکانسی می‌تواند در بهبود نتایج مؤثر باشد. به همین دلیل تصمیم گرفتیم تا از توزیع زمان-فرکانس سیگنال‌ها برای جداسازی کلاس‌ها استفاده کنیم.

در اکثر مقالاتی که در زمینه BCI از توزیع زمان-فرکانس سیگنال‌ها استفاده کرده‌اند از سطح زیر نمودار TFD سیگنال‌ها در باندهای فرکانسی مختلف به عنوان ویژگی استفاده شده است. همچنین در برخی مقالات که از توان سیگنال در باندهای مختلف استفاده کرده‌اند توان در کل بازه زمانی مورد بررسی بدست می‌آید. در واقع با اینکار اطلاعات زمانی سیگنال‌ها نادیده گرفته می‌شود. به همین دلیل تصمیم گرفتیم تا بطور جزئی‌تر به باندهای فرکانسی مختلف نگاه کرده و اطلاعات زمانی را در کنار اطلاعات فرکانسی در نظر بگیریم.

پیشنهاد ما به این صورت بود که توسط روش GMM مدلی برای توزیع زمان-فرکانس سیگنال‌ها در فضای دو بعدی زمان و فرکانس بدست آورده و سپس از یک معیار فاصله برای کلاسه‌بندی توابع

چگالی احتمال بدست آمده برای هر داده تست ورودی استفاده کنیم. این روش را CSP-GMM نامیدیم.

تخمین مدل گوسی داده‌ها زمان‌بر بوده و از سرعت پایینی برخوردار است. در این روش که برای کاهش تعداد کانال‌ها از روش CSP استفاده شده است، تنها از ۴ فیلتر فضایی برتر برای فیلتر نمودن سیگنال‌ها استفاده کرده‌ایم تا برنامه‌ها سریعتر اجرا شوند. در این صورت این روش در شرایط نابرابر نسبت به بقیه روش‌ها اجرا شده است. قطعاً با افزایش تعداد فیلترهای فضایی به نتایج مطلوبتری خواهیم رسید. بنابراین شاید کار درستی نباشد که نتایج این روش را با نتایج روش‌های قبلی مقایسه کنیم.

برای مقایسه اینکه آیا توان باندهای فرکانسی در کل بازه زمانی مورد نظر بدون در نظر گرفتن اطلاعات زمانی جواب بهتری دارد و یا با در نظر گرفتن اطلاعات زمانی، روش SEG-CSP-BP را که در بخش ۵-۱ پیشنهاد دادیم اجرا کردیم. البته در این روش طول قطعه را ۳ ثانیه در نظر گرفتیم. در نتیجه تنها یک قطعه زمانی وجود خواهد داشت. در این روش توان باندهای فرکانسی در کل ۳ ثانیه مورد نظر به عنوان ویژگی استفاده شده و به روش گسسته‌سازی چند بازه‌ای و رتبه‌بندی ویژگی‌ها کلاسه‌بندی می‌شود. SEG-CSP-BP با طول قطعه ۳ ثانیه در حقیقت قطعه‌بندی زمانی ندارد که آن را CSP-BP نامیده‌ایم. با توجه به نمودار شکل (۵-۱۱) مشاهده می‌شود که روش CSP-GMM در تمامی موارد و به طور متوسط نتایج بهتری از هر دو روش دیگر داشته است. این به معنای آن است که در نظر گرفتن اطلاعات زمانی در کنار اطلاعات فرکانسی به بهبود نتایج در کلاسه‌بندی داده‌های EEG ناشی از تصور حرکتی دو کلاس دست چپ و دست راست کمک کرده است.

لازم به ذکر است که نتایج روش CSP-GMM تنها برای مسئله دو کلاسه آورده شد. ما سعی کردیم این روش توسط الگوریتم OVR به مسئله چهار کلاسه تعمیم دهیم. برای این منظور برای کلاسه‌بندی از همان معیار فاصله استفاده کردیم. اما نتایج حاصله رضایت بخش نبود.

روش‌های پیشنهادی در مسئله چهار کلاسه، با روش OVR-CSP، روش‌های مطرح شده در مرجع [۵۳] و نفرات برتر مسابقه چهارم در زمینه BCI مقایسه شده است. همانطور که مشاهده شد روش OVR-SEG-CSP-BP در ۴ مورد، روش OVR-SEG-Var در ۳ مورد و روش OVR-LTCSP در ۲ مورد، نفر برتر مسابقه در یک مورد و مرجع [۵۳] در یک مورد نتایج بهتری از بقیه داشته‌اند. این نتایج بیانگر آن است که توانسته‌ایم با قطعه‌بندی زمانی به نتایج خوبی دست یابیم. روش OVR-LTCSP و روش OVR-SEG-CSP-Var که هر دو ساختار زمانی داده‌ها را در نظر می‌گیرند، بطور متوسط نتایج یکسانی داشته‌اند. روش OVR-SEG-CSP-BP بطور متوسط نتایج بهتری از بقیه روش‌ها داشته است. این به معنای آن است که در نظر گرفتن اطلاعات فرکانسی در کنار اطلاعات زمانی منجر به نتایج خوبی خواهد شد.

۶-۱- پیشنهاد کارهای آینده

در روش SEG-CSP-Var از کلاسه‌بند LDA استفاده شده است. با کاهش طول قطعه‌های زمانی تعداد قطعات زمانی و ابعاد بردارهای ویژگی زیاد خواهد شد. LDA در ابعاد زیاد نتایج مطلوبی نخواهد داشت. ممکن است بتوانیم با استفاده از انواع دیگر کلاسه‌بند نتایج حاصله از این روش را بهبود بخشیم. همچنین ممکن است اطلاعات تمامی قطعات مفید نبوده و تنها اطلاعات چند قطعه زمانی برای جداسازی کلاس‌ها مفید واقع شوند. برای انتخاب ویژگی‌های مناسب می‌توان از روش‌های کاهش ویژگی مانند روش رتبه‌بندی ویژگی‌ها که در فصل پنجم آورده شد استفاده نمود.

در روش SEG-CSP-Var محدوده فرکانسی سیگنال‌ها نیز تأثیر شایانی بر نتایج دارد. می‌توان این روش را با روش‌های انتخاب بازه فرکانسی مناسب تلفیق نموده و به نتایج بهتری دست یافت.

تکنیک رتبه‌بندی ویژگی‌ها روشی سریع برای کاهش ابعاد ویژگی‌هاست اما ممکن است در دام مینیمم‌های محلی بیفتد. می‌توان در کنار گسسته‌سازی چند بازه‌ای به جای تکنیک رتبه‌بندی ویژگی‌ها از الگوریتم‌های دیگر مانند الگوریتم ژنتیک، PSO و سایر روش‌هایی که تمامی فضای ویژگی

را جستجو می‌کنند استفاده کنیم. الگوریتم‌های ذکر شده سرعت کمتری دارند اما ممکن است در یافتن ویژگی‌های مفید عملکرد مطلوبتری از تکنیک رتبه‌بندی ویژگی‌ها داشته باشند. همچنین می‌توان به جای روش گسسته‌سازی چند بازه‌ای از کلاسه‌بندهای دیگر استفاده نموده و با ترکیب رتبه‌بندی ویژگی‌ها به نتایج مطلوبتری دست یافت.

همچنین همانطور که گفته شد روش CSP-GMM به دلیل استفاده از روش GMM از سرعت پایینی برخوردار است که تنها از کوانتیزه‌سازی تصاویر توزیع‌های زمان-فرکانس در ۵ سطح استفاده شده است. می‌توان تعداد سطوح کوانتیزه‌سازی را تغییر داده و نتایج مطلوبتری بدست آورد. در این پایان‌نامه از روش EM برای تخمین PDF در روش GMM با شروع از یک نقطه تصادفی استفاده شده است. برای بهینه‌سازی می‌توان از روش‌های دیگر تخمین استفاده نمود.

نتایج روش CSP-GMM تنها برای مسئله دو کلاسه آورده شد اما نتایج حاصله خیلی پایین بود. در روش‌های قبلی از روش LDA برای کلاسه‌بندی در روش OVR استفاده شد. متأسفانه استفاده از معیار فاصله χ^2 نتایج خوبی نداشت. می‌توان برای تعمیم این روش به مسئله بیشتر از دو کلاس از معیار مناسب دیگری استفاده کرد.

مراجع

- [1]. Saeid Sanei and J.A. Chambers, (2007), "*EEG signal processing*", John Wiley & sons, Centre of Digital Signal Processing Cardiff University, UK.
- [2]. Hass. L. F, (2003), "Hans Berger (1873–1941), Richard Caton (1842–1926), and electroencephalography", *J. Neurol. Neurosurg. Psychiat.*, 74, 9.
- [3]. <http://WWW.wikipedia.com>
- [4]. Wolpaw J R, Birbaumer N, McFarland D J, Pfurtscheller G , Vaughan T M, (2002), "Brain–computer interfaces for communication and control", *Clin. Neurophysiol*, 137, pp 67–91.
- [5]. Middendorf, M., McMillan, G., Calhoun, G., and Jones, K. S., (2000), "Brain–computer interfaces based on the steady-state visual-evoked response", *IEEE Trans. Rehabil. Engng*, 8, 2, pp 211–214.
- [6]. G. Pfurtscheller and C. Neuper, (1997), "Motor imagery activates primary sensorimotor areas," *Neurosci. Lett.*, 239, pp. 65–68.
- [7]. Jianfeng Hu, Dan Xiao, Zhendong Mu, (2009), "Application of Energy Entropy in Motor Imagery EEG Classification", *International Journal of Digital Content Technology and its Applications*, 3, 2.
- [8]. F Lotte, M Congedo, A L'ecuyer, F Lamarche , B Arnaldi. (2007), "A review of classification algorithms for EEG-based brain–computer interfaces", *J. Neural Eng.* 4, pp 1–13.
- [9]. <http://bbci.de/competition/iv/index.html>
- [10]. Koles, Z.J., (1991), "The quantitative extraction and topographic mapping of the abnormal components in the clinical EEG", *Electroencephalogr. Clin. Neurophysiol.* 79, 6, pp 440–447.
- [11]. J. Müller-Gerking, G. Pfurtscheller, and H. Flyvbjerg, (1999), "Designing optimal spatial filters for single-trial EEG classification in a movement task", *Electroenc. Clin. Neurophys.*, to be published.
- [12]. H. Ramoser, J. Muller-Gerking, and G. Pfurtscheller, (2000), 'Optimal spatial filtering of single trial EEG during imagined hand movement', *IEEE Trans. Rehabil. Eng.*, 8, 4, pp 441–446.
- [13]. G. Dornhege, B. Blankertz, G. Curio, and K. R. Müller, (2004), "Increase information transfer rates in BCI by CSP extension to multi-class," in *Proc. Advances in Neural Information Processing Systems*, pp.733-740.
- [14]. Guido Dornhege, Benjamin Blankertz, Gabriel Curio, Klaus-Robert Müller, (2004), "Boosting Bit Rates in Noninvasive EEG Single-Trial Classifications by Feature Combination and Multiclass Paradigms", *IEEE transactions on biomedical engineering*, 51, 6.
- [15]. Clemens Brunner , Muhammad Naeem, Robert Leeb, Bernhard Graimann, Gert Pfurtscheller, (2007), "Spatial filtering and selection of optimized components in

- four class motor imagery EEG data using independent components analysis”, *Pattern Recognition Letters*, 28, pp 957–964.
- [16]. Ziehe, P. Laskov, K.-R. Müller, and G. Nolte, (2003), “A linear least-squares algorithm for joint diagonalization” in Proc. 4th Int. Symp. Independent Component Analysis and Blind Signal Separation (ICA2003), pp 469–474, Nara, Japan
 - [17]. C. Guger, H. Ramoser, and G. Pfurtscheller, (2000), “Real-Time EEG Analysis with Subject-Specific Spatial Patterns for a Brain–Computer Interface (BCI)”, *IEEE transactions on rehabilitation engineering*, 8,4.
 - [18]. Haixian Wang and WenmingZheng, (2008), “Local Temporal Common Spatial Patterns for Robust Single-Trial EEG Classification”, *IEEE transactions on neural systems and rehabilitation engineering*, 16, 2.
 - [19]. Damien Coyle, Girijesh Prasad, Thomas Martin McGinnity, (2005), “A Time-Series Prediction Approach for Feature Extraction in a Brain–Computer Interface”, *IEEE transactions on neural systems and rehabilitation engineering*, 13,4.
 - [20]. Temel Kayikcioglu ,Onder Aydemir, (2010), “A polynomial fitting and k-NN based approach for improving classification of motor imagery BCI data” , *Pattern Recognition Letters*, 31, pp 1207–1215.
 - [21]. Shiliang Sun , (2010), ”Extreme energy difference for feature extraction of EEG signals”, *Expert Systems with Applications*, 37, pp 4350–4357.
 - [22]. Steven Lemm, Benjamin Blankertz, Gabriel Curio, Klaus-Robert Müller, (2005), ”Spatio-Spectral Filters for Improving the Classification of Single Trial EEG”, *IEEE transactions on biomedical engineering*, 52, 9.
 - [23]. Guido Dornhege, Benjamin Blankertz, Matthias Krauledat, Florian Losch, Gabriel Curio, Klaus-Robert Müller, (2006), “Combined Optimization of Spatial and Temporal Filters for Improving Brain-Computer Interfacing”, *IEEE transactions on biomedical engineering*, 53, 11.
 - [24]. Wei Wu, XiaorongGao, Bo Hong, ShangkaiGao, Fellow, (2008), ”Classifying Single-Trial EEG During Motor Imagery by Iterative Spatio-Spectral Patterns Learning (ISSPL)”, *IEEE transactions on biomedical engineering*, 55, 6.
 - [25]. Q. Novi, C. Guan, T. H. Dat, and P. Xue, (2007), “Sub-band Common Spatial Pattern (SBCSP) for Brain-Computer Interface”, 3rd International IEEE/EMBS Conference on Neural Engineering, CNE, 07, pp 204-207.
 - [26]. K. K. Ang, Z. Y. Chin, H. Zhang, and C. Guan, (2008), “Filter bank common spatial pattern (FBCSP) in brain-computer interface”, in Proc. IEEE Int.Joint Conf. Neural Netw., pp. 2390–2397.
 - [27]. Zheng Yang Chin, Kai KengAng, Chuanchu Wang, Cuntai Guan, Haihong Zhang, (2009), “Multi-Class Filter Bank Common Spatial Pattern For Four-Class Motor Imagery BCI”, 31st Annual International Conference of the IEEE EMBSMinneapolis, Minnesota, USA, pp 2-6.
 - [28]. Georg E. Fabiani, Dennis J. McFarland, Jonathan R. Wolpaw, and GertPfurtscheller, (2004), ”Conversion of EEG Activity Into Cursor Movement by

- a Brain–Computer Interface (BCI)”, *IEEE transactions on neural systems and rehabilitation engineering*, 12, 3.
- [29]. P. A. Devijer and J. Kittler, (1982), “Pattern Recognition: A Statistical Approach”, Prentice-Hall, Englewood Cliffs, NJ.
- [30]. Nobuyuki Yamawaki, Christopher Wilke, Zhongming Liu, Bin He, Fellow, (2006), “An Enhanced Time-Frequency-Spatial Approach for Motor Imagery Classification”, *IEEE transactions on neural systems and rehabilitation engineering*, 14, 2.
- [31]. Tao Wang, Jie Deng, Bin He, (2004), “Classifying EEG-based motor imagery tasks by means of time–frequency synthesized spatial patterns”, *Clinical Neurophysiology*, 115, pp 2744–2753.
- [32]. Lotte Fabien, Lécuyer Anatole, Lamarche Fabrice, Arnaldi Bruno, (2007), “Studying the Use of Fuzzy Inference Systems for Motor Imagery Classification”, *IEEE transactions on neural systems and rehabilitation engineering*, 15, 2.
- [33]. Damien Coyle, (2009), “neural network based auto association and time-series prediction for biosignal processing in brain-computer interfaces”, *IEEE computational intelligence magazine*.
- [34]. Qi Xu, Hui Zhou, Yongji Wang, Jian Huang, (2009), “Fuzzy support vector machine for classification of EEG signals using wavelet-based features”, *Medical Engineering & Physics*, 31, pp 858–865.
- [35]. George Townsend, Yi Feng, (2008), “Using phase information to reveal the nature of event-related desynchronization”, *Biomedical Signal Processing and Control*, 3, pp 192–202.
- [36]. Yang Bang-hua, Yan Guo-zheng, Yan Rong-guo, Wu Ting, (2007), “Adaptive subject-based feature extraction in brain–computer interfaces using wavelet packet best basis decomposition”, *Medical Engineering & Physics*, 29, pp 48–53.
- [37]. Valerie Morash, Ou Bai, Stephen Furlani, Peter Lin, Mark Hallett, (2008), “Classifying EEG signals preceding right hand, left hand, tongue, and right foot movements and motor imagery”, *Clinical Neurophysiology*, 119, pp 2570–2578.
- [38]. T. Kailath, (1967), “The Divergence and Bhattacharyya Distance Measures in Signal Selection”, *IEEE transactions on communication technology*.
- [39]. Steven Lemm, Christin Schäfer, and Gabriel Curio, (2004), “BCI Competition 2003—Data Set III: Probabilistic Modeling of Sensorimotor μ Rhythms for Classification of Imaginary Hand Movements”, *IEEE transactions on biomedical engineering*, 51, 6.
- [40]. Pawel Herman, Girijesh Prasad, Thomas Martin McGinnity, Damien Coyle, (2008), “Comparative Analysis of Spectral Approaches to Feature Extraction for EEG-Based Motor Imagery Classification”, *IEEE transactions on neural systems and rehabilitation engineering*, 16, 4.
- [41]. Jie Li, Liqing Zhang, (2010), “Regularized tensor discriminant analysis for single trial EEG classification in BCI”, *Pattern Recognition Letters*, 31, pp 619–628.

- [42]. Tao, D., Li, X., Wu, X., Maybank, S.J., (2007), "General tensor discriminant analysis and gabor features for gait recognition", *IEEE Trans. Pattern Anal. Machine Intell.* 29, 10, pp 1700–1715.
- [43]. Wei-Yen Hsu, (2010), "EEG-based motor imagery classification using neuro-fuzzy prediction and wavelet fractal features", *Journal of Neuroscience Methods*, 189, pp 295–302.
- [44]. Shang-Ming Zhou, John Q. Gan, Francisco Sepulveda, (2008), "Classifying mental tasks based on features of higher-order statistics from EEG signals in brain-computer interface", *Information Sciences*, 178, pp 1629–1640.
- [45]. D.D.Lee, H.S.Seung, (1999), "Learning the parts of objects by non-negative matrix factorization", *Nature*, 401, pp 788–791.
- [46]. Harshman R.A., (1970), "Foundations of the PARAFAC Procedure: Models and Conditions for an "explanatory" Multi-modal Factor Analysis. s. n.
- [47]. H .Lee, A .Cichocki, S. Choi, (2006), "Non negative matrix factorization for motor imagery EEG classification", in: Proceedings of the International Conference on Artificial Neural Networks, Athens, Greece, Springer, Berlin.
- [48]. Mørup, M., Hansen, L.K., Herrmann, C.S., Parnas, J., Arnfred, S.M., (2006), "Parallel Factor Analysis as an exploratory tool for wavelet transformed event-related EEG", *Neuroimage* 29, 3, pp 938–947.
- [49]. Hyekyoung Lee, Andrzej Cichocki ,Seungjin Choi, (2009), "Kernel nonnegative matrix factorization for spectral EEG feature extraction", *Neurocomputing*, 72, pp 3182–3190.
- [50]. Nuri F. Ince , FikriGoksu , Ahmed H. Tewfik , Sami Arica, (2009), "Adapting subject specific motor imagery EEG patterns in space-time-frequency for a brain computer interface", *Biomedical Signal Processing and Control*, 4, pp 236–246.
- [51]. Damien Coyle, T. Martin McGinnity, Girijesh Prasad, (2010), "Improving the separability of multiple EEG features for a BCI by neural-time-series-prediction-preprocessing", *Biomedical Signal Processing and Control*, 5, pp 196–204.
- [52]. Schlogl, J. Kronegg, J. E. Huggins, S. G. Mason, (2007), "Evaluation criteria in BCI research In: Toward brain-computer interfacing", MIT Press, pp 327–342.
- [53]. C'edricGouy-Pailler, Marco Congedo, Clemens Brunner, Christian Jutten, and GertPfurtscheller, (2010), "Nonstationary Brain Source Separation for Multiclass Motor Imagery" , *IEEE transactions on biomedical engineering*, 57, 2.
- [54]. D.-T. Pham, (2001), "Blind separation of instantaneous mixture of sources via the Gaussian mutual information criterion," *Signal Process.*, 81, 4, pp 855–870.
- [55]. J. Friedman, T. Hastie, and R. Tibshirani, (2008), "Regularized paths for generalized linear models via coordinate descent," Dept. of Stat., Stanford Univ., Stanford, CA 94305, Tech. Rep.
- [56]. H.H Jasper and W. Penfield, (1949), "Electrocorticograms in man: effect of the voluntary movement upon the electrical activity of the precentralgyrus", *Arch. Psychiat. Z. Neurol*, 183, pp 163-174.

- [57]. M. Fatourech, A. Bashashati, R. K. Ward, G. E. Birch, (2007), "EMG and EOG artifacts in brain computer interface systems: a survey", *Clinical Neurophysiology* 118, pp 480-494.
- [58]. Chiappa S and Bengio S, (2004), "HMM and IOHMM modeling of EEG rhythms for asynchronous BCI systems", European Symposium on Artificial Neural Networks ESANN.
- [59]. U.M. Fayyad and K.B Irani, (1993), "Multi interval Discretisation of Continuous-Valued Attributes for Classification Learning", Proc.13th Int'l Joint Conf. Artificial Intelligence, pp 1022-1027.
- [60]. Hall, M. and Holmes, G, (2003), "Benchmarking attribute selection techniques for discrete class data mining", *IEEE Transactions on Knowledge and Data Engineering*, 15, 3.
- [۶۱]. مهارلویی پ، (۱۳۸۹)، پایان نامه ارشد: "طراحی و پیاده‌سازی سیستم شناسایی زبان گفتاری به صورت خودکار"، دانشکده برق و رباتیک، دانشگاه صنعتی شاهرود
- [۶۲]. مهارلویی پ، معروضی ا.ر، مروی ح و قاهری ح، (۱۳۸۹)، "تشخیص زبان گفتاری به صورت خودکار با استفاده از تبدیل موجک"، شانزدهمین کنفرانس ملی سالانه انجمن کامپیوتر ایران، تهران، ایران
- [63]. Duda R. O, Hart P. E and Stork D. G, (2000), "*Pattern Classification*", second edition.
- [64]. Ramalingam and S. Krishnan, (2006), "Gaussian Mixture Modeling of Short-Time Fourier Transform Features for Audio Fingerprinting", *IEEE transactions on information forensics and security*, 1, 4.
- [65]. Dempster, N. Laird, and D. Rubin, (1997), "Maximum likelihood from incomplete data via the EM algorithm", *J. Roy. Stat. Soc. B*, 39, 1, pp 1-38.
- [66]. Snedecor, G., Cochran, W., (1967), "*Statistical Methods*", ed 6. Ames, Iowa.

Abstract

In recent years, one of the most popular research fields is the Brain Computer Interface (BCI). In Electroencephalogram (EEG)-based BCI, brain signals are interpreted to control external devices as human intend.

In a Motor Imagery based BCI system, subject must imagine movement of one part of her/his body. This imagination produces events in her/his brain. The BCI system extracts these events from EEG signals and then recognizes the Motor Imagery type.

In this thesis we are concerned with classifying EEG signals due to four class of Motor imagery, left hand, right hand, both feet and tongue. We propose four methods for classifying EEG signals. We evaluate the proposed methods using the dataset 2a of BCI Competition IV (2008).


One of the most successful algorithms in Motor Imagery based BCI is Common Spatial Patterns (CSP) algorithm. CSP method uses covariance matrix of two class data to extract spatial filters for discriminating them. This method fails to capture temporally local structure of samples. Moreover the noise on one sample affects the total variance. Local Temporal Common Spatial Pattern (LTCSP) method is an extension of CSP which alleviates these defects using an adjacency matrix. LTCSP has been proposed for two classes problem. In this paper we modify it using one-versus- the rest (OVR) algorithm for four-classes Motor Imagery based BCI problem.

In this thesis we propose a method named SEG-CSP-Var which captures time information from EEG signals. SEG-CSP-Var outperforms CSP method in two classes problem. The result of applying this method showed that the importance of EEG channels varies for different time segments and use of features of all segments is better than using features of whole signals as one segment.

We propose another method so called SEG-CSP-BP which uses the power of frequency bands as features for classification. In this approach multi-interval discretisation of continuous-valued attributes is used as classifier and benchmarking attribute selection technique used as feature reduction method.

For four classes problem, OVR-SEG-CSP-BP outperforms OVR-CSP, OVR-LTCSP, OVR-SEG-CSP-Var and even the best competitor of BCI competition 2008. This shows that using time and frequency domain features jointly improves the Motor Imagery classification problem.

Keywords: Brain-computer interface (BCI), electroencephalogram (EEG), Motor Imagery (MI), Common Spatial Patterns, One- Versus-the Rest (OVR) algorithm.



Shahrood University of Technology

Faculty of Electrical and Robotic Engineering

**Classifying EEG Signals due to Motor Imagery
for BCI Using Time and Frequency Features**

Habibeh Ghaheri

Supervisor:

Dr. Alireza Ahmadyfard

Associate Supervisor:

Dr. Hadi Grayloo

February 2012