

Improving the Performance of the Sparse Representation Based Classification in BCI Systems, by Enhancing the Process of Feature Extraction and Using an Optimized Sparse Solution Finding Algorithm

A. R. Mirjalili¹, V. Abootalebi^{2*}, M. T. Sadeghi²

¹M.Sc Student, Faculty of Electrical and Computer Engineering, Yazd University, Yazd, Iran

²Assistant Professor, Faculty of Electrical and Computer Engineering, Yazd University, Yazd, Iran

Receipt in the online submission system 6 June 2015, received in revised form 18 August 2015, accepted 30 August 2015

Abstract

In recent years, Brain-Computer Interface (BCI) has been noted as a new means of communication between the human brain and his surroundings. In order to set up such a system, the collaboration of several blocks, such as data recording, signal processing and user interface are needed. The signal processing block, includes two units of preprocessing and pattern recognition. Pattern recognition block itself involves two phases: feature extraction and classification. In this paper, the sparse representation based classification (SRC) has been used in the classification block. There are two important issues in using the SRC. These are creating an appropriate dictionary matrix and adopting a proper method for finding the sparse solution for an input data. In this research study, the dictionary matrix is formed by extracting an optimal set of features from the training data. Toward this goal, the common spatial patterns algorithm (CSP) is first used. Sensitivity to noise and the over learning phenomena are the main drawbacks of the CSP algorithm. In order to remove these problems, the regularized common spatial patterns algorithm (RCSP) is employed. In previous studies in within the BCI framework, the standard BP algorithm has been used to find a sparse solution. The main disadvantage of the BP algorithm is that the method is computationally expensive. To overcome this weakness, a recently proposed algorithm namely the SL0 approach is used instead. Our experimental results show that when the number of training samples is limited, the RCSP algorithm outperforms the CSP one. Using the features derived from the RCSP, the average detection rate is in average increased by a factor of 7.53%. Our classification results also show that using the SL0 algorithm, the classification process is highly speeded up as compared to the BP algorithm while an almost equivalent accuracy is achieved.

Keywords: *brain computer interface, motor imagery, regularized common spatial patterns, sparse representation based-classification, smoothed L0-norm*

*Corresponding author

Address: Faculty of Electrical and Computer Engineering, Yazd University, P. O. Box: 89195-741, Yazd, Iran
Tel: +98-35-31232398
Fax: +98-35-38200144
E-mail: abootalebi@yazd.ac.ir

بهبود عملکرد طبقه‌بندی‌کننده براساس نمایش تنک در سیستم‌های BCI با به‌سازی فرایند استخراج ویژگی و استفاده از الگوریتم بهینه یافتن پاسخ تنک

علیرضا میرجلیلی^۱، وحید ابوطالبی^{۲*}، محمدتقی صادقی^۲

^۱ کارشناسی ارشد، دانشکده مهندسی برق و کامپیوتر دانشگاه یزد، یزد، ایران

^۲ استادیار، دانشکده مهندسی برق و کامپیوتر، دانشگاه یزد، یزد، ایران

تاریخ ثبت در سامانه: ۱۳۹۴/۳/۱۶، نسخه اصلاح شده: ۱۳۹۴/۵/۲۷، پذیرش قطعی: ۱۳۹۴/۶/۸

چکیده

در سال‌های اخیر، واسط مغز/رایانه (BCI)، به عنوان وسیله‌ای جدید برای ارتباط بین مغز انسان و محیط اطرافش مورد توجه قرار گرفته‌است. راه‌اندازی این نوع سیستم‌ها به هم‌کاری چند بلوک از جمله بلوک‌های ثبت، پردازش سیگنال و رابط کاربری نیاز دارد. بلوک پردازش سیگنال شامل بلوک‌های پیش‌پردازش و شناسایی الگو است. بلوک شناسایی الگو نیز از دو مرحله استخراج ویژگی و طبقه‌بندی تشکیل شده‌است. در این پژوهش، از طبقه‌بندی‌کننده براساس نمایش تنک (SRC) در بلوک طبقه‌بندی استفاده شد. طبقه‌بندی‌کننده براساس نمایش تنک، دو مرحله‌ی اساسی تشکیل ماتریس دیکشنری و یافتن پاسخ تنک داده‌ی ورودی دارد. برای تشکیل ماتریس دیکشنری که از مرحله استخراج ویژگی به دست می‌آید، از الگوریتم الگوهای مکانی مشترک (CSP) استفاده شد. از معایب این الگوریتم، حساسیت به نویز و مسأله‌ی فرایادگیری است. برای رفع معایب CSP، از الگوریتم‌های الگوهای مکانی مشترک تنظیم شده (RCSP) استفاده شد. در مطالعات قبلی در زمینه‌ی BCI، برای یافتن پاسخ تنک از الگوریتم استاندارد BP استفاده شده که از معایب آن، پیچیدگی محاسباتی و زمان‌بر بودن آن است. برای رفع معایب این روش، با توجه به کارایی مناسب روش جدید SLO در تعدادی از تحقیقات مشابه، از این الگوریتم برای محاسبه پاسخ تنک استفاده شد. نتایج حاصل نشان می‌دهد که الگوریتم‌های RCSP در مواردی که داده‌های آموزشی کمی موجود است می‌تواند معایب CSP را به خوبی برطرف کند. به طور میانگین استفاده از این روش ۷/۵۳٪ بهبود را نسبت به CSP نشان داد. هم‌چنین الگوریتم SLO، علی‌رغم کاهش قابل ملاحظه زمان پردازش در مقایسه با BP، در صحت تشخیص معادل با آن عمل کرده‌است.

کلیدواژه‌ها: واسط مغز/رایانه، تصوّر حرکتی، الگوی مکانی مشترک، طبقه‌بندی براساس نمایش تنک، نرم صفر هموار شده

*نویسنده مسؤول

نشانی: گروه مخابرات، دانشکده مهندسی برق و کامپیوتر، دانشگاه یزد، یزد، ایران، کد پستی: ۷۴۱-۸۹۱۹۵

تلفن: ۳۱۲۳۳۳۹۸ (۳۵) +۹۸

دورنگار: ۳۸۲۰۰۱۴۴ (۳۵) +۹۸

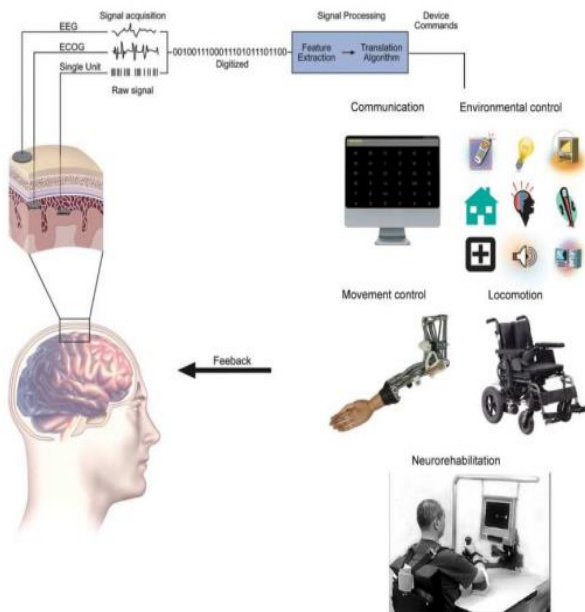
پست الکترونیکی: abootalebi@yazd.ac.ir

۱- مقدمه

پیش‌پردازش سیگنال: پس از ثبت سیگنال، لازم است که نویزها و آرتیفکت‌ها از آن حذف شود و احیاناً بعضی روش‌های آماری مثل سفیدکردن روی آن اعمال شود.

استخراج ویژگی: از سیگنال عاری از نویز و آرتیفکت، ویژگی‌هایی استخراج می‌شود که این ویژگی‌ها می‌تواند مربوط به حوزه زمان، فرکانس و یا ویژگی‌های مکانی باشد. هم‌چنین می‌توان از ترکیب این ویژگی‌ها نیز استفاده کرد (زمانی/فرکانسی، زمانی/مکانی و غیره).

طبقه‌بندی سیگنال: برای تعیین اینکه سوژه کدام تکلیف ذهنی را انجام داده‌است، بردارهای ویژگی باید دسته‌بندی شوند. ارتباط با رایانه: پس از اینکه سیگنال‌ها دسته‌بندی شدند، به وسیله یک عبارت کنترلی، برای یک کاربرد مشخص استفاده می‌شوند.



شکل (۱) - شمای کلی یک سیستم BCI [۲]

یکی از راه‌کارهای مطرح شده برای دست‌یابی به سیستم‌های BCI مبتنی بر EEG، استفاده از سیگنال‌های EEG مرتبط با فعالیت‌های ذهنی است. برای مثال، از این گونه فعالیت‌ها می‌توان تصورات حرکتی اندام‌های بدن را نام برد. برای تفکیک این فعالیت‌ها به پردازش سطح بالا و قوی نیاز است که عموماً شامل روش‌های شناسایی الگو^۵ است.

بیماری‌های مختلفی می‌توانند به سیستم عصبی/عضلانی آسیب برسانند که مغز از طریق آن عصب‌ها قادر به ایجاد ارتباط و اعمال کنترل با محیط خارج است. بیماری‌های 'ALS^۱، آسیب ساقه مغز^۲، آسیب مغزی نخاعی، قطع نخاعی و فلج کامل مثالی از انواع بیماری‌هایی است که مسیر عصبی کنترل عضلات در آن‌ها آسیب می‌بیند. در شرایط حاد بیماری، فرد مبتلا ممکن است تمام حرکت‌های ارادی خود را از دست بدهد. حتی ممکن است روی حرکات چشم و تنفس که اعمالی غیرارادی هستند نیز تأثیرگذار باشد. این گونه بیماران را، در اصطلاح «قفل شده»^۳ می‌نامند [۱]. برای جبران فیزیولوژیکی آسیب وارده در اثر این بیماری‌ها، سه انتخاب برای بازآفرینی عملکرد طبیعی بیماران وجود دارد:

(۱) افزایش قابلیت‌های مسیرهای عصبی/عضلانی باقیمانده؛

(۲) بازسازی عملکرد از دست رفته از طریق ترمیم یا

جبران‌سازی مسیر عصبی آسیب دیده؛

(۳) فراهم آوردن مسیر ارتباطی جدید و غیرماه‌یچه‌ای برای مغز که از طریق آن بتواند به طور مستقیم دستورالعمل‌ها و پیام‌های کنترلی را به محیط خارج ارسال نماید: یک واسط مغز/رایانه^۴ (BCI).

واسط مغز/رایانه از مجموعه‌ی سنسورها و اجزای پردازش سیگنال تشکیل شده که فعالیت مغزی فرد را به طور مستقیم به یک سری سیگنال‌های ارتباطی یا کنترلی تبدیل می‌کند. در این سامانه ابتدا باید فعالیت الکتریکی مغز را با دستگاه‌های ثبت امواج مغزی ثبت کرد که معمولاً به دلیل دقت زمانی بالا، ارزان بودن و نیز استفاده آسان، از الکتروانسفالوگرافی برای ثبت امواج مغزی استفاده می‌شود. الکترودهای EEG در سطح پوست سر قرار می‌گیرند و میدان الکتریکی حاصل از فعالیت نوروها را اندازه‌گیری می‌کنند. ساختار عمومی یک سیستم واسط مغز/رایانه مطابق شکل (۱)، شامل بخش‌های ذیل است [۲]:

ثبت سیگنال: سیگنال‌های الکتریکی مغز، به وسیله روش‌های تهاجمی یا غیرتهاجمی (الکترودها) ثبت می‌شوند؛ سپس، سیگنال تقویت و نمونه‌برداری می‌شود.

^۱ Amyotrophic lateral sclerosis

^۲ Brain Stem Stroke

^۳ Locked-in

^۴ Brain Computer Interface

^۵ Pattern Recognition


ورودی به سیستم، از الگوریتم جدید نرم صفر هموار شده^۸ (SL0) استفاده شد. در ادامه نحوه اجرای سیستم BCI براساس تصور حرکت شامل دادگان، پیش‌پردازش، استخراج ویژگی و طبقه‌بندی شرح داده شده است. سپس، نتایج حاصل از آزمایش‌ها مورد تحلیل و بررسی قرار گرفته و در پایان، جمع‌بندی و نتیجه‌گیری از آن‌ها انجام شده است.

۲- اجزای یک سیستم BCI

از یک سیستم شناسایی الگو برای یک سیستم BCI براساس تصور حرکتی استفاده شد که مشابه هر سیستم شناسایی الگوی دیگر شامل دو بخش اصلی استخراج ویژگی و طبقه‌بندی است. پیش از این لازم بود پیش‌پردازش‌هایی روی سیگنال انجام شود. پس از معرفی دادگان مورد استفاده، هر یک از بخش‌های فوق و روش‌های به کار رفته در هر کدام به صورت کامل تعریف شده است.

۲-۱- معرفی دادگان استفاده شده

در این پژوهش از دادگان BCI competition III (Data set IVa) استفاده شده است [۵]. این مجموعه داده شامل سیگنال‌های EEG دو تصور حرکتی دست و پای راست برای ۵ نفر است. افراد در حالتی که دست‌های آن‌ها بدون حرکت است، روی یک صندلی راحت نشسته اند. ۱۱۸ الکترواد Ag/AgCl برای ثبت داده‌های EEG با استاندارد ۲۰-۱۰ استفاده شده است. سیگنال‌ها با فرکانس نمونه‌برداری ۱۰۰ هرتز ثبت شده اند. مطابق شکل (۲)، برای هر تصور حرکتی یک نشانه به مدت ۳/۵ ثانیه نمایش داده شده است.



شکل (۲) - پارادایم ثبت سیگنال

افراد باید درین مدت به تصور حرکتی مورد نظر می‌پردازند. زمان استراحت تا آزمایش بعدی به طور تصادفی بین ۱/۷۵ تا ۲/۲۵ ثانیه در نظر گرفته شده است. در کل برای هر

با گسترش روزافزون کاربرد تکنیک‌های نمایش تنک^۱ در حوزه‌های شناسایی الگو، طبقه‌بندی‌کننده براساس نمایش تنک^۲ (SRC) در زمینه‌های مختلفی مانند تشخیص چهره مطرح شده است. [۳]. طبقه‌بندی با نمایش تنک سیگنال شامل دو مرحله است: (۱) ابتدا داده ورودی با تشکیل ماتریس دیکشنری که از کنار هم قرار دادن تمامی داده‌های آموزشی تشکیل شده، به صورت تنک کد می‌شود؛ (۲) با این ضرایب تنک و با بازسازی داده آزمایشی، طبقه‌بندی انجام می‌شود. بنابراین، تشکیل ماتریس دیکشنری فراکامل از مرحله استخراج ویژگی و یافتن تنک‌ترین نمایش ممکن برای داده ورودی به سیستم از روی ماتریس دیکشنری، برای این طبقه‌بندی‌کننده امری حیاتی محسوب می‌شود.

در حوزه BCI، اخیراً از این طبقه‌بندی‌کننده استفاده شده- است. هم‌چنین گزارش شده که طبقه‌بندی‌کننده SRC در مقایسه با طبقه‌بندی‌کننده پرکاربرد LDA، کارایی بهتری دارد [۴]. شین^۳ در این تحقیق برای استخراج ویژگی و تشکیل ماتریس دیکشنری از الگوریتم الگوهای مکانی مشترک^۴ (CSP) که به صورت موفقیت آمیزی در تحقیقات BCI استفاده می‌شود، استفاده کرد. وی برای یافتن نمایش تنک داده ورودی به سیستم نیز الگوریتم جست‌وجوی پایه^۵ (BP) را به کار گرفت که از معروف‌ترین الگوریتم‌ها برای یافتن پاسخ تنک است.

الگوریتم CSP دو اشکال عمده دارد: اول، حساسیت بالا به نویز؛ دوم، مسأله‌ی فرایادگیری^۶ در مواردی که مجموعه آموزشی کوچک باشد. از مهم‌ترین ایرادهای الگوریتم BP نیز زمان مورد نیاز آن است که به خصوص با زیاد شدن ابعاد مسأله معمولاً مشکل ساز می‌شود.

در این مقاله، از طبقه‌بندی‌کننده SRC در چارچوب یک سیستم BCI براساس تصور حرکتی استفاده شد. با هدف رفع معایب یاد شده، در فاز استخراج ویژگی از روش‌های بهبود الگوریتم CSP با نام کلی CSP تنظیم شده استفاده شد^۷ (RCSP)، و برای افزایش سرعت محاسبه پاسخ تنک داده

^۱Sparse Representation

^۲Sparse Representation-based Classifier

^۳Shin

^۴Common Spatial Pattern

^۵Basis Pursuit

^۶Over Learning

^۷Regularized Common Spatial Pattern

^۸Smoothed L0-norm

۲-۳- استخراج ویژگی به روش فیلترهای مکانی

برای به دست آوردن اطلاعات مکانی نهفته شده در سیگنال، عموماً از فیلترهای مکانی مختلف استفاده می‌شود. برای رسیدن به این هدف، می‌توان از وزن‌دار کردن یا انتخاب الکترودهای مختلف (که نواحی مکانی گوناگونی دارد) استفاده کرد.

روش‌های ساده فیلترهای مکانی، شامل انتخاب کردن بعضی الکترودها مطابق با خصوصیت‌های مورد انتظار از سیگنال‌های مغزی می‌شود. در الکترودهای انتخاب شده، نویز یا فعالیت‌های پس‌زمینه غیرمرتبط با هدف مورد نظر کم‌تر از دیگر الکترودها است. در این روش، از بقیه الکترودهای ثبت سیگنال چشم پوشی می‌شود. برای مثال، هنگامی که روی یک سیستم BCI براساس تصویر حرکتی کار می‌شود، می‌دانیم که طبق خصوصیات نوروفیزیولوژیکی، سیگنال‌های مورد نظر در محدوده‌ی منطقه‌ی حسی حرکتی قرار دارد. بنابراین؛ روی الکترودهای C_3 و C_4 تمرکز می‌شود [۸].

روش‌های پیشرفته‌تری نیز برای اعمال فیلترهای مکانی وجود دارد. در این روش‌ها سیگنال EEG به الگوهای مکانی مطابق با هدف مورد نظر سیستم‌های BCI تجزیه می‌شود. از این الگوها، ویژگی‌های مکانی مناسب استخراج می‌شود. در این پژوهش، الگوریتم الگوهای مکانی مشترک (CSP) به عنوان قوی‌ترین و پرکاربردترین الگوریتم استخراج ویژگی در سیستم‌های BCI، به خصوص سیستم‌های براساس تصویر حرکتی مورد استفاده و بررسی قرار گرفت.

۲-۳-۱- الگوهای مکانی مشترک

کارایی فیلترهای مکانی برای بهبود رزولوشن مکانی و افزایش نسبت سیگنال به نویز در سیگنال EEG قبلاً ثابت شده است [۹]. یک روش از فیلترهای مکانی با نام الگوهای مکانی مشترک است که برای روش‌های شناسایی الگو مطرح شده است [۱۰]. این روش براساس قطری سازی هم‌زمان دو ماتریس متقارن حقیقی کار می‌کند. قطری سازی هم‌زمان اجازه تجزیه سیگنال EEG خام، به دو الگوی مجزا از دو کلاس را می‌دهد. درین دو الگو به صورت هم‌زمان واریانس یکی از کلاس‌ها بیشینه و واریانس دیگری کمینه می‌شود. اگر تنها از فیلترهای با قابلیت تفکیک بیش‌تر استفاده شود، ابعاد داده هم کاهش می‌یابد


کلاس، ۱۴۰ آزمایش صورت گرفته و در مجموع ۲۸۰ آزمایش برای هر فرد حاصل شده است. مجموعه‌ی آموزشی و آزمون برای افراد مورد آزمون مطابق با جدول (۱) بوده که برای هر فرد متفاوت است.

جدول (۱)- ثبت‌های آموزشی و آزمون برای افراد مختلف

افراد	aa	al	av	aw	ay
ثبت‌های آموزش	۱۶۸	۲۲۴	۸۴	۵۶	۲۸
ثبت‌های آزمون	۱۱۲	۵۶	۱۹۶	۲۲۴	۲۵۲

۲-۲- پیش‌پردازش

در مرجع ثبت دادگان مذکور، فیلترهای میان‌گذری در مرحله ثبت سیگنال و دیجیتال کردن آن به کار رفته است. در این پژوهش سیگنال‌ها از یک مرحله پیش‌پردازش نیز عبور داده شد. در این قسمت نویزها و آرتیفکت‌های مختلفی که هم‌زمان با سیگنال اصلی ثبت شده و معمولاً باعث بروز خطا در نتایج می‌شوند تا حد ممکن حذف شدند. این بخش می‌تواند از روش‌های ساده‌ای مثل یک فیلتر فرکانسی معمولی تا روش‌های پیچیده‌ای مثل فیلترهای وقفی را دربرگیرد. جهت پاک‌سازی سیگنال از یک فیلتر میان‌گذر بین ۳۰-۸ هرتز استفاده شد. براساس مطالعات قبلی [۶]، فیلتر باترورث مرتبه ۵ انتخاب شد. محدوده‌ی فرکانسی فوق برای فیلتر میان‌گذر با هدف حفظ باندهای μ و β انتخاب شد زیرا در سیگنال‌های مربوط به ریتم‌های حسی و حرکتی، عمده انرژی سیگنال در این باندها یافت می‌شود. داده به قطعات ۲ ثانیه‌ای از ۰/۵ تا ۲/۵ ثانیه بعد از محل شروع هر آزمایش (منطبق بر روش برنده مسابقات BCI در دادگان IV Competition BCI (data set IIa) ([۷] قطعه‌بندی شد (شکل ۳).



شکل (۳)- قطعه‌بندی زمانی مورد استفاده

۲-۳-۲- الگوهای مکانی مشترک تنظیم شده

علی‌رغم کارایی بالا، روش CSP حساسیت بالایی نسبت به نویز و مسأله فریادگیری، به خصوص در مجموعه‌های آموزشی کوچک دارد. ازین روی، تنظیم این روش با افزودن اطلاعات قبلی به آن می‌تواند مفید باشد. دو روش برای تنظیم CSP پیشنهاد شده است [۱۱] که توضیحی کوتاه داده می‌شود.

الف) تنظیم در سطح تخمین ماتریس کواریانس

الگوریتم CSP نیاز به تخمین ماتریس کواریانس هر کلاس دارد. اگر مجموعه داده‌ی آموزشی نویزی و یا کم باشد، تخمین ماتریس کواریانس ضعیف شده و حالت‌های ذهنی مورد نظر را شامل نمی‌شود. نتیجه آن تولید فیلترهای مکانی ضعیفی است که قابلیت تفکیک بالایی را ندارند. بنابراین اضافه کردن دانش قبلی برای بهبود تخمین ماتریس کواریانس اجتناب‌ناپذیر است. بدین منظور می‌توان از عبارات تنظیم‌کننده استفاده نمود. مطابق با [۱۱] این کار با معادله‌های (۴) انجام می‌پذیرد:

$$\tilde{C}_c = (1 - \gamma)\hat{C}_c + \gamma I \quad (4)$$

$$\tilde{C}_c = (1 - \beta)s_c C_c + \beta G_c$$

در رابطه (۴)، C_c ماتریس کواریانس اولیه هر کلاس، \tilde{C}_c تخمین تنظیم شده آن، I ماتریس همانی، s_c پارامتر هموارکننده (یک اسکالر) که ثابت مقیاس‌دهی نامیده می‌شود، γ, β دو پارامتر تنظیم‌کننده ($\gamma, \beta \in [0, 1]$) و G_c ماتریس کواریانس عمومی است. پارامتر γ تخمین کواریانس اولیه را مطابق با ماتریس یک‌گانه کاهش می‌دهد تا بایاس تخمینی که در اثر کم بودن داده آموزشی به وجود می‌آید را خنثا کند. پارامتر β تخمین کواریانس اولیه را مطابق با ماتریس کواریانس عمومی کاهش می‌دهد. این کار برای پایداری بیش‌تر تخمین صورت می‌گیرد. ماتریس کواریانس عمومی پیش فرضی است در مورد اینکه برای هر حالت ذهنی ماتریس کواریانس چه‌گونه باید باشد. این ماتریس عموماً با سیگنال‌های افراد مختلفی که آزمایش‌های یکسانی (برای مثال تصور حرکت دست راست) روی آن‌ها انجام شده به دست می‌آید. آموزش فیلترهای مکانی با این روش‌ها با جای‌گزین کردن C_1 و C_2 در الگوریتم استاندارد CSP (معادله (۱))، با \tilde{C}_1 و \tilde{C}_2 انجام می‌شود.

و عملکرد طبقه‌بندی‌کننده نیز بهتر می‌شود. در تحلیل CSP از فیلترهای مکانی w استفاده می‌شود که از آن تابع هدف مطابق رابطه (۱) اکسترمم می‌شود. در رابطه (۱)، X_i ماتریس داده و C_i ماتریس کواریانس کلاس i ام است.

$$J(w) = \frac{w^T X_1^T X_1 w}{w^T X_2^T X_2 w} = \frac{w^T C_1 w}{w^T C_2 w} \quad (1)$$

لوت^۱ و هم‌کاران به حل این مسأله بهینه‌سازی پرداختند [۱۱]. حل معادله بهینه‌سازی رابطه (۱) معادل با اکسترمم کردن تابع (۲) است.

$$L(\lambda, w) = w^T C_1 w - \lambda(w^T C_2 w - 1) \quad (2)$$

فیلترهای w که معادله L را اکسترمم می‌کنند، به گونه‌ای هستند که مشتق L نسبت به w را صفر می‌کنند:

$$\frac{\partial L}{\partial w} = 2w^T C_1 - 2\lambda w^T C_2 = 0 \quad (3)$$

$$\Leftrightarrow C_1 w = \lambda C_2 w \Leftrightarrow C_2^{-1} C_1 w = \lambda w$$

دراین جا با یک مسأله استاندارد مقادیر ویژه روبه‌رو هستیم. فیلترهای مکانی که معادله (۱) را ماکزیمم می‌کنند، بردارهای ویژه ماتریس $M = C_2^{-1} C_1$ هستند که مطابق با مقادیر ویژه این ماتریس به دست می‌آیند. بردارهای ویژه به دست آمده از بزرگ به کوچک در ماتریس W قرار داده می‌شوند. بدین ترتیب، ماتریس فیلترهای مکانی $W \in R^{c \times c}$ (c تعداد کانال‌های ثبت) حاصل می‌شود. فیلتر مطابق با بزرگ‌ترین مقدار ویژه، بیش‌ترین قابلیت تفکیک برای کلاس ۱ را دارد. در همین زمان فیلتر مکانی مطابق با کوچک‌ترین مقدار ویژه، بیش‌ترین قابلیت تفکیک برای کلاس ۲ را دارد. در روش CSP، N_f جفت از این فیلترها (N_f فیلتر ابتدایی و N_f فیلتر انتهایی) انتخاب شده و از مابقی فیلترها صرف نظر می‌شود ($N_f \leq \frac{c}{2}$) و ویژگی‌های استخراج شده، لگاریتم واریانس سیگنال EEG بعداز تصویر شدن روی فیلترهای w است. بدین ترتیب، فیلترهای مکانی و بردارهای ویژگی مناسب برای تفکیک داده‌های دو کلاس از هم به دست می‌آید.

^۱ Lotte

مورد استفاده قرار می‌گیرند؛ زیرا، به ترتیب معادله (۱) را بیشینه و کمینه می‌کنند. برای RCSP بردارهای ویژه متناظر با کوچک‌ترین مقادیر ویژه M_1 معادله (۵) را کمینه می‌کنند. درعین حال عبارت جریمه (که باید کمینه شود) را بیشینه می‌کنند. بنابراین، برای به دست آوردن فیلترهایی که هم‌زمان G_2 را بیشینه و C_1 را کمینه کنند باید تابع هدف مطابق با معادله (۱۰) نیز بیشینه شود.

$$J_{P_2}(w) = \frac{w^T C_2 w}{w^T C_1 w + \alpha P(w)} \quad (10)$$

بدین ترتیب، فیلترهای w با به دست آمدن بردارهای ویژه متناظر با بزرگ‌ترین مقادیر ویژه $M_2 = (C_1 + \alpha K)^{-1} C_2$ به دست خواهند آمد. به عبارت دیگر در RCSP، فیلترهای مکانی به کار رفته، بردارهای ویژه متناظر با بزرگ‌ترین مقادیر ویژه دو ماتریس M_1 و M_2 هستند. جدول (۲) به‌طور خلاصه تفاوت‌های اصلی بین CSP استاندارد و RCSP را نشان می‌دهد. [۱۱]

جدول (۲) - تفاوت‌های بین تابع هدف و الگوریتم بهینه‌سازی در دو روش CSP استاندارد و RCSP [۱۱]

RCSP	CSP	
$J_{P_{1,2}}(w) = \frac{w^T \hat{C}_{\{1,2\}} w}{w^T \hat{C}_{\{2,1\}} w + \alpha P(w)}$ <p>با</p> $P(w) = \ w\ _K^2 = w^T K w$ $\hat{C}_c = (1 - \gamma) \hat{C}_c + \gamma I$ <p>with $\hat{C}_c = (1 - \beta) s_c C_c + \beta G_c$</p>	$J(w) = \frac{w^T C_1 w}{w^T C_2 w}$	تابع هدف
<p>بردار ویژه مطابق با N_f بزرگ‌ترین مقادیر ویژه ماتریس</p> $M_1 = (C_2 + \alpha K)^{-1} C_1$ <p>و</p> $M_2 = (C_1 + \alpha K)^{-1} C_2$	<p>بردار ویژه مطابق با N_f بزرگ‌ترین و N_f کوچک‌ترین مقادیر ویژه ماتریس</p> $M = C_2^{-1} C_1$	جواب‌های مسأله بهینه‌سازی

در هر دو روش تنظیم، بسته به نوع تعریف ماتریس کواریانس عمومی G_c ، ماتریس کدکننده K و استفاده از یک یا چند پارامتر تنظیم، الگوریتم‌های مختلفی می‌توان تعریف کرد [۱۱]. در ادامه چندین الگوریتم مختلف RCSP بررسی شده است.

(ب) تنظیم در سطح تابع هدف CSP

در این روش با هدف رفع عیب فرایادگیری در روش CSP استاندارد، با اضافه کردن یک عبارت تنظیم به تابع هدف اولیه، جواب‌هایی که فیلترهای مکانی به دست آمده از آن با فرض اولیه در مسأله هماهنگی ندارند، جریمه می‌شوند [۱۱]. در این روش، تابع هدف اولیه معادله (۱) به معادله (۵) تبدیل می‌شود.

$$J_{P_1}(w) = \frac{w^T C_1 w}{w^T C_2 w + \alpha P(w)} \quad (5)$$

در رابطه (۵)، $P(w)$ یک تابع جریمه است که تعیین می‌کند که فیلتر مکانی w چه مقدار با اطلاعات جانبی در مورد مسأله هماهنگ است. هرچه w بیش‌تر شرط را برآورده کند، $P(w)$ کوچک‌تر (میزان جریمه کم‌تر) است. بنابراین، برای بیشینه کردن $J_{P_1}(w)$ باید $P(w)$ کمینه شود. α یک پارامتر تنظیم است که توسط کاربر تعیین می‌شود ($\alpha \geq 0$). در این پژوهش از جریمه‌های مرتبه دوم مطابق معادله (۶) استفاده شد.

$$P(w) = \|w\|_K^2 = w^T K w \quad (6)$$

ماتریس K شرط مورد نظر را کد می‌کند. با یک جریمه مرتبه ۲ معادله (۵) به صورت معادله (۷) در می‌آید.

$$J_{P_1}(w) = \frac{w^T C_1 w}{w^T C_2 w + \alpha w^T K w} = \frac{w^T C_1 w}{w^T (C_2 + \alpha K) w} \quad (7)$$

با استفاده از روش لاگرانژ داریم:

$$L_{P_1}(\lambda, w) = w^T C_1 w - \lambda (w^T (C_2 + \alpha K) w - 1) \quad (8)$$

در نهایت با روشی مشابه CSP، با بهینه‌سازی معادله (۸)، با مسأله استاندارد مقادیر ویژه مطابق با معادله (۹) روبه‌رو هستیم:

$$(C_2 + \alpha K)^{-1} C_1 w = \lambda w \quad (9)$$

با تغییر تابع هدف، مسأله مقادیر ویژه نیز تغییر می‌کند. فیلترهای w که تابع $J_{P_1}(w)$ را بیشینه می‌کنند، بردارهای ویژه متناظر با بزرگ‌ترین مقادیر ویژه $M_1 = (C_2 + \alpha K)^{-1} C_1$ است. در روش CSP بردارهای ویژه متناظر با بزرگ‌ترین و کوچک‌ترین مقادیر ویژه M ، هر دو به عنوان فیلترهای مکانی

در رابطه (۱۳)، tr و det به ترتیب عملگرهای رد^۴ ماتریس و دترمینان و N_e تعداد الکترودهای استفاده شده است. در این روش مقدار $s_c = 1$ فرض می‌شود.

۲-۳-۴- CSP با تنظیم تیخونوف^۵ (TRCSP)

این الگوریتم برپایه تنظیم تابع هدف با جریمه‌های مرتبه دوم طراحی شده است. در این الگوریتم $\gamma = \beta = 0$ ، $\alpha \geq 0$ و $s_c = 1$ است. در این روش، جواب‌هایی که وزن بالایی دارند جریمه می‌شوند. عبارت جریمه به صورت $P(w) = \|w\|^2 = w^T w = w^T I w$ تعریف می‌شود. با توجه به مطالب قبل (بخش ۲-۳-۲)، با قرار دادن $K=I$ الگوریتم TRCSP حاصل می‌شود. انتظار می‌رود چنین تنظیمی، پاسخ‌هایی را که منجر به تولید فیلترهایی با نرم پایین می‌شوند را محدود کند. در نتیجه تأثیر آرتیفکت‌ها و داده‌های پرت^۶ را کاهش دهد.

۲-۳-۵- تنظیم مکانی CSP^۷ (SRCSP)

آموزش فیلترهای مکانی به روش CSP به طور کامل از مکان قرارگیری الکترودهای ثبت EEG چشم پوشی می‌کند. الگوریتم SRCSP با استفاده از فرض هموار بودن فیلترهای مکانی w پایه-گذاری می‌شود [۱۳]. برای تضمین این همواری، از عبارت جریمه لاپلاسیان $P(w)$ با پیروی از ماتریس کد کننده K به شرح معادله (۱۴) استفاده می‌شود. در این الگوریتم $0, \gamma = \beta = 0$ و $\alpha \geq 1$ و $s_c = 1$ است.

$$K = D_G - G \quad \text{و} \quad G(i, j) = \exp\left(-\frac{1}{2} \frac{\|v_i - v_j\|^2}{r^2}\right) \quad (14)$$

در رابطه (۱۴)، v_i بردار مختصات ۳ بعدی الکترودها، D_G ماتریس قطری به صورت $D_G(i, i) = \sum_j G(i, j)$ و r پارامتر مشخص کننده فاصله برای دو الکترودها است. با توجه به این روابط، عبارت جریمه $P(w)$ به صورت معادله (۱۵) حاصل می‌شود.

$$P(w) = w^T (D_G - G) w = \sum_{i,j} G(i, j) (w_i - w_j)^2 \quad (15)$$

۲-۳-۳- الگوریتم CSP مرکب^۱ (CCSP)

این الگوریتم توسط کانگ^۲ پیشنهاد شد [۱۲]. در این الگوریتم تنها از پارامتر β استفاده می‌شود ($\alpha = \gamma = 0$). ماتریس کواریانس عمومی با استفاده از ماتریس کواریانس دیگر افراد آزمایش به دست می‌آید. دو حالت برای تعیین این ماتریس وجود دارد که در ذیل شرح داده می‌شود.

الف) CCSP1: برای رسیدن به تخمین بهینه‌ای از ماتریس کواریانس در مواردی که داده‌های آموزش کم است از ماتریس کواریانس عمومی استفاده می‌شود. ماتریس کواریانس عمومی در این روش، جمع وزنداری از ماتریس کواریانس دیگر افراد آزمایش (مطابق با یک فعالیت ذهنی یکسان) است. مقادیر s_c و G_c مطابق با معادله (۱۱) به دست می‌آیند.

$$G_c = \sum_{i \in \Omega} \frac{N_c^i}{N_{t,c}} C_c^i \quad \text{و} \quad s_c = \frac{N_c}{N_{t,c}} \quad (11)$$

در رابطه (۱۱)، Ω مجموعه افراد آزمایش، C_c^i ماتریس کواریانس کلاس c برای فرد i ام، N_c^i تعداد سیگنال‌های آموزشی که در تخمین C_c^i استفاده شده است، N_c تعداد سیگنال‌های EEG که در تخمین G_c (ماتریس هدف) استفاده شده و $N_{t,c}$ تعداد کل سیگنال‌های آموزشی برای کلاس c است (برای همه افراد مجموعه Ω و فرد هدف). بعد از محاسبه این مقادیر، با رابطه (۴) مقادیر \tilde{C}_1 و \tilde{C}_2 محاسبه می‌شود.

ب) CCSP2: در این روش هم مانند روش قبل، ماتریس کواریانس عمومی از جمع وزندار ماتریس کواریانس دیگر افراد به دست می‌آید.

این وزن بر اساس هم‌گرایی KL ^۳ بین داده‌ی افراد به شرح رابطه (۱۲) حاصل می‌شود [۱۲].

$$G_c = \sum_{i \in \Omega} \frac{1}{Z} \frac{1}{KL(i, t)} C_c^i \quad \text{و} \quad Z = \sum_{j \in \Omega} \frac{1}{KL(j, t)} \quad (12)$$

پارامتر $KL(i, t)$ هم‌گرایی KL بین فرد هدف t و فرد i ام است که با معادله (۱۳) به دست می‌آید.

$$KL(i, t) = \frac{1}{2} \left(\log \left(\frac{\det(C_c)}{\det(C_c^i)} \right) + tr(C_c^{-1} C_c^i) - N_e \right) \quad (13)$$

⁴ Trace

⁵ Tikhonov

⁶ outlier

⁷ Spatially Regularized CSP

¹ Composite Common Spatial Pattern

² kang

³ kullback-Leibler

۲-۴-۱- طبقه‌بندی با تکنیک نمایش تنک

$$\hat{s} = \arg \min \|s\|_0 \text{ subject to } y = Xs \quad (17)$$

یکی از مباحث مهم در سیستم شناسایی الگو، بعداز استخراج ویژگی و انتقال داده‌ها به فضای ویژگی مورد نظر، طراحی مناسب طبقه‌بندی کننده است. برخی از مهم‌ترین طبقه‌بندی کننده‌ها که در سیستم‌های شناسایی الگو مورد توجه قرار گرفته‌اند، طبقه‌بندی کننده بیزین، شبکه‌های عصبی، ماشین بردار پشتیبان (SVM) و LDA است.

اخیراً طبقه‌بندی کننده جدید براساس نمایش تنک (SRC)، در حوزه‌های مختلف شناسایی الگو به ویژه تشخیص چهره [۳] مطرح شده و کارایی بالاتری نسبت به طبقه‌بندی کننده‌های رایج دارد. در این پژوهش، از این طبقه‌بندی کننده برای دسته‌بندی کلاس‌های مختلف استفاده شده است.

$$\delta_i(s) = [0, \dots, 0, s_{i,1}, \dots, s_{i,n_i}, 0, \dots, 0]^T \in R^n \quad (18)$$

در رابطه (۱۸)، $n = n_1 + \dots + n_c$ با این اوصاف $\delta_i = X\delta_i(s)$ داده y را تنها برحسب ضرایب متناظر با داده‌های کلاس i ام بیان می‌کند. این تابع برای هر c کلاس روی نمایش تنک داده y اعمال می‌شود و در نهایت برچسبی انتخاب می‌شود که میزان باقیمانده $r_i(y) = \|y - X\delta_i(s)\|_2$ را حداقل کند:

$$\text{Class}(y) = \min_i r_i(y) \quad (19)$$

یافتن پاسخ تنک کار پیچیده‌ای است، زیرا نرم صفر پیوسته نیست و بهینه‌سازی آن نیاز به جست‌وجوی ترکیباتی دارد.

۲-۴-۲- الگوریتم‌های یافتن پاسخ تنک

یک دستگاه معادلات خطی در حالت کلی به صورت ماتریسی $y = Xs$ قابل بیان است. اگر در این دستگاه تعداد مجهولات از تعداد معادلات بیش‌تر باشد، به آن فرومعین گفته می‌شود. بنابراین، تعداد پاسخ‌های s هایی که در $y = Xs$ صدق می‌کنند در این نوع دستگاه می‌تواند بیش‌از یک باشد. به همین دلیل، برای انتخاب یکی از پاسخ‌های ممکن نیاز است تا قیدهای دیگری به مسئله اضافه شوند. به دلیل مزایای فراوان، پاسخ تنک در کاربردهای یاد شده، یکی از قیدهای متداول برای انتخاب یکی از پاسخ‌های دستگاه فراکامل، قید تنک بودن به معنای حداقل کردن نرم صفر است. برای رسیدن به این هدف باید معادله‌ای مشابه با معادله (۱۷) حل شود.

ایده اصلی در این طبقه‌بندی کننده، نمایش هر داده آزمون برحسب داده‌های آموزشی دسته متناظر با آن است. فرض کنید داده‌های آموزشی دسته i ام در ستون‌های ماتریس X_i به صورت $X_i = [x_{i,1}, x_{i,2}, \dots, x_{i,n_i}] \in R^{m \times n_i}$ مرتب شده باشند. در اینجا n_i تعداد داده‌های آموزشی از کلاس i ام است. اگر $y \in R^{m \times 1}$ یک داده ورودی متعلق به دسته i ام باشد، انتظار می‌رود که بتوان y را طبق رابطه (۱۶) بر حسب ستون‌های ماتریس X_i نمایش داد.

۲-۴-۱- جزئیات روش SRC

در رابطه (۱۶)، $s_{i,j}$ اعداد اسکالر هستند. فرم ماتریسی معادله (۱۶) به صورت $y = Xs$ است. در روش SRC برای رسیدن به این هدف از تکنیک نمایش تنک استفاده می‌شود. باید توجه داشت که برحسب داده آزمون برای سیستم مجهول است، بنابراین، ماتریس X به صورت $X = [X_1, \dots, X_c]$ تعریف می‌شود. در این رابطه هر کدام از X_i ها زیر ماتریس‌هایی است که داده‌های دسته i ام در آن قرار دارند. در چارچوب نظریه نمایش تنک داده‌ها، ماتریس X همان ماتریس دیکشنری است. حال می‌توان نمایش تنک داده ورودی y را برحسب ستون‌های ماتریس X به دست آورد.

$$y = s_{i,1}x_{i,1} + \dots + s_{i,n_i}x_{i,n_i} = \sum_{j=1}^{n_i} s_{i,j}x_{i,j} \quad (16)$$

ماتریس X به دست آورد.

ستون‌های ماتریس دیکشنری است. به عبارت دیگر، در گام اول اتمی که بیش‌ترین مشابهت (بزرگ‌ترین ضریب داخلی) با سیگنال آزمون را دارد، انتخاب شده و ضریب آن محاسبه می‌شود. در گام بعد، باقی‌مانده سیگنال آزمون و اتم اول با بقیه اتم‌ها مقایسه شده و مجدداً مشابه‌ترین اتم انتخاب می‌شود. به همین ترتیب در هر گام ضریب یکی از اتم‌ها تعیین می‌شود تا جایی که خطای بازنمایی سیگنال آزمون از حدی کم‌تر شود یا آنکه تعداد مشخصی از اتم‌ها دارای ضریب مخالف صفر شوند. الگوریتم MP به سبب آنکه در هر گام به یک جست‌وجوی ساده نیاز دارد، معمولاً بسیار سریع است. اما به دلیل حریص بودن تضمینی وجود ندارد که پاسخ نهایی مشابه با پاسخ تنک باشد. به منظور بهبود الگوریتم MP با حفظ سرعت بالای آن، الگوریتم‌های متنوعی پیشنهاد شده که معروف‌ترین آن MP متعامد^۶ (OMP) نام دارد [۱۸]. در OMP در هر گام پس از آنکه اتم جدید مشخص شد، از تمام ضرایب قبلی صرف نظر شده و ترکیبی خطی از تمام اتم‌های انتخاب شده تا این گام محاسبه می‌شود که کم‌ترین خطا را برای بازنمایی سیگنال آزمون داشته باشد.

ج) الگوریتم نرم صفر هموار شده (SL0)

یکی دیگر از الگوریتم‌های مناسب برای یافتن پاسخ تنک، نرم صفر هموار شده (SL0) نام دارد که توسط بابایی‌زاده معرفی شده است [۱۹]. در این روش تلاش بر آن است تا از حداقل کردن خود نرم صفر استفاده شود. ایرادی که برای حداقل کردن نرم صفر وجود دارد آن است که تابع نرم صفر پیوسته نیست. به همین دلیل، پیشنهاد شده تا به جای نرم صفر از تابع همواری استفاده شود که تقریبی از نرم صفر را نتیجه می‌دهد. به کار بردن تابع هموار اجازه استفاده از روش‌های مبتنی بر گرادیان برای مینیمم سازی نرم صفر را امکان‌پذیر می‌سازد.

نرم صفر بردار $s = [s_1, \dots, s_n]^T$ ، تعداد مؤلفه‌های غیر صفر این بردار است. به عبارت دیگر اگر فرض کنیم:

$$V(s) = \begin{cases} 1 & s \neq 0 \\ 0 & s = 0 \end{cases} \quad (22)$$

آنگاه نرم صفر s برابر با $\sum_i V(s_i)$ است. به طور واضح ناپیوستگی نرم صفر معلول ناپیوستگی تابع $V(s)$ است.

منظور از $\| \cdot \|_0$ نرم صفر بردار است (تعداد درایه‌های ناصفر)، که تعریف ریاضی آن مطابق معادله (۲۰) است.

$$\|x\|_0 = |\text{supp}(x)|, \quad \text{که } \text{supp}(x) = \{i: x_i \neq 0\} \quad (20)$$

نتیجه بهینه‌سازی معادله (۱۷)، پاسخی از دستگاه $y = Xs$ خواهد بود که تعداد عناصر مخالف صفر در آن حداقل است. از آنجا که نرم صفر پیوسته نیست، به دست آوردن پاسخ تنک نیاز به جست‌وجوی ترکیباتی دارد و حل آن NP-سخت^۱ است [۱۴]. به همین دلیل، چند روش جای‌گزین، برای یافتن پاسخ تنک پیشنهاد شده که در ذیل به آن‌ها اشاره می‌شود.

الف) الگوریتم جست‌وجوی پایه^۲ (BP)

یکی از معروف‌ترین ابزارها برای یافتن پاسخ تنک، الگوریتم جست‌وجوی پایه (BP) است که در آن به جای نرم صفر، از حداقل کردن نرم یک، مطابق معادله (۲۱)، استفاده می‌شود.

$$l^1: \hat{s} = \text{argmin} \|s\|_1 \quad \text{subject to } y = Xs \quad (21)$$

در میان الگوریتم‌های بازسازی، مینیمم کردن نرم یک توسط کاندس^۳ ارائه شده [۱۵] که یک الگوریتم نزدیک به بهینه است و نسبت به سایر روش‌ها دارای دقت بهتر ولی سرعت پایین‌تری است. مسأله بهینه‌سازی رابطه (۲۱) به راحتی قابل تبدیل به یک مسأله خطی است. به همین دلیل با روش‌های مختلفی که برای مسایل خطی پیشنهاد شده قابل حل است. ثابت شده که اگر تعداد عناصر مخالف صفر در پاسخ تنک از حدی که به همبستگی میان اتم‌ها (ستون‌های) دیکشنری X وابسته است کم‌تر باشد، پاسخ رابطه (۲۱) دقیقاً برابر با پاسخ تنک با حداقل سازی نرم صفر است [۱۶].

ب) الگوریتم جست‌وجوی تطابق^۴ (MP)

یکی از مهم‌ترین ایرادهای الگوریتم BP زمان مورد نیاز آن است که معمولاً و به ویژه با زیاد شدن ابعاد مسأله مشکل‌زا می‌شود. یکی از سریع‌ترین روش‌ها برای تخمین پاسخ تنک، الگوریتم جست‌وجوی تطابق (MP) نام دارد [۱۷].

ذات این روش حریصانه^۵ است و تلاش می‌کند تا در هر گام تنها ضریب یکی از اتم‌ها را مشخص کند. منظور از اتم‌ها

^۱ NP-hard (Non-deterministic Polynomial-time hard)

^۲ Basis Pursuit

^۳ Candès

^۴ Matching Pursuit

^۵ Greedy

^۶ Orthogonal matching pursuit

گرادیان و تصویر کردن با چند تکرار استفاده می‌شود. یکی از مزایای SL0 سرعت بالای آن است. علاوه بر این، از آنجا که در این روش سعی بر مینیمم کردن نرم صفر است، توقع می‌رود تا مسایل تنک پیچیده‌تری با این الگوریتم قابل حل باشند.

۳- مراحل انجام آزمایش‌ها

به طور کلی در یک سیستم BCI، پس از ثبت سیگنال، برای به دست آوردن دستوره‌های کنترلی لازم برای کنترل وسایل مختلف از روی سیگنال EEG، لازم است پردازش‌های لازم روی این سیگنال‌ها صورت گیرد. در بخش قبل پیش‌پردازش‌های انجام شده روی سیگنال بیان شد. در ادامه روند انجام آزمایش‌های صورت گرفته با الگوریتم‌های مختلف استخراج ویژگی و طبقه‌بندی بیان شده است.

۳-۱- استخراج ویژگی

بعد از مرحله پیش‌پردازش، نوبت به مرحله استخراج ویژگی‌های مناسب از سیگنال می‌رسد. در این مرحله از الگوریتم الگوهای مکانی مشترک (CSP) و گونه‌های بهبود یافته آن با نام کلی الگوهای مکانی مشترک تنظیم شده (RCSP) استفاده شد. در این روش‌ها بعد از به دست آمدن ماتریس فیلترهای مکانی $W \in R^{c \times c}$ (تعداد کانال‌های ثبت)، برای استخراج ویژگی از روی سیگنال‌های خام، باید n جفت از این فیلترها انتخاب شود. برای انتخاب مناسب عدد n ، برای n ‌های مختلف آزمایش‌های لازم صورت گرفت که برای اکثر الگوریتم‌ها بیش‌ترین صحت تشخیص برای ۳ الی ۵ جفت فیلتر حاصل شد. برای مثال نتایج این آزمایش برای الگوریتم CCSP1 در شکل (۴) نشان داده شده است.

با توجه به نتایج به دست آمده، از ۳ جفت فیلتر مکانی مطابق با ۳ تا از اولین و ۳ تا از آخرین فیلترهای ماتریس W که به ترتیب دارای بیش‌ترین قابلیت تفکیک برای کلاس‌های ۱ و ۲ است استفاده شد. لازم به یاد آوری است، نتیجه‌ی به دست آمده (انتخاب ۳ جفت فیلتر)، با نتیجه‌ی مطالعات مشابه قبلی [۱۱، ۱۲، ۱۳]، هم‌خوانی دارد.

در روش CSP، ویژگی‌های استخراج شده، لگاریتم وارینانس سیگنال EEG بعد از تصویر شدن روی فیلترهای w است.

اگر این تابع با تابعی هموار جای‌گزین شود، آن‌گاه تخمین هموار نرم صفر به دست می‌آید. توابع گوناگونی برای این منظور می‌توان استفاده نمود که به نظر می‌رسد مناسب‌ترین انتخاب، قرینه تابع گوسی با میانگین صفر است. در این صورت داریم:

$$f_{\sigma}(s) = \exp\left(-|s|^2/2\sigma^2\right) \quad (23)$$

آن‌گاه:

$$\lim_{\sigma \rightarrow 0} f_{\sigma}(s) = \begin{cases} 1 & s = 0 \\ 0 & s \neq 0 \end{cases} \quad (24)$$

در نتیجه، $\lim_{\sigma \rightarrow 0} f_{\sigma}(s) = 1 - V(s)$ است. بنابراین، اگر فرض کنیم $F_{\sigma}(s) = \sum_j^n f_{\sigma}(s_j)$ داریم:

$$\lim_{\sigma \rightarrow 0} F_{\sigma}(s) = \sum_{j=1}^n (1 - V(s_j)) = n - \|s\|_0 \quad (25)$$

آن‌گاه $n - F_{\sigma}(s)$ می‌تواند تخمین نرم صفر s باشد.

$$\|s\|_0 \approx n - F_{\sigma}(s) \quad (26)$$

از آنجا که این تابع جدید هموار است به سادگی می‌توان آن را بهینه‌سازی نمود. اگر σ را در رابطه (۲۶) به سمت صفر میل دهیم، علامت تقریب به تساوی تبدیل می‌شود. بنابراین بیشینه کردن تابع $F_{\sigma}(s)$ برای σ کوچک معادل با حداقل کردن نرم صفر است.

$$(SL0): \hat{S}_0 = \text{Maximiz } F_{\sigma}(S) \text{ s. t. } y = Xs \quad (27)$$

با این وجود اگر تابع مفروض به اندازه کافی هموار نباشد ممکن است در بهینه‌سازی آن برای مجموع عناصر یک بردار، اکسترم‌های محلی زیادی وجود داشته باشد. به همین دلیل از یک روش درشت به ریز برای بهینه‌سازی استفاده می‌شود. در این روش، ابتدا تابع بسیار همواری انتخاب می‌شود (گوسی با وارینانس بزرگ) تا تنها یک اکسترم محلی داشته باشد. پس از یافتن مکان اکسترم، در گام بعدی از این مکان برای مقدار دهی اولیه در یک تابع که به نرم صفر نزدیک‌تر شده (وارینانس کاهش یافته) استفاده می‌شود. به همین ترتیب، در هر گام از نتیجه قبلی استفاده شده و تابع به نرم صفر نزدیک‌تر می‌شود. اثبات شده که با انتخاب صحیح وارینانس‌ها، در بی‌نهایت (وارینانس صفر)، پاسخ به دست آمده به پاسخ تنک هم‌گرا می‌شود. در الگوریتم SL0 برای بهینه‌سازی تابع در هر گام از الگوریتم کاهش

۲-۳- طبقه‌بندی

افزایش درصد صحت ناشی از اعمال روش‌های RCSP نیز بیان شده است.

در مرحله‌ی طبقه‌بندی، از طبقه‌بندی‌کننده براساس نمایش تنک (SRC) استفاده شد. برای تشکیل ماتریس دیکشنری که از مرحله استخراج ویژگی حاصل می‌شود، از الگوریتم الگوی مکانی مشترک (CSP) و گونه‌های بهبود یافته آن با نام کلی RCSP استفاده شد.

برای یافتن نمایش تنک داده ورودی به سیستم هم از الگوریتم‌های جست‌وجوی پایه (BP)، جست‌وجوی تطابق عمود (OMP) و نرم صفر هموار شده (SL0) استفاده شد. الگوریتم ذیل روش طبقه‌بندی را به طور خلاصه بیان می‌کند.

الگوریتم طبقه‌بندی براساس نمایش تنک (SRC)

ورودی: ماتریس دیکشنری X و داده ورودی y

- نرمالیزه کردن ستون‌های ماتریس X با تعریف نرم دو
- به دست آوردن نمایش تنک داده آزمون با یکی از روش‌های BP، OMP یا SL0
- تعریف ماتریس δ_i برای تمام کلاس‌ها

$$\delta_i(s) = [0, \dots, 0, s_{i,1}, \dots, s_{i,n_i}, 0, \dots, 0]^T \in R^n$$

- محاسبه باقیمانده $r_i(y)$ برای تمام کلاس‌ها

$$r_i(y) = \|y - X\delta_i(s)\|_2$$

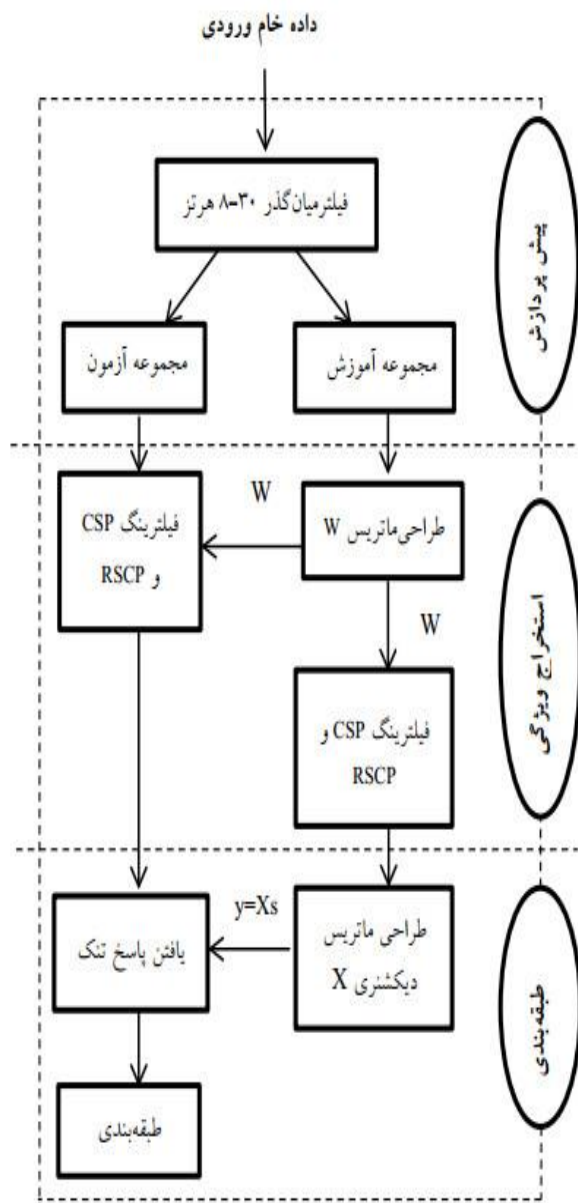
$$\text{Class}(y) = \min_i r_i(y), y \text{ برچسب داده}$$

در نهایت روندنمای شکل (۷)، روال کلی آزمایش‌ها را بیان می‌کند.

۳-۳- نتایج

جهت رسیدن به یک ارزیابی مطمئن، برای هر سیگنال آزمون عمل طبقه‌بندی بیست مرتبه تکرار شد. نتایج بیست مرتبه تکرار طبقه‌بندی‌کننده‌های SRC به صورت میانگین و انحراف معیار درصد صحت طبقه‌بندی در جدول (۳) و (۴) و جدول (۵) نشان داد شده است.

مقادیر بهینه پارامترهای تنظیم الگوریتم‌های RCSP نیز برای حالت‌های مختلف در جدول‌ها ارائه شده است. هم‌چنین با توجه به پراکندگی نتایج بین سوژه‌های مختلف، برای بررسی میزان بهبود الگوریتم‌های RCSP نسبت به CSP، میزان میانگین



شکل (۷) - روندنمای روال کلی مراحل انجام آزمایش‌ها

برای مقایسه شهودی‌تر نتایج، مقادیر میانگین و انحراف معیار درصد صحت طبقه‌بندی برای افراد مختلف به صورت نمودار میله‌ای در شکل‌های ۸ تا ۱۰ رسم شده است.

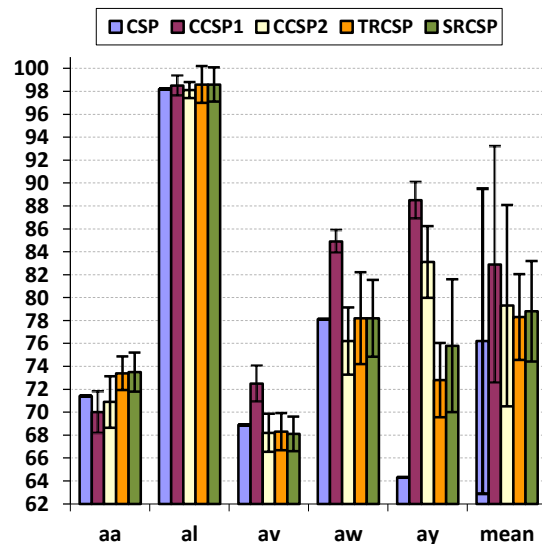
نتایج حاصل در جدول (۳) و نمودار میله‌ای شکل (۸)، با طبقه‌بندی‌کننده SRC که از الگوریتم BP برای یافتن پاسخ تنک استفاده می‌کند به دست آمد.

مشاهده می‌شود بالاترین دقت تشخیص در تمامی افراد با الگوریتم‌های RCSP به دست آمده است.


جدول (۳) - نتایج درصد صحت طبقه‌بندی‌کننده SRC با الگوریتم BP (میانگین \pm انحراف معیار) به ازای الگوریتم‌های CSP

میانگین افزایش دقت نسبت به CSP	ay (۲۸)	aw (۵۶)	av (۸۴)	al (۲۲۴)	aa (۱۶۸)	سوژه‌ها (آموزش) الگوریتم‌ها
۰	۶۴٫۲ \pm ۰	۷۸٫۱ \pm ۰	۶۸٫۸ \pm ۰	۹۸٫۲ \pm ۰	۷۱٫۴ \pm ۰	CSP
۶٫۶۹ \pm ۱۰٫۳۳	۸۸٫۵ \pm ۱٫۶ ۰٫۴	۸۴٫۹ \pm ۰٫۹۹ ۰٫۱	۷۲٫۵ \pm ۱٫۵۶ ۰٫۱	۹۸٫۴ \pm ۰٫۸۷ ۰٫۱	۷۰٫۱ \pm ۱٫۸۲ ۰٫۲	CCSP1 بهترین β
۳٫۱ \pm ۸٫۷۸	۸۳ \pm ۳٫۱۳ ۰٫۷	۷۶٫۱ \pm ۲٫۹۳ ۰٫۲	۶۸٫۲ \pm ۱٫۶۷ ۰٫۱	۹۸٫۱ \pm ۰٫۷ ۰٫۵	۷۰٫۸ \pm ۲٫۲۵ ۰٫۵	CCSP2 بهترین β
۲٫۰۶ \pm ۳٫۷۴	۷۲٫۸ \pm ۳٫۲۴ ۱۰ ^{-۴}	۷۸٫۲ \pm ۴٫۰۱ ۱۰ ^{-۶}	۶۸٫۳ \pm ۱٫۶۲ ۱۰ ^{-۶}	۹۸٫۶ \pm ۱٫۶ ۱۰ ^{-۱۰}	۷۳٫۴ \pm ۱٫۴۶ ۱۰ ^{-۸}	TRCSP بهترین α
۲٫۶۵ \pm ۴٫۳۸	۷۵٫۱ \pm ۵٫۸ (۰٫۵ و ۱۰ ^{-۶})	۷۸٫۲ \pm ۳٫۳۵ (۰٫۱ و ۱۰ ^{-۶})	۶۸٫۱ \pm ۱٫۵۱ (۰٫۱ و ۱۰ ^{-۶})	۹۸٫۶ \pm ۱٫۴۹ (۰٫۰۵ و ۱۰ ^{-۵})	۷۳٫۵ \pm ۱٫۷ (۰٫۰۵ و ۱۰ ^{-۱۱})	SRCSP بهترین (r و α)

در جدول (۴) و نمودار میله‌ای شکل (۹)، نتایج حاصل از الگوریتم‌های CSP، با طبقه‌بندی‌کننده SRC که از الگوریتم OMP برای یافتن پاسخ تنک استفاده می‌کند به دست آمد. همان‌طور که در این نتایج مشاهده می‌شود، بالاترین دقت تشخیص در همه افراد با الگوریتم‌های RCSP به دست آمد. به‌طور میانگین افزایش دقت بالای ۳/۹۹٪ نسبت به استاندارد CSP با الگوریتم CCSP1 به دست آمد. این افزایش دقت در فرد ay که تنها ۲۸ سیگنال برای آموزش سیستم داشت، برابر با ۱۳/۶٪ نسبت به CSP و با CCSP1 حاصل شد.



شکل (۸) - میزان میانگین و انحراف معیار درصد صحت طبقه‌بندی برای افراد مختلف با الگوریتم BP



شکل (۹) - میزان میانگین و انحراف معیار درصد صحت طبقه‌بندی برای افراد مختلف با الگوریتم OMP

به‌طور میانگین افزایش دقت ۶٫۶۹٪ نسبت به استاندارد CSP با الگوریتم CCSP1 به دست آمد. این افزایش دقت در افرادی که داده کمی برای آموزش آن‌ها موجود بود قابل ملاحظه است. به‌طوری‌که در فرد ay که تنها ۲۸ سیگنال برای آموزش سیستم داشت، افزایش دقت ۲۴/۳٪ نسبت به CSP و برای افراد aw و av که تعداد سیگنال‌های آموزشی آن‌ها برابر با ۵۶ و ۸۴ است، این افزایش دقت ۶/۸٪ و ۳/۷٪ است. در هر سه نفر، این افزایش دقت با CCSP1 حاصل شد. برای افراد aa و al که تعداد نمونه آموزشی مناسبی برای آموزش داشتند، افزایش دقت چشم‌گیری نسبت به CSP حاصل نشد.

جدول (۴) - نتایج درصد صحت طبقه‌بندی‌کننده SRC با الگوریتم OMP (میانگین \pm انحراف معیار) به ازای الگوریتم‌های CSP

میانگین افزایش دقت نسبت به CSP	ay (۲۸)	aw (۵۶)	av (۸۴)	al (۲۲۴)	aa (۱۶۸)	سوژه‌ها (آموزش) الگوریتم‌ها
۰	۷۳ \pm ۰	۸۰٫۸ \pm ۰	۶۳٫۸ \pm ۰	۹۸٫۲ \pm ۰	۶۵٫۲ \pm ۰	CSP
۳٫۹۹ \pm ۵٫۷۵	۸۶٫۶ \pm ۱٫۹۵ ۰٫۱	۸۴٫۱ \pm ۲٫۳۱ ۰٫۱	۶۲٫۵ \pm ۲٫۶۸ ۰٫۹	۹۸٫۸ \pm ۱٫۳۳ ۰٫۱	۶۸٫۹ \pm ۲٫۵۵ ۰٫۱	CCSP1 بهترین β
۲٫۳ \pm ۵٫۲۴	۸۳٫۳ \pm ۲٫۴۷ ۰٫۵	۷۷٫۶ \pm ۲٫۳ ۰٫۹	۶۵٫۵ \pm ۲٫۷ ۰٫۱	۹۷ \pm ۱٫۶۵ ۰٫۵	۶۹٫۲ \pm ۳٫۷ ۰٫۴	CCSP2 بهترین β
۰٫۱۴ \pm ۲٫۶۴	۷۱٫۳ \pm ۳٫۲۸ ۱۰ ^{-۴}	۷۷٫۵۴ \pm ۲٫۹۹ ۱۰ ^{-۶}	۶۵٫۸ \pm ۲٫۴۴ ۱۰ ^{-۱۰}	۹۸٫۸ \pm ۱٫۵۴ ۱۰ ^{-۶}	۶۸٫۴ \pm ۲٫۲۷ ۱۰ ^{-۷}	TRCSP بهترین α
۱٫۴۶ \pm ۳٫۵۳	۷۳٫۴ \pm ۳٫۷۱ (۰٫۵ و ۱۰ ^{-۵})	۷۸٫۲ \pm ۳٫۲۳ (۰٫۵ و ۱۰ ^{-۷})	۶۵٫۳ \pm ۲ (۰٫۱ و ۱۰ ^{-۵})	۹۹٫۱ \pm ۱٫۲۳ (۱٫۵ و ۱۰ ^{-۹})	۷۲٫۳ \pm ۲٫۸ (۰٫۱ و ۱۰ ^{-۴})	SRCSP بهترین (α و τ)

همان طور که در این نتایج مشاهده می‌شود، بالاترین دقت تشخیص در همه افراد با الگوریتم‌های RCSP به دست آمد. به طور میانگین افزایش دقت بالای ۷/۵۳٪ نسبت به استاندارد CSP با الگوریتم CCSP1 به دست آمد. این افزایش دقت در فرد ay که تنها ۲۸ سیگنال برای آموزش سیستم داشت، برابر با ۲۲/۱٪ نسبت به CSP و با CCSP1 حاصل شد.

برای افراد aw و av که به ترتیب تعداد سیگنال‌های آموزشی آن‌ها برابر با ۵۶ و ۸۴ است، این افزایش دقت به ترتیب برابر با ۷/۲٪ و ۳٪ و با CCSP2 و CCSP1 است.

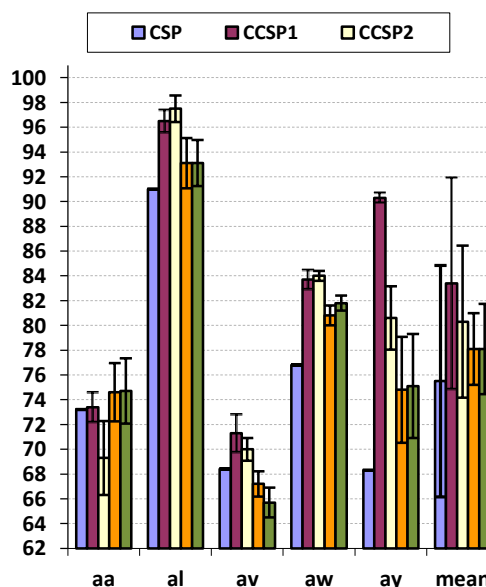
برای فرد al نیز، افزایش ۷/۵٪ در صحت تشخیص با CCSP2 به دست آمد. مشاهده می‌شود، استفاده از SL0 به جای BP به طور میانگین حدود ۱٪ و به جای OMP حدود ۲٪ به صحت تشخیص افزوده است.

۳-۱-۳- ارزیابی الگوریتم‌های RCSP

هدف از استفاده الگوریتم‌های RCSP، رفع معایب الگوریتم استاندارد CSP (حساسیت به نویز و مسأله فرایادگیری در مجموعه‌های آموزشی کوچک) و تشکیل ماتریس دیکشنری قوی برای SRC بود. نتایج به دست آمده در جدول (۳) و (۴) و (۵)، نشان می‌دهد که در اکثریت موارد بیش‌ترین صحت تشخیص طبقه‌بندی با الگوریتم‌های RCSP بدست آمده است. به طور میانگین افزایش دقتی بالای ۷٪ نسبت به الگوریتم استاندارد CSP حاصل شد. این افزایش دقت در افرادی که داده کمی برای آموزش آن‌ها موجود بود، به بالای ۲۴٪ نسبت به CSP رسید که قابل ملاحظه است.

برای افراد aw و av که به ترتیب تعداد سیگنال‌های آموزشی آن‌ها برابر با ۵۶ و ۸۴ است، این افزایش دقت در هر دو نفر برابر با ۳/۳٪ و ۲٪ به ترتیب با CCSP1 و TRCSP است. برای فرد aa نیز که CSP ضعیف عمل نموده، افزایش ۷/۱٪ در صحت تشخیص با SRCSP به دست آمد. در مجموع استفاده از OMP به جای BP به طور میانگین حدود ۲٪ از صحت تشخیص کاسته است.

در جدول (۵) و نمودار میله‌ای شکل (۱۰)، نتایج حاصل از الگوریتم‌های CSP، با طبقه‌بندی‌کننده SRC که از الگوریتم SL0 برای یافتن پاسخ تنک استفاده می‌کند به دست آمد.



شکل (۱۰) - میزان میانگین و انحراف معیار درصد صحت طبقه‌بندی برای افراد مختلف با الگوریتم SL0

جدول (۵) - نتایج درصد صحت طبقه‌بندی‌کننده SRC با الگوریتم SLO (میانگین \pm انحراف معیار) به ازای الگوریتم‌های CSP

میانگین افزایش دقت نسبت به CSP	ay (۲۸)	aw (۵۶)	av (۸۴)	al (۲۲۴)	aa (۱۶۸)	سوژه‌ها (آموزش) الگوریتم‌ها
۰	۶۸,۳ \pm ۰	۷۶,۸ \pm ۰	۶۸,۴ \pm ۰	۹۱ \pm ۰	۷۳,۲ \pm ۰	CSP
۷,۵۳ \pm ۸,۵۳	۹۰,۴ \pm ۰,۴ ۰,۱	۸۳,۷ \pm ۰,۷۷ ۰,۲	۷۱,۴ \pm ۱,۵۲ ۰,۱	۹۶,۵ \pm ۰,۹۱ ۰,۴	۷۳,۴ \pm ۱,۲ ۰,۳	CCSP1 بهترین β
۴,۷۳ \pm ۶,۱۴	۸۰,۶ \pm ۲,۵۶ ۰,۱	۸۴ \pm ۰,۳۹ ۰,۹	۷۰ \pm ۰,۹۲ ۰,۶	۹۷,۵ \pm ۱,۰۷ ۰,۴	۶۹,۳ \pm ۰,۲۹۸ ۰,۷	CCSP2 بهترین β
۲,۴ \pm ۲,۸۹	۷۴,۸ \pm ۴,۲۷ ۱۰ ^{-۵}	۸۰,۸ \pm ۰,۸ ۱۰ ^{-۴}	۶۷,۲ \pm ۱,۰۲ ۱۰ ^{-۱۰}	۹۳,۱ \pm ۲,۰۲ ۱۰ ^{-۱۰}	۷۴,۶ \pm ۲,۳۶ ۱۰ ^{-۹}	TRCSP بهترین α
۲,۵۵ \pm ۳,۶۴	۷۵,۱ \pm ۴,۲ (۰,۱ و ۱۰ ^{-۴})	۸۱,۸ \pm ۰,۶ (۱,۲ و ۱۰ ^{-۶})	۶۵,۷ \pm ۱,۲ (۱,۲ و ۱۰ ^{-۷})	۹۳,۱ \pm ۱,۸۶ (۰,۵ و ۱۰ ^{-۸})	۷۴,۷ \pm ۲,۶۴ (۱,۵ و ۱۰ ^{-۹})	SRCSP بهترین (α و τ)

برای بررسی میزان پیچیدگی محاسباتی الگوریتم‌های SRC باید مرتبه محاسباتی آن‌ها محاسبه شود. بدین منظور، زمان مورد نیاز برای اجرای الگوریتم‌ها به عنوان معیاری از پیچیدگی محاسباتی بیان شد. در جدول (۷) زمان مورد نیاز برای به دست آوردن پارامترهای تنظیم‌کننده بهینه با روش ارزیابی متقابل و در جدول (۸) مدت زمان یک مرحله آزمون ارائه شده است.

جدول (۷) - زمان مورد نیاز برای پارامترهای تنظیم‌کننده بهینه با روش ارزیابی متقابل (10-fold) با الگوریتم‌های SRC (ثانیه)

SRCSP	TRCSP	CCSP2	CCSP1	Alg Sub	SRC Alg
۳۷۹۱,۳	۴۶۶	۵۲۵,۸	۵۶۸,۵	aa	BP
۵۴۷۸,۵	۶۵۹,۵	۶۴۸,۹	۵۸۹,۶	al	
۲۲۰۳,۲	۲۴۴,۳	۳۶۹,۱	۳۵۷,۳	av	
۱۵۲۳,۸	۱۵۵,۶	۲۸۰,۷	۳۱۱,۲	aw	
۸۶۶,۷	۷۸,۵	۲۴۱,۴	۲۴۰,۵	ay	
۱۲۲۹,۳	۱۱۹,۵	۲۷۶,۴	۲۹۴,۸	aa	OMP
۱۵۶۲,۷	۱۴۳,۵	۲۵۳,۷	۲۷۵,۶	al	
۷۷۹,۴	۶۷,۲	۲۰۸,۴	۲۵۳,۴	av	
۶۴۳,۴	۵۰,۸	۱۷۴,۱	۲۰۰,۳	aw	
۴۹۶,۷	۳۳	۱۶۷,۷	۱۹۱,۷	ay	
۸۶۳,۹	۹۶,۶	۱۷۱,۴	۱۸۷,۲	aa	SLO
۱۱۶۱,۷	۱۲۵	۱۶۲,۶	۱۹۶	al	
۶۰۹,۲	۵۹,۲	۱۷۲	۱۵۶,۵	av	
۵۳۳,۵	۴۲,۷	۱۷۷,۲	۱۷۸,۱	aw	
۴۳۸,۶	۲۷,۷	۱۷۸,۶	۱۷۳,۳	ay	

۳-۲-۳- ارزیابی الگوریتم‌های مختلف SRC

برای ارزیابی طبقه‌بندی‌کننده SRC که از الگوریتم‌های مختلف برای یافتن پاسخ تنک BP، OMP، SLO استفاده می‌کند، نتایج میانگین درصد صحت تشخیص به دست آمده با الگوریتم‌های CSP و RCSP در جدول (۶) گزارش شده است.

هم‌چنین برای مقایسه نتایج حاصل از این پژوهش با کارهای قبلی، نتایج کار مشابهی که توسط لوته [۱۱] انجام شده نیز در جدول (۶) ارائه شده است. لوته در تحقیق خود الگوریتم‌های CSP و RCSP ذکر شده را با طبقه‌بندی‌کننده LDA مورد بررسی قرار داده است.

جدول (۶) - میانگین درصد صحت طبقه‌بندی‌کننده‌های LDA و SRC

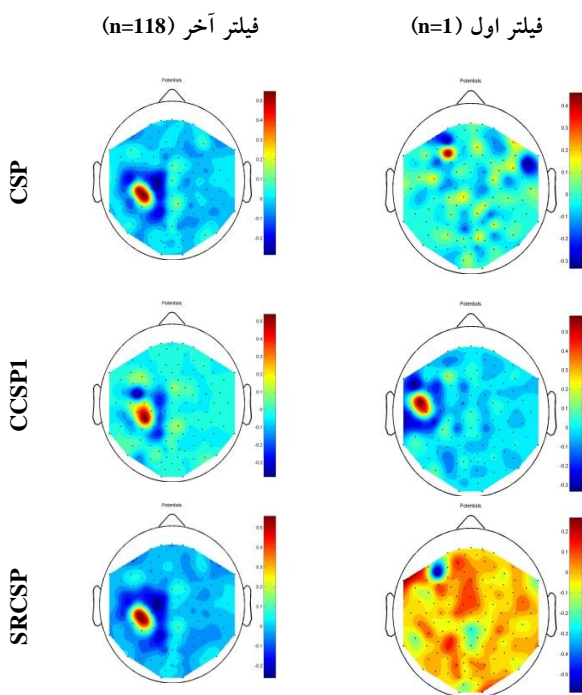
الگوریتم‌ها	SRC با BP	SRC با OMP	SRC با SLO	LDA [۱۱]
CSP	۷۶,۱۹	۷۶,۲	۷۵,۵۴	۶۶,۲۹
CCSP1	۸۲,۸۸	۸۰,۱۹	۸۳,۰۷	۷۶,۶۹
CCSP2	۷۹,۲۹	۷۸,۵	۸۰,۲۷	۶۵,۷
TRCSP	۷۸,۲۵	۷۶,۳۴	۷۷,۹۴	۷۷,۹۸
SRCSP	۷۸,۸۴	۷۷,۶۶	۷۸,۰۹	۷۸,۶۲

نتایج به دست آمده از الگوریتم‌های مختلف SRC نشان می‌دهد که الگوریتم SLO در صحت تشخیص، معادل با دو الگوریتم OMP و BP عمل نموده و در مجموع، SRC حدود ۵٪ در میزان میانگین صحت تشخیص بهتر از طبقه‌بندی‌کننده پرکاربرد LDA عمل نموده است.

راست انجام شد (کلاس ۱ دست راست و کلاس ۲ پای راست).

مطابق با انتظار، الکترودهایی که بیشترین وزن را دارند در مناطق نزدیک به الکتروود C_3 مشاهده شدند (منطقه حسی حرکتی).

هنگامی که از یک سیستم BCI براساس تصور حرکتی استفاده می‌شود، طبق خصوصیات نوروفیزیولوژیکی، سیگنال‌هایی که در اثر تصور حرکت دست یا پای راست حاصل می‌شود، در قسمت چپ مرکز حرکتی رخ می‌دهند، لذا این امر با خصوصیات نوروفیزیولوژیکی مسئله مطابقت دارد.



شکل (۱۱) - وزن الکتروودها مطابق با فیلترهای ۱ و ۱۱۸

همان طور که در نتایج مشاهده شد، استفاده از این روش‌ها (RCSP) درصد صحت تشخیص را نسبت به CSP استاندارد به طور میانگین بیش از ۷٪ بهبود داده‌است. در مواردی که داده آموزشی کمی موجود بود این افزایش درصد صحت تشخیص به ۲۴٫۳٪ رسیده‌است. همان طور که در نتایج مشاهده می‌شود، در افرادی که به علت داده‌ی آموزشی کم، تخمین ماتریس کواریانس آن‌ها ضعیف شده و این ضعف باعث تولید فیلترهای مکانی که قابلیت تفکیک بالایی ندارند می‌شود، الگوریتم‌های بهبود یافته CSP توانسته است با بهبود تخمین ماتریس کواریانس، فیلترهای مکانی قوی‌تری نسبت به CSP استاندارد

جدول (۸) - میانگین و انحراف معیار زمان مورد نیاز یک مرحله آزمون الگوریتم‌های SRC با الگوریتم‌های RCSP (میلی ثانیه)

الگوریتم‌ها	BP با SRC	OMP با SRC	SL0 با SRC
CSP	242.8 ± 11.3	12.7 ± 0.3	4 ± 1
CCSP1	186.4 ± 11.2	8.8 ± 0	3.8 ± 1.9
CCSP2	186.8 ± 37.2	9.2 ± 1.1	4.3 ± 2.1
TRCSP	244.4 ± 13.8	12.6 ± 0	3.7 ± 1.1
SRCSP	250 ± 16.9	12.6 ± 0	3.7 ± 1.6

تمامی آزمایش‌ها در سیستمی با مشخصات Intel Core i5 2410M با پردازنده 2.30 GHz و 4 GB RAM و نرم‌افزار MATLAB (R2012a) ورژن ۷٫۱۴ انجام شد.

نتایج حاصل در جدول (۸)، نشان می‌دهد که در مرحله آزمون، الگوریتم SL0 نسبت به الگوریتم BP حدود ۵۰ تا ۶۰ برابر و نسبت به الگوریتم OMP حدود ۲ تا ۳ برابر سریع‌تر عمل نموده‌است.

۴- بحث و نتیجه‌گیری

در این تحقیق، از طبقه‌بندی کننده براساس نمایش تنک (SRC)، برای طبقه‌بندی سیگنال‌های EEG براساس تصور حرکتی استفاده شد. این طبقه‌بندی کننده برای کارایی بالا نیاز به تشکیل ماتریس دیکشنری قوی دارد. بنابراین، با توجه به گزارش‌های متعدد از کارایی بالای الگوریتم CSP در مرحله استخراج ویژگی از آن استفاده شد. علی‌رغم محبوبیت بالای CSP، این روش دو اشکال عمده دارد: (۱) حساسیت بالا به نویز؛ (۲) مسئله فریادگیری در مواردی که داده آموزشی کم در اختیار باشد. برای رفع این عیب‌ها، از روش‌های مختلف الگوریتم الگوهای مکانی مشترک تنظیم شده (RCSP) که اخیراً مورد توجه قرار گرفته، استفاده شد.

برای بررسی میزان کارایی فیلترهای مکانی به دست آمده از روش‌های CSP و RCSP، میزان وزن الکتروودهای ثبت مطابق با فیلترهای اول و آخر (۱ و ۱۱۸)، برای الگوریتم‌های CSP، CCSP1 و SRCSP در شکل (۱۱)، ارائه شده‌است.

فیلتر مکانی ۱ بیشترین اطلاعات برای تفکیک کلاس ۱ و فیلتر مکانی ۱۱۸ بیشترین اطلاعات برای تفکیک کلاس ۲ را در بر دارد. درین دادگان تفکیک کلاس‌های دست راست و پای

موارد SRC کارایی بالاتری نسبت به LDA دارد. این نتیجه با گزارش شین [۴] مبنی بر عملکرد بهتر SRC نسبت به LDA روی ویژگی‌های استخراج شده از CSP استاندارد، نیز هم‌خوانی دارد.

در نهایت، برای افزایش کارایی SRC، در مرحله استخراج ویژگی و تشکیل ماتریس دیکشنری الگوریتم CCSP1 و در مرحله یافتن پاسخ تنک داده ورودی از روی این ماتریس، الگوریتم SL0 پیشنهاد می‌شود.

۵- مرجع‌ها

- [1] Z. Cashero, "Comparison of EEG preprocessing methods to Improved the classification of p300 trials" M. Sc Thesis, Department of Computer Science Colorado State University, 2011.
- [2] J. N. Mak, J. R. Wolpaw, "Clinical Applications of Brain Computer Interfaces: Current State and Future Prospects" *IEEE reviews in biomedical engineering* 2, 187-199, 2009.
- [3] J. Wright, A. Yang, S. Sastry and Y. Ma, "Robust face recognition via sparse representation" *IEEE Trans Pattern Anal Mach Intell* 31 (2), 210-227, 2009.
- [4] Y. Shin, S. Lee, S. Woo and H. N. Lee, "Performance increase by using an EEG sparse representation based classification method" *IEEE Int Conf on Consumer Electronics (ICCE)*, Las Vegas, USA, 201-203, 2013.
- [5] Site of Berlin Institute of Technology, Charité-University Medicine Berlin, Available: http://www.bbc.de/competition/iii/desc_IVa.htm.
- [6] P. F. Diez, V. Mut, E. Laciari, A. Torres, "Application of the Empirical Mode Decomposition to the Extraction of Features from EEG Signals for Mental Task Classification" *31st Annu Int Conf of the IEEE/EMBS*, Minneapolis, Minnesota, USA, pp 2-6, 2009.
- [7] K. K. Ang, Z. Y. Chin, C. Wang, C. Guan, H. Zhang, "Filter bank common spatial pattern algorithm on bci competition iv datasets 2a and 2b" *Frontiers in Neuroscience* 6 (39), 1-9, 2012.
- [8] D. J. McFarland, L. M. McCane, S. V. David, J. R. Wolpaw, "Spatial filter selection for EEG-based communication" *Electroencephalographic Clinical Neurophysiology* 103, 386-394, 1997.
- [9] A. Soong Z. Koles, "Principal component localization of the sources of the background EEG" *IEEE Trans on Biomed Eng* 42 (1), 59-67, 1995.
- [10] B. Blankertz, R. Tomioka, S. Lemm, M. Kawanabe, K. R. Müller, "Optimizing spatial filters for robust EEG single-trial analysis" *IEEE Trans Signal Processing* 25 (1), 41-56, 2008.
- [11] F. Lotte, C. Guan, "Regularizing Common Spatial Patterns to Improve BCI Designs: Unified Theory and New Algorithms" *IEEE Trans biomed Eng* v 58 (2), 355-362, 2011.

تولید کند. این فیلترها باعث تشکیل ماتریس دیکشنری قوی برای SRC شده و در نهایت افزایش دقت طبقه‌بندی شده را نشان می‌دهند.

در SRC بعد از تشکیل ماتریس دیکشنری قوی، تنک‌ترین نمایش ممکن برای داده ورودی از روی این ماتریس باید محاسبه شود. بدین منظور، در اولین مرحله از الگوریتم BP که از معروف‌ترین الگوریتم‌های یافتن پاسخ تنک است استفاده شد. ایراد اساسی این الگوریتم زمان مورد نیاز برای اجرای آن است که با زیاد شدن ابعاد مسأله مشکل‌ساز می‌شود. هرچند ممکن است زمان لازم برای مرحله آموزش چندان مهم نباشد، ولی زمان مرحله آزمون به خصوص در کاربردهای BCI امری مهم و تعیین کننده محسوب می‌شود. برای رفع این عیب، از الگوریتم OMP برای محاسبه پاسخ تنک استفاده شد. ملاحظه می‌شود که سرعت تشخیص داده مرحله آزمون حدود ۲۰ برابر نسبت به الگوریتم BP افزایش یافته است، ولی در مقابل به طور میانگین حدود ۱/۱۹ از درصد صحت دقت تشخیص کاسته شده است. برای رسیدن به سرعت بالا ضمن داشتن دقت بالا، از الگوریتم نرم صفر هموار شده (SL0) که اخیراً مطرح شده [۱۹] استفاده شد. با بررسی‌های انجام شده، تاکنون از این الگوریتم برای سیستم‌های BCI استفاده نشده است. همان طور که در نتایج به دست آمده مشاهده می‌شود، این اصلاح نه تنها باعث کاهش شدید زمان تشخیص داده آزمون نسبت به الگوریتم BP شده است، بلکه از این لحاظ حدود ۲ تا ۳ برابر از الگوریتم OMP نیز بهتر عمل نموده است. با این حال، در صحت تشخیص معادل با الگوریتم BP عمل نموده است. بهترین دقت تشخیص در اکثریت افراد با الگوریتم SL0 حاصل شد. از آنجا که در روش SL0 از الگوریتم بهینه‌سازی سریع کاهش گرادیان استفاده می‌شود و بر خلاف دیگر الگوریتم‌ها، که از تقریب نرم صفر استفاده می‌کنند، سعی بر مینیمم کردن خود تابع نرم صفر دارد، این افزایش کارایی مورد انتظار بود.

لوته در کار مشابهی [۱۱] از الگوریتم‌های RCSP یاد شده در مسأله‌ای مشابه با این تحقیق استفاده کرد. وی در پژوهش خود برای طبقه‌بندی از طبقه‌بندی کننده پرکاربرد LDA بهره برد. در جدول (۶) نتایج میانگین درصد صحت تشخیص برای هر دو طبقه‌بندی کننده ارائه شده است. ملاحظه می‌شود در همه

- [17] S. G. Mallat, Z. Zhifeng, "Matching pursuits with time-frequency dictionaries" *IEEE Trans Signal Processing* 41, 3397-3415, 1993.
- [18] Y. C. Pati, R. Rezaifar, P. S. Krishnaprasad, "Orthogonal matching pursuit: recursive function approximation with applications to wavelet decomposition" in *Conf Rec 27th Asilomar Conf Signals Syst Comput*, Pacific Grove, USA, pp 41-44, 1993.
- [19] H. Mohimani, M. Babaie-Zadeh, C. H. Jutten, "A fast approach for overcomplete sparse decomposition based on smoothed ℓ_0 norm" *IEEE Trans Signal Processing* 57 (1), 289-301, 2009.
- [12] H. Kang, Y. Nam, S. Choi, "Composite common spatial pattern for subject-to-subject transfer" *IEEE Sig Proc Let* 16 (8), 683-686, 2009.
- [13] F. Lotte, C. Guan, "Spatially regularized common spatial patterns for EEG classification" in *Proc ICPR*, Istanbul, Turkey, pp 3712-3715, 2010.
- [14] E. J. Candes, M. B. Wakin, "An introduction to compressive sampling" *IEEE Signal Processing Magazine*, pp 21-30, 2008.
- [15] E. Candes, J. Romberg, T. Tao, "Stable signal recovery from incomplete and inaccurate measurements" *Comm Pure Appl Math*, pp 1207-1223, 2006.
- [16] R. Gribonval, M. Nielsen, "Sparse representations in unions of bases" *IEEE Trans Information Theory* 49, 3320-3325, 2003.