

بهبود کارایی طبقه‌بندی کننده مبتنی بر نمایش تنک برای طبقه‌بندی سیگنال‌های مغزی

علیرضا میرجلیلی، وحید ابوطالبی و محمد تقی صادقی

دانشکده مهندسی برق و کامپیوتر، دانشگاه یزد، یزد، ایران

چکیده

در این مقاله مسئله طبقه‌بندی سیگنال‌های EEG مبتنی بر تصور حرکتی برای یک سامانه واسط مغز- رایانه (BCI)، توسط طبقه‌بندی کننده مبتنی بر نمایش تنک (SRC) مورد توجه واقع شده است. این طبقه‌بندی کننده برای کارایی بالا، نیاز به طراحی ماتریس واژه‌نامه قوی دارد. با توجه به کارایی بالای الگوریتم الگوهای مکانی مشترک (CSP) در سامانه‌های BCI، از این روش برای طراحی ماتریس واژه‌نامه استفاده شده است. از معایب CSP حساس به نویفهودن و مستلزم فرایادگیری در مجموعه‌های آموزشی کم است. برای رفع این معایب از دو نوع الگوریتم بهبود CSP با نامهای GLRCSP و DLRCSP استفاده شده است. استفاده از این روش‌ها منجر به افزایش میانگین درصد صحت تشخیص به میزان حدود ۷/۷۸٪ نسبت به گونه استاندارد CSP شده است. از سوی دیگر یکی از معایب طبقه‌بندی کننده SRC که از الگوریتم پایه BP استفاده می‌کند، زمان برپایدن آن است. برای رفع این عیب، از الگوریتم جدید SL0 به عنوان جایگزین الگوریتم BP استفاده کردیم. نتایج نشان داد که نه تنها زمان مرحله آمونی بسیار کاهش می‌یابد، بلکه این تغییر منجر به افزایش میانگین درصد صحت تشخیص به میزان ۱/۶۱٪ نسبت به الگوریتم استاندارد پایه می‌شود.

وازگان کلیدی: سیگنال‌های مغزی، طبقه‌بندی مبتنی بر نمایش تنک، الگوریتم تنظیم شده، الگوریتم نرم صفر هموارشده (SL0)

۱- مقدمه

بهمنظور پژوهه‌های BCI خود استفاده کرده‌اند. یکی از راهکارهای مطرح شده برای دستیابی به سامانه‌های BCI مبتنی بر EEG، استفاده از سیگنال‌های EEG مرتبط با فعالیت‌های ذهنی هستند. به طور مثال از این گونه فعالیتها می‌توان تصورات حرکتی اندام‌های بدن را نام برد. برای تفکیک این فعالیتها نیاز به پردازش‌های سطح بالا و قوی است که به‌طور عمومی شامل روش‌های شناسایی الگو^۲ هستند. به طور کلی این روش‌ها شامل دو مرحله استخراج ویژگی و طبقه‌بندی کننده است. با گسترش روزافزون کاربرد تکنیک‌های نمایش تنک^۳ در حوزه‌های شناسایی الگو، طبقه‌بندی کننده مبتنی بر نمایش تنک^۴ (SRC) در زمینه‌های مختلفی مانند تشخیص چهره مطرح شده است

سامانه‌های واسط مغز و رایانه (BCI)، ارتباطی یک‌طرفه میان مغز کاربر و رایانه، برای انتقال منظور وی به دنیای خارج، بدون استفاده از خروجی‌های عصبی و ماهیچه‌ای برقرار می‌کند. موجه ترین کاربران این سامانه‌ها را بیماران فلج کامل، قطع نخاعی و سایر افراد با ناتوانی‌های حرکتی مختلف تشکیل می‌دهند. در حالت پیشرفتی که این بیماران حتی قدرت تکلم و یا حرکت چشم خود را ندارند، اگر مغز سالم باشد، شاید آخرین فرصت ارتباط این افراد در تعامل با محیط خارج از همین طریق باشد (ابراهیمی و همکاران، ۲۰۰۳). در حالت کلی سامانه‌های BCI، مبتنی بر EEG نیست؛ اما با توجه به متدائل‌بودن و ثبت آسان ووضوح زمانی بهنسبه خوب EEG، اکثر گروه‌های پژوهشی از EEG

²Pattern Recognition

³Sparse Representation

⁴Sparse Representation-based Classifier

^۱Brain Computer Interface

این مقاله بدین شرح سازماندهی می‌شود: در بخش بعد دادگان مورد استفاده و پیش‌پردازش‌های صورت‌گرفته روی آن شرح داده می‌شود. بعد از آن به مرحله استخراج ویژگی که شامل الگوریتم‌های RCSP و CSP است می‌پردازیم. بخش بعدی را به طبقه‌بندی اختصاص می‌دهیم؛ در این بخش ابتدا طبقه‌بندی کننده SRC به‌اجمال شرح داده می‌شود و سپس به الگوریتم‌های یافتن پاسخ تنک می‌پردازیم. بعد از آن روال کلی مراحل انجام آزمایش‌های بیان شده و نتایج به‌دست آمده از آزمایش‌ها به همراه بحث در مورد آن آورده می‌شود و درنهایت به جمع‌بندی نتایج به‌دست آمده و نتیجه‌گیری می‌پردازیم.

۲- دادگان مورد استفاده و پیش‌پردازش

در این مقاله از دادگان III Data set Iva, BCI competition استفاده می‌کیم (www.bbci.de). این مجموعه داده شامل سیگنال‌های EEG دو تصویر حرکتی دست و پای راست برای ۵ نفر است. ۱۱۸ کاتال Ag/AgCl برای ثبت داده‌های EEG با استاندارد ۱۰۰-۲۰۰ هرتز ثبت شده است. سیگنال‌ها با فرکانس نمونه‌برداری ۱۰۰ هرتز ثبت شده‌اند. مطابق شکل (۱)، برای هر تصویر حرکتی یک نشانه به مدت ۳/۵ ثانیه نمایش داده می‌شود؛ و افراد باید در این مدت به تصویر حرکتی مورد نظر بپردازند. زمان استراحت تا آزمایش بعدی به‌طور تصادفی بین ۱/۷۵ تا ۲/۲۵ ثانیه است. مجموعه آموزشی و آزمون برای هر فرد مطابق با جدول (۱) موجود است که برای هر فرد متفاوت می‌باشد. در کل برای هر طبقه ۱۴۰ آزمایش صورت گرفته است و درمجموع ۲۸۰ آزمایش برای هر فرد موجود است. با توجه به خصوصیات مولفه‌های نوسانی حسی و حرکتی^۱ (SMRs) که در محدوده باند μ , β , θ , δ قرار دارند، فیلتر میان‌گذر ۳۰-۸ هرتز را روی دادگان اعمال کرده‌ایم (فیلتر باترورث مرتبه ۵ استفاده شده است)، سپس داده را به قطعات دو ثانیه ای از ۰/۵ تا ۲/۵ ثانیه بعد از محل رخدادن هر آزمایش مطابق شکل (۱) (منطبق بر روش برنده مسابقات BCI در دادگان IV) در این مقاله از قطعه‌بندی کرده‌ایم (انگ و همکاران، ۲۰۱۲).

(جدول ۱): میزان سیگنال‌های آموزشی و آزمون برای افراد مختلف

افراد	aa	al	av	aw	ay
سیگنال‌های آموزشی	۱۶۸	۲۲۴	۸۴	۵۶	۲۸
سیگنال‌های آزمون	۱۱۲	۵۶	۱۹۶	۲۲۴	۲۵۲

^۱Sensorimotor rhythms

(رايت و همکاران، ۲۰۰۹). طبقه‌بندی با استفاده از نمایش تنک سیگنال شامل دو مرحله است: ابتدا داده ورودی با استفاده از ماتریس واژه‌نامه که از کنار هم قراردادن تمامی داده‌های آموزشی تشکیل شده است، به‌صورت تنک کد می‌شود؛ سپس با استفاده از این ضرایب تنک و با بازسازی داده آرمایشی، طبقه‌بندی انجام می‌شود. بنابراین طراحی یک ماتریس واژه‌نامه فرآکامل که از مرحله استخراج ویژگی به‌دست می‌آید و همچنین یافتن تنک‌ترین نمایش ممکن برای داده ورودی به سامانه از روی ماتریس واژه‌نامه طراحی شده، برای این طبقه‌بندی کننده، اموری حیاتی محسوب می‌شوند. در حوزه BCI، به‌تازگی در (شین و همکاران، ۲۰۱۳) از این طبقه‌بندی کننده استفاده شده است. نشان داده شده است که طبقه‌بندی کننده SRC در مقایسه با طبقه‌بندی پرکاربرد LDA، کارایی بهتری داشته است. شین در پژوهش خود برای استخراج ویژگی و طراحی ماتریس واژه‌نامه از الگوریتم فیلترهای مکانی مشترک^۲ (CSP) که به‌صورت موفقیت‌آمیزی در پژوهش‌های BCI استفاده می‌شود، استفاده کرده است. این روش نتایج قابل ملاحظه‌ای در مقابل سایر روش‌های استخراج ویژگی مانند ICA^۳ داشته است (برانر و همکاران، ۲۰۰۷). برای یافتن نمایش تنک داده ورودی به سامانه هم از الگوریتم جستجوی پایه^۴ (BP) استفاده کرده، که از معروف‌ترین ابزارها برای یافتن پاسخ تنک است. الگوریتم CSP دو اشکال عمدۀ دارد: نخست، حساسیت بالا به نویه و دوم، مسئله فرایاد‌گیری^۵ در مواردی که مجموعه آموزشی کوچک در اختیار باشد. از مهم‌ترین ابادات الگوریتم BP نیز زمان مورد نیاز آن است که به‌خصوص با زیادشدن ابعاد مسئله به‌طور معمول مشکل‌ساز می‌شود. ما در این مقاله از طبقه‌بندی کننده SRC در چارچوب یک سامانه BCI مبتنی بر تصویر حرکتی استفاده می‌کنیم. هدف ما رفع معایب ذکرشده است. بدین منظور در مرحله استخراج ویژگی از روش‌های بهبود الگوریتم CSP با نام کلی CSP تنظیم شده^۶ (RCSP)، و برای افزایش سرعت محاسبه پاسخ تنک داده ورودی به سامانه، از الگوریتم جدید نرم‌ساز SL0^۷ استفاده می‌کنیم.

¹Common Spatial Pattern

²Independent Components Analysis

³Basis Pursuit

⁴Over Fitting

⁵Regularized Common Spatial Pattern

⁶Smoothed L0-norm



عملکرد طبقه‌بندی کننده نیز بهتر می‌شود. تحلیل CSP از فیلترهای مکانی w استفاده می‌کند که می‌خواهندتابع هدف مطابق رابطه (۱) را اکسترمم نمایند:

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

در این رابطه X_i ماتریس داده و C_i ماتریس کواریانس طبقه آنمی‌باشند. از آنجا که سیگنال از فیلتر میان‌گذر عبور کرده است، سیگنال‌های EEG میانگین صفر دارند. یک روش برای حل این مسئله بهینه‌سازی این است که در ابتدا فرض کنیم تابع $J(w)$ با تغییر مقیاس فیلتر w ثابت بماند. یعنی اگر k یک ثابت حقیقی باشد، $J(kw) = J(w)$ باشد در این صورت اکسترمم کردن تابع $J(w)$ معادل با اکسترمم کردن w با فرض $w^T C_2 w = 1$ است.

$$\text{Min}_w (-w^T C_1 w) \text{ subject to } w^T C_2 w = 1 \quad (2)$$

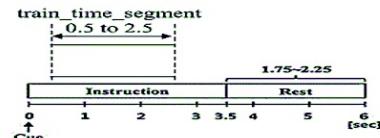
با استفاده از روش لاگرانژ، این مسئله بهینه‌سازی محدود شده با اکسترمم کردن تابع (۳) قابل حل است:

$$L(\lambda, w) = w^T C_1 w - \lambda(w^T C_2 w - 1) \quad (3)$$

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

$$\begin{aligned} \frac{\partial L}{\partial w} &= 2w^T C_1 - 2\lambda w^T C_2 = 0 \\ \Leftrightarrow C_1 w &= \lambda C_2 w \Leftrightarrow C_2^{-1} C_1 w = \lambda w \end{aligned} \quad (4)$$

در اینجا با یک مسئله استاندارد مقادیر ویژه رو به رو هستیم. فیلترهای مکانی که معادله (۱) را بیشینه می‌کنند، بردارهای ویژه ماتریس $M = C_2^{-1} C_1 = C$ هستند که مطابق با بزرگ‌ترین و کوچک‌ترین مقادیر ویژه به دست می‌آیند. بدین ترتیب ماتریس فیلترهای مکانی $W \in R^{c \times c}$ کانال‌های ثبت) حاصل می‌شود. فیلتر مطابق با بزرگ‌ترین مقدار ویژه دارای بیشترین قابلیت تفکیک برای طبقه ۱ و در همین زمان فیلتر مکانی مطابق با کوچک‌ترین مقدار ویژه دارای بیشترین قابلیت تفکیک برای طبقه دو است. در روش CSP، ویژگی‌های استخراج شده، لگاریتم واریانس سیگنال EEG بعد از تصویرشدن روی فیلترهای w است. بدین ترتیب بردارهای ویژگی و فیلترهای مکانی مناسب برای تفکیک داده‌های دو طبقه از هم به دست می‌آید. در این پژوهش از سه جفت فیلتر مکانی مطابق با سه تا از اولین و سه تای آخرین فیلترهای ماتریس W که به ترتیب دارای بیشترین قابلیت تفکیک برای طبقه‌های ۱ و ۲ هستند



(شکل-۱): پروسه ثبت سیگنال در data set Iva

۳- استخراج ویژگی

مبناًی اساسی در استفاده از تصور حرکتی در سامانه BCI بر این است که تصور حرکتی موجب پدیده ERS و ERD می‌شود که باعث تضعیف یا افزایش دامنه کوتاه‌مدت در مولفه‌های نوسانی EEG می‌شود. مولفه‌های مرتبط با حرکت در EEG، شامل نوسانات μ (۸-۱۲ هرتز) و یا نوسانات β (۲۵-۱۸ هرتز) است، که در طول حرکت و یا آماده‌شدن برای حرکت کاهش می‌یابد (ERD) و یا بعد از حرکت و یا در حالت استراحت افزایش می‌یابد (ERS) (ولپا و همکاران، ۲۰۰۲). استخراج ویژگی از پدیده‌های ERS و ERD جهت طبقه‌بندی تصور حرکتی مورد توجه قرار گرفته است. این پدیده‌ها ممکن است برای افراد مختلف در باندهای فرکانسی مختلف اتفاق بیفتد (لال و همکاران، ۲۰۰۴). همچنین به دلیل اینکه سیگنال‌های دریافت شده از پوسته سر (EEG) از غشای مغز فاصله دارد، مکانیابی دقیق منابع ERD در مغز دشوار است. فیلترهای مکانی و نوسانات ویژه برای افراد مختلف متفاوت است و برای هر فرد آموزش جدآنکه‌ای را می‌طلبد (مولر-گرکینگ و همکاران، ۱۹۹۹). روش فیلتر کردن مکانی برای استخراج ویژگی‌های مکانی از ERD برای داده‌های EEG به طور گسترده‌ای به کار گرفته می‌شود. از روش CSP به عنوان یک روش متداول برای استخراج ویژگی‌های جداساز طبقه‌ها استفاده می‌شود.

۳-۱- الگوهای مکانی مشترک (CSP)

کارایی فیلتر کردن مکانی برای بهبود وضوح مکانی و نسبت سیگنال به نویه در سیگنال EEG قبلًا ثابت شده است. یک نظریه از فیلترهای مکانی با نام الگوهای مکانی مشترک است که برای روش‌های شناسایی الگو مطرح شده است. این روش براساس قطری‌سازی همزمان دو ماتریس متقاضی کار EEG می‌کند. قطری‌سازی همزمان اجازه تجزیه سیگنال خام، به دو الگوی مجزا از دوطبقه را می‌دهد. در این دو الگو به صورت همزمان واریانس یکی از طبقه‌ها بیشینه و واریانس دیگری کمینه شده است. اگر تنها از فیلترهای با قابلیت تفکیک بیشتر استفاده شود، ابعاد داده هم کاهش می‌یابد و

پژوهش دو روش از این روش‌ها با نام‌های GLRCSP^۲ و DLRCSP^۳ را برای تنظیم فیلترهای مکانی استفاده می‌کنیم.

۱-۲-۳- CSP تنظیم شده با استفاده از آموزش کلی (GLRCSP)

تنظیم CSP با استفاده از آموزش کلی توسط لو در (لو و همکاران، ۲۰۰۹) پیشنهاد شده است و با نام کلی GLRCSP نام‌گذاری می‌شود. این روش به نوعی تنظیم ماتریس کواریانس با استفاده از داده‌های دیگر افراد است. این الگوریتم از هر دو پارامتر γ, β استفاده می‌کند. با این کار بهبود تخمین ماتریس کواریانس در هر دو سطح کاهش اربیتی تخمین (انتخاب γ) و افزایش پایداری تخمین (انتخاب β) صورت می‌گیرد. ماتریس کواریانس عمومی و پارامتر هموارکننده در این الگوریتم با استفاده از ماتریس کواریانس دیگر افراد با معادلات^(۶) به دست می‌آید.

$$G_c = s_G \sum_{i \in \Omega} C_c^i \quad (6)$$

$$s_c = s_G = \frac{1}{(1-\beta)M_{C_c} + \beta \sum_{i \in \Omega} M_{C_c^i}}$$

که در آن Ω مجموعه افراد آزمایش، C_c^i ماتریس کواریانس طبقه c برای فرد Ω ، M_c تعداد آزمایش‌ها برای محاسبه ماتریس کواریانس طبقه C است.

۲-۲-۳- تنظیم CSP با بارگذاری قطری (DLRCSP)

یکی از روش‌های تنظیم کردن ماتریس کواریانس در پژوهش‌های BCI، استفاده از بارگذاری قطری^۴ (DL) است. در این روش ماتریس کواریانس مطابق با ماتریس یکه کاهش می‌یابد و هدف آن تنها کاهش اربیتی تخمین ماتریس کواریانس است. بنابراین در این روش تنها از پارامتر تنظیم γ استفاده می‌شود ($\beta = 0$). مقدار مناسب برای γ را می‌توان به صورت خودکار با استفاده از روش LW^۵ محاسبه کرد (لیدیت و لوف، ۲۰۰۴). این الگوریتم به صورت خودکار، دو مقدار متفاوت برای پارامتر تنظیم γ (یکی برای کلاس یک و دیگری برای کلاس دو) انتخاب می‌کند. الگوریتم به دست آمده از این روش را DLRCSPauto می‌نامیم. برای بررسی میزان کارایی انتخاب خودکار پارامتر γ ، ما در اینجا این پارامتر را به صورت کلاسیک و با استفاده از روش ارزیابی

²Generic Learning Regularized Common Spatial Pattern

³Diagonal Loading Regularized Common Spatial Pattern

⁴Diagonal loading

⁵Ledoit and Wolf's method

استفاده کرده‌ایم. درنهایت با تصویر کردن سیگنال‌های اولیه بر این فیلترها، شش بردار ویژگی برای هر نفر به دست آمد، که در یک ماتریس X که به عنوان ماتریس واژه‌نامه طبقه‌بندی‌کننده SRC می‌باشد، قرار داده‌ایم.

۲-۲-۳- تخمین کردن تخمین ماتریس کواریانس

الگوریتم CSP نیاز به تخمین ماتریس کواریانس هر طبقه دارد. اگر مجموعه داده آموزشی، نویه‌ای و یا کم باشد، 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 تخمین ماتریس کواریانس با استفاده از عبارات تنظیم کننده، اجتناب‌ناپذیر است. مطابق با (لوته و گان، ۲۰۰۱) این کار با معادلات^(۵) انجام می‌پذیرد:

$$\tilde{C}_c = (1 - \gamma) \hat{C}_c + \gamma I \quad (5)$$

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

که در آن C_c ماتریس کواریانس نخستین هر طبقه، \tilde{C}_c تخمین تنظیم شده آن، I ماتریس همانی، s_c پارامتر هموارکننده (یک اسکالر) که ثابت مقیاس‌دهی نامیده می‌شود، β دو پارامتر تنظیم کننده ($0 \leq \beta \leq 1$) و G_c ماتریس کواریانس عمومی است. پارامتر γ تخمین کواریانس نخستین را مطابق با ماتریس یکه کاهش می‌دهد تا اربیتی تخمینی را که در اثر کمبودن داده آموزشی بوجود می‌آید، خنثی کند. پارامتر β تخمین کواریانس نخستین را مطابق با ماتریس کواریانس عمومی کاهش می‌دهد. این کار برای پایداری بیشتر تخمین صورت می‌گیرد. ماتریس کواریانس عمومی پیش‌فرضی است در مورد این که برای هر حالت ذهنی ماتریس کواریانس چگونه باید باشد. این ماتریس به طور عمومی با استفاده از سیگنال‌های افراد مختلفی که آزمایش‌های یکسانی (به طور مثال تصور حرکت دست راست) روی آنها انجام شده است، 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 می‌گیرد. بسته به نوع تعریف ماتریس کواریانس عمومی و استفاده از یکی یا هر دو پارامتر تنظیم، الگوریتم‌های مختلفی می‌توان تعریف کرد که با نام کلی الگوهای مکانی مشترک تنظیم شده نام برده می‌شود (لوته و گان، ۲۰۰۱). در این

¹Bias



بردار نمایش تنک داده ورودی y است. در معادله (7) فرض شده است که سیگنال کامل و بدون هیچگونه نوفه‌ای باشد و از آنجا که در داده واقعی نوفه هر چند کم وجود دارد با استفاده از معادله (7) نمی‌توان بسط تنکی از روی نمونه‌های آموزشی با توجه به این معادله به دست آورد. از این رو می‌توان با اصلاح معادله (7) از مدل نوفه‌ای به صورت معادله (9) استفاده کرد:

$$y = Xs + Z \quad (9)$$

که $Z \in R^m$ میزان نوفه با انحراف محصور شده $\epsilon < \|Z\|_2$ است. حال نمایش تنک داده ورودی y بر حسب ستون‌های X به صورت معادله (10) بدست می‌آید.

$$\hat{s} = \arg \min \|s\|_0 \quad \text{s. t.} \quad \|Xs - y\|_2 \leq \epsilon \quad (10)$$

بعد از حل مسئله کمینه‌سازی نرم صفر، s بردار نمایش تنک داده ورودی y است. برای بررسی میزان شباهت داده ورودی به هر یک از طبقه‌ها تابع $\delta_i: R^n \rightarrow R^n$ بدین گونه تعریف می‌شود که اگر δ_i بر روی بردار s اعمال شود، n_i تا از مؤلفه‌های بردار s (که با ستون‌هایی از ماتریس واژه‌نامه که مربوط به داده‌های دسته آم است، متناظر می‌باشد) حفظ شده است و سایر مؤلفه‌ها برابر صفر قرار داده می‌شوند یعنی:

$$\delta_i(s) = [0, \dots, 0, s_{i,1}, \dots, s_{i,n_i}, 0, \dots, 0]^T \in R^n \quad (11)$$

که در آن $n_i = n_1 + \dots + n_i$ با این اوصاف $\hat{y}_i = X\delta_i(s)$ ، داده y را بر حسب فقط ضرایب متناظر با داده‌های طبقه آم بیان می‌کند. این تابع برای هر i طبقه بر روی نمایش تنک داده y اعمال می‌شود و درنهایت بر جسمی انتخاب می‌شود که میزان باقیمانده $\|y - X\delta_i(s)\|_2 = r_i(y)$ حداقل کند:

$$\text{Class}(y) = \min_i r_i(y) \quad (12)$$

با این وجود، یافتن پاسخ تنک کار پیچیده‌ای است؛ زیرا نرم صفر پیوسته نیست و بهینه‌سازی آن نیاز به جستجوی ترکیباتی دارد. در بخش بعد بعضی از الگوریتم‌های معروف برای یافتن پاسخ تنک مرور می‌شود.

۴-۱- الگوریتم‌های یافتن پاسخ تنک

در این مقاله از طبقه‌بندی کننده مبتنی بر نمایش تنک (SRC)، با توجه به کارایی بالای آن در پژوهش‌های قبلی

متقابل^۱ (CV) به صورت 10-fold انتخاب می‌کنیم و این الگوریتم را DLRCPcv می‌نامیم. از آنجا که روش LW به صورت خودکار برای هر طبقه مقدار متفاوتی برای پارامتر γ ارائه می‌دهد، از روش ارزیابی متقابل برای انتخاب دو مقدار متفاوت پارامتر γ برای هر طبقه استفاده می‌کنیم و نام این روش را DLRCSpcvdif می‌نامیم.

به اختصار:

DLRCSPauto: با استفاده از روش LW دو مقدار مختلف پارامتر γ برای دو طبقه انتخاب می‌شود.
DLRCSPcv: با استفاده از روش ارزیابی متقابل یک مقدار منفرد پارامتر γ ، برای هر دو طبقه، انتخاب می‌شود.
DLRCSPcvdiff: با استفاده از روش ارزیابی متقابل دو مقدار پارامتر مختلف γ ، برای هر طبقه انتخاب می‌شود.

۴- طبقه‌بندی مبتنی بر نمایش تنک (SRC)

در این طبقه‌بندی کننده، نظریه اصلی نمایش هر داده آزمون بر حسب داده‌های آموزشی دسته متناظر با آن است. فرض کنید داده‌های آموزشی دسته آم 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 طبقه آم است. اگر $y \in R^{m \times 1}$ یک داده ورودی متعلق به دسته آم باشد، انتظار می‌رود که بتوان y را طبق رابطه (7) بر حسب ستون‌های ماتریس X_i نمایش داد:

$$y = s_{i,1}x_{i,1} + \dots + s_{i,n_i}x_{i,n_i} = \sum_{j=1}^{n_i} s_{i,j}x_{i,j} \quad (7)$$

که در آن $s_{i,j}$ اعداد اسکالر هستند. فرم ماتریسی معادله (7) به صورت $y = Xs$ است. در روش SRC برای رسیدن به این هدف از روش نمایش تنک استفاده می‌شود. باید توجه کرد که برچسب داده آزمون برای سامانه مجھول 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 هستند که داده‌های دسته آم در آن قرار دارند. در چارچوب نظریه نمایش تنک داده‌ها، ماتریس X همان ماتریس واژه‌نامه است. حال می‌توان نمایش تنک داده ورودی y را بر حسب ستون‌های ماتریس X به دست آورد:

$$\hat{s} = \arg \min \|s\|_0 \text{ subject to } y = Xs \quad (8)$$

^۱Cross-Validation



مختلفی که برای مسائل خطی پیشنهاد شده‌اند، قابل حل است. در (گریبونوال و نیلسون، ۲۰۰۳) ثابت شده است که اگر تعداد عناصر مخالف صفر در پاسخ تنک از حدی، که به همیستگی میان اتم‌ها (ستون‌های) \mathbf{D} و بسطه است، کمتر باشد، پاسخ (۱۴) به طور دقیق برابر با پاسخ تنک با کمینه‌سازی نرم صفر است. یکی از مهم‌ترین ایده‌های الگوریتم BP زمان مورد نیاز آن است که به طور معمول و به خصوص با زیادشدن ابعاد مسئله مشکل‌زا می‌شود. یکی از سریع‌ترین روش‌ها برای تخمین پاسخ تنک الگوریتم مناسب‌ترین ارتباط^۲ (MP) نام دارد که در (مالات و زینفگ، ۱۹۹۳) معرفی شده است. ذات این روش حریصانه است و تلاش می‌کند تا در هر گام تنها ضریب یکی از اتم‌ها را مشخص کند. به عبارت دیگر، در گام نخست اتمی که بیش‌ترین مشابهت (بزرگ‌ترین ضرب داخلی) با سیگنال آزمون را دارد، انتخاب شده و ضریب آن محاسبه می‌شود. در گام بعد، باقی‌مانده سیگنال آزمون و اتم نخست با بقیه اتم‌ها مقایسه شده و دوباره 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 یا آنکه تعداد مشخصی از اتم‌ها دارای ضریب مخالف صفر شوند. الگوریتم MP بدلیل آن که در هر گام نیاز به یک جستجوی ساده دارد، به طور معمول بسیار سریع است؛ اما به دلیل حریص‌بودن، تضمینی وجود ندارد که پاسخ نهایی مشابه با پاسخ تنک باشد. به‌منظور بهبود الگوریتم MP با حفظ سرعت بالای آن، الگوریتم‌های متنوعی پیشنهاد شده است که معروف‌ترین آن MP متعمادم^۳ (OMP) نام دارد (پاتی و همکاران، ۱۹۹۳). در OMP در هر گام پس از آن که اتم جدید مشخص شد، از تمام ضرایب قبلی صرف نظر شده و ترکیبی خطی از تمام اتم‌های انتخاب‌شده تا این گام، محاسبه می‌شود که کمترین خطای برای بازنمایی سیگنال آزمون داشته باشد.

۴-۱-۱- نرم صفر هموارشده (SL0)

یکی دیگر از الگوریتم‌های مناسب برای یافتن پاسخ تنک، نرم صفر هموارشده (SL0) نام دارد که در (موهیمانی و همکاران، ۲۰۰۹) معرفی شده است. در این روش تلاش بر آن است تا از کمینه‌کردن خود نرم صفر استفاده شود. ایرادی که برای کمینه‌کردن نرم صفر وجود دارد آن است که

²Matching Pursuit

³Orthogonal matching pursuit

استفاده می‌کنیم. همان‌طور که در بخش قبل مطرح شد، در این روش طبقه‌بندی، نیاز به یافتن پاسخ تنک داده و رویدی از روی ماتریس واژه‌نامه طراحی شده است. یافتن پاسخ تنک در دستگاه معادلات خطی فرومیعنی^۱ در حوزه پردازش داده اهمیت فراوانی است. به عنوان مثال، از پاسخ تنک در جداسازی کور منابع (لی و همکاران، ۲۰۰۶)، فشرده‌سازی تصویر (سزار و همکاران، ۲۰۰۸) و طبقه‌بندی (رایت و همکاران، ۲۰۰۹) استفاده شده است. یک دستگاه معادلات خطی در حالت کلی به صورت ماتریسی $y = \mathbf{X}s$ = قابل بیان است. اگر در این دستگاه تعداد معادلات از تعداد مجھولات بیشتر باشد، به آن فرومیعنی گفته می‌شود. بنابراین، تعداد پاسخ‌های s ای که در $y = \mathbf{X}s$ = صدق می‌کند، در این نوع دستگاه می‌تواند بیش از یک باشد. به همین دلیل برای انتخاب یکی از پاسخ‌های ممکن نیاز است تا قیدهای دیگری به مسئله اضافه شوند. بدلیل مزایای فراوان پاسخ تنک در کاربردهای ذکر شده، یکی از قیدهای متداول برای انتخاب یکی از پاسخ‌های دستگاه فراکامل، قید تنک‌بودن به معنای حداقل کردن نرم صفر است. این مسئله در معادله (۱۳) بیان شده است:

$$l^0: \hat{s} = \operatorname{argmin}\|s\|_0 \text{ subject to } y = \mathbf{X}s \quad (13)$$

نتیجه بهینه‌سازی معادله (۱۳) پاسخی از دستگاه $y = \mathbf{X}s$ = خواهد بود که تعداد عناصر مخالف صفر در آن حداقل است (s را k تنک گویند، اگر دارای حداقل k مؤلفهٔ غیر صفر باشد). چنانچه ماتریس واژه‌نامه X فراکامل باشد، معادله بالا پاسخی یکتا و تنک خواهد داشت. از آنجا که نرم صفر پیوسته نیست، به دست آوردن پاسخ تنک نیاز به جستجوی ترکیباتی دارد و حل آن NP-hard است (کان و آمالدی، ۱۹۹۸). به همین دلیل، چند روش جایگزین، برای یافتن پاسخ تنک پیشنهاد شده است. یکی از معروف‌ترین ابزارها برای ساختن پاسخ تنک، الگوریتم جستجوی پایه (BP) (چن و همکاران، ۱۹۹۸) است که در آن به جای نرم صفر، از کمینه‌کردن نرم یک مطابق معادله (۱۴) استفاده می‌شود:

$$l^1: \hat{s} = \operatorname{argmin}\|s\|_1 \text{ subject to } y = \mathbf{X}s \quad (14)$$

مسئله بهینه‌سازی (۱۴) به راحتی قابل تبدیل به یک مسئله خطی است و به همین دلیل با استفاده روش‌های

¹Underdetermined



درنهایت الگوریتم زیر روش طبقه‌بندی را بهطور خلاصه بیان می‌کند:

وروودی: ماتریس وارثه‌نامه X و داده ورودی y

- هنجارسازی کردن ستون‌های ماتریس X
- بهدست آوردن نمایش تنک داده آزمون با استفاده از یکی از روش‌های BP، OMP و یا SL0
- محاسبه باقیمانده $r_i(y) = \|y - X\delta_i(s)\|_2$

خروجی: برچسب داده y $Class(y) = \min_i r_i(y)$

۵- روال انجام آزمایش

در این پژوهش پس از مرحله پیش‌پردازش داده‌ها، از روش فیلترینگ مکانی CSP و گونه‌های بهبودیافته آن با نامهای DLRCSP و GLRCSP در مرحله استخراج ویژگی و طراحی ماتریس وارثه‌نامه طبقه‌بندی کننده SRC استفاده کرده‌ایم. بدین منظور همان‌طور که در بخش استخراج ویژگی شرح داده شد با استفاده از داده‌های آموزشی موجود برای هر سوژه سه جفت فیلتر مکانی انتخاب شد و سپس لگاریتم واریانس سیگنال‌های EEG تصویرشده روی این فیلترها، با هم ترکیب و شش بردار ویژگی برای هر سوژه بهدست آورده‌یم. این بردارها ماتریس وارثه‌نامه X را تشکیل دادند (با این کار کاهش بعدی از ۱۱۸ به ۶ بعد حاصل شد) و مرحله آموزش سامانه انجام گرفت؛ سپس مطابق با مباحثت بخش طبقه‌بندی کننده SRC اعمال شد و با هر سه الگوریتم محاسبه پاسخ تنک BP، OMP و SL0 آزمایش‌ها صورت گرفت. کلیه این روال در روند نمای شکل (۶) آمده است.

۶- نتایج آزمایش‌ها

در هر دو الگوریتم پارامترهای γ, β وجود دارد که مقدار آن وابسته به فرد است. در (لو و همکاران، ۲۰۰۹) برای انتخاب این پارامترها روش مشخصی ذکر نشده و نویسنده نتایج حاصل از استفاده چندین مقدار مختلف این پارامترها را ارائه کرده است. در (لوته و گان، ۲۰۱۱) برای تعیین این پارامترها از روش ارزیابی متقابل بر روی داده آموزشی استفاده شده است. در این مقاله برای انتخاب این پارامترها از ارزیابی متقابل بر روی داده‌های آموزشی و طبقه‌بندی کننده SRC استفاده می‌کنیم. مقادیر γ, β را در بازه [۰/۹، ۰/۰] با گام ۰/۱ در نظر گرفته و با اعمال این روش

تابع نرم صفر پیوسته نیست. به همین دلیل، پیشنهاد شده است تا به جای نرم صفر از تابع همواری استفاده شود که تقریبی از نرم صفر را نتیجه می‌دهد. تابع مفروض قرینه تابع گوسی است.

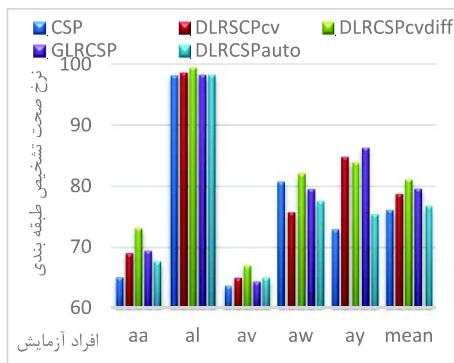
$$\|S\|_0 \approx m - \sum_i \exp\left(\frac{-S_i^2}{2\sigma^2}\right) = m - F_\sigma(S) \quad (15)$$

از آنجا که این تابع جدید هموار است به سادگی می‌توان آن را بهینه‌سازی کرد. اگر S را در رابطه (۱۵) به سمت صفر میل دهیم، علامت تقریب به تساوی تبدیل می‌شود. بنابراین بیشینه کردن تابع $F_\sigma(S)$ برای S کوچک معادل با کمینه کردن نرم صفر است. از این رو مسئله بهینه‌سازی به صورت (۱۶) خواهد بود:

$$(SL0): \hat{S}_0 = \arg \max F_\sigma(S) \text{ s.t. } y = XS \quad (16)$$

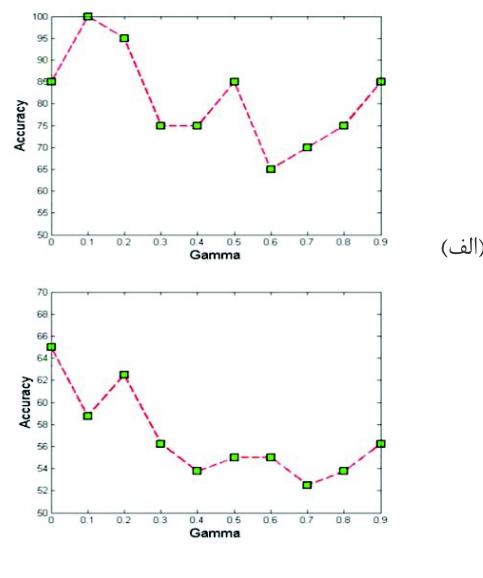
با این وجود اگر تابع مفروض به اندازه کافی هموار نباشد ممکن است در بهینه‌سازی آن برای مجموع عنصر یک بردار، کمینه‌های محلی زیادی وجود داشته باشد. به همین دلیل از یک روش درشت به ریز برای بهینه‌سازی استفاده شده است. در این روش، ابتدا تابع بسیار همواری انتخاب می‌شود (گوسی با واریانس بزرگ) تا تنها یک کمینه محلی داشته باشد. پس از یافتن مکان کمینه، در گام بعدی از این مکان برای مقداردهی اولیه در یک تابع که به نرم صفر نزدیک‌تر شده است (واریانس کاهش یافته است) استفاده می‌شود. به همین ترتیب، در هر گام از نتیجه قبلی استفاده شده و تابع به نرم صفر نزدیک‌تر می‌شود. اثبات شده است که با انتخاب صحیح واریانس‌ها، در بینهایت (واریانس صفر) پاسخ بهدست آمده به پاسخ تنک همگرا می‌شود. جزییات این الگوریتم در (موهیمانی و همکاران، ۲۰۰۹) موجود است. در الگوریتم SL0 برای بهینه‌سازی تابع در هر گام از الگوریتم کاهش گرادیان و تصویرکردن با چند تکرار استفاده می‌شود. یکی از مزایای SL0 سرعت بالای آن است و علاوه‌بر این، از آنجایی که در این روش سعی بر کمینه کردن نرم صفر است، توقع می‌رود تا مسائل تنک پیچیده‌تری توسط این الگوریتم قابل حل باشد. نکته قابل توجه این است که در چند سال اخیر این روش مورد توجه زیادی از پژوهش‌گران قرار گرفته است (کریستین و همکاران، ۲۰۱۳)، (نیاززاده و همکاران، ۲۰۱۲).

که مشاهده می‌شود در تمامی موارد الگوریتم‌های RCSP بهتر از گونه استاندارد آن عمل کرده است. به طور میانگین افزایش دقتی بالای ۶/۱۷٪ در الگوریتم GLRCSP با استفاده از الگوریتم BP، ۴/۹۸٪ و ۷/۷۸٪ در الگوریتم DLRCSPcvdiff به ترتیب با استفاده از الگوریتم OMP و SL0 مشاهده می‌شود. برای افرادی که میزان داده آموزشی آنها کمتر از داده آزمون بوده است، افزایش دقت قابل ملاحظه‌ای مشاهده می‌شود. به عنوان مثال برای فرد ay که تنها از ۲۸ سیگنال آموزش استفاده شده است (در برابر با ۲۵۲ سیگنال آزمون) افزایش دقت ۲۳٪/۷٪ نسبت به استاندارد با الگوریتم BP، ۱۲٪/۳۵٪ با الگوریتم OMP و ۲۳٪/۱۸٪ با الگوریتم SL0 دارد. این افزایش دقت در هر سه روش توسط الگوریتم GLRCSP حاصل شده است. برای فرد aw که ۵۶ سیگنال آموزشی موجود بوده است، افزایش دقت ۷٪/۱۸٪ با استفاده از الگوریتم BP و ۱/۳۷٪ با استفاده از الگوریتم OMP و DLRCSPcvdiff و ۱۰٪/۱٪ با استفاده از الگوریتم SL0 DLRCSPcvdiff نسبت به گونه استاندارد CSP به دست آمده است. برای بررسی میزان پیچیدگی محاسباتی الگوریتم‌ها باید مرتبه محاسباتی آنها را محاسبه کرد. با توجه به پیچیدگی الگوریتم‌ها برای محاسبه مرتبه محاسباتی، در این مقاله زمان مورد نیاز برای اجرای الگوریتم‌ها به عنوان یک معیار کیفی آورده می‌شود. در جدول (۵) زمان مورد نیاز برای بدست آوردن پارامترهای تنظیم‌کننده بهینه با استفاده از روش ارزیابی مقابله و در جدول (۶) مدت زمان مراحل آزمون آمده است. تمامی آزمایش‌ها در سامانه‌ای با مشخصات Intel Core i5 2410M MATLAB 4 GB RAM و 2.30 GHz CPU نرم‌افزار (R2012a) نسخه ۷/۱۴ انجام شده است.



(شکل - ۳): میزان صحت طبقه‌بندی برای افراد مختلف با الگوریتم OMP

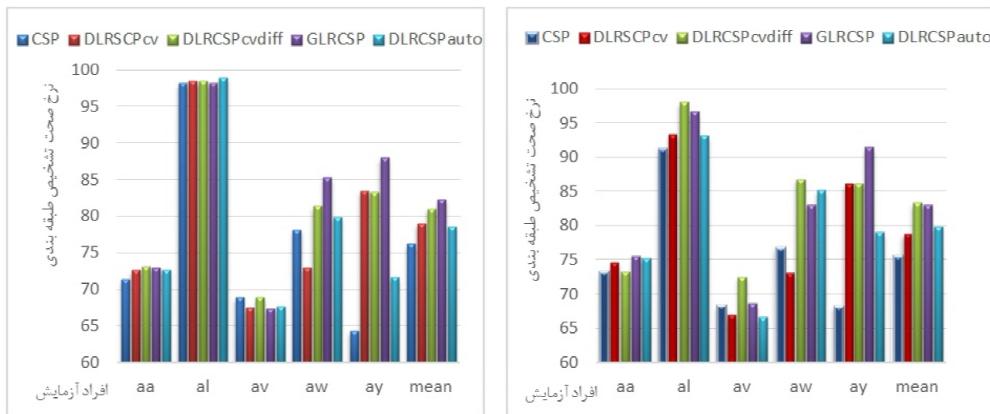
β هایی که بیشترین دقت را در مجموعه آموزشی داشته‌اند، انتخاب می‌کنیم. برای نمونه برای الگوریتم DLRCSPcv، برای فرد ay به ازای γ های مختلف میزان درصد صحت طبقه‌بندی کننده SRC با الگوریتم OMP در شکل ۲- (الف) رسم شده است. ملاحظه می‌شود به ازای $\gamma=0.1$ بیشترین صحت، طبقه‌بندی به دست آمده است. همچنین در شکل ۲- (ب) این مقدار برای فرد av با طبقه‌بندی کننده SRC با الگوریتم BP رسم شده است که به ازای $\gamma=0$ بیشترین صحت طبقه‌بندی به دست آمده است.



(شکل - ۲): میزان صحت طبقه‌بندی الگوریتم DLRCSPcv به ازای γ های مختلف برای با استفاده از طبقه‌بندی کننده SRC الف- فرد ay با الگوریتم OMP ب- فرد av با الگوریتم

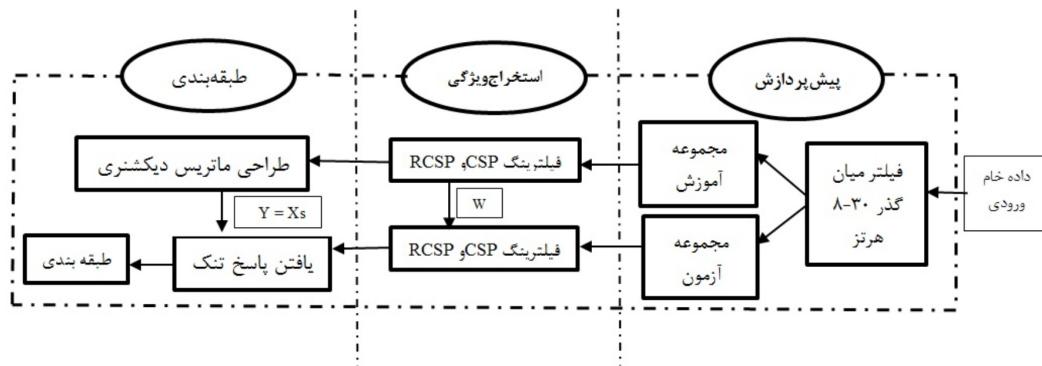
جهت رسیدن به یک ارزیابی مطمئن، برای هر سیگنال آزمون عمل طبقه‌بندی را بیست مرتبه تکرار کرده‌ایم. نتایج بیست مرتبه تکرار طبقه‌بندی کننده‌های SRC به صورت میانگین و انحراف معیار درصد صحت طبقه‌بندی در جداول (۲، ۳ و ۴) آمده است. در این جداول مقادیر بهینه γ نیز برای حالت‌های مختلف نشان داده شده است. علاوه‌بر این با توجه به پراکندگی نتایج بین سوزه‌های مختلف برای بررسی میزان بهبود الگوریتم‌های RCSP نسبت به CSP، میزان میانگین افزایش درصد صحت ناشی از اعمال روش‌های RCSP در این جداول ذکر شده است. همچنین درصد صحت طبقه‌بندی برای افراد مختلف به صورت نمودار میله‌ای در شکل‌های (۳، ۴ و ۵) رسم شده است. همان‌طور





(شکل-۴): میزان صحت طبقه‌بندی برای افراد مختلف الگوریتم BP0

(شکل-۴): میزان صحت طبقه‌بندی برای افراد مختلف الگوریتم SL0



(شکل-۶): بلوک دیاگرام روال کلی آزمایش

(جدول-۲): نتایج درصد صحت طبقه‌بندی کننده SRC با الگوریتم SL0 (میانگین \pm انحراف معیار) به ازای الگوریتم‌های مختلف CSP

میانگین افزایش دقت CSP نسبت به	ay	aw	av	al	aa	الگوریتم‌ها
.	۶۸/۲۵ \pm ۰	۷۶/۷۸ \pm ۰	۶۸/۳۷ \pm ۰	۹۱/۰۷ \pm ۰	۷۳/۲۱ \pm ۰	CSP
۷/۵۲	۹۱/۴۳ \pm ۰/۲۷ ۰/۴۰، ۰/۱	۸۳/۱ \pm ۱/۵۱ ۰، ۰/۵	۶۸/۶ \pm ۰۲/۶۹ ۰/۳، ۰/۳	۹۶/۶۹ \pm ۰/۶۵ ۰، ۰/۱	۷۵/۴۹ \pm ۰/۹۸ ۰، ۰/۳	GLRCSP بهترین (β و γ)
۴/۲۹	۷۹ \pm ۴/۰۷	۸۵/۱۶ \pm ۳/۷	۶۶/۵۸ \pm ۱/۰۲	۹۳/۱۳ \pm ۱/۹۵	۷۵/۲۷ \pm ۲/۴۸	DLRCSPAuto
۳/۲۹	۸۶/۱۱ \pm ۰/۹۷ ۰/۱	۷۳/۱۵ \pm ۳/۵۷	۶۶/۹۱ \pm ۱/۱	۹۳/۳۹ \pm ۱/۳۱ ۰/۱	۷۴/۶ \pm ۳ ۰	DLRSCPcv بهترین γ
۷/۷۸	۸۶/۱۳ \pm ۰/۷۳ ۰/۱، ۰/۱	۸۶/۷۹ \pm ۰/۵۳ ۰/۹، ۰/۷	۷۲/۴۲ \pm ۰/۴۸ ۰/۴، ۰/۲	۹۸/۰۴ \pm ۰/۵۵ ۰/۶، ۰/۱	۷۳/۲۱ \pm ۰ ۰/۴، ۰/۲	DLRCSpcvdiff بهترین (γ و α)

(جدول - ۳): نتایج درصد صحت طبقه‌بندی کننده SRC با الگوریتم BP (میانگین ± انحراف معیار) به‌ازای الگوریتم‌های مختلف CSP

میانگین افزایش دقت CSP نسبت به	ay	aw	av	al	aa	الگوریتم‌ها
.	۶۴/۲۹±۰	۷۸/۱۳±۰	۶۸/۸۸±۰	۹۸/۲۱±۰	۷۱/۴۳±۰	CSP
۶/۱۷	۸۷/۹۹±۱/۸ ۰/۱۰ ۰/۱	۸۵/۳۱±۱/۹ ۰/۳۰	۶۷/۳۲±۲/۱۵ ۰/۴۰ ۰/۱	۹۸/۲۱±۰/۸۲ ۰/۱۰۰	۷۲/۹۹±۱/۱۲ ۰/۲۰۰	GLRCSP بهترین (β و γ)
۱/۹۹	۷۱/۶۱±۷	۷۹/۸۹±۳/۷۸	۶۷/۷±۱/۸	۹۹/۰۲±۱/۲۳	۷۲/۶۸±۲/۲۳	DLRCSPauto
۲/۸	۸۳/۴۵±۳/۱۹ ۰/۱	۷۲/۹۹±۰/۹۹ ۰/۲	۶۷/۴۲±۲/۱	۹۸/۴۸±۱/۴۵	۷۲/۵۹±۰/۸۷	DLRCSPcv بهترین γ
۴/۸۵	۸۳/۲۹±۳/۳۷ ۰/۱۰ ۰/۱	۸۱/۳۸±۲/۶۳ ۰/۵۰ ۰/۲	۶۸/۹۵±۲/۵۱ ۰/۸۰ ۰/۶	۹۸/۴۸±۱/۳۳ ۰/۴۰ ۰/۱	۷۳/۰۸±۲/۵۶ ۰/۶۰ ۰/۴	DLRCSPcvdiff بهترین (γ و β)

(جدول - ۴): نتایج درصد صحت طبقه‌بندی کننده SRC با الگوریتم OMP (میانگین ± انحراف معیار) به‌ازای الگوریتم‌های مختلف CSP

میانگین افزایش دقت CSP نسبت به	ay	aw	av	al	aa	الگوریتم‌ها
.	۷۳/۰۲±۰	۸۰/۸±۰	۶۳/۷۸±۰	۹۸/۲۱±۰	۶۵/۱۸±۰	CSP
۳/۴۶	۸۶/۳۷±۲/۳۵ ۰/۲۰ ۰/۲	۷۹/۶۲±۲/۳۲ ۰/۰ ۰/۳	۶۴/۴۹±۲/۴۸ ۰/۱۰ ۰/۹	۹۸/۳±۱/۹۷ ۰/۰۰ ۰/۱	۶۹/۵۱±۲/۴۵ ۰/۰ ۰/۳	GLRCSP بهترین (γ و β)
۰/۶۸	۷۵/۵±۶/۵۵	۷۷/۶۶±۳/۶۶	۶۵/۱۵±۲/۵۸	۹۸/۳±۱/۳۶	۶۷/۷۷±۲/۹۳	DLRCSPauto
۲/۵	۸۴/۸۶±۲/۳۹ ۰/۱	۷۵/۸±۴/۸	۶۵/۰۸±۲/۰۵	۹۸/۶۶±۱/۲۳	۶۹/۱۱±۱/۹۳	DLRCSPcv بهترین γ
۴/۹۸	۸۳/۹۹±۲/۲۶ ۰/۵۰ ۰/۳	۸۲/۱۷±۲/۵۷ ۰/۳۰ ۰/۱	۶۷/۰۹±۲/۲۳ ۰/۹۰ ۰/۸	۹۹/۴۶±۱/۰۲ ۰/۵۰ ۰/۱	۷۳/۲۱±۳/۱۳ ۰/۸۰ ۰/۶	DLRCSPcvdiff بهترین (γ و β)

(جدول - ۵): زمان مورد نیاز برای به‌دست آوردن پارامترهای تنظیم کننده بهینه با روش ارزیابی متقابل (10-fold)

با الگوریتم‌های مختلف SRC (مقدار بر حسب ثانیه)

ay	aw	av	al	aa	الگوریتم‌های RCSP	الگوریتم‌های SRC
۲۶۵۷/۲	۳۱۵۴/۹	۴۰۰۱/۷	۷۲۷۸/۴	۵۵۰۸/۹	GLRCSP	BP با SRC
۷۶۸/۵	۱۴۱۹	۲۲۵۰/۵	۵۵۷۹/۸	۳۶۴۰/۲	DLRCSPcvdiff	
۶۶/۶	۱۲۹/۲	۲۳۰/۸	۶۱۳/۲	۴۰۹/۱	DLRCSPcv	
۲۲۴۹/۹	۲۳۷۸/۵	۲۴۴۳/۵	۲۶۸۴/۳	۲۸۳۹/۴	GLRCSP	OMP با SRC
۳۰۴/۲	۴۸۲/۲	۶۶۲/۵	۱۴۵۵/۵	۱۱۴۲	DLRCSPcvdiff	
۲۵/۵	۴۳/۶	۶۲/۴	۱۳۹/۵	۱۱۰/۵	DLRCSPcv	
۱۶۳۱/۸	۱۷۰۷/۷	۱۶۷۲/۵	۱۹۵۶/۳	۱۸۵۸/۴	GLRCSP	SL0 با SRC
۲۴۹	۳۶۵/۶	۴۷۲/۱	۱۰۷۷/۲	۸۲۴/۷	DLRCSPcvdiff	
۱۳/۲	۳۱/۷	۴۹	۱۱۴	۹۶/۲	DLRCSPcv	

فصل نهم





(جدول-۶): میانگین و انحراف معیار زمان مورد نیاز یک مرحله آزمون طبقه‌بندی کننده‌های مختلف SRC با الگوریتم‌های مختلف RCSP (مقادیر بر حسب ثانیه)

SL0 با SRC	OMP با SRC	BP با SRC	الگوریتم‌ها
0.004 ± 0.001	0.0127 ± 0.0003	0.2428 ± 0.0113	CSP
0.0036 ± 0.0008	0.013 ± 0.0006	0.2426 ± 0.0227	GLRCSP
0.0037 ± 0.0015	0.0127 ± 0.0002	0.2136 ± 0.0215	DLRCSPdiff
0.0036 ± 0.0017	0.0123 ± 0.0001	0.2484 ± 0.0115	DLRCSPauto
0.0037 ± 0.0013	0.0129 ± 0.0001	0.226 ± 0.028	DLRCSPcv

الگوریتم زمان مورد نیاز برای اجرای آن است، که با زیادشدن ابعاد مسئله مشکل‌ساز می‌شود. هر چند شاید زمان لازم برای مرحله آموزش چندان مهم نباشد، ولی زمان مرحله آزمون به خصوص در کاربردهای BCI امری مهم و تعیین کننده محاسبه می‌شود. برای رفع این عیوب، از الگوریتم OMP برای محاسبه پاسخ تک استفاده کردیم. ملاحظه می‌شود که سرعت تشخیص داده مرحله آزمون حدود بیست 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 هموارشده (SL0) که به تازگی مطرح شده است (موهیمانی و همکاران، ۲۰۰۹) استفاده کردیم. در حد بررسی‌های انجام‌شده توسط ما تاکنون از این الگوریتم برای سامانه‌های BCI استفاده نشده است. همان‌طور 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 چهار برابر از الگوریتم OMP نیز بهتر عمل کرده است. در عین حال به طور میانگین حدود ۱/۶۱٪ در صحت تشخیص بهتر از الگوریتم BP عمل کرده است. بهترین دقت تشخیص در همه افراد (به جز فرد (al)، با استفاده از الگوریتم SL0 حاصل شد. از آنجا که روش SL0 برخلاف دیگر الگوریتم‌ها، که به جای نرم صفر از تقریب نرم صفر استفاده می‌کنند، سعی بر کمینه کردن خود تابع نرم صفر دارد، این افزایش کارایی مورد انتظار ما بود. لوته در کار مشابهی (لوته و گان، ۲۰۱۱) از الگوریتم‌های RCSP ذکر شده در مسائلهای مشابه با این مقاله استفاده کرده است. وی در مقاله خود برای طبقه‌بندی از طبقه‌بندی کننده پر کاربرد LDA استفاده کرده است. در جدول (۷) نتایج میانگین درصد صحت تشخیص برای هر دو طبقه‌بندی کننده آمده است. ملاحظه می‌شود در همه موارد طبقه‌بندی کننده

۷- بحث و نتیجه‌گیری

در این پژوهش با توجه به کارایی بالای گزارش‌شده طبقه‌بندی کننده SRC در کاربردهای مختلف EEG مبتنی طبقه‌بندی کننده برای طبقه‌بندی سیگنال‌های EEG بر تصور حرکتی استفاده شد. این طبقه‌بندی کننده برای کارایی بالا نیاز به طراحی ماتریس واژه‌نامه قوی دارد. بنابراین، با توجه به گزارش‌های متعدد از کارایی بالای الگوریتم CSP در مرحله استخراج ویژگی از آن استفاده کردیم. برخلاف محبوبیت بالای CSP، این روش، دو اسکال عمده دارد: نخست حساسیت بالا به نوشه و دیگری مسئله فرایادگیری در مواردی که داده آموزشی کم در اختیار باشد. برای رفع این عیوب، از دو روش الگوهای مکانی مشترک تنظیم شده (GLRCSP و DLRCSP) که به تازگی مورد توجه قرار گرفته‌اند، استفاده کردیم. همان‌طور که در نتایج مشاهده شد استفاده از این روش‌ها درصد صحت تشخیص را نسبت به CSP استاندارد به طور میانگین حدود ۷/۷۸٪ بهبود داده است. در مواردی که داده آموزشی کمی موجود بود، این افزایش درصد صحت تشخیص به ۲۳/۷٪ رسیده است. همان‌طور که در نتایج مشاهده می‌شود در افرادی که به‌علت داده آموزشی کم، تخمین ماتریس کواریانس آنها ضعیف شده و این ضعف باعث تولید فیلترهای مکانی که قابلیت تفکیک بالایی ندارند می‌شود، الگوریتم‌های بهبودیافته CSP توانسته است با بهبود تخمین ماتریس کواریانس، فیلترهای مکانی قوی‌تری نسبت به CSP استاندارد تولید کند این فیلترها باعث تشکیل ماتریس واژه‌نامه قوی برای طبقه‌بندی کننده SRC و درنهایت افزایش دقت طبقه‌بندی شده است. در طبقه‌بندی کننده SRC بعد از طراحی ماتریس واژه‌نامه قوی، باید تنک‌ترین نمایش ممکن برای داده ورودی از روی این ماتریس محاسبه شود. برای این منظور از الگوریتم BP که از معروف‌ترین الگوریتم‌های یافتن پاسخ تک می‌باشد، استفاده کردیم. ایراد اساسی این

Lal, T. N., M., Schröder, T., Hinterberger, J., Weston, M., Bogdan, N., Birbaumer, and , SchölkopfB. 2004. "Support vector channel selection in BCI." IEEE Trans. on Biomed. Eng., Vol. 51 1003-1010.

Ledoit, O., and M., wolf. 2004. "A well-conditioned estimator for large dimensional covariance matrices." J. Multivariate Anal., vol. 88, no. 2 365–411.

Li, Y., S. I., Amari, A., Cichocki, D. W., Ho, and S., Xie. 2006. "Underdetermined blind source separation based on sparse representation." IEEE Trans. on Signal Processing, vol. 54 423-437.

Lotte, F., and C., Guan. 2011. "Regularizing Common Spatial Patterns to Improve BCI Designs: Unified Theory and New Algorithms." IEEE trans. on biomed. Eng., vol.58, no. 2 355-362.

Lu, H., K., Plataniotis, and A., Venetsanopoulos. 2009. "Regularized common spatial patterns with generic learning for EEG signal classification." EMBC. 6599 – 6602.

Mallat, S. G., and Z., Zhifeng. 1993. "Matching pursuits with time-frequency dictionaries." IEEE Trans. on Signal Processing, vol. 41 3397-3415.

Mohimani, H, M., Babaie-Zadeh, and C., Jutten. 2009. "A Fast Approach for Overcomplete Sparse Decomposition Basedon Smoothed L0 Norm." IEEE Transactions on Signal Processing, vol. 57 289-301.

Müller-Gerking, J., G., Pfurtscheller, and H., Flyvbjerg. 1999. "Designing optimal spatial filters for single-trial EEG classification in a movement task." Clinical Neurophysiology, Vol. 110 787-798.

Niazadeh, R., S. H., Ghalehgheh, M., Babai-Zadeh, and C., Jutten. 2012. "ISI Sparse Channel Estimation Based on SL0 and its Application in ML Sequence-by-Sequence Equalization." Latent Variable Analysis and Signal Separation 1-15.

Pati, Y. C., R., Rezaifar, and P. S., Krishnaprasad. 1993. "Orthogonal matching pursuit:recursive function approximation with applications to wavelet decomposition." rec. 27 Asilomar cnf. Signals, syst. Comput. 41-44.

Sezer, O. G., O., Harmancı, and O. G., Guleryuz. 2008. "Sparse orthonormal transforms for image compression." 15th IEEE Inter. Conf. in Image Processing, ICIP. 149-152.

Shin, Y., S., Lee, S., Woo, and H. N., Lee. 2013. "Performance increase by using a EEG sparse representation based classification method." IEEE Inter. Conf. on Consumer Electronics (ICCE). 201-203.

SRC کارایی بالاتری نسبت به LDA دارد. این نتیجه با گزارش شین (شین و همکاران، ۲۰۱۳) مبنی بر عملکرد بهتر SRC نسبت به LDA بروی ویژگی‌های مستخرج از استاندارد، همخوانی دارد. CSP

(جدول - ۷): میانگین صحت طبقه‌بندی کننده‌های SRC و LDA

الگوریتمها	LDA	SRC BP	SRC OMP	SRC SL0
CSP	۶۶/۲۹	۷۶/۱۹	۷۶/۲	۷۵/۵۴
GLRCSP	۷۸/۵۵	۸۲/۳۶	۷۹/۶۶	۸۳/۰۶
DLRCSPcvdiff	۷۵/۴۷	۸۱/۰۴	۸۱/۱۸	۸۳/۳۲
DLRCSPcv	۷۳/۴۴	۷۸/۹۹	۷۸/۷	۷۸/۸۳
DLRCSPauto	۶۶/۳۵	۷۸/۱۸	۷۶/۸۸	۷۹/۸۳

۸- مراجع

Ang, K. K., Z. Y., Chin, C., Wang, C., Guan, and H., Zhang. 2012. "Filter bank common spatial pattern algorithm on bci competition iv datasets 2a and 2b." Frontiers in Neuroscience, vol. 6, no. 39.

n.d.bbcde.
http://www.bbci.de/competition/iii/desc_IVa.htm.

Brunner, C., M., Naeem, R., Leeb, B., Graimann, and G., Pfurtscheller. 2007. "Spatial filtering and selection of optimized components in four class motor imagery EEG data using independent components analysis." pattern Recognition Letters, Vol. 28 957-964.

Chen, S. S., D. L., Donoho, and M. A., Saunders. 1998. "Atomic decomposition by basis pursuit." SIAM journal on scientific computing, vol. 20 33-61.

Christian, S. O., P. S., Pedersen, T., Arildsen, and T., Larsen. 2013. "Improving Smoothed l0 Norm in Compressive Sensing Using Adaptive Parameter Selection." International Conference on Acoustics, Speech, and Signal Processing IEEE ICASSP 2013.

Ebrahimi, T., J. F., Vesin, and G., Garcia. 2003. "Brain computer interface in multimedia." IEEE Signal Process. Mag vol. 20, no. 1 14–24.

Gribonval, R., and M., Nielsen. 2003. "Sparse representations in unions of bases." IEEE Trans. on Inf. Theo., vol. 49 3320-3325.

Kann, V., and E., Amaldi. 1998. "On the approximability of minimizing nonzero variables or unsatisfied relations in linear systems." Theoretical Computer Science, vol. 209 237-260.





محمد تقی صادقی تحصیلات خود را در مقاطع کارشناسی برق-الکترونیک و کارشناسی ارشد برق-مخابرات به ترتیب در سال‌های ۱۳۷۰ و ۱۳۷۳ در دانشگاه‌های صنعتی شریف و تربیت مدرس تهران به پایان رسانید. نامبرده از سال ۱۳۷۴ الی ۱۳۸۷ در دانشکده مهندسی برق دانشگاه یزد مشغول به کار بود. پس از آن دوره دکتری مهندسی برق-مخابرات را در دانشگاه ساری انگلستان آغاز نموده و در سال ۱۳۸۱ موفق به اخذ درجه دکتری از آن دانشگاه شد. سپس به مدت دو سال در مرکز تحقیقات بینائی ماشین و پردازش سیگنال همان دانشگاه، در زمینه سیستم‌های بازناسی چهره پژوهش نموده و از آن پس تاکنون استادیار دانشکده مهندسی برق و کامپیوتر دانشگاه یزد است. زمینه‌های تحقیقاتی مورد علاقه نامبرده عبارتند از: بازناسی آماری الگو، پردازش تصویر و بینائی ماشین.

نشانی رایانمۀ ایشان عبارت است از:

m.sadeghi@yazd.ac.ir

Wolpaw, J. R., N., Birbaumer, D. J., McFarland, G., Pfurtscheller, and T. M., Vaughan. 2002. "Brain-computer interfaces for communication and control." Clinical Neurophysiology, Vol. 113 767-791.

Wright, J., A., Yang, Sastry S., and Y., Ma. 2009. "Robust face recognition via sparse representation." IEEE Trans. on Pattern Analysis and Machine Intelligence, vol. 31, no. 2 210-227.



علیرضا میرجلیلی دوره کارشناسی خود را در سال ۱۳۸۷ در رشته مهندسی برق-الکترونیک در دانشگاه آزاد واحد یزد گذرانده و مدرک کارشناسی ارشد خود را در سال ۱۳۹۲ در رشته مهندسی برق-مخابرات گرایش سیستم از دانشگاه یزد اخذ نموده است. موضوع پایان‌نامه کارشناسی ارشد ایشان بهبود کارایی سیستم‌های BCI با استفاده از تکنیک‌های شناسایی الگو مبتنی بر نمایش تک بوده است. زمینه‌های علمی مورد علاقه وی پردازش سیگنال‌های مغزی و بازناسی آماری الگو می‌باشد.

نشانی رایانمۀ ایشان عبارت است از:
alireza.mirjalili@stu.yazd.ac.ir



وحید ابوطالبی مدرک کارشناسی خود را در رشته مهندسی برق-الکترونیک در سال ۱۳۷۵ از دانشگاه صنعتی شریف و مدرک کارشناسی ارشد در رشته مهندسی برق-

مهندسی پزشکی را در سال ۱۳۷۸ از همان دانشگاه اخذ نمود. وی در سال ۱۳۸۵ دکترای خود را در رشته مهندسی پزشکی-بیوالکتریک از دانشگاه صنعتی امیرکبیر دریافت نمود و هم‌اکنون عضو هیات علمی دانشکده مهندسی برق و کامپیوتر دانشگاه یزد می‌باشد. زمینه‌های تحقیقاتی مورد علاقه وی پردازش سیگنال‌های حیاتی، تجزیه و تحلیل سیگنال‌های مغزی و بررسی فعالیت‌های شناختی می‌باشد.

نشانی رایانمۀ ایشان عبارت است از:
abootalebi@yazd.ac.ir