

ارزیابی و مقایسه روش‌های الگوهای مکانی مشترک و قطعه‌بندی هوشمند در آشکارسازی

مؤلفه P300

زهرا امینی^۱، وحید ابوطالبی^۲ و محمد تقی صادقی^۳

۱- کارشناس ارشد، دانشکده مهندسی برق و کامپیوتر- دانشگاه یزد- یزد- ایران

zamini@stu.yazduni.ac.ir

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

abootalebi@yazduni.ac.ir

۳- استادیار، دانشکده مهندسی برق و کامپیوتر- دانشگاه یزد- یزد- ایران

m.sadeghi@yazduni.ac.ir

چکیده: هدف از این مقاله ارزیابی دو روش قطعه‌بندی هوشمند و الگوهای مکانی مشترک به عنوان دو راهکار استخراج ویژگی در سیستم‌های آشکارسازی مؤلفه P300 است. بدین منظور، یک سیستم مبتنی بر بازشناسی آماری الگو طراحی شد. در این سیستم که با دادگان P300-Speller مسابقات BCI 2005 کار می‌کند، پس از اعمال پیش‌پردازش‌های اولیه، دو دسته ویژگی قطعه‌بندی هوشمند و الگوهای مکانی مشترک از دادگان استخراج گردید. این ویژگی‌ها از دو دیدگاه تک‌ (با آزمون t-test) و گروهی (با استفاده از درصد صحت طبقه‌بندی‌کننده LDA و انتخاب ویژگی به روش تحلیل تفکیکی گام به گام و محاسبه درصد صحت با طبقه‌بندی‌کننده SWLDA) سنجش شدند که در نهایت، دسته ویژگی قطعه‌بندی هوشمند با کسب بالاترین درصد صحت (۹۵/۲۵٪) به عنوان روش برتر انتخاب شد.

واژه‌های کلیدی: استخراج ویژگی، الگوهای مکانی مشترک، طبقه‌بندی‌کننده، قطعه‌بندی هوشمند، مؤلفه P300.

۱- مقدمه

میانگین گرفت تا قسمت نوبز تصادفی EEG تضعیف شود و بتوان در میان آن سیگنال ERP را مشاهده نمود [۱]. تقریباً تمامی مطالعات انجام شده در مورد ERPها، P300 را برجسته‌ترین مؤلفه در بین مؤلفه‌های شناختی مختلف موجود در سیگنال‌های مغزی می‌دانند. P300 نوع خاصی از ERP و یا به تعبیر دیگر، مؤلفه‌ای از ERP است که در موقعیت خاصی ظاهر می‌شود. طبق تحقیقات انجام شده، هنگامی که مغز هنگام پردازش یک سری از تحریکات معمول، به یک تحریک غیرمعمول (تحریک هدف) برمی‌خورد، در سیگنال مغزی ثبت‌شده، یک موج P300 ظاهر می‌شود.

از لحاظ فیزیکی، P300 دارای قطبیت مثبت و دامنه حدود ۱۰ تا ۱۵ میکروولت (در افراد جوان) است. برای تحریک‌های صوتی، میزان تأخیر موج P300 به طور متوسط

Danielovsky در سال ۱۸۷۷ و Marcow در سال ۱۸۸۳ از نوعی سیگنال EEG خبر دادند که در موقعیت تحریک شخص و یا وقوع یک رخداد ظهور می‌کند و به همین علت، این پتانسیل‌ها، وابسته به رخداد یا به اختصار ERP^۱ نام گرفتند. دامنه این سیگنال به قدری ضعیف است (از مرتبه ۰/۱ دامنه سیگنال^۲ EEG معمولی) که برای مشاهده آن نیاز است تعداد زیادی از آنها را با یکدیگر

^۱ تاریخ ارسال مقاله : ۱۳۹۰/۳/۱۲

تاریخ پذیرش مقاله : ۱۳۹۰/۱۱/۱۶

نام نویسنده مسؤول : زهرا امینی

نشانی نویسنده مسؤول : ایران - اصفهان - خیابان هزار جریب

کوی امام جعفر صادق - بوستان ۴ شرقی - پلاک ۱۱ -

کد پستی ۸۱۷۴۶۶۳۷۷

است که حالت ذهنی شخص را به صورت مستقیم به سیگنال‌های کنترل و ارتباطی تبدیل می‌کند.

کاربردهای BCI تاکنون به دو دسته کلی توانبخشی برای افراد معلول حرکتی و سرگرمی برای افراد سالم تقسیم شده است. BCI برای افراد معلول به منظور کنترل اندام مصنوعی، کنترل صندلی چرخدار، کنترل نشانگر یک یا دو بعدی در صفحه رایانه و کنترل صفحه کلید مجازی به کار رفته است، اما کاربرد آن برای افراد سالم هم اینک به بازی‌های سه بعدی در محیط‌های مجازی و در آزمایشگاه‌ها محدود می‌شود.

در کارهای online و شبیه‌سازی‌های offline، الگوریتم‌های متفاوت و متنوعی (مثل: آنالیز مؤلفه‌های مستقل (ICA) [۶]، تبدیل موجک [۷]، آستانه‌گذاری و بازشناسی آماری الگو [۸]) شامل روش‌های مختلف استخراج ویژگی و طبقه‌بندی)) برای تشخیص سیگنال‌های حاوی P300 به کار گرفته شده است. براساس این تحلیل‌ها، سیستم‌های BCI مبتنی بر P300، امروزه نرخ ارتباطی برابر با یک کلمه (یعنی پنج حرف) در هر دقیقه را دارند و در آینده پیشرفت‌های قابل ملاحظه‌ای در سرعت آنها، ممکن خواهد بود.

همچنین از سال ۲۰۰۰ مسابقاتی با عنوان BCI Competition به صورت دو سالانه برگزار می‌شود که یکی از بخش‌های این مسابقه یک سیستم P300-speller است که در آن از مؤلفه P300 برای برقراری ارتباط بین مغز و رایانه، از طریق انتخاب حروف از روی یک صفحه کلید ۶×۶ استفاده می‌شود [۹]. از زمان برگزاری این مسابقات تاکنون، بسیاری از افراد و گروه‌های پراکنده که قصد کارکردن روی مسأله آشکارسازی P300 را داشته‌اند از این دادگان استفاده کرده‌اند. از جمله افرادی که با استفاده از این داگان به نتایج خوبی رسیده‌اند، می‌توان به موارد زیر اشاره کرد:

Neng Xu در مسابقه BCI2003 از آنالیز مؤلفه‌های مستقل (ICA) برای آشکارسازی P300 استفاده کرد تا هم منابع مستقل سیگنال را از هم جدا کند و هم قطعات زمانی مشکوک را از میان بردارد. وی با استفاده از دو ویژگی پیک (قله) سیگنال و همچنین، متوسط سیگنال در بازه زمانی ۲۷۵

حدود 300ms است که علت انتخاب نام P300 نیز به علت قطبیت مثبت و تأخیر 300ms آن بوده است. ولی برای تحریکات دیگر، مثلاً تحریک تصویری، این زمان ممکن است تا حدود 1000ms هم افزایش یابد؛ اگرچه در هر حال، این موج به عنوان P300 نامیده می‌شود. در کل، در تعریف P300، تأخیری بین ۳۰۰ تا ۱۰۰۰ میلی‌ثانیه برای آن ذکر می‌شود.

با توجه به ارتباط تنگاتنگی که بین بروز مؤلفه P300 و فعالیت شناختی مغز وجود دارد، از این مؤلفه در تحقیقاتی که به نحوی با جنبه شناختی فعالیت مغز سر و کار دارند، از جمله در کارهای کلینیکی برای تشخیص بیماری‌هایی مانند آلزایمر، اعتیاد به الکل، اوتیسم، اسکیزوفرنی و MS و تشخیص میزان خستگی سوژه [۲] استفاده شده است. از کاربردهای دیگری که برای P300 مطرح شده، استفاده از این مؤلفه شناختی به منظور دروغ سنجی است. در این کاربرد، نحوه آزمون باید طوری طرح شود که بتواند به صورت یک الگوی Oddball عمل کند؛ یعنی سوژه از بین چند مورد سؤال (مثلاً ۵ مورد) تنها به یک مورد حساس باشد و هدف نیز تشخیص همین مورد از روی سیگنال‌های مغزی او باشد. در این زمینه نیز کارهایی، خصوصاً به وسیله Rosenfeld، Farwell و Donchin انجام شده است [۳، ۴]. در سال ۲۰۰۶ نیز ابوطالبی با ارزیابی آزمون‌های مختلف دروغ سنجی، پروتکلی بر مبنای بروز P300 در فرد خطاکار در رویارویی با تحریک مرتبط با جرم طراحی کرد. وی با ارزیابی روش‌های مختلف طبقه‌بندی، LDA^۳ را به عنوان طبقه‌بندی کننده بهینه در تفکیک این دادگان برگزید و در نهایت، درصد صحت ۸۶٪ در تفکیک افراد خطاکار و بی‌گناه حاصل شد [۵].

یکی از کاربردهای مهم سیگنال EEG و مؤلفه P300، در سیستم‌های واسط مغز با رایانه (BCI) است. هدف یک سیستم BCI برقراری ارتباطی میان مغز کاربر و رایانه برای انتقال منظور وی به دنیای خارج، بدون استفاده از خروجی‌های عصبی و ماهیچه‌ای است. یک سیستم BCI مجموعه‌ای از حسگرها و وسایلی برای ثبت و پردازش سیگنال مانند نمایشگر، تحریک کننده‌های حسی و رایانه

Fz, Cz, Pz, P3 و P4 و حداکثر ۶۰ ویژگی مدل، صحت ۹۲/۵٪ به دست آمده است [۱۲].

Salvaris و همکارانش [۱۳] در سال ۲۰۰۹ طی تحقیقی روی دادگان P300 مسابقات BCI 2005، از تبدیل موجک گسسته برای استخراج ویژگی‌های سیگنال مغزی استفاده کردند. آنها با قطعه‌بندی دادگان ورودی طبقه‌بندی کننده، برای هر قطعه از یک FLD^9 استفاده کردند. سپس نمره هر طبقه‌بندی کننده حساب شده و این نمره‌ها جمع شده است تا بهترین رتبه برای قطعه به دست آید (Ensemble of FLDS). این گروه توانست با این روش به صحت میانگین ۹۵٪ دست یابد.

در این مقاله، هدف آن است تا توسط یک سیستم مبتنی بر بازشناسی آماری الگو به آشکارسازی مؤلفه P300 پرداخته شود و ضمن آن کارایی دو روش نسبتاً جدید استخراج ویژگی، شامل قطعه‌بندی و الگوهای مکانی مشترک 10 (CSP) نیز ارزیابی و با یکدیگر مقایسه گردد. همچنین، اثر ترکیب دو روش فوق در افزایش یا کاهش میزان صحت سیستم بررسی خواهد شد. بدین منظور، پس از معرفی دادگان مورد استفاده و پیش‌پردازش‌های صورت گرفته بر روی آن، هر یک از این روش‌های استخراج ویژگی، شرح داده خواهند شد و در ادامه با به‌کارگیری دو دیدگاه تکی و گروهی این ویژگی‌ها ارزیابی و دسته‌بندی ویژگی کاراتر در آشکارسازی مؤلفه P300 مشخص خواهد شد. نهایتاً نتایج حاصل در قسمت آخر بیان می‌گردد.

۲- دادگان مورد استفاده

بسیاری از گروه‌های تحقیقاتی که بر روی مسأله آشکارسازی مؤلفه P300 کار می‌کنند، از دادگانی استفاده می‌کنند که برای مسابقات BCI فراهم شده است [۹]. در این مقاله نیز سیگنال‌هایی استفاده می‌شوند که به وسیله گروه وادثورث و در چهارچوب BCI2000 تهیه شده‌اند و از راه سایت اینترنتی مسابقه BCI2005 در اختیار قرار گرفته‌اند. در این آزمایش یک جدول با ابعاد ۶×۶ حاوی ۳۶ کاراکتر (مطابق شکل ۱) در مقابل فرد وجود دارد. یک کلمه (به

تا ۳۷۰ میلی‌ثانیه به میزان صحت ۱۰۰٪ در تشخیص کاراکتر رسید [۶].

Kaper در مسابقه BCI2003 با استفاده از ماشین بردار پشتیبان^۷ (SVM) با هسته گوسی توانست به صحت ۱۰۰٪ در تشخیص کاراکتر برسد. وی سیگنال ۱۰ کاناله از زمان اعمال تحریک تا ۶۰۰ میلی‌ثانیه بعد را به عنوان ویژگی به کار برد [۸].

Hoffmann نیز در تحقیقی در سال ۲۰۰۵ روش Boosting را برای آشکارسازی P300 در دادگان مسابقه BCI2003 بررسی کرد. وی با متوسط‌گیری روی چهار بار تکرار تحریک ماتریس P300-speller، در تشخیص کاراکتر به میزان صحت ۱۰۰٪ دست یافت [۱۰].

Yang Liu در مقاله‌ای در سال ۲۰۰۵ دیدگاه T-Weighted برای پردازش اطلاعات عصبی در P300 وابسته به BCI را بررسی کرده که در آن از دو سری دادگان BCI2003-IIb و BCI2005-II استفاده شده است. او توانست با استفاده از آنالیز مؤلفه‌های اصلی^۸ (PCA) و استخراج ویژگی با روش T-weighted، روی دادگان سال ۲۰۰۳ به صحت ۱۰۰٪ و روی دادگان سال ۲۰۰۵ به صحت ۹۰٪ در تشخیص کاراکتر برسد [۱۱].

در تحقیقی دیگر در سال ۲۰۰۷، Sellers, Krusinski به بررسی اثر گسترش فضای ویژگی P300 روی عملکرد طبقه‌بندی‌کننده پرداختند و دادگان خود را از طریق ماتریس استاندارد P300 speller و رعایت قوانین سیستم BCI 2000 و با آزمایش روی ۷ فرد سالم به دست آوردند. برای رسیدن به هدف فوق‌الذکر، در انتخاب ویژگی سعی شد تا علاوه بر ویژگی‌های به‌دست آمده از کانال‌های قسمت مرکزی مغز، از قسمت پسین هم کانال‌هایی برای به دست آوردن اطلاعات جدید اضافه شود. همچنین اثر انتخاب کانال ثبت EEG، مرجع کانال‌ها، بُعد داده‌ها و حداکثر تعداد ویژگی‌های یک مدل هم مورد بحث قرار گرفت و نتیجه نهایی که ذکر شده، آن است که با روش SWLDA و با استفاده از الکتروود مرجع گوش، کانال‌های O7, PO7, PO8

بخش به شرح قسمت‌های مختلف این سیستم آشکارساز پرداخته می‌شود. قابل ذکر است که در این تحقیق، کلیه پردازش‌های مربوط به پیش پردازش، استخراج ویژگی و طبقه بندی سیگنال‌ها در نرم افزار MATLAB R2009a و روال انتخاب ویژگی با استفاده از نرم افزار SPSS انجام شده است.

۳-۱- پیش پردازش

قبل از مرحله استخراج ویژگی، لازم است تا یکسری پردازش‌های اولیه روی سیگنال‌ها اعمال شود تا برای مراحل بعدی آماده شوند. بدین منظور ابتدا یک فیلتر میان‌گذر ۰/۵ تا ۳۵ هرتز به سیگنال اعمال شد، زیرا عمده مولفه‌های انرژی P300 در فرکانس‌های پایین است. پس از فیلتر کردن، نوبت به نرمالیزه کردن دادگان می‌رسد. با توجه به یکسان نبودن شرایط ثبت در کانال‌های مختلف و تفاوت کیفیت و قدرت سیگنال ثبت شده در بعضی کانال‌ها، سیگنال فیلتر شده در هر کانال، به بازه [۱، -۱] نرمالیزه شد. به منظور سهولت در انجام کار و جلوگیری از بروز اشتباه، سیگنال‌ها به قطعاتی که از زمان روشن شدن یک سطر یا یک ستون آغاز می‌شوند و به مدت یک ثانیه (معادل ۲۴۰ نمونه) ادامه دارند، تقسیم می‌شوند.

همچنین همان‌طور که گفته شد ثبت دادگان طبق سیستم ۱۰-۲۰ و به صورت ۶۴ کاناله صورت گرفته است، اما از آنجا که این تعداد کانال بسیار زیاد است و حجم و پیچیدگی محاسبات را زیاد می‌کند؛ لازم است که در ابتدای کار کانال‌های مناسب را انتخاب کرد. با بررسی قدرت موج P300 به دست آمده از متوسط سیگنال‌ها، این نکته مشخص می‌گردد که بیشترین فعالیت P300 در مرکز سر صورت می‌گیرد و تقریباً در هر دو سمت چپ و راست متقارن است [۱۴]. با توجه به این مسئله و با استفاده از کانال‌های مناسب مشترک برای هر دو سوژه A و B، که توسط نفر دوم مسابقات BCI معرفی شده بود، در این مقاله در مرحله استخراج ویژگی‌های قطعه‌بندی هوشمند از هفت کانال Pz, C4, Cz, C3, Fz, Po8, Po7 استفاده شد [۱۵]، اما در روش الگوهای مکانی مشترک (با توجه به خاصیت

تفکیک کاراکترهایش) به عنوان مورد هدف توسط آزمایشگر تعیین شده است که در بالای جدول نمایش داده می‌شود.



شکل (۱): ماتریس تحریک برای ثبت دادگان [۹]

در ابتدای ظاهر شدن جدول، تمام حروف به رنگ خاکستری در یک پس زمینه سیاه نمایان می‌شوند. سپس به طور تصادفی یک سطر یا ستون روشن شده و به رنگ سفید در می‌آید. این سطر یا ستون به مدت ۱۰۰ میلی ثانیه در وضعیت روشن باقی می‌ماند و سپس ۷۵ میلی ثانیه تمام سطر و ستون‌ها خاموش می‌مانند تا آنکه سطر یا ستون بعدی به طور تصادفی روشن شود، به نحوی که قبل از روشن شدن سطر یا ستون تکراری تمام سطرها و ستون‌ها یک بار روشن شده باشند. بدین ترتیب برای یک دور کامل از آزمایش، ۱۲ تحریک اتفاق می‌افتد که فقط دو مورد حاوی کاراکتر هدف و در نتیجه مولفه P300 هستند. این آزمایشات برای هر کاراکتر ۱۵ مرتبه تکرار شده است، لذا برای هر کاراکتر ۳۰ سیگنال حاوی P300 و ۱۵۰ سیگنال فاقد آن موجود می‌باشد. این سیگنال‌ها از یک فیلتر میان‌گذر ۰/۱ تا ۶۰ هرتز عبور داده شده و با نرخ ۲۴۰ هرتز نمونه برداری شده‌اند. همچنین از استاندارد ۱۰-۲۰، ۶۴ کاناله برای الکتروگذاری در ثبت EEG استفاده شده است.

۳- روش کار

همان‌طور که اشاره شد، سیستم مورد استفاده در این مقاله برای آشکارسازی مؤلفه P300، مبتنی بر روش بازشناسی آماری الگو است. این سیستم‌ها عموماً از دو بلوک اصلی استخراج ویژگی و طبقه‌بندی تشکیل شده‌اند که می‌تواند بلوک‌های جانبی دیگری همچون پیش پردازش یا انتخاب ویژگی نیز به آن اضافه گردد. با این مقدمه، در این

اختلاف بین دو کلاس را واضح تر کند و درجه تفکیک بین دو کلاس را بالا ببرد. برای پیاده سازی این روش قطعه بندی، الگوریتم جایگزینی تکراری محلی^{۱۲} (LIR) به کار گرفته شد.

در این الگوریتم، پس از یک قطعه بندی اولیه، مکان جدید یک نقطه شکست به صورت بهینه بین دو نقطه شکست همسایه اش انتخاب می شود و به این ترتیب، نقاط شکست به تدریج به سمت محل بهتر حرکت می کنند تا به نقطه بهینه محلی برسند [۱۸]. مراحل اجرای این الگوریتم را می توان در چهار گام زیر خلاصه کرد:

- ۱- انتخاب اولیه نقاط شکست به صورت سلسله مراتبی (با استفاده از نمونه برداری یکنواخت یا به صورت تصادفی یا با استفاده از روش هایی مثل روش از بالا به پایین).
- ۲- انتخاب نقطه شکست $(1 \leq i \leq k - 1)$ به c_i به صورت تصادفی یا ترتیبی و حذف این نقطه و اتصال دو قطعه متوالی که در c_i به یکدیگر می رسیدند:

$$s(c_{i-1} + 1, c_{i+1})$$

- ۳- یافتن یک مکان بهینه (بر اساس معیار بهینگی مورد نظر) برای نقطه شکست جدید (c'_i) قطعه مرکب ساخته شده در گام دوم و جایگزین کردن c'_i به جای c_i .
 - ۴- تکرار گام های ۲ و ۳ تا رسیدن به معیار توقف.
- در اینجا ذکر دو نکته لازم است؛ اول آنکه می توان نشان داد که این الگوریتم در حلقه تکرار گیر نمی کند و پس از چند بار اجرا متوقف می شود [۱۸]. اما از طرفی تضمینی نیست که نهایتاً به حل بهینه منجر شود، زیرا این روش نقطه بهینه محلی را انتخاب می کند، نه نقطه بهینه مطلق را.

نکته دیگر آنکه در هر مرحله لازم نیست تمامی نقاط شکست بررسی شوند و اگر سه قطعه مجاور

$$s\left(\begin{matrix} c_{i-2} + \\ 1, c_{i-1} \end{matrix}\right), s(c_{i-1} + 1, c_i), s(c_i + 1, c_{i+1})$$

در یک مرحله تغییری نکردند، دیگر لازم نیست که نقاط c_i و c_{i-1} در مرحله بعد بررسی شوند. با توجه به این مسئله، تعداد بررسی های لازم در هر مرحله نهایتاً سه برابر تعداد نقاط شکست تغییر یافته در مرحله قبل است. زمان کلی محاسبات نیز به نحوه تنظیمات اولیه و نوع دادگان مورد بررسی وابسته است.

این روش که در ادامه توضیح داده خواهد شد، کل ۶۴ کانال به کار گرفته شد.

آخرین مرحله پیش پردازش، میانگین گیری است. در بسیاری از تحقیقات، پیشنهاد می شود سیگنال های دارای کد تحریک یکسان در هر حرف با یکدیگر متوسط گیری شوند [۱۴]. این امر سبب می شود الگوی P300 که در تمام ثبت ها دارای شکل یکسانی است، با همان قدرت باقی بماند و با توجه به مستقل بودن نویزها در ثبت های مختلف از یکدیگر قدرت نویز کاهش یابد.

۳-۲- استخراج ویژگی

پس از اعمال پیش پردازش، نوبت به استخراج ویژگی می رسد. در اینجا از دو روش قطعه بندی هوشمند و الگوهای مکانی مشترک استفاده شده است که در ادامه هر کدام از این روش ها شرح داده می شوند.

قطعه بندی هوشمند

در سال های اخیر مسأله قطعه بندی سری های زمانی به صورت گسترده و با روش های مختلفی مطالعه شده و تقریب سیگنال ها با استفاده از قطعات خطی هم از این دست است. هدف این مسائل، غالباً فشرده سازی دادگان، استخراج ویژگی یا فیلتر کردن و حذف نویز است. در کاربردهای مختلفی نظیر گرافیک های رایانه ای، نقشه کشی و بازشناسی الگو از این تکنیک کاهش حجم به منظور ساده سازی یا برای تحلیل کانتورها و خطوط مرزی استفاده می شود [۱۷، ۱۶].

در اینجا روشی برای قطعه بندی سیگنال ارائه می شود که در آن یک سیگنال به طول N ، با k قطعه خط مستقیم تقریب زده می شود و از آنجا که عموماً k بسیار کوچکتر از N است، این قطعه بندی در کاهش حجم محاسبات و حافظه لازم برای آن بسیار مؤثر است. این پروسه می تواند به عنوان یک مرحله استخراج ویژگی در سیستم بازشناسی الگو استفاده شود.

در این مقاله از یک روش قطعه بندی هوشمند استفاده شده است. ایده اولیه این طرح آن است که فرض شده یک کاهش نرخ نمونه برداری مؤثر بر روی دادگان می تواند

شکل (۲): کاهش نرخ نمونه برداری وقتی و تولید بردار ویژگی [۲۱]

ایده اصلی آن است که این بازه‌ها با تعلیم گرفتن از دادگان آموزش به گونه‌ای تعیین شوند که درجه تفکیک بین دو کلاس بیشینه شود. برای جدا کردن کلاس‌ها به معیاری از شباهت یا عدم شباهت نیاز است و در اینجا از معیار جداپذیری فیشر^{۱۵} (FDC) استفاده شده است [۲۲]. از این معیار در تحلیل تفکیکی فیشر (FDA)^{۱۶} که یک روش تحلیل تفکیکی خطی است هم استفاده می‌شود. FDA یک روش کاهش بعد آموزش پذیر است که در آن نگاشتی خطی اعمال می‌شود که درجه تفکیک بین کلاس‌ها را بر اساس دادگان آموزش بیشینه می‌کند. در FDA بردار نگاشتی ساخته می‌شود که نسبت مربع تفاضل میانگین بین کلاس‌ها به مجموع واریانس بین کلاس‌ها را بیشینه می‌کند. برای رسیدن به این بردار ابتدا بردارهای میانگین را تعریف می‌کنیم:

$$m_0 = \frac{1}{N_0} \sum_{i:y_i=0} x_i, m_1 = \frac{1}{N_1} \sum_{i:y_i=1} x_i \quad (1)$$

که در آن N_0 و N_1 بیانگر تعداد دادگان آموزش برای دو کلاس و $y_i \in \{0,1\}$ بیانگر برچسب هر کلاس است. سپس دو نوع واریانس با نام‌های کوواریانس درون کلاسی^{۱۷} (W) و کوواریانس بین کلاسی (B)^{۱۸} تعریف می‌شود:

$$W = \sum_{i=0}^1 \sum_{i:y_i=i} (x_i - m_i)(x_i - m_i)^T \quad (2)$$

$$B = (m_0 - m_1)(m_0 - m_1)^T$$

حال بردار نگاشت FDA توسط برداری که مقدار $J(a)$

را در رابطه زیر بیشینه کند، داده می‌شود:

$$J(a) = \frac{a^T B a}{a^T W a} \quad (3)$$

$J(a)$ در رابطه فوق همان معیار جداپذیری فیشر

(FDC) است. همان‌طور که پیش از این ذکر شد، هدف

بیشینه کردن این معیار و در نتیجه بیشینه کردن تفکیک

پذیری بین دو کلاس است. به همین منظور، با مشتق‌گیری

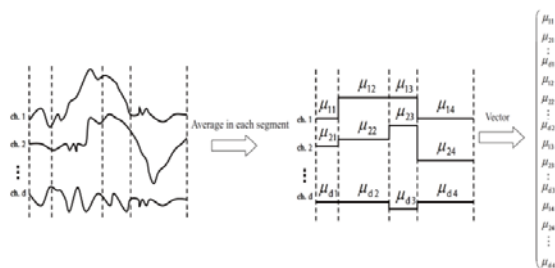
از رابطه فوق بر حسب a و پس از ساده‌سازی خواهیم

داشت:

یک معیار توقف طبیعی برای این الگوریتم آن است که زمانی الگوریتم متوقف شود که با هرگونه حرکت مجاز نقاط شکست، هزینه کلی قطعه‌بندی کمتر از میزان فعلی آن نشود. طبق این معیار LIR پس از تعداد محدودی اجرا متوقف می‌شود، زیرا در هر مرحله هزینه کم می‌شود و تعداد نقاط در دنباله هم محدود است. یک معیار ساده دیگر هم برای توقف الگوریتم می‌تواند محدود کردن تعداد تکرارهای الگوریتم باشد. الگوریتم‌های تکراری تصادفی می‌توانند تعداد دفعات کمی اجرا شوند تا احتمال گرفتار شدنشان در مینیمم محلی ضعیف شود.

برای آشکارسازی مؤلفه P300 از طریق بازشناسی آماری الگو، به تعریف یک بردار ویژگی نیاز داریم. یکی از راه‌های رایج برای ساخت این بردار، متوالی کردن دادگان سیگنال EEG ثبت شده از کانال‌های مختلف است، ولی ساخت بردار ویژگی با تمامی نمونه‌های همه این کانال‌ها می‌تواند به ایجاد یک بردار ویژگی با بعد بسیار بالا منجر شود و با توجه به تعداد محدود دادگان، این امر ممکن است سیستم را به نفرین ابعاد^{۱۳} دچار سازد. برای اجتناب از این مشکل بسیاری از محققان از کاهش نرخ نمونه برداری برای کم کردن بعد بردار ویژگی استفاده کرده‌اند که در اغلب تحقیقات از یکی از دو روش حذف نمونه‌های بینابینی^{۱۴} یا نمونه برداری یکنواخت استفاده شده است (در روش اول از هر k نمونه یکی انتخاب و بقیه حذف می‌شوند و در روش دوم از متوسط این k نمونه استفاده می‌شود) [۲۰، ۱۹، ۱۰].

ولی در اینجا از یک روش کاهش نرخ نمونه برداری وقتی آموزش پذیر استفاده شده و به این طریق صحت سیستم در تشخیص مؤلفه P300 افزایش یافته است. در این روش از قطعه‌بندی غیریکنواخت بازه‌ها که در شکل (۲) دیده می‌شود، استفاده شده است و از متوسط هر قطعه به عنوان نماینده آن قطعه در بردار ویژگی استفاده می‌شود [۲۱].



$$X_i(T) = \text{Make Vector}(S_i, T) = \begin{pmatrix} \frac{1}{\tau_1 - \tau_0} \sum_{t=\tau_0+1}^{\tau_1} s_i(t) \\ \frac{1}{\tau_2 - \tau_1} \sum_{t=\tau_1+1}^{\tau_2} s_i(t) \\ \vdots \\ \frac{1}{\tau_k - \tau_{k-1}} \sum_{t=\tau_{k-1}+1}^{\tau_k} s_i(t) \end{pmatrix} \quad (8)$$

X_i به دست آمده توسط این تابع یک بردار $d \times k$ بعدی است و پس از اعمال این تابع به دادگان آموزش، مجموعه E به \tilde{E} تبدیل می‌شود: $\tilde{E}(T) = \{(X_i(T), y_i) | i = 1, \dots, N\}$ حال m_0 و m_1 و W از روی دادگان \tilde{E} محاسبه می‌شوند تا معیار جداپذیری فیشر در فضای جدید به دست آید که چون m_0 و m_1 و W محاسبه شده تابعی از T خواهند شد، معیار J هم تابعی از T می‌شود و معادله (۷) به معادله زیر تبدیل می‌شود:

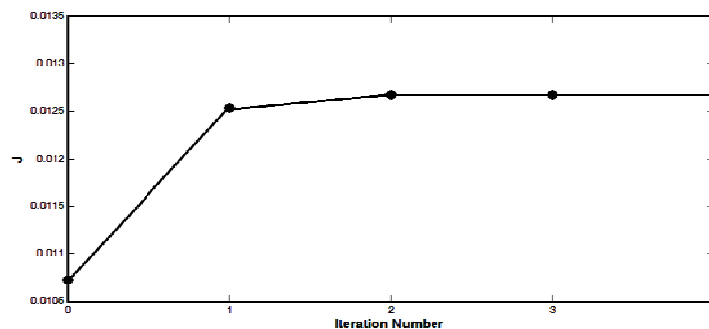
$$J(T) = (m_0(T) - m_1(T))^T W(T)^{-1} (m_0(T) - m_1(T)) \quad (9)$$

نهایتاً مسأله یافتن قطعاتی که درجه تفکیک بین کلاس‌ها را بیشینه کند، به مسأله یافتن \hat{T} بهینه تقلیل می‌یابد که آن را می‌توان در رابطه زیر خلاصه کرد:

$$\hat{T} = \text{argmax}_T J(T) = \text{argmax}_{\tau_0, \tau_1, \dots, \tau_k} J(T) \quad (10)$$

subject to $\tau_j \in N, \tau_j < \tau_{j+1}, \tau_0 = 0, \tau_k = n$

با استفاده از الگوریتم LIR توضیح داده شده و با توجه به آنکه هدف، بیشینه کردن میزان تفکیک بین دو کلاس است، الگوریتم زمانی متوقف می‌شود که در دو اجرای متوالی آن، مقدار معیار تفکیک پذیری (J) بیشتر نشود یا ثابت بماند. برای مثال، در شکل (۳) روند تغییرات J هنگام اجرای الگوریتم برای سوژه A رسم شده است.



شکل (۳): روند تغییرات معیار تفکیک پذیری دو کلاس (J) هنگام اجرای الگوریتم LIR برای سوژه A

$$Ba = \lambda Wa \quad \text{where: } \lambda = \frac{a^t Ba}{a^t Wa} \quad (4)$$

اگر W معکوس پذیر باشد، معادله مقادیر ویژه تعمیم یافته فوق را می‌توان به فرم معادله مقادیر ویژه استاندارد زیر نوشت:

$$W^{-1}Ba = \lambda a \quad (5)$$

و با توجه به رابطه فوق، می‌توان a را از رابطه زیر به دست آورد:

$$a \propto W^{-1}(m_0 - m_1) \quad (6)$$

با جای گذاری معادله (۶) در معادله (۳) رابطه زیر حاصل می‌شود که از آن به عنوان معیار جداپذیری فیشر استفاده می‌شود.

$$J = (m_0 - m_1)^T W^{-1} (m_0 - m_1) \quad (7)$$

با توجه به مطالب فوق، اگر $E = \{(S_i, y_i) | i = 1, \dots, N\}$ مجموعه دادگان آموزش باشد که در آن $y_i \in \{0, 1\}$ برچسب هر کلاس و S_i بیانگر دادگان EEG شامل n نمونه باشد، S_i به صورت $S_i = \{s_i(1), s_i(2), \dots, s_i(n)\}$ که $s_i(t) \in R^d$ است، تعریف می‌شود و d هم تعداد کانال‌ها را مشخص می‌کند. اگر تعداد قطعات مد نظر برای قطعه بندی k تا باشد، نقاط شکست بین این قطعات به صورت $T = (\tau_0, \tau_1, \dots, \tau_k)$ که $\tau_j \in N, \tau_j < \tau_{j+1}, \tau_0 = 0, \tau_k = n$ تعریف می‌شود. سپس تابعی با نام $\text{Make Vector}(S_i, T)$ تعریف می‌شود که به وسیله آن نرخ نمونه برداری در S_i کاهش یافته و به یک بردار تبدیل می‌شود:

بیشتر برای روش‌های بازشناسی الگو طراحی شده- در سال ۱۹۹۵ توسط Koles مطرح شد [۲۳] و نخستین بار برای تجزیه مؤلفه‌های نوروفیزیولوژیک در کاربردی کلینیکی از الکتروانسفالوگرافی استفاده شد. روش الگوهای مکانی مشترک بر اساس قطری سازی همزمان دو ماتریس متقارن حقیقی (که توسط Fukunaga ارائه شدند [۲۴]) کار می‌کند. قطری سازی همزمان اجازه تجزیه سیگنال EEG خام به دو الگوی مجزا از دو کلاس را می‌دهد که در این دو کلاس به صورت همزمان، واریانس یکی از کلاس‌ها بیشینه و واریانس دیگری کمینه شده است. در این صورت، اگر تنها از فیلترهای با قابلیت تفکیک بیشتر استفاده شود، ابعاد داده هم کاهش می‌یابد و عملکرد طبقه بندی کننده نیز بهتر می‌شود.

این روش به صورت موفقیت آمیزی در تحقیقات BCI برای استخراج و افزایش ERD/ERS و در مسائل تفکیک تصورات حرکتی^{۲۰} به کار رفته است، ولی کاربرد روش CSP در آشکارسازی ERP و P300 بسیار کم بوده و در تحقیقات کمی از آن استفاده شده است [۲۵، ۲۶، ۲۷]. یکی از روش‌های استخراج ویژگی مورد استفاده در این مقاله، روش الگوهای مکانی مشترک است که در اینجا به بیان مفهوم آن می‌پردازیم [۲۸]:

فرض کنید X_t و X_{nt} هر کدام ماتریسی $N \times T$ باشند که N تعداد کانال‌های ثبت و T تعداد نمونه‌های زمانی از هر کانال باشد و این دو ماتریس به ترتیب مربوط به دادگان هدف (حاوی مؤلفه P300) و دادگان غیرهدف (فاقد P300) هستند. روش CSP بر اساس تجزیه مؤلفه اصلی ماتریس کوواریانس R است که این ماتریس از مجموع ماتریس کوواریانس‌های دادگان هدف (\bar{R}_t) و غیر هدف (\bar{R}_{nt}) به دست می‌آید [۲۸]. تجزیه این ماتریس در رابطه (۱۱) نشان داده شده است.

$$\bar{R} = \bar{R}_t + \bar{R}_{nt} = \lambda \lambda' \quad (11)$$

در رابطه (۱۱)، A ماتریس متعامد بردارهای ویژه \bar{R} و λ ماتریس قطری مقادیر ویژه \bar{R} است. اکنون با استفاده از ماتریس سفیدکنندگی W ، ماتریس کوواریانس \bar{R} به ماتریس همانی I تبدیل می‌شود.

پس از همگرا شدن الگوریتم، بردار ویژگی حاصل می‌شود. در این بردار، تعداد ویژگی‌ها به ازای هر کانال برابر تعداد قطعات (k) است که هر ویژگی به صورت میانگین مقادیر دامنه نمونه‌ها در قطعه مربوطه تعریف می‌شود (مطابق شکل (۲)). بردار ویژگی برای هر کاراکتر از متوالی کردن ویژگی‌های کانال‌های هفتگانه پشت سر هم به دست می‌آید؛ یعنی بُعد بردار حاصل برای هر کاراکتر برابر $7k$ می‌شود.

مسئله مهم دیگر در مورد این الگوریتم، انتخاب k مناسب است، زیرا اگر k بیش از حد کوچک باشد، ممکن است تقریب حاصل از سیگنال، تقریب مناسبی نباشد و بخشی از اطلاعات مهم سیگنال از دست برود و از طرفی اگر هم k بیش از اندازه بزرگ شود، دیگر به خواسته اصلی خود که کم کردن حجم دادگان و جلوگیری از مشکل نفرین ابعاد است، نمی‌رسیم. بر این اساس، با آزمودن چند مقدار متوالی برای k و محاسبه دقت سیستم با استفاده از طبقه بندی کننده SWLDA^{۱۹} در هر آزمون، نهایتاً k مناسب برای دادگان استفاده شده در اینجا، که صحت در آن بیش از k های قبلی و بعدی بود ($k=10$)، انتخاب شد. نتایج بررسی k های مختلف در جدول (۱) آمده است.

جدول (۱): بررسی اثر تغییرات تعداد قطعات روی صحت

طبقه بندی کننده

| تعداد قطعات (k) | درصد صحت طبقه بندی |
|---------------------|--------------------|
| ۸ | ۹۲/۸٪ |
| ۹ | ۹۲/۹٪ |
| ۱۰ | ۹۴/۶٪ |
| ۱۱ | ۹۴/۵٪ |
| ۱۲ | ۹۴٪ |

الگوهای مکانی مشترک (CSP)

کارایی فیلتر کردن مکانی برای بهبود رزولوشن مکانی و نسبت سیگنال به نویز در سیگنال EEG قبلاً ثابت شده است [۲۳، ۲۴]. برخی از انواع فیلترهای مکانی مبتنی بر روش‌های EEG referencing هستند. این فیلترها به عنوان فیلترهای مکانی بالاگذری عمل می‌کنند که فعالیت محلی را تقویت و فعالیت توزیع شده را ضعیف می‌کنند. یک ایده متفاوت، فیلترهای مکانی با نام الگوهای مکانی مشترک- که

کاهش بعد هم صورت می‌گیرد و به جای استفاده از تعداد زیادی کانال، در فضایی جدید، کانال‌های جایگزین کمتری با قابلیت تفکیک بیشتر دو کلاس فراهم می‌شود. بنابراین برای استخراج ویژگی‌ها با این روش، از کلیه سیگنال‌های ثبت شده در ۶۴ کانال استفاده شد که خود سبب افزایش حجم دادگان می‌شد. برای مقابله با این مسأله، پس از اعمال یک فیلتر آنتی‌الیاسینگ، از کاهش نرخ نمونه برداری استفاده کرده، تعداد دادگان در هر قطعه یک ثانیه‌ای از ۲۴۰ نمونه به ۲۴ نمونه کاهش داده شد. پس از آن با اعمال CSP، بردارها و مقادیر ویژه هر کلاس طبق روابط (۱۷) و (۱۸) محاسبه شدند. سپس از دو بردار ویژه ابتدایی و دو بردار ویژه انتهایی ماتریس بردارهای ویژه برای ساخت ماتریس فیلترهای مکانی استفاده شد و ماتریس H با اندازه $N \times 4$ به دست آمد. برای استخراج ویژگی‌های CSP، با توجه به تحقیقات قبلی [۲۸] دو دسته ویژگی بیشتر مطرح بود: دسته اول ویژگی‌ها در واقع همان دادگان زمانی هستند که توسط فیلتر مکانی تهیه شده فیلتر شده‌اند؛ به صورتی که هر داده زمانی $N \times T$ بعدی - که N تعداد کانال‌های ثبت (۶۴ تا) و T تعداد نمونه‌های زمانی از هر کانال است به داده فیلتر شده $4 \times T$ بعدی تبدیل می‌شود، دسته دوم ویژگی‌هایی مبتنی بر واریانس هستند که بیشتر در کاربردهای تصورات حرکتی سیستم‌های BCI کاربرد دارند. این ویژگی‌ها در بحث‌های تصورات حرکتی معمولاً به صورت نسبت واریانس یک داده فیلتر شده به مجموع واریانس‌های کل دادگان فیلتر شده تعریف می‌شوند. برای ساخت این دسته ویژگی‌ها طبق رابطه زیر، برای هر داده زمانی چهار ویژگی جدید به دست می‌آید:

$$f_k = \log \left[\frac{\text{var}(H_k S)}{\sum_{i=1}^4 \text{var}(H_i S)} \right] \quad (21)$$

که در آن S یک داده زمانی $T \times N$ بعدی و H_k سطر k ام از ماتریس H در رابطه (۲۰) (متناظر با یک بردار ویژه) است. به این ترتیب، بردار ویژه حاصل از CSP هم با متوالی کردن این دو دسته ویژگی به دست می‌آید.

$$W = \lambda \frac{1}{2} A' \quad (12)$$

$$S = WRW' = I \quad (13)$$

سپس با استفاده از تبدیل سفید کردن برای هر کلاس به دست می‌آید:

$$\begin{aligned} S_t &= \overline{WR_t W'} \\ S_{nt} &= \overline{WR_{nt} W'} \end{aligned} \quad (14)$$

با استفاده از سه رابطه اخیر به دست می‌آید:

$$S_t + S_{nt} = I \quad (15)$$

با اعمال آنالیز مؤلفه‌های اصلی به روابط (۱۴) داریم:

$$S_t = A_t \lambda_t A_t' \quad S_{nt} = A_{nt} \lambda_{nt} A_{nt}' \quad (16)$$

و از (۱۵) و (۱۶) نتیجه می‌شود:

$$A_t = A_{nt} \quad (17)$$

$$\lambda_t = I - \lambda_{nt} \quad (18)$$

با توجه به روابط فوق دیده می‌شود که هر دو کلاس بردارهای ویژه یکسان دارند و ترتیب صعود و نزول مقادیر ویژه آنها برعکس یکدیگر است. به این ترتیب، یک تبدیل بهینه کننده به دست می‌آید که می‌تواند حجم محاسبات را کاهش دهد؛ زیرا با این وضعیت اولین و آخرین سطرهای ماتریس بردارهای ویژه بیشترین اهمیت در تفکیک بین دو کلاس را دارد و پس از آنها دومین سطر و سطر ماقبل آخر و به همین منوال تا آخر. اگر A_t و A_{nt} به عنوان اولین و آخرین بردارهای ویژه با بُعد $N \times 1$ تعریف شوند، فیلترهای مکانی به صورت زیر طراحی می‌شوند:

$$\begin{aligned} H_t &= A_t' W \\ H_{nt} &= A_{nt}' W \end{aligned} \quad (19)$$

و دادگان فیلتر شده به وسیله این فیلترها از رابطه (۲۰)

به دست می‌آیند؛ که در آن H ماتریس یا برداری از فیلترهای منتخب است.

$$Y = HX \quad (20)$$

همان طور که روابط فوق نشان داد، الگوهای مکانی مشترک یک روش استخراج ویژگی است که ضمن آن

۳-۳- ابزارهای ارزیابی ویژگی

پس از محاسبه ویژگی‌های مختلف، نوبت به ارزیابی ویژگی‌ها می‌رسد. ارزیابی ویژگی‌ها در هر دو حالت تکی و گروهی قابل بررسی است. بدین منظور، ابتدا با استفاده از آزمون آماری t-test تک تک ویژگی‌ها ارزیابی شدند تا مشخص شود که در هر دسته ویژگی کدام ویژگی‌ها اطلاعات بیشتر و مفیدتری از سیگنال را دارا هستند. در قدم بعدی یک بار از طبقه‌بندی‌کننده LDA برای بررسی هر دسته ویژگی استفاده شد تا مشخص شود که کدام دسته ویژگی توانایی بیشتری در تفکیک دو کلاس دارد. یک بار هم از طبقه‌بندی‌کننده SWLDA استفاده شد. در این روش، ابتدا هر دسته ویژگی با استفاده از تحلیل تفکیکی گام به گام و با معیار Wilk's Lambda تحلیل و ویژگی‌های منتخب آن مشخص شد و سپس کار طبقه‌بندی با LDA صورت پذیرفت.

۳-۴- طبقه‌بندی

هدف نهایی در هر مسأله شناسایی الگو، تفکیک مجموعه‌ای از نمونه‌ها به دو یا چند کلاس مختلف است. در این جا هدف نهایی، تفکیک سیگنال‌ها به دو گروه حاوی P300 و فاقد P300 است. در این مقاله، از طبقه‌بندی‌کننده‌های SWLDA و LDA (که در کارهای قبلی هم نتایج خوبی با استفاده از این طبقه‌بندی‌کننده‌ها گزارش شده بود) [۲۹] استفاده شد.

LDA ساده‌ترین و پرکاربردترین طبقه‌بندی‌کننده آماری است [۲۹]. این طبقه‌بندی‌کننده در فرم استانداردش یک طبقه‌بندی‌کننده باینری است که با اعمال تخمین MAP^{۲۱} و با فرض گوسی بودن تابع توزیع احتمال شرطی ویژگی‌ها در فضای ویژگی و همچنین تساوی ماتریس‌های کوواریانس کلاس‌ها محاسبه می‌شود.

طبقه‌بندی‌کننده SWLDA هم در واقع همان LDA است که قبل از انجام عملیات طبقه‌بندی از یک روش پیشرو-پسرو برای انتخاب ویژگی استفاده می‌کند. در شروع هیچ ویژگی‌ای برای مدل در نظر گرفته نمی‌شود و

ویژگی‌ای که معیار ورود به سیستم را برآورده کند، به مدل اضافه می‌شود. پس از اضافه شدن هر ورودی جدید به مدل، یک روند بازگشتی گام به گام پسرو برای حذف ویژگی‌هایی که کمترین اهمیت را دارند، به کار می‌رود. این پروسه تا زمانی که مدل شامل تعداد ویژگی‌های از پیش تعیین شده بشود، یا تا زمانی که هیچ ویژگی اضافه‌ای نمانده باشد که معیار خروج / ورود را برآورده کند، ادامه می‌یابد.

۴- نتایج

در این بخش نتایج کمی به دست آمده در قسمت‌های مختلف، بیان شده، تحلیل‌های حاصل از آنها ارائه خواهد شد.

۴-۱- نتایج ارزیابی تکی ویژگی‌ها با استفاده از

معیار t

برای بررسی ویژگی‌های مختلف و میزان تغییرات آنها در دو گروه مورد بررسی (هدف و غیرهدف)، در نخستین گام آزمون t-test برای تک تک ویژگی‌ها اجرا شد. متغیرهای مورد بررسی در این ارزیابی، ویژگی‌های استخراج شده از تک ثبت‌ها بودند و کلاس‌های مورد مقایسه، دو گروه حاوی P300 و فاقد P300 (هدف و غیرهدف) بودند.

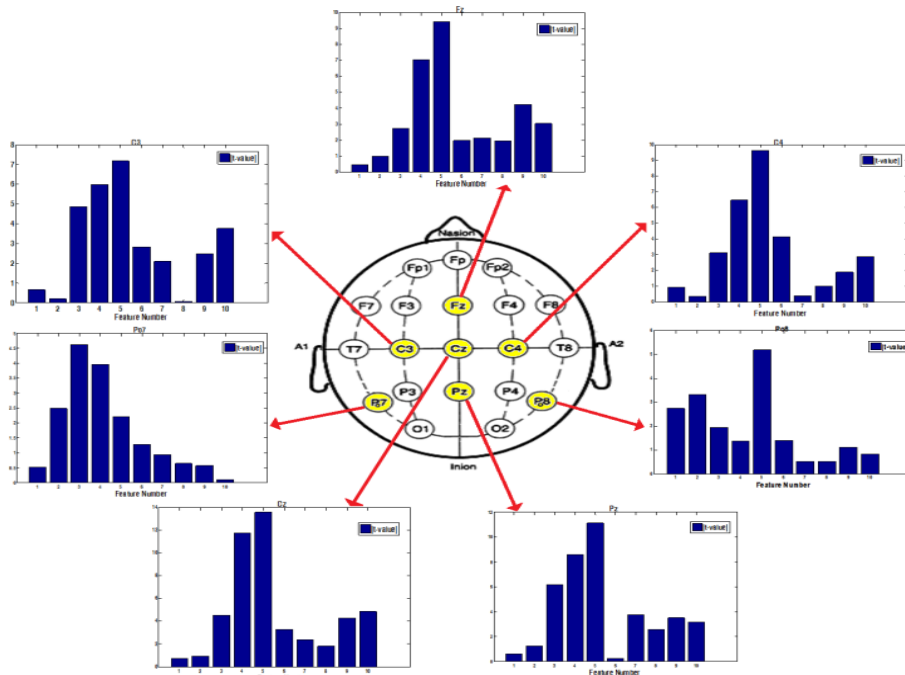
دسته ویژگی قطعه‌بندی هوشمند، شامل ۷۰ ویژگی است به طوری که برای هر کانال ۱۰ ویژگی استخراج شده است. برای نمایش گویاتر نتایج، در شکل (۴) نمودار ستونی قدرمطلق t-value برای ویژگی‌های هر کانال تصویر شده است.

نتایج شکل (۴) نشان می‌دهد که در ارزیابی ویژگی‌های قطعه‌بندی هوشمند به صورت تک تک و با آزمون t-test، در اغلب کانال‌ها ویژگی‌های ۳، ۴ و ۵ جزو ویژگی‌های برتر بوده‌اند. از طرفی، با توجه به مرزهای حاصل از قطعه‌بندی، مشخص می‌شود که ویژگی‌های ۳، ۴ و ۵ مربوط به بازه زمانی ۲۰۰ تا ۵۰۸ میلی‌ثانیه (محدوده رخداد مؤلفه P300) هستند.


همچنین، با بررسی الگوریتم LIR پیاده‌سازی شده، مشخص شد که مرزهای ده قطعه حاصل بر حسب نمونه

با توجه به محل قرار گرفتن این مرزها، مشخص است که در قسمت‌هایی که تفاوت شکل موج دو سیگنال هدف و غیر هدف بیشتر بوده، تعداد قطعه بیشتری تعریف شده است، اما در قسمت‌هایی که این تفاوت کمتر است، قطعات کمتر با طول بیشتر لحاظ شده‌اند.

به صورت ۰، ۳۲، ۴۲، ۵۵، ۹۱، ۱۲۲، ۱۴۶، ۱۶۰، ۱۶۶، ۲۳۹ و ۲۴۰ یا بر حسب زمان به صورت ۰، ۱۳۳، ۲۰۰، ۲۲۹، ۳۷۹، ۵۰۸، ۶۰۸، ۶۶۷، ۶۹۲، ۹۹۶ و ۱۰۰۰ میلی‌ثانیه بوده است. در شکل (۵) نمونه‌ای از متوسط سیگنال‌های هدف و غیرهدف، قبل و پس از قطعه‌بندی هوشمند دیده می‌شود.



شکل (۴): مقادیر |t-value| برای ۱۰ ویژگی قطعه‌بندی هوشمند مربوط به هریک از هفت کانال انتخابی



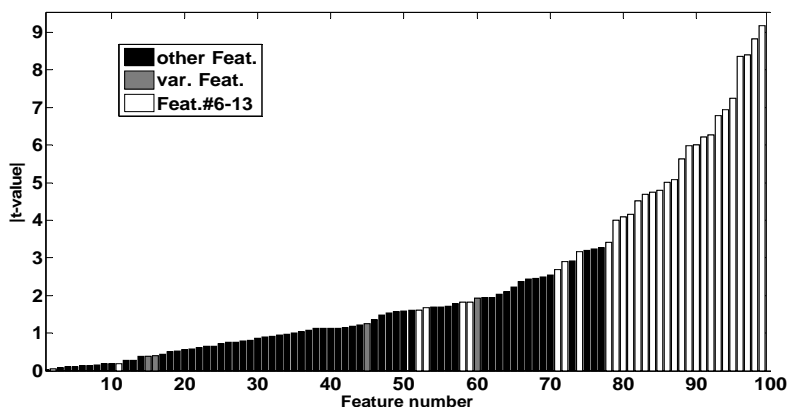
شکل (۵): بالا: متوسط کلیه سیگنال‌های هدف قبل و پس از اعمال قطعه‌بندی هوشمند در کانال Cz، پایین: متوسط کلیه

سیگنال‌های غیر هدف قبل و پس از اعمال قطعه‌بندی هوشمند در کانال Cz

دوم ویژگی‌های مبتنی بر واریانس، که طبق توضیحات قبلی برای هر ثبت، $۴ \times ۲۴ = ۹۶$ ویژگی نوع اول و چهار ویژگی نوع دوم تعریف شد و به این طریق دسته ویژگی حاصل از CSP شامل ۱۰۰ ویژگی شد. در ارزیابی ویژگی‌های الگوی مکانی مشترک توسط آزمون t -test، در سه کانال از چهار کانال مورد استفاده در فضای CSP، ویژگی‌های متعلق به بازه زمانی ۵۴۲-۲۵۰ میلی‌ثانیه (ویژگی‌های ۶ تا ۱۳ هر کانال) ویژگی‌های برتر بوده‌اند که تشابه این محدوده زمانی در هر دو دسته ویژگی قطعه‌بندی هوشمند و الگوهای مکانی مشترک، مؤید این مطلب است که در هر دو فضای دادگان خام و فضای CSP، ویژگی‌های دو کلاس هدف و غیرهدف در بازه زمانی رخداد P300 تفاوت آشکاری با یکدیگر دارند و این بازه، بازه مناسبی برای استخراج ویژگی‌های مؤثر و مفید در آشکارسازی P300 است. این ویژگی‌ها در شکل (۶) با رنگ سفید مشخص شده‌اند و به وضوح مشخص است که تجمع آنها بیشتر در انتهای نمودار و مقادیر بیشتر $|t\text{-value}|$ است.

مثلاً در محدوده ۱۳۳ تا ۶۹۱/۵ میلی‌ثانیه، که طبق تعاریف فیزیولوژیک سیگنال ERP، محل رخداد مؤلفه‌هایی از قبیل N100، P300 و N400 (مؤلفه‌هایی که هنگام اعمال یک تحریک هدف رخ می‌دهند) است، هفت قطعه تعریف شده، ولی در محدوده انتهایی سیگنال (۶۹۲ تا ۹۹۵ میلی‌ثانیه) تنها یک قطعه برای نشان دادن سیگنال به کار رفته است. به این ترتیب، با استفاده از این روش قطعه‌بندی هوشمند، می‌توان بدون نگرانی از مشکلاتی مانند تعداد زیاد نمونه‌ها و بالا رفتن بُعد بردار ویژگی، از مزایا و خواص مطلوب نمونه‌های زمانی سیگنال استفاده و قسمت‌های مهم سیگنال را بارزتر نمود. در شکل (۵) هم این مسأله به شکل واضح‌تر بر روی دو سیگنال هدف و غیر هدف و نتیجه اعمال قطعه‌بندی بر روی آنها نشان داده شده است.

شکل (۶) مقادیر قدرمطلق t -value را به صورت صعودی برای دسته ویژگی CSP نشان می‌دهد. همان‌طور که در بخش ۳-۲ ذکر شد، این دسته ویژگی شامل دو نوع ویژگی است. نوع اول ویژگی‌های حاصل از فیلتر کردن داده‌ها با فیلتر مکانی به دست آمده با روش CSP و نوع



شکل (۶): مقادیر $|t\text{-value}|$ برای دسته ویژگی الگوهای مکانی مشترک

اصلی توان‌های باند μ و β هستند، این نوع ویژگی‌ها، ویژگی‌های مناسبی هستند، ولی در بحث آشکارسازی P300 که مهمترین ویژگی‌ها، ویژگی‌های شکلی-زمانی هستند، نه واریانس سیگنال، بهتر است که از خود دادگان فیلتر شده به وسیله فیلترهای مکانی به عنوان ویژگی استفاده شود.

در مورد این دسته ویژگی، ذکر این نکته هم مفید به نظر می‌رسد که ویژگی‌های مبتنی بر واریانس (که در شکل (۶) با رنگ خاکستری مشخص شده‌اند)، ویژگی‌های مطلوبی نبوده‌اند. البته، قبلاً هم ذکر شد که این ویژگی‌ها بیشتر در سیستم‌های BCI با کاربرد تصورات حرکتی استفاده می‌شوند. برای چنین سیستم‌هایی که در آنها ویژگی‌های

است. ابتدا طبقه بندی کننده خطی LDA بر هر دسته ویژگی اعمال و دقت با روش 22 LOO محاسبه شده است. در جدول (۲) این نتایج برای دو سوژه A و B و میانگین آن دو آورده شده است. بر اساس این نتایج، برای هر دو سوژه، قطعه بندی هوشمند سیگنال به روش LIR بهترین کارایی را داشته است.

۲-۴- ارزیابی گروهی ویژگی ها

معیار دوم برای ارزیابی دسته ویژگی ها، مقایسه درصد صحت تفکیک آنها با یک طبقه بندی کننده است. در اینجا از دو طبقه بندی کننده LDA و SWLDA استفاده شده

جدول (۲): نتایج ارزیابی گروهی ویژگی ها با استفاده از صحت طبقه بندی کننده LDA

| درصد صحت نوع ویژگی | بعد بردار ویژگی | سوژه | هدف | غیرهدف | میانگین | میانگین A و B |
|-----------------------|--------------------|------|-------|--------|---------|---------------|
| قطعه بندی هوشمند | ۷۰ | A | ٪۹۰ | ٪۹۴/۸ | ٪۹۴ | ٪۹۵/۰۵ |
| | | B | ٪۹۰/۵ | ٪۹۷/۲ | ٪۹۶/۱ | |
| CSP | ۱۰۰ | A | ٪۷۷/۱ | ٪۸۶/۶ | ٪۸۵ | ٪۸۲/۴۵ |
| | | B | ٪۷۲/۴ | ٪۸۱/۴ | ٪۷۹/۹ | |

ویژگی های ۵ تا ۹ (مربوط به بازه ۳۷۵-۲۰۸ میلی ثانیه) انتخاب شده اند. بنابراین، هر دو روش t-test و تحلیل تفکیکی گام به گام، بیانگر اهمیت بازه رخداد مؤلفه P300 هستند.

در مورد میزان صحت حاصل توسط طبقه بندی کننده SWLDA هم در جدول (۳) بعد بردار ویژگی و درصد صحت برای هر دسته ویژگی و برای هر کدام از دو سوژه و به صورت میانگین آمده است.

در مرتبه دوم، روش تحلیل تفکیکی گام به گام به کار گرفته شد. با استفاده از این روش، ابتدا در هر دسته ویژگی های برتر انتخاب شدند و سپس با طبقه بندی کننده SWLDA درصد صحت هر دسته محاسبه شد.

با اعمال این روش انتخاب ویژگی به دسته ویژگی اول، از میان ۷۰ ویژگی طبقه بندی هوشمند، ۲۰ ویژگی انتخاب شدند که در این میان هم بیشتر ویژگی ها در همان محدوده رخداد P300 قرار دارند. در مورد دسته ویژگی CSP هم از میان ۲۶ ویژگی منتخب این دسته، در اغلب کانال ها

جدول (۳): نتایج ارزیابی ویژگی ها با روش تحلیل تفکیکی گام به گام و صحت طبقه بندی کننده SWLDA

| درصد صحت نوع ویژگی | بعد بردار ویژگی | سوژه | هدف | غیرهدف | میانگین | میانگین A و B |
|-----------------------|--------------------|------|-------|--------|---------|---------------|
| قطعه بندی هوشمند | ۲۰ | A | ٪۹۱/۲ | ٪۹۵/۳ | ٪۹۴/۶ | ٪۹۵/۲۵ |
| | | B | ٪۹۲/۹ | ٪۹۶/۵ | ٪۹۵/۹ | |
| CSP | ۲۶ | A | ٪۸۲/۹ | ٪۸۷/۹ | ٪۸۷/۱ | ٪۸۳/۴ |
| | | B | ٪۷۶/۵ | ٪۸۰/۴ | ٪۷۹/۷ | |

برای سوژه A، طبقه بندی کننده LDA از ۷۰ ویژگی استفاده کرده، ولی در SWLDA تنها از ۲۰ ویژگی استفاده شده است که این مسأله پیچیدگی تابع تصمیم گیری را کمتر کرده، تعمیم پذیری طبقه بندی کننده را افزایش می دهد. در واقع، برای

طبق جداول (۲) و (۳) دیده می شود که نتایج حاصل از این دو طبقه بندی کننده بسیار به هم نزدیک است، اما شاید بتوان حسن SWLDA را در تعداد ویژگی کمتر استفاده شده در آن دانست؛ مثلاً در مورد ویژگی های طبقه بندی هوشمند


برای ساخت این دسته ویژگی، ابتدا CSP در نقش یک کاهش دهنده بُعد ظاهر شده، دادگان را به فضایی جدید می‌برد که با وجود استفاده از تعداد کانال کمتر در آن فضا، قابلیت تفکیک زیادی از دست نمی‌رود و در عین حال، از مزیت کاهش تعداد کانال‌ها هم بهره برده می‌شود. سپس با استفاده از روش قطعه‌بندی هوشمند حجم دادگان را کاهش داده، دادگان بهینه‌تری را انتخاب می‌کنیم. با تکیه بر این ایده، این دسته ویژگی ترکیبی (با استفاده از همان پارامترهای به کار رفته در دو روش قطعه‌بندی هوشمند و CSP) ساخته شد؛ یعنی با استفاده از تعداد قطعه بهینه محاسبه شده ($k=10$)، این روش ترکیبی شامل ۴۰ ویژگی روی مجموع ۴ کانال منتخب فضای جدید CSP است. نتایج ارزیابی این دسته ویژگی از دو دیدگاه تکی و گروهی در ادامه آمده است.

در ارزیابی تکی این ویژگی‌ها با آزمون t -test دیده می‌شود که در این دسته ویژگی نیز، مشابه دسته ویژگی اول و دوم، ویژگی‌های مربوط به بازه رخداد P300 (ویژگی‌های ۳ تا ۶ هر کانال) ویژگی‌های مناسبی بوده‌اند و اختلاف آنها در دو کلاس مشهود بوده است. نمودار صعودی قدرمطلق مقادیر t -value برای ویژگی‌های ترکیبی در شکل (۷) (که ویژگی‌های ۳ تا ۶ هر کانال در آن با رنگ سفید مشخص شده است) مؤید همین مطلب است. نتایج ارزیابی گروهی این دسته ویژگی با دو طبقه‌بندی‌کننده LDA و SWLDA در جدول (۴) خلاصه شده است.

حل مشکل LDA، روش SWLDA راه حلی ارائه داده است که با محدود کردن اندازه فضای ویژگی ورودی مشکل گستردگی ابعاد را برطرف کند. در این روش انتخاب ویژگی به صورت خودکار صورت می‌گیرد و جملات غیر مهم از مدل حذف می‌شوند. همچنین، می‌توان الگوریتم را به شیوه‌ای تنظیم کرد که سریعتر به همگرایی برسد.

۳-۴- بررسی امکان تلفیق دو روش قطعه‌بندی هوشمند و الگوهای مکانی مشترک

با توجه به آنچه تا کنون درباره دو دسته ویژگی قطعه‌بندی هوشمند و الگوهای مکانی مشترک گفته شد، این ایده به ذهن می‌رسد که شاید ترکیب دو روش فوق به منظور ساخت یک دسته ویژگی ترکیبی مناسب باشد، زیرا همان طور که بیان شد، مزیت روش CSP در این است که در فضایی جدید، از تعداد کانال کمتری استفاده می‌کند و حسن قطعه‌بندی هوشمند هم در این است که با به کارگیری تعداد کمی نمونه به ازای هر کانال می‌تواند به قدرت تفکیک بالایی در آشکارسازی P300 برسد، اما در روش قطعه‌بندی از تعداد کانال زیادی استفاده شد که این امر حجم محاسبات را افزایش می‌دهد، بنابراین، می‌توان با ترکیب دو روش فوق، علاوه بر استفاده از مزایای دو روش، حجم محاسبات را هم کاهش داد. با این ایده دسته ویژگی ترکیبی CSP+LIR ساخته شد تا نتایج حاصل از آن نیز ارزیابی گردد.



شکل (۷): مقادیر $|t$ -value برای دسته ویژگی ترکیبی CSP+LIR

جدول (۴): نتایج ارزیابی گروهی دسته ویژگی ترکیبی

| درصد صحت طبقه بندی کننده | بعد بردار ویژگی | سوژه | هدف | غیرهدف | میانگین | میانگین A و B |
|--------------------------|-----------------|------|-------|--------|---------|---------------|
| LDA | ۴۰ | A | ٪۸۵/۳ | ٪۸۶/۲ | ٪۸۶/۱ | ٪۸۵/۲ |
| | ۴۰ | B | ٪۷۸/۸ | ٪۸۵/۴ | ٪۸۴/۳ | |
| SWLDA | ۱۸ | A | ٪۸۴/۱ | ٪۸۶/۲ | ٪۸۵/۹ | ٪۸۴/۰۵ |
| | ۱۷ | B | ٪۷۸/۸ | ٪۸۲/۸ | ٪۸۲/۲ | |

مکانی مشترک بود که هرچند در سایر حوزه‌های BCI پرکاربرد بوده، اما ویژگی‌های مستخرج از آن غالباً به گونه‌ای بوده‌اند (ویژگی‌های مبتنی بر واریانس) که در سیستم‌های مبتنی بر P300 توفیق چندانی نداشته‌اند. در این مقاله سعی شد تا با تعریف نوع دیگری از ویژگی‌های مبتنی بر CSP، کارایی هر دو نوع ویژگی در آشکارسازی P300 محک زده شود. در دسته ویژگی آخر هم از ترکیب دو روش استفاده شد تا از مزایای هر دو روش قبل بهره برده شود؛ یعنی هم با استفاده از CSP تعداد کانال‌ها را کاهش داد و هم با روش قطعه‌بندی هوشمند و کاهش نرخ نمونه‌برداری و فقی حجم محاسبات را کم کرد. بدین ترتیب، سه دسته ویژگی مختلف به دست آمد که با سه معیار t -test، استفاده از درصد صحت طبقه‌بندی کننده LDA و استفاده از روش SWLDA به ارزیابی آنها پرداخته شد که نتایج به دست آمده نشان دهنده برتری روش قطعه‌بندی هوشمند نسبت به سایر روش‌ها بود؛ به طوری که با هر دو طبقه‌بندی کننده LDA و SWLDA بالاترین درصد صحت میانگین (٪۹۵/۲۵) توسط این دسته ویژگی به دست آمد. این درصد صحت بالا بیانگر قدرت و توانایی این دسته ویژگی و اهمیت نحوه تقسیم‌بندی سیگنال است. برتری روش قطعه‌بندی هوشمند نسبت به سایر روش‌های کاهش نرخ نمونه‌برداری در این است که این روش یک روش و فقی و آموزش‌پذیر است که سعی می‌کند مرزهای قطعات را به نحوی تعیین کند که در عین زیاد کردن اختلاف بین دو کلاس، کمترین میزان اطلاعات از دست برود. همچنین، این روش کاهش نرخ نمونه‌برداری این امکان را فراهم می‌کند تا از قسمت‌هایی از سیگنال که اهمیت بیشتری دارد و حاوی اطلاعات بیشتری است، تعداد نمونه‌های بیشتری

در دسته ویژگی ترکیبی، فرضیه اولیه این بود که بهره‌مندی از مزایای هر دو روش قبلی احتمالاً باید به نتایج برتری نسبت به هر دو روش به صورت مجزا، دست یافت، اما طبق جدول (۴) دیده شد، که هرچند نتایج روش ترکیبی از روش CSP بهتر شد، اما باز هم ضعیفتر از روش قطعه‌بندی است. این مسأله نشان می‌دهد که به کارگیری قطعه‌بندی در فضای خام دادگان و روی تعداد کانال بیشتر، کارایی بهتری نسبت به اعمال آن در فضای جدید با تعداد کانال کمتر دارد.

یک مسأله جانبی دیگر در مورد ویژگی‌های انتخاب شده به روش تحلیل تفکیکی گام به گام است. دیده می‌شود که در این دسته ویژگی هم غالباً ویژگی‌های مربوط به بازه رخداد P300 برگزیده شده‌اند، به طوری که در بین ۱۸ ویژگی انتخابی این دسته ویژگی، اکثر آنها (ویژگی‌های ۲ تا ۶ در هر کانال) در بازه زمانی ۶۹۳-۱۴۷ میلی‌ثانیه قرار می‌گیرند.

۵- نتیجه گیری

در این مطالعه، تلاش بر این بود تا با استفاده از یک سیستم مبتنی بر بازشناسی الگو به آشکارسازی P300 پرداخته شود و ضمن آن، کارایی سه روش مختلف استخراج ویژگی هم بررسی شود. دسته ویژگی اول، ویژگی‌های حاصل از قطعه‌بندی هوشمند سیگنال بودند. قطعه‌بندی، روش رایجی برای استخراج ویژگی در سیستم‌های بازشناسی الگو است، اما کاربرد آن در آشکارسازی مؤلفه P300 تا کنون بسیار کم بوده است. روش دوم هم استفاده از فیلتر کردن مکانی و الگوهای

- [2] J. Polich, "P300 in Clinical Applications," in *Electroencephalography: Basic Principles, Clinical Applications, and Related Fields*, E. Niedermeyer and F. Lopes Da Silva, Eds., 4th ed. Baltimore, Maryland: Lippincott Williams and Wilkins, 2000, ch. 58, pp. 1073-1091.
- [3] J. P. Rosenfeld, "Event-Related Potentials in the Detection of Deception, Malingering, and False Memories," in *Handbook of Polygraph Testing*, M. Kleiner, Ed. New York: Academic Press, 2002, ch. 10, pp. 265-286.
- [4] L. A. Farwell and E. Donchin, "The truth will out: Interrogative polygraphy ('lie detection') with event-related brain potentials," *Psychophysiology*, vol. 28, no. 5, pp. 531-547, 1991.
- [۵] و. ابوطالبی، "تجزیه و تحلیل مؤلفه‌های شناختی سیگنال الکتریکی مغز و کاربرد آن در دروغ سنجی،" پایان نامه دکترای مهندسی پزشکی - بیوالکترونیک، دانشگاه صنعتی امیرکبیر، اردیبهشت ۱۳۸۵.
- [6] X. Neng, G. Xiaorong, H. Bo, M. Xiaobo, G. Shangkai, Y. Fusheng, "BCI competition 2003-data set IIB: enhancing P300 wave detection using ICA-based subspace projections for BCI applications," *IEEE Trans. on Biomed. Eng.*, vol.51, no.6, pp.1067-1072, June 2004.
- [7] S.A. Markazia, L.K. Stergioulas, A. Ramchurn, D. Bunce, "Latency Corrected Wavelet Filtering of the P300 Event-Related Potential in Young and Old Adults," *In Proc. 3rd IEEE EMBS Conf., Neural Eng., CNE '07.*, pp.582-586, 2-5 May 2007.
- [8] M. Kaper, P. Meinicke, U. Grossekhoefer, T. Lingner, H. Ritter, "BCI competition 2003-data set IIB: support vector machines for the P300 speller paradigm," *IEEE Trans. on Biomed. Eng.*, vol.51, no.6, pp.1073-1076, June 2004.
- [9] BCI Competition 2005. ida.first.fraunhofer.de/projects/bci/competition_ii
- [10] U. Hoffmann, G. Garcia, J.-M. Vesin, K. Diserens, T. Ebrahimi, "A Boosting Approach to P300 Detection with Application to Brain-Computer Interfaces," *In Proc. 2nd IEEE EMBS Conf. on Neural Eng., 2005.*, pp.97-100, 16-19 March 2005.
- [11] L. Yang, Z. Zongtan, H. Dewen, D. Guohua, "T-weighted Approach for Neural Information Processing in P300 based Brain-Computer Interface," *Int. Conf. on Neural Net. and Brain, 2005. ICNN&B '05.*, vol.3, pp.1535-1539, 13-15 Oct. 2005.

ذخیره کرد و در عوض نمونه‌های حفظ شده از قسمت‌های کم اهمیت‌تر را کاهش داد.

در مورد ویژگی‌های CSP، هرچند ویژگی‌هایی که از دادگان فیلتر شده به وسیله فیلتر مکانی تهیه شدند، به مراتب از ویژگی‌های مبتنی بر واریانس بهتر بودند، اما بازهم کارایی روش قطعه‌بندی هوشمند برتر از روش CSP است و این مسئله در نتایج حاصل از طبقه‌بندی‌کننده‌ها به وضوح مشخص است.

آخرین نکته، از نتایج t-test به دست می‌آید. طبق این نتایج در هر سه دسته ویژگی، ویژگی‌هایی که متعلق به محدوده زمانی رخداد P300 هستند، دارای |t-value| بالایی هستند و قدرت تفکیک دو کلاس در آنها بالاست. این قضیه اهمیت بازه‌زمانی رخداد P300 را بیش از پیش نمایان می‌کند.

در مقام قیاس با سایر مطالعات انجام گرفته در این زمینه نیز باید گفت که نتایج حاصل از این تحقیق، نتایج خوب و قابل قبولی هستند؛ برای مثال، می‌توان به کارهای افرادی مانند Seller, Yang Liu و یا Salvaris اشاره کرد که با روش‌های مختلفی روی همین دادگان کار کرده‌اند و نتایج ضعیف‌تری به دست آورده‌اند. همان‌طور که در قسمت مقدمه هم ذکر شد؛ Yang Liu با روش T-weighted، روی دادگان سال ۲۰۰۵ به صحت ۹۰٪ در تشخیص کاراکتر رسید و یا Krusinski و Sellers توانستند با حداکثر ۶۰ ویژگی مدل، به صحت ۹۲/۵٪ روی این دادگان دست یابند. همچنین، بهترین صحت حاصل توسط Salvaris و همکارانش با استفاده از تبدیل موجک گسسته و طبقه‌بندی کننده FLD، صحت میانگین ۹۵٪ بوده است، اما در این تحقیق ما توانستیم به صحت متوسط ۹۵/۲۵٪ برسیم.

مراجع

- [۱] س. رضایان، "کمی سازی پتانسیل‌های وابسته به رخداد (ERP) در فرایند حافظه اپیزودیک بر پایه ویژگی‌های زمان-فرکانس جدید،" پایان نامه کارشناسی ارشد مهندسی پزشکی - بیوالکترونیک، دانشگاه آزاد اسلامی واحد علوم و تحقیقات، ۸۷-۱۳۸۶.

- spelling," *IEEE Int. Conf. on Machine Learning and Appl.*, pp.386-391, 2009.
- [21] Y. Sakamoto and M. Aono, "Supervised Adaptive Downsampling for P300-based Brain Computer Interface," *31st Int. Conf. on IEEE EMBS*, pp.567-570, September 2-6, 2009.
- [22] D. H. Foley, J. W. Sammon Jr., "An Optimal Set of Discriminant Vectors," *IEEE Trans. on Comp.*, Vol.24, No.3, pp.281-289, March 1975.
- [23] A. Soong and Z. Koles, "Principal-component localization of the sources of the background eeg," *IEEE Trans. on Biomed. Eng.*, vol. 42, no. 1, pp. 59-67, Jan. 1995.
- [24] K. Fukunaga, "Introduction to Statistical Pattern Recognition," *Second Edition. Morgan Kaufmann - Academic Press*, 1990.
- [25] D.J. Krusienski, E.W. Sellers, T.M. Vaughan, "Common Spatio-Temporal Patterns for the P300 Speller," *3rd Int. IEEE/EMBS Conf. on Neural Eng.*, 2007. *CNE '07*, vol., no., pp.421-424, 2-5 May 2007.
- [26] R. Li, A. Keil, J.C. Principe, "Single-trial P300 estimation with a spatiotemporal filtering method," *J. Neuroscience Methods*, vol.177, pp.488-496, 2009.
- [27] B. Rivet, H. Cecotti, R. Phlypo, O. Bertrand, E. Maby, J. Mattout, "EEG sensor selection by sparse spatial filtering in P300 speller brain-computer interface," *32nd Int. IEEE EMBC Conf.*, pp. 5379-5382, Aug. 31- Sep. 4, 2010.
- [28] G. Pires, U. Nunes, M. Castelo-Branco, "P300 spatial filtering and coherence-based channel selection," *4th IEEE EMBS Conf. on Neural Eng.*, *NER '09.*, pp.311-314, April 29 2009-May 2 2009.
- [29] D. J. Krusienski, E.W. Sellers, F. ois Cabestaing, S. Bayoudh, D. J McFarland, T. M Vaughan and J. RWolpaw, "A comparison of classification techniques for the P300 Speller," *J. Neural Eng.*, vol.3, pp.299-305, 2006.
- [12] D.J. Krusienski, E.W. Sellers, D.J. McFarland, T.M. Vaughan, J.R. Wolpaw, "Toward enhanced P300 speller performance," *J. Neuroscience Methods*, Vol. 167, pp.15-21, 2008.
- [13] M. Salvaris, F. Sepulveda, "Wavelets and ensemble of FLDs for P300 classification," *4th Int. IEEE/EMBS Conf. on Neural Eng.*, 2009. *NER '09.* vol., no., pp.339-342, April 29 2009-May 2 2009.
- [۱۴] ف. عطری، "استخراج و پردازش سیگنال‌های EEG متاثر از بیوفیدبک جهت ارسال کاراکترهای مورد توجه شخص به کامپیوتر،" پایان نامه کارشناسی ارشد مهندسی پزشکی-بیوالکترونیک، دانشگاه تهران، شهر یور ۱۳۸۴.
- [15] Z. Seyyedsalehi, A.M. Nasrabadi, V. Abootalebi, "Committee Machines and Quadratic B-spline Wavelet for the P300 Speller Paradigm," *IEEE/ACS Conf. on Comp. Sys. And Appl.*, pp.866-869, 2008.
- [16] T. Pavlidis, "Algorithm for Shape Analysis and Waveforms," *IEEE Trans. on Pattern Analysis and Machine Intelligence, PAMI-2(4)*: pp.301-312, 1980.
- [17] T. Rohlfing, D.B. Russakoff, and C.R. Maurer, "Performance-Based Classifier Combination in Atlas-Based Image Segmentation Using Expectation-Maximization Parameter Estimation," *IEEE Trans. on Med. Imag.*, vol.23, no.8, pp.983-994, Aug. 2004.
- [18] T. Pavlidis, "Waveform Segmentation Through Functional Approximation," *IEEE Trans. on Comp.*, C- 22(7): pp.689-697, 1973.
- [19] A. Rakotomamonjy, V. Guigue, "BCI Competition III: Dataset II- Ensemble of SVMs for BCI P300 Speller," *IEEE Trans.on Biomed. Eng.*, vol.55, no.3, pp.1147-1154, March 2008.
- [20] A. Combazl, N.V. Manyakov, N. Chumerin1, J. A. K. Suykens, M. M. Van Hulle, "Feature Extraction and Classification of EEG Signals for Rapid P300 Mind

زیر نویس‌ها

¹ Event Related Potentials

² ElectroEncephaloGrphy

³ Linear Discriminant Analysis

⁴ Brain Computer Interface

⁵ Independent Component Analysis

- ⁶ Communication rate
- ⁷ Support Vector Machine
- ⁸ Principle Component Analysis
- ⁹ Fisher Linear Discriminant
- ¹⁰ Common Spatial Pattern
- ¹¹ Segmentation
- ¹² Local Iterative Replacement-LIR
- ¹³ Curse of dimensionality
- ¹⁴ Decimation
- ¹⁵ Fisher Discriminant Criterion
- ¹⁶ Fisher Discriminant Analysis
- ¹⁷ Within-class covariance
- ¹⁸ Between-class covariance
- ¹⁹ Stepwise Linier Discriminant Analysis
- ²⁰ motor imagery
- ²¹ Maximum A Posterior
- ²² Leave One Out