

Development of P300 detection by Combination of Time, Frequency and Spatial Feature Extraction Methods

Z. Amini¹, V. Abootalebi^{2*}, M. T. Sadeghi³

¹M.Sc Student, Electrical and Computer Engineering Department, Yazd University, Yazd, Iran, zamini@stu.yazduni.ac.ir

²Assistant Professor, Electrical and Computer Engineering Department, Yazd University, Yazd, Iran

³ Assistant Professor, Electrical and Computer Engineering Department, Yazd University, Yazd, Iran, m.sadeghi@yazduni.ac.ir

Abstract

The aim of this paper is to design a pattern recognition based system to detect P300 component in multi-channel electroencephalogram (EEG) trials. This system has two main blocks, feature extraction and classification. In feature extraction block, in addition to conventional features namely morphological, frequency and wavelet features, some new features included intelligent segmentation, common spatial pattern (CSP) and combined features (CSP + Segmentation) have also been used. Three criteria were used for evaluation and selection of a feature set by choosing a subset of the original features that contains most of essential information. Firstly, a statistical analysis has been applied for evaluating the fitness of each feature in discriminating between target and non target signals. Secondly, each of these six groups of features was evaluated by a Linear Discriminant Analysis (LDA) classifier. Furthermore by using Stepwise Linear Discriminant Analysis (SWLDA), the best set of features was selected. Among these six feature vectors, intelligent segmentation was seen to be most efficient in classification of these signals. In classification phase, two linear classifiers -LDA and SWLDA- were used. The algorithm was described here has tested with dataset II from the BCI competition 2005. In this research, the best result for P300 detection is 97.05% .This result have proven to be more accurate than the results of previous works carried out in this filed.

Key words:P300, Brain Computer Interface (BCI), Pattern Recognition, Feature Extraction, Classification

*Corresponding author

Address: Vahid Abootalebi, Electrical and Computer Engineering Department, Yazd University, Yazd, Iran
Tel: +983518122398
Fax: +983518200144
E-mail: Abootalebi@yazduni.ac.ir

بهبود آشکارسازی مؤلفه P300 با استفاده از تلفیق روش‌های مختلف زمانی، فرکانسی و مکانی استخراج ویژگی

زهرا امینی^۱، وحید ابوطالبی^{۲*}، محمد تقی صادقی^۳

^۱ دانش آموخته کارشناسی ارشد، دانشگاه یزد، یزد Zamini@stu.yazduni.ac.ir

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

^۳ استادیار، دانشکده مهندسی برق و کامپیوتر، دانشگاه یزد، یزد M.sadeghi@yazduni.ac.ir

چکیده

در این مقاله سیستمی مبتنی بر بازنگاری آماری الگو جهت تفکیک سیگنال‌های حاوی P300 و فاقد آن، ارائه می‌شود. این سیستم - که بر روی دادگان P300-Speller مسابقات BCI 2005 کار می‌کند - از چهار بخش اصلی پیش‌پردازش، استخراج ویژگی، انتخاب ویژگی و طبقه‌بند تشکیل شده که تأکید اصلی این مقاله بر بخش استخراج ویژگی و بررسی کارایی ویژگی‌های مختلف است. در مرحله استخراج ویژگی، شش دسته ویژگی شامل قطعه‌بندی هوشمند، ضرایب موجک، الگوهای مکانی مشترک، ویژگی‌های شکلی-زمانی، ویژگی‌های فرکانسی و دسته ویژگی ترکیبی الگوهای مکانی مشترک و قطعه‌بندی، تعریف شدن که برخی از این ویژگی‌ها (مانند ویژگی‌های قطعه‌بندی هوشمند، الگوهای مکانی مشترک و ترکیبی) تا کنون یا مستقیماً برای آشکارسازی P300 به کار نرفته بودند و یا در موارد بسیار محدودی از آنها استفاده شده بود. سپس ویژگی‌ها با معیارهای مختلفی به صورت تک تک و گروهی ارزیابی شدند و در نهایت ترکیبی بهینه از مجموع این ویژگی‌ها به طبقه‌بند SWLDA داده شد. بدین ترتیب درصد صحت تشخیص مؤلفه P300 با این سیستم به ۹۷/۰۵٪ رسید که در قیاس با نتایج مطالعات قبلی در این حوزه، نتیجه برتری است.

کلیدواژگان: طبقه‌بندی مؤلفه P300، سیستم‌های واسط مغز و رایانه (BCI)، بازنگاری آماری الگو، استخراج ویژگی، طبقه‌بند

* عهده‌دار مکاتبات

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

تلفن: ۰۳۵۱-۸۱۲۲۳۹۸، دورنگار: ۰۳۵۱-۸۲۰۰۱۴۴، پیام نگار: Abootalebi@yazduni.ac.ir

۱- مقدمه

طبقه‌بند SVM^۱ خطی و متوسط‌گیری از خروجی SVM‌ها، نتیجه طبقه‌بندی نهایی مشخص شده است. نویسنده‌گان علت استفاده از SVM را مناسب بودن آن برای داده‌هایی با بعد بالا ذکر کرده‌اند و در بهترین حالت به صحت ۹۶/۵٪ رسیده‌اند^[۶]. Salvaris و همکارانش^[۷] در سال ۲۰۰۹ با انجام تحقیقی در مورد دادگان P300 مسابقات ۲۰۰۵ BCI، از تبدیل موجک گسته برای استخراج ویژگی‌های سیگنال مغزی استفاده کرده‌اند. آنها با قطعه‌بندی دادگان ورودی طبقه‌بند، برای هر قطعه از یک FLD^۲ استفاده کرده؛ سپس نمره هر طبقه‌بند را محاسبه کرده‌اند. از مجموع این نمره‌ها بهترین رتبه برای قطعه به دست آمده است (Ensemble of FLDS). این گروه توانستند با چنین روشی به صحت میانگین ۹۵٪ دست یابند.

Yang Liu در مقاله‌ای در سال ۲۰۰۵ دیدگاه T-Weighted را برای پردازش اطلاعات عصبی در BCI مبتنی بر P300^۳ بررسی کرده؛ که در آن از دادگان BCI2005-II استفاده شده است^[۸]. در این تحقیق ابتدا برای کاهش همبستگی، تحلیل مؤلفه‌های اصلی^۴ (PCA) بر روی سیگنال‌های ۶۴ کاناله اجرا شده؛ سپس از جمع T-Weighted برای طبقه‌بندی ویژگی‌ها استفاده می‌شود. در این روش ابتدا مجموع وزن‌دار ویژگی‌ها که در اینجا مقادیر سیگنال هر طبقه هستند- محاسبه می‌شود و سپس با استفاده از معیار t-test^۵ بهترین مقدار برای وزن هر ویژگی به دست می‌آید. نتایج به دست آمده صحت ۹۰٪ را نشان می‌دهد.

Qushoni و خلیل زاده^[۹] در سال ۱۳۸۴ با استفاده از شبکه عصبی چند لایه و الگوریتم ژنتیک به آشکارسازی مؤلفه P300 پرداخته‌اند. در این تحقیق از دادگان مطالعه ابوطالبی^[۱۰] استفاده شده است. برای استخراج اطلاعات مرتبط با فعالیت شناختی مغز، ویژگی‌هایی براساس مشخصات زمانی سیگنال‌های تک ثبت ERP استخراج شده است و همچنین برای انتخاب ویژگی‌های بهینه، از الگوریتم ژنتیک بهره برده است. در این روش با کمک ۷ ویژگی بهینه به دست آمده از کanal Pz تکثیت‌های حاوی موج P300 با صحت ۷۸٪ از تک ثبت‌های فاقد این موج، تفکیک شده‌اند^[۹].

Sied صالحی و همکارانش^[۱۱] در سال ۲۰۰۸ برای نخستین بار از مدل مخفی مارکوف^۶ بمنظور تشخیص مؤلفه P300

فعالیت‌های شناختی مغز، یکی از جذاب‌ترین زمینه‌های مطالعاتی در بسیاری از شاخه‌های علوم مرتبط با مغز است. با توجه به رابطه تنگاتنگی که بین بروز مؤلفه P300^[۱] و فعالیت شناختی مغز وجود دارد، از این مؤلفه در تحقیقاتی که به نحوی با فعالیت شناختی مغز مرتبط هستند؛ استفاده می‌شود. به طور مثال با توجه به پایداری این مؤلفه در افراد معلول جسمی و یا ذهنی، مؤلفه P300 سیستم‌های رابط بین انسان و رایانه (BCI)^۷ مورد توجه محققان قرار گرفته است.

یکی از کاربردهای مهم سیگنال EEG و مؤلفه P300 در سیستم‌های واسط مغز با رایانه است. در سیستم‌های BCI مبتنی بر P300^۸ از این مؤلفه به عنوان ورودی سیستم استفاده می‌شود. مزیت سیستم BCI مبتنی بر P300 عدم نیاز به آموزش اولیه کاربر بوده؛ زیرا P300 یک پاسخ ذاتی به یک انتخاب مطلوب است. Bayliss و Ballard مؤلفه‌های P300 را در محیط مجازی P300 ثبت کردند و براساس تحلیل‌های برونو خط، دامنه قله‌های P300 محاسبه شده از تکثیت‌ها را برای کنترل محیط خارجی به کار بردن^[۲,۳]. Inbar و همکارانش نیز از مؤلفه P300 برای برقراری ارتباط بین مغز و رایانه، با انتخاب حروف از روی یک صفحه کلید ۶×۶، استفاده کرده‌اند^[۴]. همچنین از سال ۲۰۰۰ مسابقاتی دوسالانه با نام BCI Competition برگزار می‌شود که یکی از بخش‌های این مسابقه سیستم P300-speller است که در آن مؤلفه P300 برای برقراری ارتباط بین مغز و رایانه، از طریق انتخاب حروف از روی یک صفحه کلید ۶×۶، به کار می‌رود^[۵]. از زمان برگزاری این مسابقات تاکنون، بسیاری از افراد و گروه‌های تحقیقاتی با هدف پژوهش در زمینه آشکارسازی P300، از سیستم P300-Speller استفاده کرده‌اند و برخی از آنها به نتایج خوبی دست یافته‌اند که از آن جمله می‌توان به موارد زیر اشاره کرد:

Rakotmamonjy و Guigue که ایده آنها برای آشکارسازی مؤلفه P300 یکی از طرح‌های برتر مسابقات P300 در قسمت دادگان II BCICompetition2005^۹ بوده است، با مقاله‌ای در سال ۲۰۰۸^[۶] به بیان طرح پیشنهادی خود پرداختند. طبق این طرح، کل داده‌های آموزشی P300 Speller مربوط به هر فرد به ۱۷ قسمت تقسیم شده و با کمک ۱۷

^۱ Brain Computer Interface
^۵ Hidden markov model

² Support Vector Machine

³ Fisher Linear Discriminant

⁴ Principle components Analysis

۲- اجزای سیستم آشکارساز

همانطور که اشاره شد در این مقاله از یک سیستم بازشناسی آماری الگو برای آشکارسازی P300 استفاده شده که مشابه هر سیستم بازشناسی آماری الگوی دیگر، این سیستم نیز از دو بخش اصلی استخراج ویژگی و طبقه‌بندی تشکیل شده است. همان‌طور که در شکل (۱) دیده می‌شود، در روندnamی این سیستم، پیش از این دو بخش، لازم است پیش‌پردازش‌هایی بر روی سیگنال انجام شود و بعلاوه یک بخش ارزیابی ویژگی نیز پس از استخراج ویژگی برای بررسی و انتخاب ویژگی‌های برتر به کار گرفته شده است. در این بخش پس از معرفی دادگان مورد استفاده، هر یک از بخش‌های فوق و روش‌های به کار رفته در هر کدام به صورت کامل و کاربردی تعریف خواهد شد.



شکل (۱)- روندnamی سیستم آشکارساز P300 مورد استفاده

۲-۱- معرفی دادگان مورد استفاده

سیگنال‌های مورد استفاده در این مطالعه را گروه وادثوثر در چهارچوب BCI2000 تهیه کردند و از طریق سایت اینترنتی مسابقه BCI2005 در اختیار قرار گرفته است^[۵]. در روند ثبت این دادگان، یک جدول با ابعاد ۶×۶ حاوی ۳۶ حرف مطابق شکل (۲) مقابله فرد قرار گرفته است. آزمایشگر کلمه‌ای را (به تفکیک حرفهایش) به عنوان هدف تعیین کرده که این کلمه در بالای جدول نمایش داده شده است.

شکل (۲)- ماتریس تحریک برای ثبت دادگان

در یک مرحله از آزمایش، ۱۲ تحریک (۶ ستون و ۶ ستون) اتفاق می‌افتد که هر تحریک به صورت روشن شدن تصادفی یکی از سطرها یا یکی از ستون‌ها انجام می‌شود و فقط دو مورد

استفاده کرده‌اند.^۱ CDHMM-ها- که از نوع پیوسته مدل‌های مخفی مارکوف هستند- در این مطالعه با کمک روش یادگیری مدولار برای تفکیک دادگان حاوی P300 و قادر آن در دادگان II-BCI2005، استفاده شده‌اند. ضرایب را که تبدیل موجک Quadratic B-spline استخراج کرده به عنوان زنجیره ویژگی در مدل‌ها استفاده شده است. این ضرایب از ۶۴ کanal استخراج و با اعمال PCA بر فضای ویژگی‌ها، کاهش بعد انجام شده است. بعد از آموزش دو مدل CDHMM، SVM میزان شباهت به دو مدل را بررسی کرده؛ تصمیم نهایی اتخاذ شده است. در این تحقیق ۹۵/۸٪ صحبت تشخیص برای مؤلفه P300 به دست آمد^[۱۱].

هدف اصلی مقاله حاضر آشکارسازی مؤلفه P300 با تکیه بر روش‌های بازشناسی آماری الگو است. این روش‌ها اغلب شامل دو بخش اساسی استخراج و انتخاب ویژگی و طبقه‌بندی هستند. در روش‌های استخراج ویژگی، معمولاً سعی می‌شود ابتدا ویژگی‌های مناسبی از سیگنال استخراج شود و سپس در مرحله بعدی باید با بکارگیری ویژگی‌های به دست آمده، از یک طبقه‌بند برای تفکیک سیگنال‌ها به دو گروه حاوی P300 و قادر P300 استفاده شود.

در این مطالعه از میان قسمت‌های مختلف سیستم بازشناسی الگو، بیشترین تأکید بر بخش استخراج ویژگی است. بدین منظور با در نظر گرفتن ویژگی‌های ذاتی سیگنال مغزی مورد نظر و با مطالعه روش‌های گوناگون موجود در حوزه‌های مختلف پردازشی، سعی شده تا از روش‌های نوینی که تا کنون در این زمینه کاربرد کمتری داشته‌اند ولی روش‌های مناسبی به نظر می‌رسند (مانند قطعه‌بندی هوشمند سیگنال و الگوهای مکانی مشترک(CSP)^۲؛ برای استخراج ویژگی استفاده شود. همراه این روش‌های نوین، از برخی روش‌های رایج استخراج ویژگی (مثل ویژگی‌های شکلی- زمانی، فرکانسی و نوع بهبود یافته‌ای از ویژگی‌های زمانی- فرکانسی) نیز استفاده شده است.

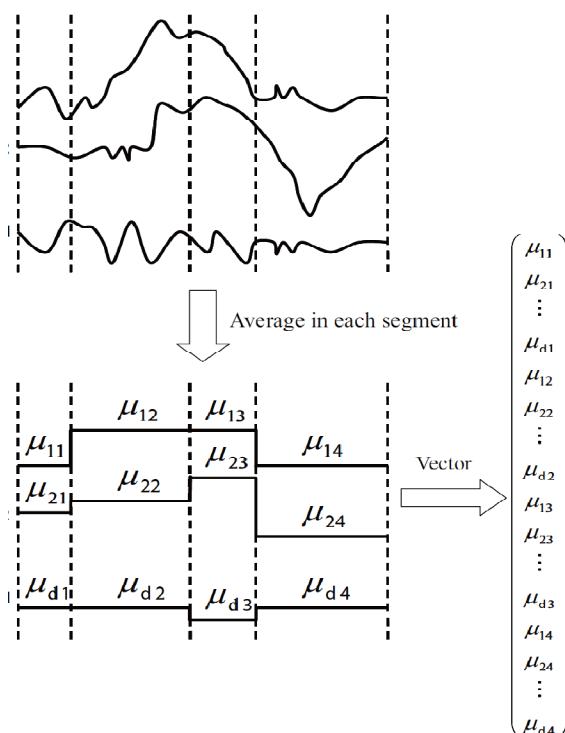
بدین منظور، در بخش دوم مقاله نحوه اجرای سیستم آشکارساز شامل دادگان، پیش‌پردازش، استخراج ویژگی، ارزیابی و انتخاب ویژگی و طبقه‌بندی شرح داده خواهد شد. پس از آن در بخش سوم نتایج حاصل، بیان و تحلیل می‌شود و در بخش چهارم نیز جمع‌بندی مطالب و نتیجه‌گیری از آنها انجام خواهد شد.

^۱ Continuous DensityHidden markov model

^۲ Common Spatial Pattern

۱-۳-۲- قطعه‌بندی هوشمند

برای آشکارسازی مؤلفه P300 از طریق بازشناسی آماری الگو، به تعریف یک بردار ویژگی نیاز داریم. یکی از راههای رایج برای ساخت این بردار، متواالی کردن دادگان سیگنال EEG ثبت شده از کanal‌های مختلف است؛ ولی ساخت بردار ویژگی با تمامی نمونه‌های همه این کanal‌ها می‌تواند به ایجاد یک بردار ویژگی با بعد بسیار بالا بیانجامد. با توجه به تعداد محدود دادگان، این امر ممکن است سیستم را به نفرین ابعاد^۸ دچار سازد. در اینجا برای اجتناب از این مشکل از یک روش قطعه‌بندی هوشمند استفاده شده است. در این روش از قطعه‌بندی غیریکنواخت بازه‌ها- که در شکل (۳) دیده می‌شود- استفاده شده است و از متوسط هر قطعه به جای نماینده آن قطعه در بردار ویژگی استفاده می‌شود[۱۳].



شکل (۳)- کاهش نرخ نمونه برداری و فضی و تولید بردار ویژگی [۱۳]

در طرح اولیه فرض می‌شود یک کاهش نرخ نمونه برداری مؤثر بر دادگان می‌تواند اختلاف بین دو طبقه را واضح‌تر کند و درجه تفکیک بین آن دو را بالا ببرد.

برای جدا کردن طبقه‌ها به معیاری از شباهت یا عدم شباهت نیاز است و در اینجا از معیار جدایزیری فیشر^۹ (FDC) [۱۴]

حاوی حرف هدف و در نتیجه مؤلفه P300 هستند. این آزمایشات برای هر حرف ۱۵ بار تکرار شده، لذا برای هر حرف ۳۰ سیگنال حاوی P300 و ۱۵۰ سیگنال فاقد آن موجود است. این سیگنال‌ها از یک صافی میان‌گذر ۰/۱ تا ۶۰ هرتز عبورداده شده و با نرخ ۲۴۰ هرتز نمونه‌برداری شده‌اند. همچنین از استاندارد ۲۰-۱۰، ۶۴ کanal در الکترودگذاری برای ثبت EEG استفاده شده است. این دادگان در سال ۲۰۰۵ از دو نمونه A و B تهیه شده است.

۲-۲- پیش‌پردازش

با توجه به محدوده فرکانسی مؤلفه P300 و همچنین به منظور حذف DC، سیگنال‌ها در محدوده ۰/۵ تا ۳۵ هرتز فیلتر شدند. پس از فیلتر کردن، سیگنال هر کanal به بازه [۱، ۱]- بهنجار شد و سپس سیگنال‌ها به قطعات یک ثانیه‌ای تقسیم شدند. مسأله مهم دیگر، انتخاب کanal‌های مناسب است؛ زیرا با توجه به تعداد زیاد کanal‌های مورد استفاده برای ثبت داده باید به نحوی از طولانی شدن محاسبات جلوگیری شود. بر همین اساس در این مقاله نیز در تمامی مراحل - به جز در روش الگوهای مکانی مشترک که از کل ۶۴ کanal استفاده می‌شود- از هفت کanal P07، P08، Fz، C3، Cz، C4، Pz مسابقات BCI، برای هر دو نمونه A و B به عنوان کanal‌های مناسب معرفی کرده بود[۱۲].

در مرحله بعد، سیگنال‌های دارای کد تحریک یکسان در هر حرف برای کل ۱۵ تکرار، با یکدیگر متوسط‌گیری شدند. این امر صحت سیستم را به میزان قابل توجهی افزایش می‌دهد.

۳-۲- استخراج ویژگی

در روش‌های بازشناسی الگو، معمولاً سعی می‌شود به جای دسته‌بندی داده‌ها در فضای اطلاعات خام، از فضای ویژگی مناسبی استفاده شود که بازنمایی بهتری از اطلاعات دارد. با توجه به اینکه تأکید اصلی مقاله حاضر بر این بخش در سیستم آشکارساز است، در این بخش سعی شده روش‌های مختلف به کار رفته برای استخراج ویژگی تا حد امکان به طور مبسوط شرح داده شوند. در این تحقیق با تکیه بر مطالعات قبلی انجام شده، شش دسته مختلف از ویژگی‌ها پیشنهاد شده است و برنامه‌های لازم برای استخراج آنها اجرا شده که به معرفی آنها می‌پردازیم.

⁸ Curse of dimensionality

⁹ Fisher Discriminant Criterion

$$X_i(T) = \text{Make Vector}(S_i, T) =$$

$$\begin{pmatrix} \frac{1}{\tau_1 - \tau_0} \sum_{t=\tau_0+1}^{\tau_1} s_i(t) \\ \frac{1}{\tau_2 - \tau_1} \sum_{t=\tau_1+1}^{\tau_2} s_i(t) \\ \vdots \\ \frac{1}{\tau_k - \tau_{k-1}} \sum_{t=\tau_{k-1}+1}^{\tau_k} s_i(t) \end{pmatrix}^T$$

X_i به دست آمده با 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 جدایزیری W 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 (۴) به معادله (۶) تبدیل می‌شود:

(۶)

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

نهایتاً مسئله یافتن قطعاتی که درجه تفکیک بین کلاس‌ها را بیشینه کند به مسئله یافتن \hat{T} بینه تبدیل می‌شود که آن را می‌توان در رابطه (۷) خلاصه کرد:

$$\hat{T} = \text{argmax}_{T \in \mathcal{J}} J(T) = \text{argmax}_{\tau_0, \tau_1, \dots, \tau_k} J(T) \quad (7)$$

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

الگوریتم مورد استفاده ما برای حل معادله (۷)، الگوریتم LIR^{۱۰} اصلاح شده برای قطعه‌بندی هوشمند دادگان سری زمانی EEG است. در این روش پس از قطعه‌بندی اولیه، مکان جدید یک نقطه شکست به صورت بینه بین دو نقطه شکست همسایه اش انتخاب می‌شود و بدین ترتیب نقاط شکست به تدریج به سمت محل بهتر حرکت می‌کنند تا به نقطه بینه محلی برسند[۱۵]. نهایتاً با توجه به آنکه هدف، بیشینه کردن میزان تفکیک بین دو طبقه است؛ الگوریتم هنگامی متوقف می‌شود که در دو اجرای متوالی آن، مقدار معیار تفکیک پذیری (J) بیشتر نشود یا ثابت بماند. طبق این معیار LIR پس از تعداد محدودی اجرا، متوقف می‌شود.

پس از همگرا شدن الگوریتم، بردار ویژگی حاصل می‌شود. در این بردار، تعداد ویژگی‌ها به ازای هر کanal برابر تعداد قطعات (k) است که هر ویژگی به صورت میانگین مقادیر دامنه نمونه‌ها در قطعه مربوط، تعریف می‌شود (شکل ۳). بردار ویژگی برای هر حرف از متوالی کردن ویژگی‌های کanal‌های هفت‌گانه

استفاده شده است. در روش فیشر بردار نگاشتی ساخته می‌شود که نسبت مربع تفاضل میانگین بین طبقه‌ها به مجموع واریانس بین آنها را بیشینه می‌کند. برای رسیدن به این بردار ابتدا بردارهای میانگین (m_i) و دو نوع واریانس با نام‌های کوواریانس درون‌کلاسی^{۱۱} (W) و کوواریانس بین‌کلاسی^{۱۲} (B) تعریف می‌شود:

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

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

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

که در آن N_0 و N_1 بیانگر تعداد دادگان آموزش برای دو طبقه بوده و $y_i \in \{0,1\}$ بیانگر برچسب هر طبقه است.

حال بردار نگاشت فیشر با برداری که مقدار $J(a)$ را در رابطه (۳) بیشینه کند؛ داده می‌شود:

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

(FDC) در رابطه فوق همان معیار جدایزیری فیشر است. همان‌طور که پیش از این ذکر شد، هدف بیشینه کردن این معیار است. به همین منظور با مشتق‌گیری از رابطه (۳) بر حسب a و انجام یکسری عملیات ریاضی، رابطه (۴) به دست می‌آید که از آن به عنوان معیار جدایزیری فیشر استفاده خواهیم کرد.

$$J = (m_0 - m_1)^T W^{-1} (m_0 - m_1) \quad (4)$$

پس از این توضیحات، مسئله قطعه‌بندی هوشمند را به صورت ریاضی مطرح می‌کنیم. فرض کنید $E = \{(S_i, y_i) | i = 1, \dots, N\}$ مجموعه دادگان آموزش باشد که در آن $y_i \in \{0,1\}$ برچسب هر طبقه و S_i بیانگر دادگان EEG است که اگر هر تک ثبت EEG شامل n نمونه باشد، S_i به صورت $\{S_i(1), S_i(2), \dots, S_i(n)\}$ است، $S_i(t) \in R^d$ است. $T = (\tau_0, \tau_1, \dots, \tau_k)$ که $\tau_j \in n, \tau_j < \tau_{j+1}, \tau_0 = 0, \tau_k = n$ تعریف می‌شود و d نیز تعداد کanal‌ها را مشخص می‌کند. اگر تعداد قطعات مورد نظر برای قطعه‌بندی k باشد، نقاط شکست بین این قطعات به صورت τ_j تعریف می‌شود. در اینجا تابعی با نام $\text{Make Vector}(S_i, T)$ تعریف می‌شود که نرخ نمونه‌برداری در S_i را کاهش داده و آن را به یک بردار تبدیل می‌کند:

¹⁰ Within-class covariance¹¹ Between-class covariance¹² Local Iterative Replacement-LIR

صورت نمایی با زمان نمونهبرداری شد. بدین ترتیب اگر $f(t)$ سیگنال اصلی باشد، سیگنال پس از نمونهبرداری مجدد در نقطه t' دارای مقداری است که با استفاده از الگوریتم اسپلاین بر داده‌های $f(t)$ بدست می‌آید. رابطه t' در معادله (۸) نشان داده شده است:

$$t' = \frac{1}{\lambda} (e^{\lambda t} - 1) \quad (8)$$

در این رابطه λ ثابت زمانی رابطه نمایی و در حقیقت نشان‌دهنده شدت کاهش فرکانس نمونهبرداری با افزایش زمان است.

بوستانف پس از محاسبه سیگنال در نقاط جدید t' و اعمال پیش پردازش‌هایی - همان‌طور که در ابتدا بیان شد - برای استخراج ویژگی از تبدیل موجک پیوسته سیگنال $(W(s,t))$ استفاده کرد. او ابتدا تبدیل موجک پیوسته تک تک سیگنال‌های مربوط به هر کلاس را محاسبه کرد و پس از آن با استفاده از رابطه:

$$t^k(s, t) = \sqrt{\frac{N_1 N_2}{N_1 + N_2}} \frac{d^k(s, t)}{\delta^k(s, t)} \quad (9)$$

که در آن k شماره کانال، $\delta(s, t)$ واریانس مجموعه‌ای^{۱۵} داده‌ها در نقطه (s, t) و $d^k(s, t) = \overline{W_2^k(s, t)} - \overline{W_1^k(s, t)}$ معیاری از فاصله دو کلاس در نقطه (s, t) و $\overline{W_i^k(s, t)}$ میانگین ضرایب موجک کلاس i است؛ میزان جدابیتی دو دسته داده را در نقطه (s, t) کمی کرد. این جدابیتی برای هر کانال، دارای اکسترمم‌هایی در نقاط مختلف است. با کمی اغماض می‌توان گفت نقاط اکسترمم در میان نقاط همسایگی خود بهترین تفکیک را برای دو طبقه ایجاد می‌کنند. از این‌رو مقدار ضرایب تبدیل موجک پیوسته در این نقاط به عنوان ویژگی استخراج شده‌اند. موجک مادری که بوستانف در مطالعه‌اش از آن استفاده کرده است شکل تغییر یافته‌ای از موجک کلاه مکزیکی^{۱۶} است که از رابطه (۱۰) حاصل می‌شود:

$$\Psi(t) = (1 - 16t^2)e^{-\frac{16t^2}{2}} \quad (10)$$

در این تحقیق برای اجرای این روش، ابتدا با استفاده از کاهش نرخ نمونهبرداری، تعداد نمونه‌ها در هر کانال از ۲۴۰ به ۳۰ کاهش داده شد و سپس طبق روش اسپلاین، از سیگنال دوباره نمونهبرداری شد و ۳۰ نمونه جدید با فواصل غیر یکسان به دست آمد.

پشت سر هم به دست می‌آید. یعنی بُعد بردار حاصل برای هر کاراکتر برابر $7k$ می‌شود.

یک مسئله مهم دیگر در مورد این الگوریتم، انتخاب مقدار مناسب برای k 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. از طرفی اگر هم k بیش از اندازه بزرگ شود، زیاد شدن حجم دادگان و مشکل نفرین ابعاد همچنان باقی می‌ماند. بر این اساس، با آزمودن چند مقدار مختلف برای k و محاسبه صحت سیستم با استفاده از طبقه‌بند "SWLDA"^{۱۷} در هر آزمون، نهایتاً k مناسب برای دادگان استفاده شده در این مطالعه - که صحت در آن بیش از k های دیگر بود - برابر با مقدار ۱۰ ($k=10$) انتخاب شد.

۲-۳-۲- ضرایب موجک

با توجه به اینکه سیگنال ERP یک سیگنال متغیر با زمان و فرکانس است، به نظر می‌رسد استفاده از روش‌های حوزه زمان - فرکانس برای استخراج ویژگی از این سیگنال مناسب استند. بر این اساس و با توجه به مطالعات قبلی [۱۶]، در اینجا نیز از حالت خاصی از ضرایب موجک پیوسته استفاده شد.

از جمله عیوب‌هایی که برای تبدیل موجک پیوسته ذکر می‌کنند؛ بهینه نبودن آن است؛ زیرا اولاً اطلاعاتی که تولید می‌کند شدیداً همبسته است و بنابراین ایجاد افزونگی می‌کند، ثانیاً محاسبه آن زمان‌بر است. اما بوستانف [۱۷] با این دیدگاه که موجک پیوسته توانایی حفظ همه اطلاعات را دارد و از دور ریختن برخی اطلاعات جلوگیری می‌کند، از این روش برای آشکارسازی مؤلفه P300 در دادگان مسابقات BCI-2003 استفاده کرده است. وی معتقد بود استفاده از تبدیل موجک گستته موجک دارای بیشترین جدایی بین دو طبقه مورد نظر است؛ موجک دارای بیشترین جدایی بین دو طبقه مورد نظر است؛ ضرایب ممکن حفظ شوند و بتوان از میان کلیه این ضرایب بهترین ویژگی‌ها را استخراج کرد [۱۷]. بنابراین بوستانف ابتدا سیگنال را به قطعات یک ثانیه‌ای مطابق معمول کار بر این داده (یک ثانیه از زمان شروع هر تحریک) تقسیم کرد. پس از آن، این قطعه یک ثانیه‌ای با استفاده از الگوریتم اسپلاین^{۱۸} مجدداً به

¹³ Stepwise Linear Discriminant Analysis

¹⁴ Spline

¹⁵ Pooled Variance

¹⁶ Mexican hat

سفیدکنندگی W ، ماتریس کوواریانس \bar{R} به ماتریس همانی I تبدیل می‌شود.

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

$$S = W \bar{R} W' = I \quad (13)$$

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

$$S_t = W \bar{R}_t W' \quad (14)$$

$$S_{nt} = W \bar{R}_{nt} W' \quad (15)$$

از سه رابطهٔ اخیر به دست می‌آید:

$$S_t + S_{nt} = I \quad (16)$$

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

$$S_t = A_t \lambda_t A_t' \quad S_{nt} = A_{nt} \lambda_{nt} A_{nt}' \quad (17)$$

و از (۱۵) و (۱۶) نتیجه می‌شود:

$$A_t = A_{nt} \quad (18)$$

$$\lambda_t = I - \lambda_{nt} \quad (19)$$

در روابط فوق دیده می‌شود که هر دو کلاس بردارهای ویژه یکسان دارند و ترتیب صعود و نزول مقادیر ویژه آنها برعکس یکدیگر است. این موضوع نشان می‌دهد که اگر سیگنال‌ها مطابق این قاعده تبدیل شوند، سیگنال‌های جدید به گونه‌ای هستند که هر گاه سیگنال مربوط به طبقه یک باشد، اولین سطرهای ماتریس بردارهای ویژه دارای واریانس زیاد و آخرین سطرها دارای واریانس کم خواهند بود و برعکس. بدین ترتیب یک تبدیل بهینه کننده به دست می‌آید که می‌تواند حجم محاسبات را کاهش دهد. اگر A_t و A_{nt} را اولین و آخرین بردارهای ویژه با $N \times 1$ تعریف کنیم؛ صافی‌های مکانی با رابطهٔ (۱۹) طراحی شوند:

$$H_t = A_t' W \quad (19)$$

$H_{nt} = A_{nt}' W$ و دادگان فیلتر شده با این صافی‌ها از رابطهٔ (۲۰) به دست می‌آیند؛ که در آن H ماتریس یا برداری از صافی‌های منتخب است.

$$Y = H X \quad (20)$$

بعد از محاسبه بردارهای ویژه دو طبقه، می‌بایست از بردارهای ویژه متناظر با مقادیر ویژه بیشینه و کمینه برای هر طبقه استفاده کرد تا بیشترین میزان جدایزیتی در دو طبقه به دست آید. بدین منظور در این تحقیق از دو بردار ویژه ابتدایی و

در ادامه ضرایب تبدیل موجک پیوسته تمام سیگنال‌ها در تک تک کانال‌های انتخابی با استفاده از موجک مادر کلاه مکریکی معرفی و رابطهٔ (۱۰) محاسبه شد. برای این کار، مقیاس در محدوده ۱ تا ۷۲ قرار گرفت. بدین ترتیب تعداد بسیار زیادی ضریب به دست آمد. حال با استفاده از آزمون t به روش گفته شده در رابطهٔ (۹)، از این تعداد بسیار زیاد ضرایب، آنهایی که دارای بیشترین قابلیت تفکیک هستند – یعنی ضرایب موجک در نقاط اکسترم معيار t – انتخاب شده و به عنوان ویژگی در اختیار طبقه‌بند قرار گرفت.

۳-۲-۳-۲- الگوهای مکانی مشترک

الگوهای مکانی مشترک، روشی برای استخراج ویژگی است که ضمن کاهش بعد، به جای استفاده از تعداد زیادی کانال در فضایی جدید کانال‌های جایگزین کمتری را با قابلیت تفکیک بیشتر دو طبقه فراهم می‌کند. بنابراین برای استخراج ویژگی‌ها با این روش، از تمامی سیگنال‌های ثبت شده در ۶۴ کانال استفاده شد. از طرفی این روش سبب افزایش حجم دادگان می‌شد، لذا برای رفع این مشکل، بعد از اعمال یک فیلتر پایین گذر مناسب، از کاهش نرخ نمونه‌برداری استفاده کرده و تعداد دادگان در هر قطعه یک ثانیه‌ای از ۲۴۰ نمونه به ۲۴ نمونه کاهش داده شد و پس از آن، دسته ویژگی CSP برای دادگان محاسبه شد. برای روش‌تر شدن مطلب؛ پیش از ادامه بحث در اینجا به بیان مفهوم روش CSP می‌پردازیم:

فرض کنید X_t و X_{nt} هر کدام ماتریسی $N \times T$ باشند که 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 غیر هدف (فاقد P300) هستند. روش CSP بر اساس تجزیه مؤلفه اصلی ماتریس کوواریانس متوسط \bar{R} است که این ماتریس از مجموع ماتریس کوواریانس‌های دادگان هدف (\bar{R}_t) و غیر هدف (\bar{R}_{nt}) به دست می‌آید [۱۸]. با استفاده از تحلیل مؤلفه‌های اصلی (PCA)، ماتریس \bar{R} به صورت (۱۱) تجزیه می‌شود [۱۹]:

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

که در آن A ماتریس متعامد بردارهای ویژه \bar{R} و λ ماتریس قطری مقادیر ویژه \bar{R} است. حال با استفاده از ماتریس

پنجره زمانی قله تا قله	
شیب قله تا قله	
دامنه قله منفی N100	
تأخیر قله منفی N100	
P3N4 (اختلاف دامنه بین پیک مثبت در بازه [۵۰۰، ۱۸۵] میلی ثانیه و پیک منفی در بازه [۵۰۰، ۳۲۰] میلی ثانیه؛ که به ترتیب متناظر با مؤلفه های P300 و N400 هستند)	
P3N1 (اختلاف دامنه بین پیک مثبت در بازه [۵۰۰، ۱۸۵] میلی ثانیه و پیک منفی در بازه [۱۷۰، ۵۰] میلی ثانیه؛ که به ترتیب متناظر با مؤلفه های P300 و N100 هستند).	

برای سیگنال قطعه‌بندی شده به روش LIR نیز بر هر سیگنال k قطعه‌ای، چهار ویژگی شامل بیشترین مقدار دامنه سیگنال (max)، کمترین مقدار دامنه سیگنال (min)، میانگین مقدار دامنه‌ها (mean) و دامنه قله تا قله سیگنال (range) (به عنوان ویژگی‌های زمانی استخراج شدند).

۶-۳-۲- ویژگی‌های فرکانسی

دسته ویژگی آخر، ویژگی‌های فرکانسی هستند. در اینجا سه ویژگی معروف شده‌اند که از جمله مشخصات این ویژگی‌ها، استخراج اطلاعات مربوط به توزیع انرژی سیگنال در فرکانس‌های مختلف و وابسته نبودن آنها به میزان انرژی کلی سیگنال است[۱۰]. این سه ویژگی که بر روی دادگان خام هر یک از هفت کanal انتخابی، با نام ویژگی‌های فرکانسی تعریف شدن؛ عبارتند از فرکانس مده، میانه و میانگین که تعاریف آنها در رابطه (۲۱) آمده است:

$$S(f_{mode}) = \operatorname{Max}_f\{S(f)\} \quad (21)$$

$$\int_0^{f_{median}} S(w) dw = \int_{f_{median}}^{\infty} S(w) dw$$

$$f_{mean} = \frac{\int_0^{\infty} f \cdot S(f) df}{\int_0^{\infty} S(f) df}$$

در این رابطه، S چگالی طیف توان سیگنال و f فرکانس است.

دو بردار ویژه انتهایی ماتریس بردارهای ویژه، برای ساخت ماتریس صافی‌های مکانی استفاده شد و ماتریس H با اندازه N×4 به دست آمد. ویژگی‌های مستخرج از روش CSP، با توجه به تحقیقات قبلی [۲۰] در واقع همان دادگان زمانی هستند که با صافی مکانی تهیه شده، فیلتر شده‌اند؛ به صورتی که هر داده زمانی N×T بُعدی - که N تعداد کanal‌های ثبت (۶۴ تا) و T تعداد نمونه‌های زمانی از هر کanal است- به داده فیلتر شده 4×T بعدی تبدیل می‌شود و بدین ترتیب ضمن کاهش بعد، تفکیک‌پذیری دادگان نیز بیشتر شده است.

۶-۳-۳-۲- اعمال قطعه‌بندی هوشمند برروی خروجی روش

الگوهای مکانی مشترک

یکی دیگر از دسته ویژگی‌های مورد استفاده در این مقاله، دسته ویژگی ترکیبی CSP+LIR است. در این دسته ویژگی ترکیبی، CSP نقش یک کاهش‌دهنده بُعد را ایفا می‌کند و با اعمال آن می‌توان دادگان را به فضایی جدید منتقل کرد. با وجود استفاده از تعداد کanal‌های کمتری در این فضا، قابلیت تفکیک‌پذیری چندان کاهش نمی‌یابد؛ اما در عین حال از مزیت کاهش تعداد کanal‌ها بهره برده‌ایم. حال اگر با همین تعداد کanal کم نیز بتوان با استفاده از روش کاهش نرخ نمونه‌برداری و فقی آموزش‌پذیر حجم دادگان را کاهش داد و دادگان بهینه‌تری را انتخاب کرد؛ شاید نتیجه حاصل از نتایج هر دسته ویژگی به تنهایی، بهتر باشد. با تکیه بر این ایده، این دسته ویژگی ترکیبی ساخته شد و نتایج طبقه‌بندی با استفاده از آن محاسبه شد.

۶-۳-۴- ویژگی‌های شکلی - زمانی

در این مقاله در دو مقطع از ویژگی‌های شکلی - زمانی استفاده شده است. یک بار تعدادی ویژگی زمانی بر دادگان خام (البته پس از اعمال پیش‌پردازش‌ها) تعریف شد و یک بار هم پس از اعمال قطعه‌بندی هوشمند، تعدادی ویژگی دیگر بر سیگنال قطعه‌بندی شده تعریف شدند. ویژگی‌های تعریف شده بر دادگان خام عبارتند از:

تأخیر (زمانی که بیشینه دامنه سیگنال رخ می‌دهد)

دامنه (بیشترین مقدار دامنه سیگنال)

سطح مثبت (مجموع مقادیر مثبت سیگنال)

سطح منفی (مجموع مقادیر منفی سیگنال)

دامنه قله تا قله سیگنال

۲-۴- ارزیابی و انتخاب ویژگی

۳- نتایج

در این بخش ابتدا نتایج کمی، بیان شده و سپس به ارزیابی و تحلیل این نتایج پرداخته می‌شود.

۳-۱- 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 اولین مرحله معیار t برای تک تک ویژگی‌ها اجرا شد. متغیرهای مورد بررسی در این ارزیابی، ویژگی‌های استخراج شده از تک ثابت‌ها بودند و طبقه‌های مورد مقایسه، دو گروه حاوی P300 و فاقد P300 (هدف و غیرهدف) بودند.

در این آزمون قدر مطلق t-value با میزان اختلاف ویژگی در دو گروه، رابطه مستقیم و مقدار p-value با آن رابطه عکس دارد و به طور کلی می‌توان کلیه ویژگی‌ها را بحسب یکی از این دو مقدار مرتب کرد تا امکان مقایسه بین دسته ویژگی‌های مختلف فراهم شود؛ اما در اینجا با توجه به تعداد زیاد ویژگی‌ها انجام این کار منطقی به نظر نمی‌رسد. به همین دلیل در جدول‌های ۱ و ۲، به ترتیب تنها ۲۰ ویژگی برتر و ۲۰ ویژگی بدتر بر حسب قدر مطلق مقدار t-value به صورت نزولی مرتب شده‌اند تا بهترین و بدترین ویژگی‌ها مشخص شوند. طبق توضیحات فوق، هر اندازه یک ویژگی در جدول بالاتر باشد، برتر محسوب می‌شود. لازم است ذکر شود که نتایج این آزمون در دو حالت برابری یا عدم برابری واریانسها بسیار به یکدیگر نزدیک بود؛ لذا از ذکر نتایج آزمون واریانسها صرف نظر شده است.

با توجه به دو جدول (۱) و (۲) به نظر می‌رسد ضرایب موجک جزو بهترین ویژگی‌ها از نظر آزمون t بوده‌اند و در مقابل ویژگی‌های زمانی از این حیث چندان مطلوب نیستند.

برای روشن‌تر شدن بحث و فراهم شدن امکان مقایسه نتایج در روش‌های ارزیابی مختلف، در شکل (۴)، درصد حضور انواع مختلف ویژگی‌های ۲۰ ویژگی برتر t-test نشان داده شده است.

به علت تعدد روش‌ها، تعداد ویژگی‌های استخراج شده در مقایسه با حجم دادگان موجود بسیار زیاد است و احتمال دچار شدن به نفرین ابعاد بسیار زیاد است. علاوه بر این ممکن است قسمتی از اطلاعات این ویژگی‌ها همپوشان باشند و استفاده از تمام آنها نه تنها کمکی به بهبود صحت نهایی نکند بلکه سیستم را دچار افزونگی کرده؛ مشکل ساز نیز باشد. از این رو استفاده از روش‌های ارزیابی ویژگی برای تشخیص و انتخاب ویژگی‌های مناسب و برتر، ضروری به نظر می‌رسد. 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 دارند. در مرحله بعدی از طبقه‌بند LDA برای بررسی هر دسته ویژگی استفاده شد تا مشخص شود کدام دسته ویژگی توانایی بیشتری در تفکیک دو طبقه دارد. در نهایت نیز از روش تحلیل تفکیکی گام به گام جهت انتخاب ویژگی‌های مناسب‌تر استفاده شد. بدین ترتیب با استفاده از نرم-افزار SPSS (و با معیار Wilk's Lambda) هر دسته ویژگی تحلیل شد و ویژگی‌های منتخب هر دسته مشخص شدند.

۵- طبقه‌بندی

پس از استخراج ویژگی و انتخاب ویژگی‌های برتر، نوبت به بخش آخر سیستم آشکارساز P300 یعنی بخش طبقه‌بند می‌رسد. در سیستم‌های بازشناسی آماری الگو معمولاً رابطه‌ای دوطرفه بین بخش‌های استخراج ویژگی و طبقه‌بند وجود دارد. در واقع هرچه بار اطلاعاتی بردار ویژگی از طبقه‌های مورد تفکیک بیشتر باشد، یا تعریف ویژگی مناسب‌تر باشد، کار بخش طبقه‌بند ساده‌تر می‌شود. در این مقاله با توجه به طیف گسترده ویژگی‌هایی که در بخش استخراج ویژگی به کار گرفته شد (که شامل انواع ویژگی‌های زمانی، فرکانسی و زمانی- فرکانسی است) و با توجه به نتایج اولیه مطلوبی که به دست آمد، تصمیم گرفته شد در بخش طبقه‌بندی از طبقه‌بند ساده و کارآمد SWLDA (که در کارهای قبلی هم نتایج خوبی با استفاده از این طبقه‌بند گزارش شده بود) استفاده شود تا سیستم حاصل علاوه بر صحت تشخیص، از نظر زمان لازم برای اجرا و پیچیدگی محاسباتی نیز قابل قبول باشد. نتایج حاصل این فرضیه را تائید کردند.

هوشمند بهترین کارایی را از نظر معیار صحت طبقه‌بند داشته است.

جدول (۲)- ۲۰ ویژگی بدتر استخراج شده بر حسب آزمون t برای نمونه A

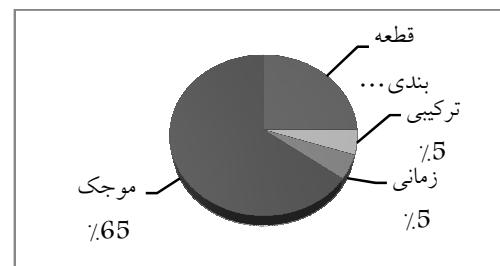
t_value	p_value	نام ویژگی	نوع ویژگی	شماره ویژگی
-0.004	0.997	Cz-NAR	زمانی سیگنال خام	۱
-0.015	0.988	Ch1-4	CSP+LIR	۲
0.020	0.984	Fz-LAT	زمانی سیگنال خام	۳
-0.023	0.982	Ch2-1	CSP	۴
-0.038	0.970	Ch2-1	CSP+LIR	۵
0.044	0.965	Cz-PP	زمانی سیگنال خام	۶
-0.044	0.965	Ch1-10	CSP	۷
0.051	0.960	Fz-AMP	زمانی سیگنال خام	۸
-0.068	0.946	Ch3-2	CSP+LIR	۹
-0.070	0.944	Pz-7	ضرایب موجک	۱۰
0.071	0.944	C3-8	قطعه‌بندی	۱۱
-0.078	0.938	Ch1-18	CSP	۱۲
-0.089	0.929	PO8-fmean	فرکانسی	۱۳
-0.099	0.921	Ch4-1	CSP	۱۴
-0.100	0.920	Pz-N100	زمانی سیگنال خام	۱۵
-0.102	0.919	Cz-PPS	زمانی سیگنال خام	۱۶
-0.102	0.919	PO7-10	قطعه‌بندی	۱۷
0.125	0.901	PO8-range	زمانی قطعه‌بندی شده	۱۸
-0.139	0.890	Ch1-17	CSP	۱۹
-0.139	0.889	Pz-P3N4	زمانی سیگنال خام	۲۰

جدول (۳)- نتایج ارزیابی گروهی ویژگی‌ها با استفاده از صحت طبقه‌بند LDA

نمونه B	نمونه A	درصد صحت	
		نوع ویژگی	قطعه‌بندی هوشمند
٪۹۶/۱۰	٪۹۴/۰۰		قطعه‌بندی هوشمند
٪۸۷/۳۰	٪۸۹/۲۰		شکلی- زمانی
٪۸۴/۳۰	٪۸۶/۱۰	LIR+CSP	ترکیبی
٪۷۹/۹۰	٪۸۵/۰۰		الگوهای مکانی مشترک
٪۷۹/۰۰	٪۸۱/۱۰		ضرایب موجک
٪۵۹/۳۰	٪۶۱/۰۰		فرکانسی

جدول (۱)- ۲۰ ویژگی برتر استخراج شده بر حسب آزمون t برای نمونه A

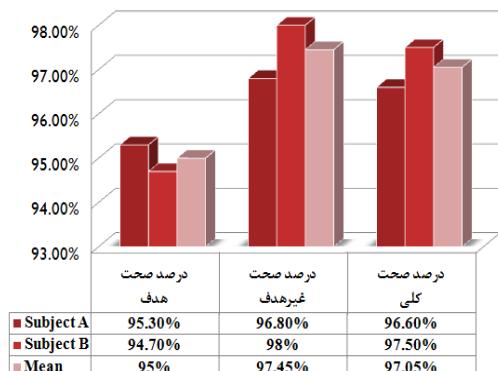
شماره ویژگی	نوع ویژگی	نام ویژگی	p_value	t_value
۱	ضرایب موجک	Cz-7	5.65E-53	-16.251
۲	قطعه‌بندی	Cz-5	1.10E-38	-13.571
۳	ضرایب موجک	Fz-6	3.76E-37	-13.263
۴	ضرایب موجک	Cz-27	2.52E-36	13.095
۵	ضرایب موجک	Pz-9	6.37E-36	-13.013
۶	ضرایب موجک	Cz-8	2.42E-31	-12.047
۷	قطعه‌بندی	Cz-4	8.53E-30	-11.708
۸	زمانی سیگنال خام	C3-LAT	1.62E-27	-11.195
۹	قطعه‌بندی	Pz-5	3.17E-27	-11.128
۱۰	ضرایب موجک	C4-7	7.24E-27	-11.045
۱۱	ضرایب موجک	Pz-33	2.17E-24	10.459
۱۲	ضرایب موجک	Fz-22	3.07E-24	10.423
۱۳	ضرایب موجک	Pz-1	1.06E-23	-10.292
۱۴	ضرایب موجک	Cz-1	2.26E-23	-10.211
۱۵	ضرایب موجک	Cz-21	1.01E-21	9.798
۱۶	ضرایب موجک	Fz-1	1.87E-21	-9.729
۱۷	قطعه‌بندی	C4-5	4.43E-21	-9.633
۱۸	ترکیبی CSP+LIR	Ch2-4	5.3E-21	9.612
۱۹	قطعه‌بندی	Fz-5	3.36E-20	-9.404
۲۰	ضرایب موجک	Pz-25	1.67E-19	9.219



شکل (۴)- درصد حضور انواع مختلف ویژگی در بین ۲۰ ویژگی برتر t-test در نمونه A

۲-۳- نتایج ارزیابی گروهی ویژگی‌ها مبنی بر صحت طبقه‌بند

معیار دوم برای ارزیابی دسته ویژگی‌ها، مقایسه درصد صحت تفکیک آنها با یک طبقه‌بندی کننده ثابت است. در این مقاله ابزار طبقه‌بندی اعمال شده بر دسته ویژگی‌ها، یک طبقه‌بند خطی LDA بوده است و صحت با روش LOO^{۱۷} محاسبه شده است. در جدول (۳) این نتایج برای نمونه‌های A و B آورده شده است. بر اساس این نتایج، برای هر دو نمونه، قطعه‌بندی



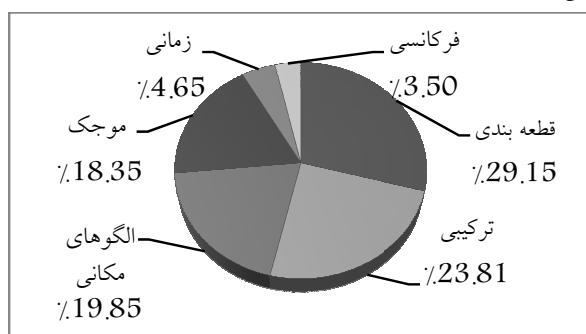
شکل (۷)- نتایج طبقه‌بندی مجموعه ویژگی برتر هر نمونه با استفاده از طبقه‌بند SWLDA

۳-۳- نتایج انتخاب ویژگی‌ها با روش تحلیل تفکیکی گام به گام

در روش سوم از تحلیل تفکیکی گام به گام برای انتخاب بهترین دسته ویژگی استفاده شد. این بار نیز ابتدا هر دسته ویژگی با استفاده از این روش، تحلیل و ویژگی‌های برتر آن انتخاب شد و سپس با استفاده از ویژگی‌های برتر هر دسته، مجموع ویژگی‌های منتخب برای هر نمونه به دست آمد. تعداد ویژگی‌های این مجموعه برای نمونه A برابر ۱۲۲ و برای نمونه B برابر ۱۲۵ است.

۳-۴- نتایج طبقه‌بندی مجموعه ویژگی انتخابی با طبقه‌بند

در بخش آخر سیستم پیشنهادی، مجموعه ویژگی‌های انتخابی هر یک از دو نمونه- که تعداد این ویژگی‌ها برای نمونه A برابر ۱۲۲ و برای نمونه B برابر ۱۲۵ است- به طبقه‌بند SWLDA داده شد. این طبقه‌بند ابتدا از میان این ویژگی‌ها، ویژگی‌های برتر را برای هر نمونه انتخاب و سپس درصد صحت نهایی سیستم را محاسبه کرد. این مجموعه ویژگی برتر برای نمونه A شامل ۴۲ مورد و برای نمونه B شامل ۴۴ مورد است و در شکل (۶) میانگین درصد حضور هر یک از شش دسته ویژگی در میان ویژگی‌های انتخابی دو نمونه، نشان داده شده است. شکل (۷) نیز صحت حاصل از این طبقه‌بندی را برای هر نمونه نشان می‌دهد.



شکل (۶)- میانگین درصد حضور انواع مختلف ویژگی در بین ویژگی‌های انتخابی طبقه‌بند SWLDA در دو نمونه

با توجه به جداول (۱) و (۲)، در جمع‌بندی ارزیابی ویژگی‌ها آزمون t دیده می‌شود که در میان ویژگی‌های برتر، بیشترین تعداد ویژگی متعلق به دسته ویژگی‌های ضرایب موجک و قطعه‌بندی هوشمند است و در مقابل هیچ ویژگی‌ای از دسته ویژگی‌های فرکانسی و الگوهای مکانی مشترک، رؤیت نمی‌شود. در میان ویژگی‌های ضعیفتر، طبق جدول (۲)، بیشترین ویژگی‌ها از گروه ویژگی‌های زمانی و الگوهای مکانی مشترک است؛ در حالی که بر خلاف جدول (۱)، تنها یک ویژگی از ضرایب موجک در میان ویژگی‌های ضعیف وجود دارد. پس به طور کلی می‌توان گفت ویژگی‌های ضرایب موجک و قطعه‌بندی هوشمند از نظر آزمون t ویژگی‌های مناسب‌تری بوده‌اند.

مسئله قابل توجه دیگر این است که پس از اعمال t-test بر هر دسته ویژگی دیده می‌شود که برای هر سه دسته قطعه‌بندی هوشمند، الگوهای مکانی مشترک و ویژگی‌های ترکیبی، ویژگی‌های متعلق به بازه زمانی ۲۵۰ تا ۵۵۰ میلی‌ثانیه ویژگی‌های مناسبی بوده‌اند؛ که این بازه زمانی همان محدوده رخداد مؤلفه P300 است و این نتایج نشان‌دهنده اختلاف شکل موج سیگنال در این محدوده و اهمیت آن در آشکارسازی P300 است. برتری ویژگی‌های متعلق به این بازه زمانی برای این سه دسته ویژگی، در انتخاب ویژگی به روش تحلیل تفکیکی گام به گام نیز دیده می‌شود.

در بررسی نتایج نهایی روش تحلیل تفکیکی گام به گام طبق شکل (۶)، دیده می‌شود که برای هر دو نمونه به ترتیب دسته ویژگی‌های قطعه‌بندی هوشمند، ترکیبی، الگوهای مکانی مشترک، ضرایب موجک، شکلی- زمانی و فرکانسی بیشترین

این روش برای آشکارسازی P300 استفاده شده است. به نظر می‌رسد امکان پژوهش بیشتر در این حوزه وجود دارد.

نکته دوم اینکه در میان ویژگی‌های شکلی- زمانی، با توجه

به نتایج به نظر می‌رسد ویژگی‌های تعریف شده بر سیگنال خام بهتر از ویژگی‌های تعریف شده بر سیگنال پس از قطعه‌بندی هستند. دلیل این امر می‌تواند در کاهش تعداد نمونه‌های سیگنال پس از قطعه‌بندی باشد که باعث گسترش بیشتر شکل موج سیگنال شده؛ معانی و مفاهیم ویژگی‌های زمانی تعریف شده را تا حدی تحت الشاعر قرار می‌دهد.

نکته آخر مربوط به نتایج ارزیابی گروهی ویژگی‌هاست که نشان می‌دهد دو دسته ویژگی قطعه‌بندی و ویژگی‌های شکلی- زمانی بهترین نتایج را در طبقه‌بندی دادگان دو طبقه کسب کرده‌اند. این نتیجه فرضیه برتری ویژگی‌های مرتبط با زمان و شکل موج سیگنال برای آشکارسازی مؤلفه P300 را- که در تحقیقات بسیاری بیان شده است- تقویت می‌کند. برای ارزیابی نهایی ویژگی‌های برتر انتخابی، از طبقه‌بند SWLDA استفاده شد. در طوری که در این طبقه‌بند تنها از ۴۲ ویژگی استفاده شده است. این مسئله پیچیدگی تابع تصمیم‌گیری را کمتر می‌کند و تعیین‌پذیری طبقه‌بند را افزایش می‌دهد. در واقع این طبقه‌بند با محدود کردن اندازه فضای ویژگی ورودی مشکل گستردگی ابعاد را برطرف می‌کند. در این روش، استخراج ویژگی به صورت خودکار انجام می‌شود و جملات غیر مهم از مدل حذف می‌شوند. همچنین می‌توان الگوریتم را به شیوه‌ای تنظیم کرد که سریع‌تر به همگرایی برسد.

۴- جمع‌بندی و نتیجه‌گیری

در این مقاله با هدف طراحی یک سیستم آشکارساز مؤلفه P300 مبتنی بر روش‌های بازناسانی آماری الگو، بخش‌های مختلف کار، بررسی شد. بدین منظور سیستم پیشنهادی با چهار بخش اصلی پیش‌پردازش، استخراج ویژگی، ارزیابی و انتخاب ویژگی و طبقه‌بندی معرفی شد و با توجه به تأکید بیشتر این مقاله بر بخش استخراج ویژگی، در این بخش از شش دسته ویژگی شامل قطعه‌بندی، ضرایب موجک، الگوهای مکانی مسترک، ویژگی‌های شکلی- زمانی، ویژگی‌های فرکانسی و دسته ویژگی ترکیبی الگوهای مکانی مسترک و قطعه‌بندی

تعداد ویژگی را در ویژگی‌های انتخاب شده دارند که در این میان تعداد ویژگی‌های شکلی- زمانی و فرکانسی بسیار اندک است.

شش دسته ویژگی تعریف شده به صورت گروهی نیز با پارامتر صحبت طبقه‌بندی مقایسه شدند که نتایج آن در جدول (۳) آمده است. طبق این نتایج برای هر دو نمونه، دسته ویژگی‌های برتر به ترتیب عبارتند از: ویژگی‌های قطعه‌بندی هوشمند، شکلی- زمانی، ترکیبی، الگوهای مکانی مشترک، ضرایب موجک و فرکانسی.

از جمله نکات قابل توجه در این مورد، قرار گرفتن ویژگی‌های موجک در رتبه‌ای پایین در میان دسته ویژگی‌های شش‌گانه است؛ در حالی که هم با توجه به نتایج t-test و نیز با توجه به حضور مؤثر این ویژگی‌ها در میان ویژگی‌های انتخابی SWLDA، این نتیجه کمی غیر قابل قبول به نظر می‌رسد. در بررسی علت این نتیجه ضعیف بایست مجدداً این نکته را یادآور شد که در روش ارزیابی ویژگی‌ها با استفاده از طبقه‌بند، نوع طبقه‌بند مورد استفاده می‌تواند در نتایج حاصل تاثیرگذار باشد. درباره دسته ویژگی موجک مورد استفاده در این مقاله نیز باید گفت که با توجه به بُعد بالای این دسته ویژگی (۲۸۱ ویژگی برای نمونه A و ۳۱۰ ویژگی برای نمونه B)، هنگام ارزیابی این ویژگی‌ها با طبقه‌بند LDA، مشکل نفرین ابعاد رخ می‌دهد و جواب‌ها ضعیف می‌شوند. در صورتی که اگر از طبقه‌بند SWLDA برای تفکیک دادگان دو طبقه استفاده شود، با توجه به فرایند انتخاب ویژگی‌ای که در این طبقه‌بند انجام می‌شود، مشکل بُعد بالای بردار ویژگی حل شده؛ نتایج بسیار بهبود می‌یابد. برای مثال درصد صحبت این دسته ویژگی با طبقه‌بند SWLDA برای نمونه A برابر ۹۳/۸٪ می‌شود؛ در حالی که میزان صحبت این ویژگی در همین نمونه با طبقه‌بند LDA برابر ۸۱/۱٪ گزارش شده بود.

در مورد نتایج حاصل از ارزیابی ویژگی‌های مختلف، چند نکته قابل توجه است:

اول آنکه در تمامی روش‌های ارزیابی ویژگی، دسته ویژگی قطعه‌بندی هوشمند یکی از بهترین روش‌های استخراج ویژگی شناخته شد؛ اما با وجود این تاکنون در مقالات بسیار کمی از

مراجع

- [1] Polich J., "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: 1073-1091.
- [2] Wolpaw J.R., Birbaumer N., McFarland D. J., Pfurtscheller G., Vaughan T. M., Brain-computer interfaces for communication and control; *J. Clin. Neurophysiol*, 2002; 113: 767-791.
- [3] Bayliss J. D., "A Flexible Brain-Computer Interface," Phd. Thesis, University of Rochester, Rochester, New York, 2001.
- [4] Serby H., Yom-Tov E., Inbar G. F., An improved P300-based brain-computer interface; *IEEE Trans. on Neural Systems and Rehabilitation Eng.*, 2005; 13(1): 89-98.
- [5] BCI Competition 2005. ida.first.fraunhofer.de/projects/bci/competition_ii
- [6] Rakotomamonjy A., Guigue V., BCI Competition III: Dataset II- Ensemble of SVMs for BCI P300 Speller; *IEEE Trans.on Biomed. Eng.*, 2008; 55(3): 1147-1154.
- [7] Salvaris M., Sepulveda F., Wavelets and ensemble of FLDs for P300 classification; *4th Int. IEEE/EMBS Conf. on Neural Eng.*, 2009; 9: 339-342.
- [8] Yang L., Zongtan Z., Dewen H., Guohua D., T-weighted Approach for Neural Information Processing in P300 based Brain-Computer Interface; *Int. Conf. on Neural Net. and Brain*, 2005; 5(3): 1535-1539.
- [۹] قشونی مجید، خلیل زاده محمدعلی، بهبود تشخیص مؤلفه های شناختی در سیگنال ERP تک ثبت با استفاده از فضای ویژگی جدید و الگوریتم ژنتیک، دوازدهمین کنفرانس مهندسی پزشکی ایران، آبان ۱۳۸۴
- [۱۰] ابوطالبی وحید، تجزیه و تحلیل مؤلفه های شناختی سیگنال الکتریکی مغز و کاربرد آن در دروغ سنجی، پایان نامه دکتری مهندسی پزشکی - بیوالکتریک، دانشگاه صنعتی امیر کبیر، اردیبهشت ۱۳۸۵
- [۱۱] سیدصالحی سیده زهره، ع. مطیع نصرآبادی علی، ابوطالبی وحید، تشخیص مؤلفه P300 با استفاده از مدل های مخفی مارکوف، چهاردهمین کنفرانس مهندسی پزشکی ایران، بهمن ۱۳۸۶
- [12] Seyyedsalehi Z., Nasrabad A.M., Abootalebi V., Committee Machines and Quadratic B-spline Wavelet for the P300 Speller Paradigm; *IEEE/ACS Conf. on Comp. Sys. And Appl.* 2008: 866-869, 2008.
- [13] Sakamoto Y., Aono M., Supervised Adaptive Downsampling for P300-based Brain Computer Interface; *31st Int. Conf. on IEEE EMBS*, 2009: .567-570.

استفاده شد. برخی از این ویژگی ها پیش از این نیز برای آشکارسازی مؤلفه P300 پرکاربرد بودند؛ اما برخی دیگر از جمله قطعه بنده هوشمند، الگوهای مکانی مشترک و یا ویژگی های ترکیبی تا کنون چندان در این حوزه به کار نرفته بودند. با وجود این، با توجه به خواص فیزیولوژیک سیگنال P300 به نظر می رسید که این ویژگی ها توانایی خوبی در تفکیک سیگنال های P300 از سیگنال های فاقد P300 داشته باشند و بر همین اساس این شش دسته ویژگی تعریف شدند. سپس این ویژگی ها به صورت تکی با آزمون t و به صورت گروهی با استفاده از درصد صحت یک طبقه بنده ثابت، ارزیابی شدند که این دو روش نقاط ضعف و قوت هر دسته ویژگی را نمایان کرد. نهایتاً برای رسیدن به یک مجموعه ویژگی های منتخب تحلیل تفکیکی گام به گام به کار برده شد و ویژگی های منتخب به طبقه بنده SWLDA داده شد تا تفکیک دادگان دو طبقه هدف و غیر هدف انجام شود.

این سیستم توانست با استفاده از طبقه بنده SWLDA و با ترکیبی منتخب از هر شش دسته ویژگی تعریف شده به صحت میانگین $0.97/0.05$ در تشخیص مؤلفه P300 برسد. این نتیجه از نتایج سایر مطالعات موجود در این زمینه و بر این دادگان، برتر است. مثلاً همانطور که در مقدمه اشاره شد، سید صالحی با استفاده از مدل مخفی مارکوف، ضرایب موجک-B و Quadratic spline و طبقه بنده SVM به صحت $0.95/0.08$ در تفکیک دادگان P300 مسابقات BCI سال ۲۰۰۵ رسیده است. در تحقیقات برتر خارجی نیز می توان به نتایج Rakotmamonjy و Rakotmamonjy Salvaris اشاره کرد. Rakotmamonjy که برنده مسابقه BCI در سال ۲۰۰۵ بوده است، توانسته با استفاده از نمونه های زمانی سیگنال و بکارگیری چند طبقه بنده ماشین بردار پشتیبان^{۱۸}، به صحت میانگین $0.96/0.05$ در تشخیص حرف برسد و Salvaris نیز با روش Ensamble of FLDs به صحت 0.95 برای همان دادگان دست یافته است. نکته قابل تأمل در مقایسه نتایج آن است که برای تشخیص هر حرف، بایست از ترکیب سطر و ستون های حاوی P300 استفاده کرد و بنابراین درصد صحت تشخیص حرف عموماً بالاتر از درصد صحت تشخیص P300 است.

^{۱۸} Ensemble of SVMs

- [14] Foley D. H., Sammon Jr. J. W., An Optimal Set of Discriminant Vectors; IEEE Trans. on Comp. 1975; 24(3): 281-289.
- [15] Pavlidis T., Waveform Segmentation Through Functional Approximation; IEEE Trans. on Comp., 1973; 22(7): 689-697.
- [16] Markazi S.A., Qazi S., Stergioulas L.S., Ramchurn A., Bunce D., Wavelet Filtering of the P300 Component in Event-Related Potentials; In Proc. 28th IEEE EMBS Conf., Med. and Biomed. Soc., 2006: 1719-1722.
- [17] Bostanov V., BCI competition 2003-data sets Ib and IIb: feature extraction from event-related brain potentials with the continuous wavelet transform and the t-value scalogram; IEEE Trans. on Biomed. Eng. 2004; .51(6): 1057-1061.
- [18] Pires G., Nunes U., Castelo-Branco M., P300 spatial filtering and coherence-based channel selection; 4th IEEE EMBS Conf. on Neural Eng., NER '09, 2009:.311-314.
- [19] Jolliffe I. T., "Principal Component Analysis," Second Edition. Springer Series in Statistics, 2002.
- [20] Combaz1 A., Manyakov N.V., Chumerin1 N., Suykens J. A. K., Van Hulle M. M., Feature Extraction and Classification of EEG Signals for Rapid P300 Mind spelling; IEEE Int. Conf. on Machine Learning and Appl., 2009: 386-391.