

P300 Component Detection by using Weighted Common Temporal Pattern

F. S Rizi¹, V. Abootalebi^{2*}, M.T. Sadeghi³

¹M.Sc Student, Electrical Engineering Department, Yazd University, Yazd, Iran

²Associate Professor, Electrical Engineering Department, Yazd University, Yazd, Iran

³Assistant Professor, Electrical Engineering Department, Yazd University, Yazd, Iran

Receipt in the online submission system: 17 October 2016, received in revised form: 9 February 2017, accepted: 25 March 2017

Abstract

Detection of Event Related Potentials (ERP) is an important prerequisite in the ERP-based Brain-Computer Interface (BCI) systems. In order to increase the classification accuracy in these systems, different filtering methods are used for improving the signal to noise ratio. This improvement facilitates the diagnosis and classification of the ERPs. In a number of studies, the performance of P300 detection systems which are based on common spatial pattern (CSP) and common temporal pattern (CTP) has been investigated. The former uses spatial filters while the latter is based on temporal filters. In these methods the filters are trained such that they maximize variance of one class and simultaneously minimize the other class variance. The associated results show that in P300 speller systems, the temporal filters outperform the spatial filters. In this study, in order to improve the performance of the CTP based systems, a Weighted Common Temporal Pattern (WCTP) algorithm which is a combined method is proposed. In this algorithm, each category of features has a weight based on the importance of its eigenvalues. In fact, the features produced by the initial and final CTP filters have more weight in the decision making process. In the combined method used in this algorithm, the LDA classifiers are used. It is shown that the set of features obtained by the WCTP method leads to an average classification accuracy of 90.2 percent which is about 4 percent better than the CTP method. The experiments are performed considering two different subjects on 5 trials.

Key words: *P300 component, a common spatial pattern (CSP), a common temporal pattern (CSP), weighted common temporal pattern (WCTP).*

***Corresponding author**

Address: Electrical Engineering Department, Yazd University, P.O.Box: 89195-741, Yazd, Iran

Tel: +98-35-31232398

Fax: +98-35-38200144

E-mail: abootalebi@yazd.ac.ir

آشکارسازی مولفه P300 سیگنال مغزی با استفاده از الگوی زمانی مشترک وزن دار

فرشته سلیمیان ریزی^۱، وحید ابوطالبی^{۲*}، محمدتقی صادقی^۳

^۱ دانش آموخته کارشناسی ارشد، دانشکده مهندسی برق، دانشگاه یزد، یزد

^۲ دانشیار، دانشکده مهندسی برق، دانشگاه یزد، یزد

^۳ استادیار، دانشکده مهندسی برق، دانشگاه یزد، یزد

تاریخ ثبت در سامانه: ۱۳۹۵/۷/۲۶، بازنگری: ۱۳۹۵/۱۱/۲۱، پذیرش قطعی: ۱۳۹۶/۱/۵

چکیده

آشکارسازی پتانسیل‌های وابسته به رخداد، یک پیش‌نیاز مهم در سیستم‌های واسط مغز و کامپیوتر (*BCI*) مبتنی بر *ERP* است. برای افزایش درصد صحت طبقه‌بندی در این سیستم‌ها، از روش‌های فیلترینگ مختلفی استفاده می‌شود تا نرخ سیگنال به نویز بهبود یابد و در نتیجه تشخیص و طبقه‌بندی پتانسیل‌های وابسته به رخداد آسان شود. پیش از این، عملکرد فیلترهای الگوی مکانی مشترک (*CSP*) و الگوی زمانی مشترک (*CTP*) که به ترتیب فیلترهای مکانی و زمانی هستند، در آشکارسازی مولفه *P300* بررسی شده است. در این روش‌ها، فیلترها به صورتی آموزش داده می‌شوند که واریانس یک کلاس، بیشینه شده و واریانس کلاس دیگر به‌طور همزمان کمینه شود. نتایج نشان داده است که در سیستم *P300Speller* عملکرد فیلترهای زمانی *CTP* بهتر از فیلترهای مکانی *CSP* است. در این مطالعه برای بهبود عملکرد روش *CTP*، الگوریتم ترکیبی الگوی زمانی مشترک وزن دار (*WCTP*) پیشنهاد شده است. در این روش به هر دسته ویژگی، وزنی متناسب با اهمیت مقادیر ویژه مربوطه داده می‌شود. در واقع در این روش، ویژگی‌های تولیدی توسط فیلترهای ابتدایی و انتهایی *CTP* وزن بیشتری در تصمیم‌گیری دارند. در روش ترکیبی به کار رفته در این الگوریتم، از طبقه‌بندی کننده‌های *LDA* استفاده شده است. با توجه به آزمایش‌های انجام شده روی دو نمونه مورد بررسی و با ۵ ثبت میانگین‌گیری شده، دسته ویژگی به‌دست آمده توسط *WCTP* با میانگین درصد صحت طبقه‌بندی ۹۰/۲ بهترین عملکرد را از خود نشان داد که نشانگر بهبود تقریباً ۴ درصدی نسبت به *CTP* است.

کلیدواژه‌ها: مولفه *P300*، الگوی مکانی مشترک (*CSP*)، الگوی زمانی مشترک (*CTP*)، الگوی زمانی وزن دار (*WCTP*).

* نویسنده مسئول

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

تلفن: ۳۱۲۳۳۳۹۸ (۳۵) ۰۹۸+

دورنگار: ۳۸۲۰۰۱۴۴ (۳۵) ۰۹۸+

پست الکترونیکی: abootalebi@yazd.ac.ir


۱- مقدمه

واسط مغز و کامپیوتر^۱ به وسایلی ارتباطی گفته می‌شود که فعالیت‌های مغزی را به فرمان‌های الکتریکی تبدیل می‌کند؛ در نتیجه کاربر را قادر می‌سازد تا با استفاده از افکار خود، برنامه‌ها و وسایل خاصی را کنترل کند [۱]. می‌توان هم در کلینیک‌های تخصصی و هم در زندگی روزمره از این رابطه‌ها استفاده کرد.

طرح کلی یک سیستم BCI در شکل (۱) نشان داده شده است. در این سیستم‌ها، ابتدا سیگنال الکتریکی مغز به وسیله الکترودهای مستقر روی پوست سر ثبت می‌شود. این داده‌های خام، ورودی سیستم BCI را تشکیل می‌دهند؛ سپس پیش پردازش‌هایی مانند فیلترینگ، کاهش نرخ نمونه برداری و قطعه‌بندی روی سیگنال ثبت‌شده انجام می‌شود. مرحله سوم یا استخراج ویژگی، مهم‌ترین مرحله در هر سیستم BCI است. در این مرحله، ویژگی‌های وابسته به دستور و قابل تفکیک از سیگنال‌های مغزی حاصل از مرحله پیش‌پردازش استخراج می‌شوند. برای استخراج این ویژگی‌ها معمولاً از الگوریتم‌های شناسایی آماری الگو استفاده می‌شود. در مرحله طبقه‌بندی، مرزهای تفکیک برای دسته‌بندی ویژگی‌ها یا همان دستورات کاربر مشخص می‌شود. در نهایت سیگنال طبقه‌بندی شده توسط الگوریتم‌های مناسب مورد استفاده قرار می‌گیرد تا برنامه‌های خاصی را کنترل کند. میان تکنیک‌های متنوع ثبت سیگنال مغزی، این مطالعه روی سیگنال الکتروانسفالوگرام (EEG^۲) تمرکز دارد. سیگنال EEG به دلیل غیرتهاجمی بودن، مزیت اقتصادی و رزولوشن یا قدرت تفکیک زمانی بالا مناسب‌تر از سایر روش‌های ثبت سیگنال و نظارت مغزی موجود برای کاربردهای BCI است [۲]. اگرچه سیگنال EEG، سیگنالی تصادفی است، اما می‌توان ریت‌های مختلف مغزی را از آن استخراج کرد و در سیستم BCI استفاده کرد؛ مانند پتانسیل‌های قشری کند [۳]، ریت میو و بتا [۴ و ۵]، تصورات حرکتی [۶]، پتانسیل برانگیخته حالت پایدار (SSVEP^۳) [۷] و پتانسیل برانگیخته P300 [۸]، که از بین آنها، هدف این مطالعه بررسی سیستم‌های BCI مبتنی بر P300 است.

چاپمن^۴ و برایدن^۵ [۹] و ساتون^۶ و همکاران [۱۰] به ترتیب در سال ۱۹۶۴ و ۱۹۶۵، به‌طور مستقل قله‌های پدیده‌ای حدود

۳۰۰ میلی ثانیه پس از تحریک هدف را کشف کردند. این مولفه به‌عنوان P300 شناخته می‌شود. در آزمایش‌های کنترل شده برای ثبت مولفه P300، نمونه تحت آزمایشی آموزش داده به برخی از تحریک‌ها به صورت خاصی پاسخ دهد. این تحریک‌ها می‌توانند دیداری، شنیداری یا حسی باشند. مولفه P300، بیشتر از ناحیه آهیانه‌ای مرکزی^۷ مغز به‌دست می‌آید و یکی از مهم‌ترین امضاهای فرایندهای شناختی است. مولفه P300، وضعیت به‌نسبت پایداری در بیماران با سندروم قفل شدگی دارد و حتی پس از چندین آسیب در ساقه مغز نیز ظاهر می‌شود [۱۱]. فارول^۸ و دانچین^۹ برای اولین بار نشان دادند که می‌توان از این سیگنال به‌طور موفقیت آمیزی در کاربردهای BCI استفاده کرد [۱۲].



شکل (۱) - شمای کلی یک سیستم BCI

همانطور که اشاره شد، طراحی یک سیستم BCI در چهار مرحله اصلی انجام می‌شود (شکل (۱)). بلوک‌های استخراج ویژگی و طبقه‌بندی، نقش بسیار مهمی در یک سیستم BCI دارند و موفقیت این سیستم‌ها به میزان زیادی به توانایی استخراج ویژگی‌های مناسب و طبقه‌بندی موثر ویژگی‌ها وابسته است. تاکنون روش‌های زیادی برای استخراج ویژگی و طبقه‌بندی پتانسیل‌های وابسته به رخداد (ERP^{۱۰}) مطرح شده است. یکی از روش‌های کارآمد برای استخراج ویژگی، استفاده از فیلترهای مکانی است. پیش از این، کارایی فیلتر کردن مکانی برای بهبود رزولوشن مکانی و نسبت سیگنال به نویز در سیگنال EEG ثابت شده است. برخی از انواع فیلترهای مکانی مبتنی بر روش‌های مرجع‌دهی^{۱۱} EEG هستند؛ مانند مرجع میانگین‌گیری مشترک^{۱۲} و لاپلاسیان کوچک و بزرگ^{۱۳} [۱۳]. این فیلترها به‌عنوان فیلترهای مکانی بالاگذری عمل می‌کنند

⁷ central-parietal

⁸ Farwell

⁹Donchin

¹⁰ Event Related Potential

¹¹EEG referencing

¹²Common Average Reference

¹³Large Laplacian, Small Laplacian

¹ Brain Computer Interface (BCI)

² Electroencephalography

³ Steady-State Visual Evoked Potentials

⁴Chapman

⁵Bragdon

⁶ Sutton

آزمایش شده و کارایی آن‌ها براساس معیارهای خاص تعیین می‌شود. در این مقاله، ابتدا از دو روش استخراج ویژگی الگوی مکانی مشترک (CSP) و الگوی زمانی مشترک (CTP) برای استخراج ویژگی استفاده می‌شود و سپس، الگوریتم پیشنهادی برای آشکارسازی مولفه P300 بیان می‌شود. در این الگوریتم به هر یک از طبقه‌بندی کننده‌ها، وزنی متناسب با اهمیت مولفه ویژه به کار رفته در ساخت فیلترهای زمانی داده می‌شود؛ از این رو، این روش را الگوی زمانی مشترک وزن دار (WCTP) می‌نامیم. در ادامه، روابط ریاضی و الگوریتم‌های به کار رفته در هر یک از این روش‌ها تشریح می‌شوند.

۲-۱- الگوی مکانی مشترک (CSP)

CSP، یک روش استخراج ویژگی قوی برای ایجاد تفکیک بین دو کلاس ارائه داده است. هدف این روش یافتن فیلتر مکانی H است، به طوری که واریانس یک کلاس بیشینه و واریانس کلاس دیگر هم‌زمان کمینه شود؛ در حالی که مجموع واریانس دو کلاس برابر با یک می‌شود [۱۸]. اگر $X_1(i)$ و $X_2(i)$ ماتریس‌هایی $N \times T$ در نظر گرفته شوند، که N تعداد کانال‌ها، T تعداد نمونه زمانی هر کانال، اندیس ۱ نشان دهنده وضعیت هدف (وجود سیگنال P300) و اندیس ۲ نشان دهنده وضعیت غیرهدف (عدم وجود سیگنال P300) می‌باشد، ماتریس‌های نرمال کوواریانس مکانی \bar{R}_1 و \bar{R}_2 از رابطه زیر محاسبه می‌شوند:

$$\bar{R}_a = \frac{1}{n} \sum_{i=1}^n \frac{X_a(i)X_a'(i)}{\text{trace}(X_a(i)X_a'(i))}, a \in \{1, 2\} \quad (1)$$

در رابطه بالا، n نشان دهنده تعداد ثبت‌های هدف و غیر هدف در مجموعه داده‌های آموزشی و علامت « ' » نشان دهنده عملگر ترانهاده است.

ماتریس ترکیب مکانی \bar{R} به صورت زیر تعریف می‌شود:

$$\bar{R} = \bar{R}_1 + \bar{R}_2 = A \lambda A' \quad (2)$$

که در آن A ماتریس متعامد بردارهای ویژه \bar{R} و λ ماتریس قطری مقادیر ویژه \bar{R} است. حال با استفاده از ماتریس سفیدکنندگی W ، ماتریس کوواریانس \bar{R} به ماتریس همانی I تبدیل می‌شود.

$$W = \lambda^{-\frac{1}{2}} A' \quad (3)$$

$$S = W \bar{R} W' = W (\bar{R}_1 + \bar{R}_2) W' = I \quad (4)$$

که فعالیت محلی را تقویت کرده و فعالیت توزیع شده را ضعیف می‌کند. Koles در سال ۱۹۹۵ یک ایده متفاوت فیلترهای مکانی با نام الگوهای مکانی مشترک (CSP)، که بیشتر برای روش‌های بازشناسی الگو طراحی شده است، را مطرح کرد [۱۴]. از این ایده نخستین بار برای تجزیه مؤلفه نروفیزیولوژیکی در کاربردی کلینیکی از الکتروانسفالوگرافی استفاده شد [۱۵]. به تازگی روش CSP به روش‌های الگوی مکانی - طیفی مشترک (CSSP) و الگوی مکانی تنک مشترک (CSSSP) گسترش یافته است [۱۶ و ۱۷]. در مسائلی که همپوشانی قابل توجهی بین دوره‌های زمانی دسته‌های مجاور وجود داشته باشد (مانند P300 Speller)، کارایی فیلترهای مکانی کاهش می‌یابد. برای حل این مشکل در روش CSP، الگوی مکانی - زمانی مشترک (CSTP) پیشنهاد شده است [۱۸]. در روش CSTP، ویژگی‌های مکانی و زمانی سیگنال به‌طور هم‌زمان وجود دارند و در نتیجه این روش عملکرد بهتری نسبت به روش CSP در آشکارسازی پتانسیل‌های برانگیخته دارد. در سال ۲۰۱۱، Yu و همکاران نشان دادند که کارایی فیلترهای زمانی مبتنی بر الگوی زمانی مشترک (CTP) بهتر از فیلترهای مکانی مشابه مبتنی بر CSP است [۱۸].

در این مطالعه، روش جدیدی مبتنی بر CTP برای استخراج ویژگی پیشنهاد می‌شود. در این روش، از ترکیب طبقه‌بندی کننده‌ها استفاده شده است تا دو کلاس شامل مولفه P300 و فاقد مولفه P300 را متمایز کند. ابتدا، CTP بر داده‌های EEG پیش‌پردازش شده هر کانال به صورت مجزا اعمال می‌شود؛ سپس به تعداد فیلترهای انتخابی (فیلترهای منتخب با مقادیر ویژه‌ای که شامل بیشترین اطلاعات تفکیک برای هر دو وضعیت هدف و غیر هدف هستند، رابطه دارد)، به طبقه‌بندی کننده آموزش داده می‌شود. پس از آن، ویژگی‌های مربوط به آمین مقدار ویژه برای همه کانال‌ها به صورت وزن دار با هم ترکیب می‌شوند؛ در نهایت خروجی طبقه‌بندی کننده‌ها براساس اهمیت مولفه‌های ویژه، ترکیب می‌شوند.

۲- تئوری روش‌ها

تلاش می‌شود که در روش‌های مبتنی بر شناسایی آماری الگو به جای استفاده از داده‌ها در فضای اطلاعات خام از فضای ویژگی مناسبی استفاده شود که بازنمایی بهتری از اطلاعات داشته باشد. در گام اول، فضای ویژگی مناسب برای هر کاربرد با استفاده از اطلاعات جنبی برای داده‌های مورد بررسی انتخاب می‌شود. در گام بعدی، ویژگی‌های مختلف پیشنهادی

دوره مجاور در مفهوم الگوهای زمانی متفاوت هستند؛ برای این منظور از الگوی زمانی مشترک استفاده می‌شود. روند به‌دست آوردن فیلترهای زمانی و استخراج ویژگی، مشابه با روش CSP است. ماتریس‌های نرمال کوواریانس زمانی \tilde{R}_1 و \tilde{R}_2 از رابطه زیر به‌دست می‌آیند:

$$\tilde{R}_a = \frac{1}{n} \sum_{i=1}^n \frac{X_a'(i)X_a(i)}{\text{trace}(X_a'(i)X_a(i))}, \quad a \in \{1, 2\} \quad (13)$$

ماتریس ترکیب زمانی \tilde{R} به‌صورت زیر تعریف می‌شود:

$$\tilde{R} = \tilde{R}_1 + \tilde{R}_2 \quad (14)$$

سایر روابط، مشابه با روش CSP است.

۲-۳- الگوی زمانی مشترک وزن دار (WCTP)

روش پیشنهادی الگوی زمانی مشترک وزن دار بر این ایده استوار است که هر یک از بردارهای ویژگی، وزنی متناسب با اهمیت مقدار ویژه مربوطه داشته باشند. در این روش، ابتدا CTP بر هر یک از کانال‌های مجموعه آموزش به‌طور جدا اعمال می‌شود و فیلترهای زمانی، تعلیم داده می‌شوند؛ سپس داده‌های آموزش با استفاده از فیلترهای منتخب به فضای ویژگی نگاشت می‌شوند. لازم به ذکر است که فیلترهای منتخب در ارتباط با مقادیر ویژه‌ای هستند که بیشترین میزان تفکیک پذیری بین دو کلاس هدف و غیر هدف را ایجاد می‌کنند (یعنی اولین و آخرین سطرها ماتریس بردارهای ویژه، بیشترین اهمیت را در تفکیک بین دو کلاس خواهند داشت و پس از آنها دومین سطر و سطر ماقبل آخر و به همین ترتیب تا آخر). ایده ابتدایی این روش از کار الساوی^{۱۵} و همکاران گرفته شده است [۱۹]. در الگوریتم پیشنهادی آنها، وزنی متناسب با بزرگی مقادیر ویژه به بردارهای ویژگی در روش PCA اختصاص می‌یافت.

در مرحله بعد، بردارهای ویژگی الحاقی از کنار هم قرار دادن ویژگی‌های با رتبه مقدار ویژه یکسان در تمام کانال‌ها، همانطور که در شکل (۲) مشاهده می‌شود، به‌دست می‌آیند. سپس یک طبقه‌بندی کننده به هر یک از بردارهای ویژگی الحاقی اعمال می‌شود. در این جا، خروجی هر یک از طبقه‌بندی کننده‌ها یک نمره است. نمره کلی از جمع وزن دار نمره طبقه‌بندی کننده‌ها به‌دست می‌آید.

$$\text{total_score} = \sum_{i=1}^M (\eta_i * \text{score}_i) \quad (15)$$

با توجه به رابطه بالا، ماتریس S_1 و S_2 به‌صورت زیر تعریف می‌شوند:

$$S_1 = W\tilde{R}_1W' \quad (5)$$

$$S_2 = W\tilde{R}_2W'$$

با استفاده از سه رابطه قبل:

$$S_1 + S_2 = I \quad (6)$$

با اعمال آنالیز مؤلفه‌های اصلی به روابط (۵) داریم:

$$S_1 = A_1\lambda_1A_1', \quad S_2 = A_2\lambda_2A_2' \quad (7)$$

و با توجه به معادلات (۶) و (۷) به‌دست می‌آید:

$$A_1 = A_2 = A \quad (8)$$

$$\lambda_1 = I - \lambda_2 \quad (9)$$

اگر A به‌عنوان m بردار ویژه با بیشترین قدرت تفکیک فرض شود ($m < N$)، فیلترهای مکانی به‌صورت زیر طراحی می‌شوند:

$$H = A'W \quad (10)$$

و داده‌های فیلتر شده توسط این فیلترها، از رابطه زیر به‌دست می‌آیند.

$$Z = HX \quad (11)$$

از آنجایی که مجموع دو مقدار ویژه همواره برابر با یک است، بردار ویژه متناسب با بزرگترین مقدار ویژه S_1 همان بردار ویژه متناسب با کوچکترین مقدار ویژه S_2 است و بالعکس. این ویژگی باعث می‌شود که بردارهای ویژه A برای طبقه‌بندی هر دو کلاس مفید باشند. علاوه بر آن، می‌توان حجم محاسبات را کاهش داد؛ زیرا اولین و آخرین سطرها ماتریس بردارهای ویژه بیشترین اهمیت را در تفکیک بین دو کلاس خواهند داشت و پس از آنها دومین سطر و سطر ماقبل آخر و به همین ترتیب تا آخر.

۲-۲- الگوی زمانی مشترک (CTP)

یکی از مشکلات سیستم‌های BCI با ISI^{۱۴} کم (مثل P300Speller)، همپوشانی قابل توجهی است که بین دوره‌های هدف و غیر هدف مجاور وجود دارد [۱۸]. زمانی که کاراکتر هدف ظاهر می‌شود، ERP به‌دست آمده هم در دوره کاراکتر هدف و هم در دوره‌های غیر هدف مجاور وجود دارد. این دو

¹⁵Elsawy


¹⁴ Inter Stimulus Interval

۳-۱- معرفی داده‌های استفاده شده

بسیاری از گروه‌هایی که روی مسأله آشکارسازی P300 کار می‌کنند، از داده‌های مسابقات BCI استفاده می‌کنند تا امکان مقایسه نتایج وجود داشته باشد. در این مقاله نیز از سیگنال‌های ارائه شده توسط گروه وادورث^{۱۶} که در چارچوب BCI2000 تهیه شده و از طریق سایت اینترنتی BCI2005 در اختیار قرار گرفته‌اند [۲۰]، استفاده شده است. در آزمایش طراحی شده برای ثبت این داده‌ها، از یک سیستم P300 speller استفاده شده است. در این آزمایش، یک ماتریس ۶×۶ مشابه شکل (۳) به نمونه نشان داده می‌شود که شامل حروف، اعداد و سمبل فاصله است. در هر مرحله، یکی از سطرها یا ستون‌ها به‌طور تصادفی و به مدت ۱۰۰ میلی‌ثانیه روشن می‌شود، پس از آن به مدت ۷۵ میلی‌ثانیه، تمام سطرها و ستون‌ها خاموش می‌شوند.



شکل (۳) - ماتریس تحریک برای ثبت دادگان



شکل (۴) - نحوه‌ی الکترود گذاری

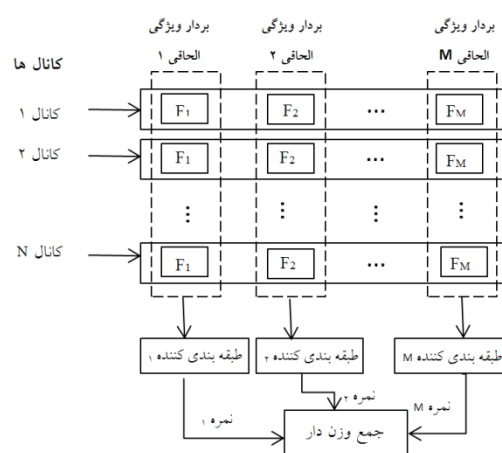
که در آن، M تعداد طبقه‌بندی کننده‌ها و η_i وزن تخصیص داده شده به هر نمره است. نمره هریک از طبقه‌بندی کننده‌ها به‌صورت زیر محاسبه می‌شود:

$$score_i = W_i' X_i \quad (16)$$

و وزن η_i به‌صورت زیر به‌دست می‌آید:

$$\eta_i = \left(\frac{M-i}{2} + 1 \right) / \sum_{K=1}^M K \quad (17)$$

در این روش وزن‌دهی، به هریک از نمره‌ها وزنی متناسب با اهمیت مولفه اصلی مربوط به آن اختصاص داده می‌شود؛ یعنی ویژگی‌های مرتبط با فیلترهای ابتدایی و انتهایی که در رابطه با مقادیر ویژه پراهمیت‌تر هستند، وزن بیشتری می‌گیرند و به ترتیب ویژگی‌های مرتبط با فیلترهای دوم و یکی مانده به آخر در رتبه دوم هستند و به همین صورت تا آخر. جمع وزن دار نمره طبقه‌بندی کننده‌ها، به یک نمره منجر می‌شود و در نهایت آستانه‌گذاری روی آن اعمال می‌شود.



شکل (۲) - بلوک دیاگرام روش آشکارسازی پیشنهادی.

۳- جزئیات روش‌ها و پیاده‌سازی

در این بخش به توصیف جزئیات روش‌ها و پیاده‌سازی‌ها پرداخته می‌شود. برای این منظور، ابتدا داده‌های مورد استفاده معرفی می‌شوند و پس از آن، جزئیاتی در رابطه با هریک از بلوک‌های سیستم آشکارساز بیان می‌شود.

¹⁶Wadsworth

پیش‌پردازشی مهم است؛ زیرا اگر از کاهش نرخ نمونه‌برداری استفاده نشود، بعد بردارهای ویژگی بسیار زیاد شده و طبقه‌بندی کننده با نفرین ابعاد مواجه می‌شود. به علاوه، استفاده از تمام نمونه‌های سیگنال باعث بالا رفتن حجم داده‌های ورودی می‌شود؛ در حالی که ممکن است اطلاعات مفیدی نیز در اختیار قرار ندهد. به همین منظور در روش‌های استفاده‌شده، قبل از استخراج ویژگی از کاهش یکنواخت نرخ نمونه‌برداری با نرخ ۱۰ استفاده شده است. مولفه P300 بیشتر در بازه فرکانسی ۰٫۱ تا ۱۲ هرتز قرار دارد و طبق قضیه نایکوئیست با این کاهش نرخ نمونه‌برداری، هنوز مولفه‌های فرکانسی مربوط به P300 حفظ می‌شود ($12 > 10/240$).

۳-۳- استخراج ویژگی

بلوک استخراج ویژگی یکی از مهمترین بلوک‌های سیستم آشکارساز است. همانطور که پیش از این ذکر شد، در این مطالعه از سه روش الگوی مکانی مشترک، الگوی زمانی مشترک و روش پیشنهادی الگوی زمانی مشترک وزن‌دار برای استخراج ویژگی استفاده شده است. در روش‌های CSP و CTP، تنها از سه سطر اول و سه سطر آخر از ماتریس بردارهای ویژه برای تولید فیلترهای مکانی و زمانی استفاده شده است. به این ترتیب، حجم اطلاعات پردازشی از ۶۴ (تعداد کل کانال‌ها) به ۶ (تعداد بردارهای ویژه انتخابی) کاهش یافته‌است؛ سپس با ضرب فیلترهای تولیدی در این مرحله در داده‌های پیش‌پردازش شده X، بردارهای ویژگی Z تولید شده است.

$$Z = XH' \quad (18)$$

در روش WCTP نیز از سه سطر ابتدایی و سه سطر انتهایی از ماتریس بردارهای ویژه برای تولید فیلترهای زمانی استفاده شده است و سپس بردارهای ویژگی الحاقی همان‌طور که در بخش پیش توضیح داده شد، از کنار هم قرار دادن ویژگی‌های با رتبه مقدار ویژه یکسان در تمام کانال‌ها به دست می‌آیند.

۳-۴- طبقه‌بندی

هدف نهایی در هر مسئله شناسایی الگو، تفکیک مجموعه‌ای از نمونه‌ها به دو یا چند کلاس مختلف است. در این جا نیز هدف نهایی، تفکیک سیگنال‌ها به دو گروه شامل P300 و فاقد P300 است. اغلب رابطه‌ای دوطرفه بین بلوک‌های استخراج

این روند تا زمانی که همه ۱۲ سطر و ستون برای هر کاراکتر روشن شوند، ادامه می‌یابد. از میان این ۱۲ تحریر، دو عدد (یک سطر و یک ستون) شامل کاراکتر هدف هستند که سیگنال P300 را تولید می‌کنند. برای افزایش دقت و امکان میانگین‌گیری برای کاهش نویز، این روند ۱۵ مرتبه برای هر کاراکتر تکرار می‌شود. از داده‌های استفاده‌شده از ۶۴ کانال، مطابق شکل (۴)، برای ثبت سیگنال استفاده‌شده است. سیگنال‌های ثبت‌شده در این مسیر، پس از عبور از یک فیلتر میان‌گذر ۰٫۱ تا ۶۰ هرتز با فرکانس ۲۴۰ هرتز نمونه‌برداری شده‌اند.

۳-۲- پیش پردازش

استخراج ویژگی‌های دقیق از سیگنال EEG آلوده به نویز و آرتیفکت^{۱۷}، یکی از جدی‌ترین چالش‌های سیستم‌های BCI است و عملکرد طبقه‌بندی کننده، به میزان زیادی به کیفیت ویژگی‌های استخراجی بستگی دارد. نویز خارجی و آرتیفکت به دلایل زیادی در ثبت سیگنال EEG تولید می‌شود. این اختلالات نامطلوب، آنالیز سیگنال EEG و استخراج اطلاعات کلینیکی از آن را مشکل‌تر می‌کند. بنابراین ابتدا باید پیش‌پردازش‌هایی روی این سیگنال اجرا شود تا نرخ سیگنال به نویز آن بهبود یابد و برای استفاده در سیستم BCI مناسب شود. برای این منظور، ابتدا سیگنال خام از یک فیلتر بیضوی پایین‌گذر با فرکانس قطع ۳۵ هرتز و سپس از یک فیلتر بیضوی بالاگذر با فرکانس قطع ۱۰۰ هرتز عبور داده شد تا نویز و آرتیفکت‌های سیگنال کاهش یابد. سپس با توجه به یکسان نبودن شرایط ثبت و قدرت سیگنال در افراد مختلف، سیگنال فیلتر شده به بازه [۱، -۱] نرمال شد. با توجه به این که اغلب مولفه‌های شناختی مربوط به هر تحریر، در فاصله اعمال تحریر تا حدود یک ثانیه پس از آن رخ می‌دهد، با استفاده از پنجره‌ای مستطیلی، سیگنال به صورت قطعاتی یک ثانیه‌ای پس از هر تحریر بلوک‌بندی شد. گام بعدی در پیش‌پردازش، میانگین‌گیری است؛ از این رو سیگنال‌های دارای کد تحریر یکسان (هر سطر یا ستون دارای یک کد تحریر است) در هر حرف، با هم میانگین‌گیری شدند تا الگوی P300 که در تمام ثبت‌ها شکل تقریباً ثابتی دارد، باقی بماند و نویز که رفتار تصادفی دارد، حذف شود. در بسیاری از روش‌های مبتنی بر شناسایی آماری الگو که برای آشکارسازی مولفه P300 استفاده می‌شوند، کاهش نرخ نمونه‌برداری یک گام

¹⁷ Artifact

همان طور که پیش از این اشاره شد، داده‌های استفاده شده در این مطالعه شامل اطلاعات دو نمونه A و B است. برای هر یک از نمونه‌ها، دو دسته دادهٔ تعلیم با ۸۵ کاراکتر و تست با ۱۰۰ کاراکتر در اختیار قرار گرفته است. از داده‌های تعلیم برای آموزش طبقه‌بندی کننده‌ها استفاده شده است و از داده‌های تست برای ارزیابی عملکرد روش‌های ذکر شده استفاده شده است.

در این مطالعه، دقت طبقه‌بندی برای هر دو وضعیت هدف و غیرهدف مهم بود؛ از این رو علاوه بر روش معمول ارزیابی براساس درصد صحت طبقه‌بندی، نتایج ارزیابی براساس دقت متعادل^{۱۹} (BA) نیز گزارش شده است [۱۸ و ۲۳]. اگر وضعیت هدف را مثبت و وضعیت غیر هدف را منفی در نظر بگیریم، می‌توان BA را به صورت زیر بیان کرد:

$$BA = \frac{1}{2} \left(\frac{TP}{TP + FN} + \frac{TN}{TN + FP} \right) \quad (21)$$

که TP, FN, TN, FP به ترتیب تعداد مثبت صحیح، منفی صحیح، منفی اشتباه و مثبت اشتباه است.

۴- یافته‌ها و بحث

در این بخش، نتایج ارزیابی هر یک از روش‌های استخراج ویژگی در حالت‌های تک ثبت (بدون میانگین‌گیری) و نیز میانگین‌گیری روی ثبت‌های حاصل از تکرار ۳ و ۵ آزمایش برای هر کاراکتر ارائه شده است. در حالت تک ثبت از میان ۱۵ ثبت موجود برای هر کاراکتر، تنها از اولین ثبت استفاده شده است تا نتایج به حالت آنلاین واقعی نزدیک‌تر شود.

همانطور که پیش از این ذکر شد، مجموعهٔ تست شامل اطلاعات ۱۰۰ کاراکتر است که با ضرب در فیلترهای آموزش داده شده، بردارهای تست را تولید می‌کنند. در روش‌های CSP و CTP، این بردارهای تست برای آزمودن کارایی روش به طبقه‌بندی کننده‌ها داده می‌شوند؛ ولی در روش پیشنهادی WCTP از روش طبقه‌بندی ترکیبی بیان شده استفاده می‌شود. در جدول‌های (۱) و (۲)، نتایج ارزیابی ویژگی‌ها برای دو نمونه A و B به ترتیب براساس میانگین درصد صحت طبقه‌بندی و دقت متعادل BA ارائه شده است.

ویژگی و طبقه‌بندی وجود دارد. در واقع، هر چه بار اطلاعاتی بردار ویژگی از کلاس‌های تفکیک شده بیشتر باشد یا تعریف ویژگی مناسب‌تر باشد، از طبقه‌بندی کنندهٔ ساده‌تری استفاده می‌شود. در این مطالعه، از طبقه‌بندی کنندهٔ سادهٔ خطی استفاده شده است. از مزایای طبقه‌بندی کنندهٔ خطی، پیچیدگی محاسباتی کم و راحتی در پیاده‌سازی است.

LDA، ساده‌ترین و پرکاربردترین طبقه‌بندی کنندهٔ خطی است [۲۱ و ۲۲]. این طبقه‌بندی کننده در شکل استانداردش یک طبقه‌بندی کنندهٔ باینری است که با اعمال تخمین MAP و با فرض گوسی بودن تابع توزیع، احتمال شرطی ویژگی‌ها در فضای ویژگی و همچنین تساوی ماتریس‌های کوواریانس کلاس‌ها محاسبه می‌شود. در روش LDA، ابر صفحهٔ تصمیم‌گیری به صورت زیر تعریف می‌شود:

$$V.U + b = 0 \quad (19)$$

که U بردار ویژگی، V بردار وزن ویژگی‌ها و b جملهٔ بایاس است [۲۱]. بردار وزن نیز از رابطهٔ زیر محاسبه می‌شود:

$$V = (U^T U)^{-1} U^T Y \quad (20)$$

که در آن Y برداری است که شامل برچسب ویژگی‌ها می‌باشد. در روش WCTP، به ازای هر یک از بردارهای ویژگی الحاقی از یک طبقه‌بندی کنندهٔ LDA استفاده شده است.

۳-۵- ارزیابی


در بخش‌های قبل به توضیح روش‌های استفاده شده برای آشکارسازی مولفه P300 پرداختیم. بعد از این مرحله، نوبت به ارزیابی کارایی این روش‌ها و انتخاب روش بهینه می‌رسد. در سیستم P300Speller، اصولاً از دو معیار کلی برای ارزیابی روش‌ها استفاده می‌شود که عبارت‌اند از: درصد صحت طبقه‌بندی و سرعت انتقال اطلاعات (بیت بر دقیقه و یا کاراکتر بر دقیقه). موضوع مورد بحث در این مطالعه، تنها آشکارسازی مولفه P300 است و تشخیص کاراکتر بررسی نشده است؛ در نتیجه تنها از معیار درصد صحت طبقه‌بندی مولفه P300 برای ارزیابی روش‌ها استفاده می‌شود. برای منظور، در این مطالعه از روش ارزیابی^{۱۸} HCV استفاده می‌شود.

¹⁹ balanced accuracy

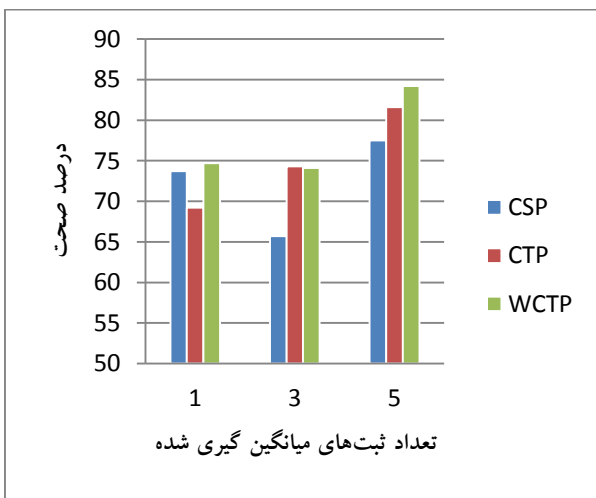
¹⁸ Hold out Cross Validation

الگوهای زمانی متفاوتی دارند، CTP روش کارآمدتری نسبت به CSP در رابطه با این داده‌ها محسوب می‌شود.

در شکل‌های (۵) و (۶) به ترتیب، نمودار مقایسه عملکرد روش‌های استخراج ویژگی در تعداد ثبت‌های میانگین‌گیری متفاوت با معیار درصد صحت طبقه‌بندی و BA برای نمونه A نشان داده شده است. با ارزیابی نمودارها مشخص است که روش پیشنهادی WCTP به دلیل اختصاص دادن وزن بالاتر به ویژگی‌های مناسب‌تر، اغلب تفکیک بالاتری نسبت به روش CTP ایجاد کرده است. در واقع ویژگی‌های تولیدی توسط فیلترهای ابتدایی و انتهایی، که بیشترین اطلاعات تفکیکی را دارند، وزن بالاتری را در تصمیم‌گیری دریافت کرده‌اند.



شکل (۵) - نمودار مقایسه عملکرد روش‌های استخراج ویژگی در تعداد ثبت‌های میانگین‌گیری متفاوت با معیار درصد صحت طبقه‌بندی برای نمونه A.



شکل (۶) - نمودار مقایسه عملکرد روش‌های استخراج ویژگی در تعداد ثبت‌های میانگین‌گیری متفاوت با معیار BA برای نمونه A.

جدول (۱): نتایج ارزیابی ویژگی‌ها با استفاده از درصد صحت طبقه‌بندی

روش	تک ثبت	۳ مرتبه میانگین‌گیری	۵ مرتبه میانگین‌گیری
CSP	سوژه A	۸۱,۷	۸۲,۵
	سوژه B	۸۵,۴	۸۵,۵
CTP	سوژه A	۸۲,۷	۸۵,۷
	سوژه B	۸۲,۸	۸۸,۲
WCTP	سوژه A	۸۶,۴	۸۹,۷
	سوژه B	۸۶,۰	۸۷,۵

جدول (۲): نتایج ارزیابی ویژگی‌ها با استفاده از دقت متعادل BA

روش	تک ثبت	۳ مرتبه میانگین‌گیری	۵ مرتبه میانگین‌گیری
CSP	سوژه A	۷۳,۷	۶۹,۲
	سوژه B	۶۶,۶	۶۷,۹
CTP	سوژه A	۶۵,۷	۷۴,۳
	سوژه B	۶۵,۶	۷۸,۳
WCTP	سوژه A	۷۷,۵	۸۱,۶
	سوژه B	۷۷,۶	۷۷,۶

همانطور که از نتایج پیداست، ویژگی‌های تولید شده با استفاده از فیلترهای زمانی CTP تفکیک بهتری نسبت به CSP ایجاد کرده‌اند. این نتیجه قابل پیش‌بینی بود؛ زیرا در سیستم P300 speller، دوره‌های هدف و غیر هدف مجاور هم‌پوشانی قابل ملاحظه‌ای دارند. در نتیجه زمانی که کاراکتر هدف ظاهر می‌شود، هم در دوره‌های هدف و هم در دوره‌های غیر هدف مجاور حضور دارند. از آنجا که دوره‌های مجاور

۵- نتیجه گیری

در این مطالعه، کارایی روش پیشنهادی WCTP در آشکارسازی مولفه P300 بررسی شد. برای این منظور، ابتدا مقایسه‌ای بین روش‌های ساخت فیلتر مکانی و زمانی توسط روش‌های CSP و CTP انجام شد. روش الگوی مکانی مشترک (CSP)، روشی پرکاربرد در حوزه BCI مبتنی بر تصورات حرکتی است؛ اما این روش در سیستم‌های BCI مبتنی بر P300 عملکرد مطلوبی ندارد. از این رو ساخت بردار ویژگی زمانی به روش الگوی زمانی مشترک (CTP) پیشنهاد شده است [۱۸]. در این روش، الگوهای زمانی به جای الگوهای مکانی پردازش می‌شوند. براساس نتایج، فیلترهای زمانی مبتنی بر CTP تفکیک بالاتری نسبت به CSP ایجاد می‌کنند. در این مطالعه با الگو گرفتن از روش PCA وزن دار، روش WCTP پیشنهاد شد. اگرچه تعداد طبقه‌بندی کننده‌ها در این روش افزایش می‌یابد؛ اما به دلیل تعداد بسیار کم ویژگی‌های داده شده به هر طبقه‌بندی کننده، پیچیدگی محاسباتی آنها کاهش می‌یابد و تفاوت چشمگیری در سرعت عمل سیستم ایجاد نمی‌شود. تعداد ویژگی استفاده شده در روش CTP، ۳۸۴ ویژگی است؛ در حالی که در روش WCTP، تعداد ویژگی‌ها تنها ۶۴ عدد است. کاهش تعداد ویژگی‌ها، علاوه بر کاهش پیچیدگی، موجب عدم نیاز به تعداد داده آموزشی بالا برای آموزش طبقه‌بندی کننده‌ها نیز می‌شود.

برای بررسی تأثیر میانگین‌گیری بر عملکرد این سیستم، نتایج در حالت‌های تک ثبت، ۳ و ۵ مرتبه میانگین‌گیری محاسبه شدند. از بررسی نتایج مشخص است که روش پیشنهادی در حالت تک ثبت به طور متوسط به درصد صحت طبقه‌بندی ۸۶٫۲ و دقت متعادل BA ۷۷٫۵ درصد رسیده است، که مقدار قابل توجهی است. علاوه بر این برای افزایش سرعت سیستم، تعداد ثبت‌های میانگین‌گیری را از ۱۵ به ۵ کاهش دادیم؛ با این حال درصد صحت بالایی به دست آمد. به عنوان مثال، برای نمونه A در حالت ۵ ثبت میانگین‌گیری شده، میانگین درصد صحت ۹۱٫۴ و دقت متعادل BA ۸۴٫۲ به دست آمد که درصد صحت مطلوبی با این تعداد میانگین‌گیری است. همچنین روش پیشنهادی باعث بهبود تقریبی ۴ درصدی نسبت به روش CTP شده است.

۶- مراجع

- [1] E. Donchin, K. M. Spencer, and R. Wijesinghe, "The mental prosthesis: Assessing the speed of a P300-based brain-computer interface", *IEEE Trans. Rehab. Eng.*, vol. 8, pp. 174-179, 2000.
- [2] J.S. Lin and W.C. Yang, "Wireless brain-computer interface for electric wheelchairs with EEG and eye-blinking signals," *Int. J. Innov. Comp. Inf. Control*, vol.8, no. 9, pp 6011-6024, 2012.
- [3] Y. Gu, O. F. Do Nascimento, M.-F. Lucas and D. Farina, "Identification of task parameters from movement-related cortical potentials", *Medical & biological engineering & computing*, vol. 47, no. 12, pp. 1257-1264, 2009.
- [4] A. S. Royer and B. He, "Goal selection versus process control in a brain-computer interface based on sensorimotor rhythms", *J. Neural Eng.*, vol. 6, pp. 16005, 2009.
- [5] D.Jarchi, V.Abolghasemi and S. Sanei, "Source localization of brain rhythms by empirical mode decomposition and spatial notch filtering", 17th European Signal Processing Conference (EUSIPCO2009) Glasgow, Scotland, August 24-28, 2009 .
- [6] K. Thomas , C. Guan , C. Lau , A. Vinod and K. Ang, "A new discriminative common spatial pattern method for motor imagery brain-Computer interfaces", *IEEE Trans. Biomed. Eng.*, vol. 56, no. 11, pp. 2730-2733, 2009.
- [7] D. Zhu, J. Bieger, G. Garcia-Molina, and R. Aarts, "A survey of stimulation methods used in SSVEP-based BCIs", *Journal of Computational Intelligence and Neuroscience*, vol. Article ID 702357, 12 pages, 2010.
- [8] D. Linden, "The P300: Where in the Brain Is It Produced and What Does It Tell Us?", *The Neuroscientist*, Vol. 11, No. 6, pp. 563-576, 2005.
- [9] R. M. Chapman and H. R. Bragdon, "Evoked responses to numerical and nonnumerical visual stimuli while problem solving", *Nature*, vol. 203, pp. 1155-1157, 1964.
- [10] S. Sutton, M. Braren, J. Zubin, and E. John, "Evoked correlates of stimulus uncertainty ", *Science*, vol. 150, pp. 1187-1188, 1965.
- [11] M. Onofrtj, D. Melchionda, A. Thomas and T. Fulgente, "Reappearance of event-related P3 potential in locked-in syndrome," *Cognitive Brain Research*, vol.4, no.2, pp. 95-97, 1996.
- [12] L. A. Farwell and E. Donchin, "Talking off the top of your head: Toward a mental prosthesis utilizing event-related brain potentials", *Electroenceph. Clin. Neurophysiol.*, vol. 70, no. 6, pp. 510-523, 1988.
- [13] D. J. McFarland, L. McCane, S. V. David, and J. R. Wolpaw, "Spatial filter selection for eeg-based communication," *J. Electroencephalogr. and clin. Neurophys.*, vol. 103, pp. 386-394, 1997.

- A.S. Elsayy, S. Eldawlatly, M. Taher and G. M. Aly, "Performance Analysis of a Principal Component Analysis Ensemble Classifier for Emotiv Headset P300 Spellers," 36th EMBS, pp. 5032-5035, 2014.
- [19] B. Blankertz, BCI Competition III Webpage. [Online]. Available: http://ida.first.fraunhofer.de/projects/bci/competition_iii. 2005.
- [20] 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.
- [21] H. Mirghasemi, R. Fazel-Rezai and M.B. Shamsollahi, "Analysis of P300 Classifiers in Brain Computer Interface Speller," 31th IEEE EMBS Conf.on Med. and Biomed, pp.6205-6208, Aug. 30 2006.
- [22] B. E. Boser, I. M. Guyon, and V. N. Vapnik, "A training algorithm for optimal margin classifiers," in Proc. 5th Annu. ACM Workshop Comput.Learning Theory, pp. 144-152, 1992.
- [14] 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.
- [۱۵] امینی زهرا، ابوطالبی وحید، صادقی محمدتقی، "ارزیابی و مقایسه روش‌های الگوهای مکانی مشترک و قطعه‌بندی هوشمند در آشکارسازی مولفه P300"، سیستم‌های هوشمند در مهندسی برق، ۵۴-۳۷، ایران، سال دوم، شماره دوم، تابستان ۹۰.
- [16] S. Lemm , B. Blankertz , G. Curio, K.-R. MÄller, "Spatio-spectral filters for improving classification of single trial EEG," IEEE Trans. Biomed. Eng., vol. 52, no. 9, pp.1541 -1548 2005.
- [17] G. Dornhege, B. Blankertz, M. Krauledat, F. Losch, G. Curio and K.-R. Muller, "Combined Optimization of Spatial and Temporal Filters for Improving Brain-Computer Interfacing," IEEE Trans. Biomed. Eng., vol. 53, no. 11, pp. 2274-2281, 2006.
- [18] K. Yu , K. Shen , S. Shao , W. C. Ng , K. Kwok , X. Li, "Common spatio-temporal pattern for single-trial detection of event-related potential in rapid serial visual presentation triage," IEEE Trans. Biomed. Eng., vol. 58, no. 9, pp. 2513-2520, 2011.