

## Designing Spectral and Spatial Filters Simultaneously for Brain-Computer Interface Based on Mutual Information and Particle Swarm Optimization

R. Foodeh<sup>1</sup>, V. Shalchyan<sup>2\*</sup>, M. R. Daliri<sup>3\*</sup>

<sup>1</sup> Ph.D Student, Biomedical Engineering Department, Electrical Engineering Faculty, Iran university of Science and Technology, Tehran, Iran

<sup>2</sup> Assistant Professor, Biomedical Engineering Department, Electrical Engineering Faculty, Iran university of Science and Technology, Tehran, Iran

<sup>3</sup> Associate Professor, Biomedical Engineering Department, Electrical Engineering Faculty, Iran university of Science and Technology

Receipt in the online submission system: 3 October 2017, accepted: 6 October 2017

---

### Abstract

Extracting discriminative features is a crucial step in brain-computer interfaces (BCIs) that could affect directly on the classification performance. Common spatial patterns (CSP) is a commonly used algorithm for such propose in motor imagery based BCI systems. CPS tries to extract the most appropriate spatial patterns in the electroencephalogram (EEG) signals to discriminate different motor imagery classes. Before applying CSP, Usually EEG signals are filtered out in 8-30 Hz to capture event related desynchronization (ERD) specific frequency rhythms called mu and beta bands. However, this frequency band could be highly subject specific. Therefore, optimizing spectral and spatial filters jointly could improve the classification accuracy. In this paper, we proposed a novel learning algorithm to derive spatial and spectral filters simultaneously using an evolutionary learning algorithm called particle swarm optimization (PSO). Furthermore, we utilized mutual information between extracted features and class labels as a cost function in the learning algorithm. Our simulations on BCI competition IV, dataset 1 reveals that the proposed method significantly outperforms the conventional CSP and filter bank CSP (FBCSP) with two different filter bank architectures.

**Key words:** *Brain-computer interfaces, common spatial patterns, Spatio-spectral features, particle swarm optimization, mutual information*

---

### \*Corresponding authors

**Address:** Biomedical Engineering Department, Electrical Engineering Faculty, Iran university of Science and Technology, P.O.Box: 1684613114, Tehran, Iran

**Tel:** +98-21-73225738 - +98-21-73225628

**Fax:** +98-21-73225777

**E-mail:** [daliri@iust.ac.ir](mailto:daliri@iust.ac.ir) - [shalchyan@iust.ac.ir](mailto:shalchyan@iust.ac.ir)

## طراحی هم‌زمان فیلترهای طیفی و فضایی برای واسط‌های مغز-کامپیوتر، براساس اطلاعات متقابل و بهینه‌سازی ازدحام ذرات

رضا فوده<sup>۱</sup>، وحید شالچیان<sup>۲\*</sup>، محمدرضا دلیری<sup>۳\*</sup>

<sup>۱</sup> دانشجوی دکتری مهندسی پزشکی، گروه مهندسی پزشکی، دانشکده مهندسی برق، دانشگاه علم و صنعت ایران، تهران  
<sup>۲</sup> استادیار گروه مهندسی پزشکی، دانشکده مهندسی برق، دانشگاه علم و صنعت ایران، تهران  
<sup>۳</sup> دانشیار گروه مهندسی پزشکی، دانشکده مهندسی برق، دانشگاه علم و صنعت ایران، تهران

تاریخ ثبت در سامانه: ۱۳۹۶/۷/۱۱، پذیرش قطعی: ۱۳۹۶/۷/۱۴

### چکیده

استخراج ویژگی‌های تفکیک‌پذیر، بخشی مهم در سیستم‌های واسط مغز-کامپیوتر (BCI) است، که می‌تواند بر کارایی طبقه‌بندی، تأثیرگذار باشد. برای رسیدن به این هدف، الگوهای فضایی مشترک (CSP)، روشی متداول است که در سیستم‌های BCI مبتنی بر تصورات حرکتی، استفاده می‌شود. CSP سعی می‌کند تا مناسب‌ترین الگوهای فضایی در سیگنال الکتروانسفالوگرام (EEG) را برای تفکیک گروه‌های مختلف تصور حرکتی، استخراج کند. به‌طور معمول پیش از اعمال CSP، سیگنال‌های EEG در باند فرکانسی ۳۰-۸ هرتز، فیلتر می‌شوند تا ریتم‌های مربوط به ناهمگامی وابسته به رویداد (ERD)، که میو و بتا نام دارند، استخراج شوند. با این حال، این باند فرکانسی ممکن است در افراد مختلف، یکسان نباشد؛ به همین دلیل، بهینه‌سازی فیلترهای طیفی در کنار فیلترهای فضایی، می‌تواند تأثیر بسزایی در بهبود صحت طبقه‌بندی داشته باشد. در این مقاله، با استفاده از الگوریتم تکاملی بهینه‌سازی ازدحام ذرات (PSO)، روش یادگیری نوینی را برای به دست آوردن هم‌زمان فیلترهای طیفی و فضایی ارائه می‌دهیم. همچنین، از معیار اطلاعات متقابل بین ویژگی‌های استخراج‌شده و برچسب گروه‌ها، به‌عنوان تابع هزینه استفاده می‌شود. شبیه‌سازی‌های انجام‌شده روی مجموعه داده یک از رقابت BCI، نشان می‌دهد که صحت طبقه‌بندی روش پیشنهادی، به‌طور معناداری بیشتر از روش‌های CSP و بانک فیلتر (FBCSP) است. با دو نوع بانک فیلتر متفاوت، است.

**کلیدواژه‌ها:** واسط‌های مغز-کامپیوتر، الگوهای فضایی مشترک، ویژگی‌های طیفی-فضایی، بهینه‌سازی ازدحام ذرات، اطلاعات متقابل

\*نویسندگان مسئول

نشانی: گروه مهندسی پزشکی، دانشکده مهندسی برق، دانشگاه علم و صنعت ایران، تهران، ایران، کد پستی: ۱۶۸۴۶۱۳۱۱۴

تلفن: ۷۳۲۲۵۷۳۸ (۲۱) ۹۸+ - ۷۳۲۲۵۶۲۸ (۲۱) ۹۸+

دورنگار: ۷۳۲۲۵۷۷۷ (۲۱) ۹۸+

پست الکترونیکی: daliri@iust.ac.ir - shalchyan@iust.ac.ir

## ۱- مقدمه

استخراج ویژگی‌های تفکیک‌کننده<sup>۱</sup>، بخشی مهم در یک مسئله شناسایی آماری الگو است؛ چون تفکیک‌پذیری ویژگی‌ها به افزایش عملکرد طبقه‌بندی منجر می‌شود [۱]. با توجه به اهمیت این موضوع در مسائل شناسایی آماری الگو، مانند واسطه‌های مغز-کامپیوتر (BCI<sup>۲</sup>)، تشخیص بیماری‌ها و ...، روش‌های پیش‌پردازش مختلفی برای این منظور استفاده می‌شوند که در میان آن‌ها، استفاده از فیلترهای حوزه فرکانس<sup>۳</sup> و فیلترهای فضایی<sup>۴</sup>، نقش مهم و قابل توجهی دارند.

همان‌طور که ذکر شد، یکی از کاربردهای مهم شناسایی آماری الگو، واسطه‌های مغز-کامپیوتری هستند. این سیستم‌ها سعی دارند تا فعالیت‌های مغزی را به دستورات کنترلی تبدیل کنند [۲]. در این میان، سیستم‌های BCI که برای تولید سیگنال‌های کنترلی از سیگنال الکتروانسفالوگرام (EEG<sup>۵</sup>) و طبقه‌بندی تصورات حرکتی<sup>۶</sup> استفاده می‌کنند، توجه بسیاری از محققان را جلب کرده است. تصور حرکت یک اندام خاص، باعث کاهش توان سیگنال EEG در باندهای فرکانسی میو<sup>۷</sup> (حدود ۱۳-۸ هرتز) و بتا<sup>۸</sup> (حدود ۱۳-۳۰ هرتز) در نواحی حسی-حرکتی نیم‌کره سمت مخالف<sup>۹</sup> و همچنین افزایش توان سیگنال EEG در باندهای ذکر شده در نواحی حسی-حرکتی نیم‌کره سمت موافق<sup>۱۰</sup> می‌شود. پدیده‌های بالا، به ترتیب با عناوین ناهمگامی وابسته به رویداد (ERD<sup>۱۱</sup>) و همگامی وابسته به رویداد (ERS<sup>۱۲</sup>) شناخته می‌شوند. این پدیده‌ها در تصورات حرکت اندام‌های مختلف، الگوهای متفاوتی از نظر زمان وقوع و دامنه نوسانات فرکانس‌ها را روی کانال‌های مختلف سیگنال‌های EEG ثبت شده، ایجاد می‌کنند، که استفاده از این الگوها در تفکیک گروه‌های مختلف تصور حرکتی، مؤثر است [۳]. مطالعات گذشته نشان داده است که با انتخاب ترکیب‌های وزن دار مناسب

از کانال‌های EEG، می‌توان مجموعه‌ای از فیلترهای فضایی ساخت، که تفکیک‌پذیری این الگوها را در دسته‌های مختلف تصور حرکتی افزایش دهد [۳].

یکی از روش‌های بسیار پرکاربرد در موارد بسیار مختلف برای استخراج ویژگی‌های جداپذیر، که نتایج قابل‌قبولی را از خود نشان داده، روش الگوهای فضایی مشترک (CSP<sup>۱۳</sup>) است. CSP با اجرای یک روش بهینه‌سازی روی داده‌های آموزشی مربوط به دو گروه مختلف تصور حرکتی، وزن‌های یک یا چند جفت فیلتر فضایی را یافته و سیگنال‌ها را با آن فیلتر می‌کند. به گونه‌ای که هم‌زمان توان (واریانس) داده‌های فیلتر شده در یک گروه، بیشینه و در گروه دیگر، کمینه شود. به این ترتیب، CSP ویژگی‌هایی را استخراج می‌کند که در گروه‌های مختلف نسبت به یکدیگر، متمایز باشند. در سیستم‌های BCI وابسته به تصورات حرکتی، به‌طور معمول الگوریتم CSP، روی سیگنال EEG فیلتر شده در بازه فرکانسی مربوط به ریتم‌های میو و بتا، یعنی حدود ۳۰-۸ هرتز، اعمال می‌شود؛ درحالی‌که این باند فرکانسی می‌تواند در افراد مختلف، متفاوت باشد [۴].

تاکنون مطالعات زیادی در حوزه طراحی هم‌زمان فیلترهای فرکانسی و فضایی انجام شده است. روش الگوهای فضایی-طیفی مشترک (CSSP<sup>۱۵</sup>)، با کنار هم قراردادن یک تأخیر زمانی معین از سیگنال و سیگنال اصلی و نیز اعمال CSP روی آن، علاوه بر فیلترهای فضایی، یک فیلتر فرکانسی پاسخ ضربه محدود (FIR<sup>۱۶</sup>) مرتبه یک نیز طراحی می‌کند [۵]. در [۶]، نویسنده روشی به نام الگوهای تُنک فضایی-طیفی مشترک (CSSSP<sup>۱۷</sup>) را برای طراحی یک فیلتر FIR مرتبه بالا و مقاوم در برابر بیش‌برازش<sup>۱۸</sup> در کنار فیلترهای فضایی، ارائه می‌دهد. در [۷] نویسنده با فیلتر کردن سیگنال در باندهای فرکانسی مختلف و اعمال جداگانه CSP روی هر باند و انتخاب بهترین ویژگی‌های تولید شده، روش بانک فیلتر CSP (FBCSP<sup>۱۹</sup>) را

<sup>۱۱</sup> Event Related Desynchronization

<sup>۱۲</sup> Event Related Synchronization

<sup>۱۳</sup> Common Spatial Patterns

<sup>۱۴</sup> Subject Specific

<sup>۱۵</sup> Common Spatio-Spectral Pattern

<sup>۱۶</sup> Finite Impulse Response

<sup>۱۷</sup> Common Sparse Spectral Spatial Pattern

<sup>۱۸</sup> Overfitting

<sup>۱۹</sup> Filter Bank CSP

<sup>۱</sup> Discriminant

<sup>۲</sup> Brain Computer Interface

<sup>۳</sup> Frequency Domain Filters

<sup>۴</sup> Spatial Filters

<sup>۵</sup> Electroencephalogram

<sup>۶</sup> Motor Imagery

<sup>۷</sup> Mu

<sup>۸</sup> Beta

<sup>۹</sup> Contralateral

<sup>۱۰</sup> Ipsilateral

هدف این مقاله، بهینه‌سازی هم‌زمان فیلتر فرکانسی در حوزه فرکانس (فیلتر طیفی)، براساس معیار اطلاعات متقابل و فیلترهای فضایی، با استفاده از CSP است. رویکرد این مقاله، طراحی فیلتر فرکانسی با استفاده از تبدیل ویولت مورلت<sup>۸</sup> است. ایده اصلی این است که ویولت مورلت در حوزه فرکانس، به یک توزیع گوسی تبدیل شده و در نتیجه، بهینه‌سازی یک باند فرکانسی، معادل با بهینه‌سازی دو متغیر مرکز (میانگین) و عرض (انحراف معیار) یک توزیع گوسی در حوزه فرکانس است. همچنین در این مقاله، برخلاف روش‌های ذکر شده، برای بهینه‌سازی پارامترهای فیلتر فرکانسی از الگوریتم تکاملی بهینه‌سازی ازدحام ذرات (PSO<sup>۹</sup>) استفاده می‌شود، تا خطر گیر کردن در اکسترمم‌های محلی کم شده و قابلیت اعمال محدودیت روی فضای جست و جو را داشته باشیم. در نهایت برای ارزیابی، روش ارائه شده بر مجموعه داده یک از رقابت BCI چهار<sup>۱۰</sup>، اعمال شده و نتایج آن با دو روش مرسوم CSP و FBCSP، مقایسه می‌شود.

## ۲- مواد و روش‌ها

در این قسمت، مجموعه داده استفاده شده، تشریح و سپس روش‌های CSP، FBCSP و روش پیشنهادی به‌طور کامل توضیح داده خواهند شد.

### ۲-۱- مجموعه داده

در این مقاله برای ارزیابی روش ارائه شده، از داده‌های کالیبراسیون در مجموعه داده یک از رقابت BCI چهار<sup>۱۱</sup>، استفاده می‌شود<sup>۱۲</sup>. این مجموعه داده، شامل سیگنال‌های EEG با ۵۹ کانال از هفت کاربر است [۹]. نرخ نمونه‌برداری این سیگنال‌ها، ۱۰۰۰ هرتز بوده و مطابق با سیستم ۲۰-۱۰، ثبت شده‌اند [۱۰]. هر کدام از کاربران قبل از شروع آزمایش، دو عمل را از بین تصور حرکت دست راست، دست چپ و پاها، انتخاب کرده و هر کدام از این وظایف<sup>۱۳</sup> را، ۱۰۰ بار به‌طور تصادفی انجام می‌دهند (در مجموع ۲۰۰ انجام وظیفه برای هر کاربر). در هر

ارائه می‌کند. لازم به ذکر است که در تمام روش‌های ذکر شده، فیلتر فرکانسی در حوزه زمان، طراحی شده است، که به آن فیلتر زمانی<sup>۱</sup> می‌گویند.

برخلاف مطالعات بالا، که به دنبال بهینه‌سازی فیلتر فرکانسی در حوزه زمان هستند، برخی از مطالعات انجام شده دیگر، طراحی و بهینه‌سازی در حوزه فرکانس را ترجیح می‌دهند (لازم به ذکر است که در این مقاله به فیلترهای فرکانسی طراحی شده در حوزه فرکانس، فیلترهای طیفی گفته می‌شود). برای مثال، روش CSP وزن‌دار طیفی (SWCSP<sup>۲</sup>)، با استفاده از یک الگوریتم تکرار شونده، سعی دارد تا فیلترهای فضایی را با استفاده از CSP و فیلترهای طیفی را با بیشینه کردن نرخ تفکیک فیشر<sup>۳</sup>، بهینه کند [۸]. روش‌های جدیدتر، مانند شبکه فیلترینگ فضایی-طیفی بهینه (OSSFN<sup>۴</sup> [4]) و بیشینه کردن اطلاعات متقابل ویژگی‌های فضایی-طیفی (MMISS<sup>۵</sup> [1])، از روش CSP برای به دست آوردن فیلترهای فضایی استفاده نکرده‌اند و سعی دارند تا فیلترهای فضایی و فرکانسی را هم‌زمان به نحوی بهینه‌سازی کنند که اطلاعات متقابل<sup>۶</sup> بین ویژگی‌های استخراج شده و برچسب گروه‌ها، بیشینه شود.

طراحی هم‌زمان فیلترهای فرکانسی و فضایی به‌کارایی بیشتر در سیستم‌های BCI، همچنان مبحثی باز و مورد علاقه پژوهشگران است. استفاده از معیار اطلاعات متقابل، چشم‌انداز نوینی در بهینه‌سازی هم‌زمان فیلترهای فضایی و فرکانسی، پیش روی پژوهشگران قرار داده است. با این حال هر دو مقاله ارائه‌کننده روش‌های OSSFN و MMISS، که از این معیار برای بهینه‌سازی استفاده کرده‌اند؛ اذعان دارند که فضای جست‌وجوی بزرگ، بهینه‌سازی هم‌زمان فیلترهای فضایی و فرکانسی را دشوار می‌کند و در نتیجه این مطالعات برای رفع این مشکل، از راهکار بهینه‌سازی زیرمجموعه‌ای<sup>۷</sup> استفاده می‌کنند؛ درحالی‌که انتخاب زیرمجموعه مناسب برای بهینه‌سازی فیلترهای فضایی و فرکانسی، خود موضوعی چالش برانگیز است [۱، ۴].

<sup>۸</sup> Morlet Wavelet Transform

<sup>۹</sup> Particle Swarm Optimization

<sup>۱۰</sup> BCI Competition

<sup>۱۱</sup> <http://www.bbc.de/competition/iv/#dataset1>

<sup>۱۲</sup> لازم به ذکر است که این مجموعه داده شامل دو مجموعه داده‌ی

کالیبراسیون و ارزیابی است

<sup>۱۳</sup> Tasks

<sup>۱</sup> Temporal Domain

<sup>۲</sup> Spectrally Weighted CSP

<sup>۳</sup> Fisher Discriminant Ratio

<sup>۴</sup> Optimum Spatio-Spectral Filtering Network

<sup>۵</sup> Maximizing Mutual Information of Spatial Spectral Features

<sup>۶</sup> Mutual Information

<sup>۷</sup> Subspace Optimization

تکرار، کاربر پس از مشاهده یک نشانه روی نمایشگر، تصور حرکتی را به مدت ۴ ثانیه انجام داده و سپس به مدت ۴ ثانیه استراحت می‌کند. اطلاعات کامل‌تر از نحوه ثبت داده‌ها، در [۱۰] ارائه شده است. لازم به ذکر است که در این مقاله، نرخ نمونه‌برداری سیگنال‌های EEG به ۱۰۰ هرتز کاهش می‌یابد.

## ۲-۲- روش‌های پردازشی

### الف) الگوهای فضایی مشترک (CSP)

در حالت دو گروهه، الگوریتم CSP تلاش می‌کند تا فیلترهای فضایی را به نحوی بیابد که توان (واریانس) سیگنال فیلترشده فضایی در یک گروه، بیشینه و در گروه دیگر، کمینه شود. فرض کنید  $\mathbf{X}_1, \mathbf{X}_2 \in \mathbb{R}^{M \times L}$ ، سیگنال‌های مربوط به دو گروه با  $M$  کانال و  $L$ ، نمونه زمانی (با میانگین صفر) باشند. تابع هزینه CSP، به صورت زیر تعریف می‌شود:

$$\max_{\mathbf{w}} \lambda = \frac{\mathbf{w}^T \mathbf{C}_1 \mathbf{w}}{\mathbf{w}^T \mathbf{C}_2 \mathbf{w}} \quad (1)$$

که در آن  $\mathbf{w} \in \mathbb{R}^M$  فیلتر فضایی،  $\mathbf{C}_i = E[\mathbf{X}_i \mathbf{X}_i^T] \in \mathbb{R}^{M \times M}$  ماتریس کواریانس فضایی گروه  $i = 1, 2$ ،  $T$  عملگر ترانپوز و  $E[\cdot]$  عملگر امید ریاضی است. می‌توان ماتریس کواریانس را به صورت  $\mathbf{C}_i \approx \frac{\mathbf{X}_i \mathbf{X}_i^T}{\text{tr}(\mathbf{X}_i \mathbf{X}_i^T)}$  تخمین زد که در آن،  $\text{tr}(\cdot)$  عملگر اثر<sup>۱</sup> است [۱۱]. لازم به ذکر است که برای محاسبه  $\mathbf{C}_i$ ، به‌طور معمول ماتریس کواریانس در آزمایش‌های<sup>۲</sup> مختلف مربوط به گروه  $i$  را به دست آورده و بین آن‌ها، میانگین گرفته می‌شود. به همین دلیل، نرمالیزاسیون ماتریس کواریانس هر انجام وظیفه به وسیله اثر آن ماتریس، باعث بهبود تخمین ماتریس کواریانس میانگین می‌شود؛ چرا که اثر یک ماتریس مربعی متقارن، برابر با جمع مقادیر ویژه آن ماتریس است و در حقیقت با این کار، ماتریس کواریانس هر قطعه سیگنال به مجموع مقادیر ویژه آن، نرمال می‌شود [۱۲].

بیشینه‌سازی رابطه (۱)، معادل با حل کردن مسئله تجزیه مقادیر ویژه<sup>۳</sup> تعمیم‌یافته زیر است:

$$\mathbf{C}_1 \mathbf{w} = \lambda \mathbf{C}_2 \mathbf{w} \rightarrow (\mathbf{C}_2)^{-1} \mathbf{C}_1 \mathbf{w} = \lambda \mathbf{w} \quad (2)$$

$$\mathbf{a} = \log \left[ \frac{1}{L} \text{diag}(\mathbf{Y} \mathbf{Y}^T) \right]^T \quad (3)$$

که در آن  $\mathbf{a} = [a_1, a_2, \dots, a_{2m}]$ ، ویژگی‌های به دست آمده از سیگنال  $\mathbf{X}$  است. لازم به ذکر است که عملگر لگاریتم، برای نرمال‌سازی توزیع و کاهش بازه تغییرات ویژگی‌های به دست آمده، استفاده می‌شود [۴].

### ب) بانک فیلتر الگوهای فضایی مشترک (FBCSP)

الگوریتم FBCSP، سیگنال EEG را در باندهای مختلف فرکانسی، فیلتر کرده، روی هر باند فرکانسی CSP، اعمال کرده و ویژگی‌های به دست آمده از هر باند را در کنار هم قرار می‌دهد. در نهایت FBCSP، با استفاده از الگوریتم انتخاب ویژگی مبتنی بر اطلاعات متقابل، تعداد  $2m$  ویژگی دارای بیشترین اطلاعات متقابل با برچسب گروه‌ها را انتخاب می‌کند. در حالت دو گروهه، به دلیل جفت بودن ویژگی‌های به دست آمده از CSP (برای مثال ویژگی‌های به دست آمده از اولین و آخرین فیلتر فضایی)، به‌طور معمول در FBCSP نیز ویژگی‌ها به صورت جفت انتخاب می‌شوند. در این مقاله، انتخاب ویژگی با استفاده از الگوریتم بهترین اطلاعات متقابل فردی انجام می‌شود [۱۳].

### ج) روش پیشنهادی

فرض کنید ماتریس گردشی  $\mathbf{A} \in \mathbb{R}^{L \times L}$ <sup>۴</sup>، یک فیلتر میان‌گذر در حوزه زمان است، که سیگنال را به صورت  $\mathbf{X}_{filt} = \mathbf{X} \mathbf{B}$  فیلتر

<sup>۴</sup> Circulant

<sup>۱</sup> Trace

<sup>۲</sup> Trials

برای کاهش فضای جست‌وجو در بهینه‌سازی  $\beta$ ، از تبدیل ویولت مُرلت به عنوان فیلتر طیفی در حوزه فرکانس استفاده می‌کنیم. ویولت مُرلت در حوزه زمان به صورت تابع مُرلت است. به سادگی اثبات می‌شود:

$\psi(t) = e^{-\frac{1}{2}(\frac{t-\mu}{\sigma})^2} e^{j\omega t}$  بوده، که  $\mu$  و  $\sigma$  به ترتیب مرکز و عرض فوریه تابع مورلت است. بنابراین تبدیل ویولت مُرلت، یک سیگنال در حوزه فرکانس معادل با ضرب یک تابع گوسی با مرکز  $\mu$  و عرض  $\sigma$  در تبدیل فوریه آن سیگنال است؛ پس می‌توان ضرایب فیلتر طیفی  $\beta$  را به راحتی توسط ویولت مُرلت به دست آورد. به عبارتی:

$$\beta = [\psi(1), \dots, \psi(L)] \quad (7)$$

با این کار، فضای جست‌وجو به مقدار زیادی کاهش می‌یابد؛ چون برای استخراج یک باند فرکانسی، به جای بهینه‌سازی  $L/2+1$  نمونه (در حوزه فرکانس، دامنه فیلتر حول نمونه میانی، متقارن است)، حال تنها کافیست دو متغیر  $\mu$  و  $\sigma$ ، بهینه شوند.

تابع هزینه استفاده شده برای بهینه‌سازی پارامترهای فیلتر طیفی در این مقاله، معیار اطلاعات متقابل بین ویژگی‌های استخراجی و برجسب گروه‌ها است. با فرض این که  $A = \{a_i\}$ ، مجموعه بردارهای ویژگی استخراجی و  $\Gamma = \{\gamma\}$ ، برجسب گروه‌ها باشند (برای مثال در حالت دو گروه داریم:  $\gamma = 1$  و  $\gamma = 2$ )، تابع هزینه به صورت زیر تعریف می‌شود:

$$\max_{\beta} I(A, \Gamma) = H(A) - \sum_{\gamma \in \Gamma} H(A | \gamma) P(\gamma) \quad (8)$$

که  $H(A)$  و  $H(A | \gamma)$ ، به ترتیب آنترپی بردارهای ویژگی استخراج شده و آنترپی شرطی بردارهای ویژگی استخراجی در گروه  $\gamma$  هستند. همچنین  $P(\gamma)$ ، بیان کننده احتمال وقوع گروه  $\gamma$  است. برای تخمین  $I(A, \Gamma)$ ، از روش ارائه شده در مقاله [۴] استفاده می‌کنیم.

برای بهینه‌سازی رابطه (۸)، از الگوریتم تکاملی PSO استفاده می‌کنیم. به طور خلاصه، PSO یک الگوریتم بهینه‌سازی

می‌کند. می‌دانیم که یک ماتریس گردشی در حوزه فرکانس، به یک ماتریس قطری تبدیل می‌شود [۸]:

$$U^T B = \text{diag}(\beta) \quad (4)$$

که در آن  $\beta = [\beta_1, \dots, \beta_L]$  ضرایب فیلتر فرکانسی در حوزه فرکانس (طیفی) و  $U \in \mathbb{R}^{L \times L}$  ماتریس متعامد یکه تبدیل فوریه است، که  $UU^T = U^T U = I$  و ماتریس همانی هستند؛ بنابراین می‌توان ماتریس کواریانس سیگنال فیلترشده  $X_{filt}$  را به صورت زیر به دست آورد:

$$\begin{aligned} \langle C \rangle^i &= \langle E [X_{filt} X_{filt}^T] \rangle^i = \langle E [X B B^T X^T] \rangle^i \\ &= \langle E [X U U^T B B^T U U^T X^T] \rangle^i \\ &= \langle E [\hat{X} \text{diag}(\beta_1^2, \dots, \beta_L^2) \hat{X}^T] \rangle^i \\ &= \langle E \left[ \sum_{l=1}^L \beta_l^2 \hat{X}(:, l) \hat{X}^T(:, l) \right] \rangle^i \\ &= \sum_{l=1}^L \beta_l^2 \langle E [V_l] \rangle^i \approx \sum_{l=1}^L \beta_l^2 \left\langle \frac{V_l}{\text{tr}(V_l)} \right\rangle^i \end{aligned} \quad (5)$$

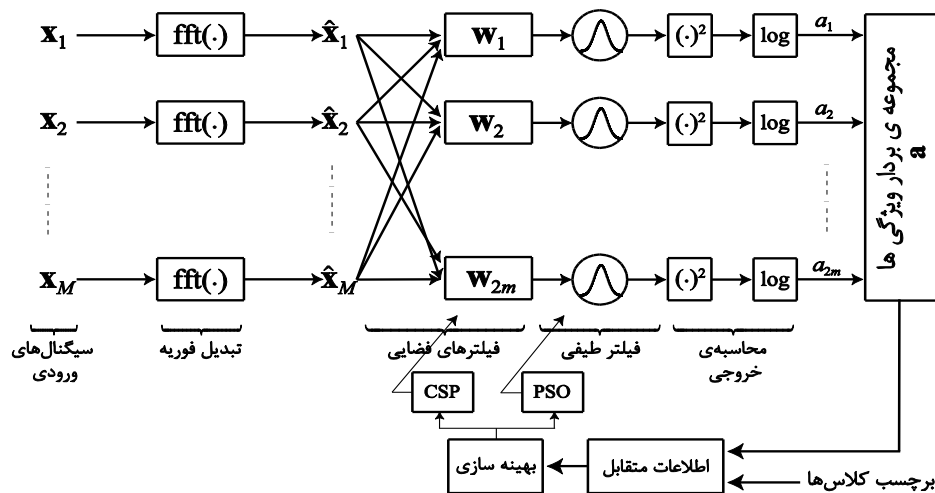
که  $\hat{X}$  تبدیل فوریه  $X$  و  $\langle \cdot \rangle^i$ ، عملگر میانگین‌گیری روی قطعه سیگنال‌های مربوط به گروه  $i$ ام است. لازم به ذکر است که  $V_l = \hat{X}(:, l) \hat{X}^T(:, l)$  یک ماتریس مربعی  $M \times M$  با رتبه<sup>۱</sup> یک است؛ بنابراین تنها یک مقدار ویژه غیر صفر دارد. در این مقاله برای تخمین ماتریس کواریانس یک گروه، ماتریس کواریانس رتبه<sup>۱</sup> یک برای نمونه فرکانسی  $i$ ام، که به مقدار ویژه خود نرمال شده است، به دست می‌آید. میانگین این ماتریس در آزمایش‌های مختلف مربوط به آن گروه، محاسبه شده است و سپس این ماتریس‌ها با ضرایب مربوطه در فیلتر طیفی، با یکدیگر ترکیب خطی می‌شوند.

پس از یافتن فیلترهای فضایی  $W_s$  و فیلتر طیفی  $\beta$ ، ویژگی‌های مربوط به هر قطعه از سیگنال، مطابق با رابطه‌های (۳) و (۵)، به صورت زیر استخراج می‌شوند:

$$\begin{aligned} a &= \log \left[ \frac{1}{L} \text{diag}(Y Y^T) \right]^T \\ &= \log \left[ \frac{1}{L} \text{diag}(W_s^T X_{filt} X_{filt}^T W_s) \right]^T \\ &= \log \left[ W_s^T \hat{X} \text{diag}(\beta_1^2, \dots, \beta_L^2) \hat{X}^T W_s \right]^T \end{aligned} \quad (6)$$

<sup>۲</sup> به عبارتی پهنای باند این فیلتر فرکانسی برابر  $2\sigma$  است.

<sup>۱</sup> Rank



شکل (۱) - بلوک دیاگرام روش ارائه شده برای استخراج ویژگی‌های جداپذیر در BCI‌های مبتنی بر تصورات حرکتی در EEG. مراحل عملکرد روش پیشنهادی به این شرح است: تبدیل فوریه سیگنال‌های  $M$  کاناله EEG محاسبه شده، توسط فیلترهای فضایی و طیفی فیلتر شده و در آخر، لگاریتم هر سیگنال فیلتر شده، به عنوان ویژگی در نظر گرفته می‌شود. یادگیری فیلترهای فضایی و طیفی، با استفاده از بهینه‌سازی متناوب انجام می‌شود؛ به طوری که فیلترهای فضایی، توسط CSP و فیلتر طیفی، توسط PSO به نحوی بهینه شده تا اطلاعات متقابل بین ویژگی‌های استخراجی و برچسب گروه‌ها، بیشینه شود.

(۱) انتخاب بازه‌های زمانی: در انتخاب بازه‌های زمانی سیگنال EEG مربوط به هر انجام وظیفه در مجموعه داده ذکر شده، در این مقاله از یک تا چهار ثانیه پس از شروع تصور حرکتی توسط کاربر در سیگنال استفاده می‌شود؛ به عبارتی، از یک ثانیه اول انجام تصور حرکت در هر تکرار، صرف نظر می‌کنیم. به این دلیل که نشان دادن علامت برای شروع تصور حرکت به کاربر، ممکن است به ایجاد پتانسیل‌های برانگیخته در سیگنال EEG منجر شود [۴، ۱۵].

(۲) CSP: پیش از اعمال CSP، سیگنال EEG به وسیله یک فیلتر میان‌گذر باترورث<sup>۲</sup> درجه چهار با فرکانس قطع ۳۰-۸ هرتز، فیلتر می‌شود، تا ریتم میو و بتا استخراج شود [۴، ۱۱]. همچنین تعداد جفت فیلترهای فضایی برابر با  $m=1$  قرار داده شده است؛ در نتیجه تعداد ۲ ویژگی، استخراج می‌شود.

(۳) FBCSP: برای اعمال الگوریتم FBCSP در این مقاله، دو بانک فیلتر مختلف بررسی می‌شوند در اولین بانک فیلتر، مانند مقاله ارائه دهنده FBCSP، بازه فرکانسی ۴۰-۴ هرتز به ۸ قسمت مساوی تقسیم می‌شود، تا ۹ باند فرکانسی متفاوت بدون هم‌پوشانی با پهنای باند ۴ هرتز ایجاد شوند [۷]. این کار با استفاده از فیلترهای میان‌گذر باترورث درجه ۴، انجام می‌شود. در قسمت نتایج، این روش با عنوان FBCSP1 مطرح خواهد شد.

مبتنی بر جمعیت (ازدحام) است، که سعی دارد تا نقطه اکسترمم سراسری در تابع هزینه را یافته و به دام اکسترمم‌های محلی گرفتار نشود [۱۴]. همچنین الگوریتم PSO، قابلیت اعمال محدودیت بر فضای جست‌وجو را دارد؛ پس به راحتی می‌توان بهینه‌سازی مرکز و عرض یک باند فرکانسی را به صورت  $\mu_{down} \leq \mu \leq \mu_{up}$  و  $\sigma_{down} \leq \sigma \leq \sigma_{up}$  محدود کرد.

شکل ۱، بلوک دیاگرام عملکرد روش پیشنهادی را نشان می‌دهد. همچنین شکل ۲، شبه کد روش ارائه شده را شرح می‌دهد. به طور خلاصه، برای بهینه‌سازی هم‌زمان فیلترهای فضایی و طیفی از روش بهینه‌سازی تناوبی<sup>۱</sup> استفاده می‌کنیم؛ به عبارتی، در ابتدا با یک فیلتر طیفی ثابت، فیلترهای فضایی به وسیله رابطه (۲)، بهینه شده‌اند؛ سپس با ثابت در نظر گرفتن فیلتر فضایی به دست آمده، فیلتر طیفی به وسیله رابطه (۸) و الگوریتم PSO، بهینه می‌شود. این کار تا زمانی ادامه می‌یابد که PSO، اطلاعات متقابل  $I(A, \Gamma)$  را به بیشترین مقدار ممکن برساند.

## ۲-۳- پیش پردازش و انتخاب پارامترها

در این قسمت پیش پردازش انجام شده در پیاده‌سازی هر روش، تشریح می‌شود.

<sup>۲</sup> Butterworth

<sup>۱</sup> Alternative Optimization.

- ورودی:** مجموعه داده‌های آموزشی  $\mathcal{X} = \{\mathbf{X}^{(1)}, \mathbf{X}^{(2)}, \dots, \mathbf{X}^{(N)}\}$  که در آن  $\mathbf{X}^{(n)} \in \mathbb{R}^{M \times L_n}$  سیگنالی با  $M$  کانال  $L_n$  نمونه‌ی زمانی است. مجموعه‌ی برجسب‌های داده‌های آموزشی  $\mathcal{L} = \{\ell^{(1)}, \ell^{(2)}, \dots, \ell^{(N)}\}$  که در آن  $\ell^{(n)} \in \{1, 2\}$  است.
- تعداد جفت فیلترهای فضایی:  $m$
- خروجی:** فیلترهای فضایی  $\mathbf{W}_S = [\mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_m]$  و فیلتر طیفی  $\beta$  بهینه.
- مرحله ۱:** محاسبه‌ی تبدیل فوریه  $\hat{\mathbf{X}}$  برای تمامی سیگنال‌ها.
- مرحله ۲:** محاسبه‌ی ماتریس‌های رتبه یک  $\frac{\mathbf{V}_i}{\text{tr}(\mathbf{V}_i)}$  مربوط به تمامی نمونه‌های فرکانسی که در آن  $\hat{\mathbf{X}}^T(:, l) \hat{\mathbf{X}}(:, l) = \mathbf{V}_i$  است.
- مرحله ۳:** محاسبه‌ی میانگین ماتریس‌های رتبه یک به صورت  $\mathbf{G}_i' = \left\langle \frac{\mathbf{V}_i}{\text{tr}(\mathbf{V}_i)} \right\rangle_i$  به ازای کلاس‌های  $i \in \{1, 2\}$ .
- مرحله ۴:** بهینه‌سازی مرکز  $\mu$  و عرض  $\sigma$  در فیلتر طیفی توسط الگوریتم PSO به منظور حداکثرسازی  $I(A, \Gamma)$ .
- 
- ورودی:**  $\mathcal{X}, \mathcal{L}, m$  و مجموعه ماتریس‌های  $\mathbf{G}_i'$  به دست آمده در مرحله ۲
- خروجی:** مرکز  $\mu$  و عرض  $\sigma$  در فیلتر طیفی.
- مرحله ۱-۴:** ساختن فیلتر طیفی  $\beta$  توسط رابطه (۷).
- مرحله ۲-۴:** محاسبه‌ی ماتریس کواریانس مربوط به هر کلاس توسط رابطه (۵).
- مرحله ۳-۴:** یافتن فیلترهای فضایی از رابطه (۲) و انتخاب  $m$  جفت از بهترین فیلترهای فضایی.
- مرحله ۴-۴:** محاسبه‌ی بردارهای ویژگی با استفاده از رابطه (۶).
- مرحله ۵-۴:** محاسبه‌ی اطلاعات متقابل  $I(A, \Gamma)$  از رابطه (۸).
- 
- مرحله ۱۰:** تکرار مراحل ۱-۴ الی ۳-۴ به منظور یافتن فیلتر طیفی  $\beta$  و فیلتر فضایی  $\mathbf{W}_S$  بهینه.

شکل (۲) - شبه کد الگوریتم ارائه شده برای یافتن همزمان فیلترهای فضایی و طیفی بهینه

سایر روش‌ها، در روش پیشنهادی نیز تعداد  $m=1$  جفت فیلتر فضایی انتخاب می‌شود. در پیاده‌سازی PSO، از دستور "particleswarm" متلب و تنظیمات پیش‌فرض آن استفاده شده است.

### ۳- یافته‌ها و بحث

در این قسمت، نتایج اعمال هریک از روش‌های بالا در حالت آفلاین روی مجموعه داده ذکر شده، بررسی می‌شود. در این مقاله، برای به‌دست آوردن ارزیابی عملکردها، از اعتبارسنجی متقابل  $10 \times 10$  تایی<sup>۱</sup> استفاده می‌شود؛ یعنی مجموعه داده‌ها به‌طور تصادفی به ۱۰ قسمت مساوی تقسیم می‌شود و هر بار، یکی از قسمت‌ها به‌عنوان داده‌های آزمایشی و سایر قسمت‌ها، به‌عنوان داده‌های آموزشی استفاده می‌شوند. این روند ۱۰ بار دیگر نیز انجام می‌شود. پس در این فرایند، ۱۰۰ عملکرد به‌دست می‌آید، که میانگین و انحراف معیار آنها محاسبه و گزارش خواهد شد. همچنین در این مقاله برای گروه‌بندی ویژگی‌های استخراج‌شده از هر روش، از طبقه‌بند آنالیز افتراق خطی (LDA<sup>۲</sup>) استفاده شده است و معیار عملکرد گزارش شده برای هر روش، صحت گروه‌بندی خواهد بود [۱۶]. جدول ۱، نتایج به‌دست آمده در هریک از روش‌ها را نشان می‌دهد. در این جدول، میانگین و انحراف معیار صحت

در روش دیگر تقسیم باند فرکانسی، مانند مقاله [۴]، بازه ۳۲-۸ هرتز به‌صورت لگاریتمی تقسیم شده، تا مرکز ۸ باند فرکانسی مختلف به‌صورت ۸، ۹/۷۵، ۱۱/۸۹، ۱۴/۴۹، ۱۷/۶۷، ۲۱/۵۱، ۲۶/۲۵ و ۳۲ هرتز تولید شوند؛ سپس با استفاده از این مراکز، ۸ فیلتر میان‌گذر باترورث درجه ۴ با فاکتور Q ای برابر ۰/۳۳ ایجاد می‌شوند. لازم به ذکر است که فیلترهای فرکانسی ایجاد شده در این روش، با یک‌دیگر هم‌پوشانی خواهند داشت. در ادامه، از این روش با نام FBCSP2 یاد می‌شود. همچنین در محاسبه معیار اطلاعات متقابل، مانند روش پیشنهادی، از الگوریتم ارائه‌شده در [۴] استفاده خواهد شد. در پایان، پس از انتخاب ویژگی در FBCSP، تعداد  $m=1$  جفت فیلترهای فضایی، انتخاب می‌شود، تا تعداد ویژگی‌های استخراج‌شده برابر با ۲ شود.

۴ روش پیشنهادی: پیش از اعمال روش پیشنهادی، سیگنال‌های EEG به‌وسیله یک فیلتر میان‌گذر باترورث درجه ۴ با فرکانس قطع ۴-۴۰ هرتز فیلتر می‌شوند. همچنین در بهینه‌سازی فیلتر طیفی، پارامترهای محدودیت مرکز و عرض باند فرکانسی به‌صورت  $\mu_{down} = 7$ ،  $\mu_{up} = 35$ ،  $\sigma_{down} = 0.5$  و  $\sigma_{up} = 14$  هرتز در نظر گرفته می‌شوند؛ به‌عبارتی، فیلتر طیفی را محدود می‌کنیم که مرکز آن بین بازه ۷-۳۵ هرتز بوده و عرض آن کمتر از ۰/۵ هرتز و بیشتر از ۱۴ هرتز نشود. مانند

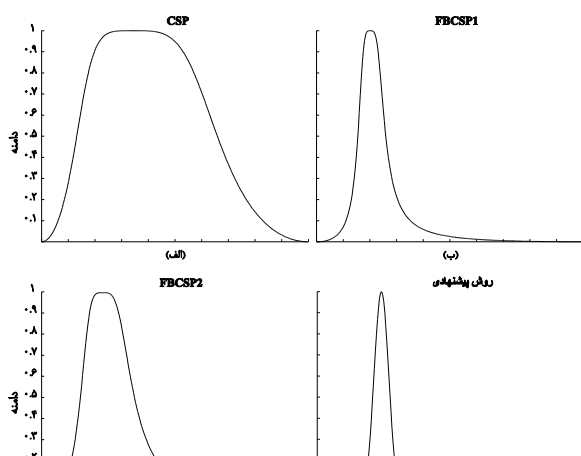
<sup>۲</sup> Linear Discriminant Analysis

<sup>۱</sup> 10×10 Fold Cross Validation



است. از طرف دیگر، فیلتر طیفی بهینه شده در روش این مقاله، حول مرکز ۱۲/۰۶ هرتز واقع شده و پهنای باند آن، کمتر از روش‌های دیگر است. عملکرد به دست آمده در این مثال خاص برای روش CSP، FBCSP1، FBCSP2 و روش پیشنهادی، به ترتیب ۰/۶۵، ۰/۷۰، ۰/۸۰ و ۰/۹۵ بوده است؛ پس می‌توان این نتیجه را از بیشتر بودن عملکرد روش پیشنهادی گرفت، که تصور حرکت دست‌ها باعث ایجاد ERD در باندی باریک به مرکزیت ۱۲ هرتز در این کاربر شده است.

شکل ۴، دو فیلتر فضایی با بیشترین تمایز (مربوط به بزرگ‌ترین و کوچک‌ترین مقدار ویژه) در مثال یادشده را برای تمام روش‌ها نشان می‌دهد. برای مقایسه بهتر، هر کدام از فیلترهای فضایی، به نحوی نرمالیزه شده‌اند تا نرم آنها برابر با یک باشد. ملاحظه می‌شود که فیلترهای فضایی به دست آمده در روش پیشنهادی نسبت به سایر روش‌ها، سازگاری بیشتری با دانسته‌های فیزیولوژیکی ما از ایجاد ERD دارد؛ زیرا فیلتر فضایی مربوط به گروه اول (دست راست)، وزن بیشتری برای کانال‌های مرکزی در نیمکره سمت چپ نسبت داده و فیلتر فضایی دوم (دست چپ)، وزن بیشتری به کانال‌های مرکزی در نیمکره راست داده است. این در حالی است که در فیلتر فضایی دوم در CSP و FBCSP1، چنین رفتاری دیده نمی‌شود. همچنین با این که در فیلترهای فضایی اول و دوم در FBCSP2 و فیلتر فضایی اول در CSP، الگوی وزن‌دهی به کانال‌ها با بحث فیزیولوژیک ERD هم‌خوانی دارد؛ اما وزن‌دهی در کانال‌های مرکزی، تمرکز ندارد و کمی پراکنده است. می‌توان متمرکز بودن وزن‌دهی به کانال‌های مرکزی و هم‌خوانی آن با تفسیر فیزیولوژیکی از ایجاد ERD در فیلترهای فضایی، را عامل کسب کارایی بیشتر در روش پیشنهادی دانست.



شکل (۳) - فیلترهای فرکانسی در روش‌های (الف) CSP (ب)

FBCSP1 (ج) FBCSP2 و (د) روش پیشنهادی

طبقه‌بندی هر روش ارائه شده است. همان‌طور که ملاحظه می‌شود، در تمام کاربرها، میانگین صحت روش ارائه‌شده بیشتر از سایر روش‌ها است. همچنین مشاهده می‌شود که میانگین صحت روی تمام کاربرها، ۹/۶٪ نسبت به CSP، ۸/۸٪ نسبت به FBCSP1 و ۶/۸٪ نسبت به FBCSP2، بیشتر است. در این مقاله، از آزمون ویلکاکسون نیز استفاده شده است تا میانگین عملکرد ۷ کاربر در روش‌های CSP، FBCSP1 و FBCSP2، در مقابل عملکرد روش پیشنهادی قرار گیرند و احتمال فرضیه برابری میانگین عملکرد روش پیشنهادی با سایر روش‌ها (به صورت دوطرفه) بررسی شود. سطر آخر در جدول ۱، احتمالات به دست آمده در این فرضیه را نشان می‌دهد. ملاحظه می‌شود که احتمال‌های برابری میانگین عملکرد روش پیشنهادی با روش دیگر، کمتر از ۰/۰۵٪ است.

#### جدول (۱) - نتایج صحت گروه‌بندی در هر روش برای

کاربرهای مختلف. سطر آخر، بیان‌کننده احتمال فرض تپی در آزمون ویلکاکسون است. نتایج بالاتر در هر کاربر، با خط درشت نمایش داده شده است

روش ارائه شده	CSP	FBCSP1	FBCSP2	کاربر
	$65/6 \pm 13/6$	$72/7 \pm 11/6$	$65/6 \pm 14/5$	$79 \pm 10/3$
	$79 \pm 8/2$	$71/9 \pm 9/7$	$83 \pm 8/2$	$86/1 \pm 7/6$
	$72/4 \pm 8/3$	$73/9 \pm 8/9$	$78/4 \pm 9/6$	$78/9 \pm 9/4$
	$82/9 \pm 9/6$	$90/1 \pm 6/5$	$87/5 \pm 7/8$	$92/1 \pm 6$
	$96/6 \pm 3/4$	$93/8 \pm 4/7$	$96/5 \pm 3/7$	$97/6 \pm 3/4$
	$56/9 \pm 11/3$	$60/2 \pm 15/5$	$64/1 \pm 13/2$	$85,5 \pm 13/1$
	$76/3 \pm 14/2$	$73 \pm 12/6$	$74/5 \pm 14/9$	$78/2 \pm 11/1$
میانگین	$75/7 \pm 9/8$	$76/5 \pm 9/9$	$78/5 \pm 10/3$	$85/3 \pm 8/7$
p-value	۰/۰۰۷۸	۰/۰۰۷۸	۰/۰۲۳۴	-

در ادامه برای بررسی بیشتر تفاوت روش ارائه‌شده با سایر روش‌ها، یک نمونه از فیلترهای طیفی و فضایی در آن‌ها را مقایسه می‌کنیم. شکل ۳، یک مثال خاص از فیلتر فرکانسی استفاده شده (بهینه‌شده) در کاربر *b* در هر روش را نشان می‌دهد، که در آزمایشات خود تصور حرکت دست راست و چپ را انجام می‌دهد. فیلتر فرکانسی در روش CSP، از قبل تعیین شده است و بازه مشخص ۳۰-۸ هرتز را دارد. فیلتر فرکانسی انتخاب‌شده در روش FBCSP1 و FBCSP2، به ترتیب حول فرکانس ۱۰ و ۱۱/۸۹ هرتز قرار دارند. همچنین پهنای باند فیلتر فرکانسی مربوط به FBCSP2، بیشتر از FBCSP1

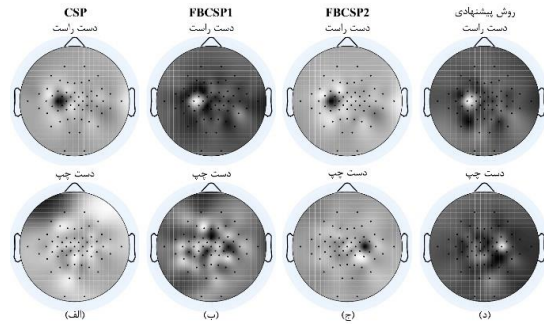
کارایی در طبقه‌بندی تصورات حرکتی شود؛ چون ممکن است پارامتر مرکز در فیلتر طیفی، به سمت فرکانسی میل کند که هیچ تناسبی با رخداد ERD نداشته باشد (برای مثال کمتر از ۴ هرتز) یا پارامتر عرض فیلتر طیفی به سمت عددی کوچک، متمایل شده و باعث ایجاد فیلتری با پهنای باند بسیار کوچک شود. برای این منظور، استفاده از الگوریتم بهینه‌سازی PSO، علاوه بر کاهش خطر گیر کردن در نقاط اکسترمم محلی، اعمال چنین محدودیت‌هایی را روی پارامترها ممکن می‌کند. از طرفی دیگر، حجم محاسباتی این الگوریتم، بیشتر از الگوریتم‌های بهینه‌سازی مبتنی بر مشتق‌گیری است؛ از این رو با ایده استفاده از ویولت مُرلت در حوزه فرکانس، به‌عنوان یک فیلتر طیفی، تعداد متغیرها در بهینه‌سازی و در نتیجه حجم محاسبات را کاهش داده‌ایم. با این حال، با وجود کارایی بیشتر، حجم محاسباتی روش پیشنهادی، به مقدار قابل توجهی بیشتر از سایر روش‌های استفاده‌شده در این مقاله است.

#### ۴- نتیجه‌گیری

در این مقاله، روشی نوین برای بهینه‌سازی هم‌زمان فیلترهای طیفی و فیلترهای فضایی برای هر کاربر ارائه شد. ایده‌های اصلی ما، (۱) استفاده از ویولت مُرلت در حوزه فرکانس، به‌عنوان فیلتر طیفی، برای کاهش متغیرهای بهینه‌سازی و در نتیجه کاهش فضای جست‌وجو، (۲) تخمین ماتریس کواریانس در حوزه فرکانس با استفاده از نرمالیزه کردن ماتریس‌های رتبه یک هر فرکانس به اثر آن، (۳) استفاده از معیار اطلاعات متقابل، به‌عنوان تابع هزینه در بهینه‌سازی و (۴) استفاده از الگوریتم تکاملی PSO، برای ایجاد محدودیت در فضای جست‌وجو و کاهش خطر گیر کردن در اکسترمم‌های محلی، بوده است. نتایج به‌دست آمده در این مقاله نشان داد که روش پیشنهادی به‌طور معنادار، عملکردی بیشتر از دو روش CSP و FBCSP (با دو ساختار مختلف بانک فیلتر) داشته است. پیشنهاد ما برای ادامه و بهبود این رویکرد، بهینه‌سازی هم‌زمان فیلترهای فضایی و فرکانسی با استفاده از معیار اطلاعات متقابل و الگوریتم تکاملی PSO است.

#### ۵- مراجع

- [1] J. Meng, L. Yao, X. Sheng, D. Zhang, and X. Zhu, "Simultaneously optimizing spatial spectral features based on mutual information for EEG classification," *IEEE Transactions on Biomedical Engineering*, vol. 62, no. 1, pp. 227-240, 2015.
- [2] J. R. Wolpaw, N. Birbaumer, D. J. McFarland, G. Pfurtscheller, and T. M. Vaughan, "Brain-computer interfaces for communication and



شکل (۴)- متمایزترین فیلترهای فضایی به‌دست آمده در روش‌های (الف) CSP (ب) FBCSP1 (ج) FBCSP2 و (د) روش پیشنهادی. تصاویر بالا و پایین به ترتیب فیلتر فضایی مربوط به بزرگ‌ترین و کوچک‌ترین مقدار ویژه در هر روش را نشان می‌دهد. لازم به ذکر است که رنگ روشن‌تر بیانگر وزن بیشتر و رنگ تیره‌تر بیانگر وزن‌دهی کمتر به هر ناحیه است

همچنین در شبیه‌سازی روش پیشنهادی، تنها یک باند فرکانسی را بهینه کرده‌ایم؛ به عبارتی در حالت دو گروهه، با تعداد زوج فیلترهای فضایی  $m=1$  نیازی به بهینه‌سازی بیش از یک باند فرکانسی نیست. به‌عنوان مثال، فرض کنید که در این مثال خاص، ما تعداد  $R$  باند فرکانسی را بهینه کنیم. در این حالت از هر باند فرکانسی، تعداد ۲ فیلتر فضایی و در نتیجه ۲ ویژگی استخراج شده است و در نهایت، تعداد  $2R$  ویژگی به‌دست می‌آوریم. حال اگر بخواهیم از میان این ویژگی‌ها، دوتا از بهترین‌ها را انتخاب کنیم، هردوی ویژگی‌های انتخاب‌شده باید از یک باند فرکانسی باشند؛ چرا که فیلترهای فضایی در CSP، به‌صورت جفت عمل کرده و در صورت انتخاب یک فیلتر فضایی از یک باند خاص (برای مثال، مربوط به بزرگ‌ترین مقدار ویژه)، باید فیلتر فضایی جفت آن (مربوط به کوچک‌ترین مقدار ویژه) نیز انتخاب شود. پس به‌طور کلی در روش پیشنهادی، همیشه به بهینه‌سازی  $m$  باند فرکانسی نیاز داریم (حتی در حالت  $C$  گروهه). همچنین روش پیشنهادی، می‌تواند به‌سادگی بهینه‌سازی بیش از ۱ باند فرکانسی تعمیم یافته و در نتیجه بیش از ۲ ویژگی را ایجاد کند. برای این کار، کافیست  $m$  باند فرکانسی به همراه فیلترهای فضایی مربوط به هر باند را از طریق الگوریتم ارائه‌شده در شکل ۲، بهینه کرده و در نهایت، مانند FBCSP، تعداد  $m$  جفت فیلتر فضایی و فیلترهای طیفی مربوط به آنها را انتخاب کرد.

در انتها، باید این موضوع را ذکر کرد که محدودیت اعمال شده در بهینه‌سازی فیلتر طیفی روی مرکز و عرض آن، تأثیر به‌سزایی در عملکرد روش پیشنهادی دارد. آزمایش‌های ما نشان می‌دهد که وجود نداشتن چنین محدودیتی، می‌تواند باعث کاهش

- [9] B. Blankertz, G. Dornhege, M. Krauledat, K.-R. Müller, and G. Curio, "The non-invasive Berlin brain-computer interface: fast acquisition of effective performance in untrained subjects," *NeuroImage*, vol. 37, no. 2, pp. 539-550, 2007.
- [10] G. H. Klem, H. O. Lüders, H. Jasper, and C. Elger, "The ten-twenty electrode system of the International Federation," *Electroencephalogr Clin Neurophysiol*, vol. 52, no. suppl., pp. 3, 1999.
- [11] H. Ramoser, J. Müller-Gerking, and G. Pfurtscheller, "Optimal spatial filtering of single trial EEG during imagined hand movement," *Rehabilitation Engineering, IEEE Transactions on*, vol. 8, no. 4, pp. 441-446, 2000.
- [12] G. Strang, G. Strang, G. Strang, and G. Strang, *Introduction to linear algebra*: Wellesley-Cambridge Press Wellesley, MA, 1993.
- [13] K. K. Ang, Z. Y. Chin, C. Wang, C. Guan, and H. Zhang, "Filter bank common spatial pattern algorithm on BCI competition IV datasets 2a and 2b," *Frontiers in neuroscience*, vol. 6, 2012.
- [14] J. Kennedy, "Particle swarm optimization," *Encyclopedia of machine learning*, pp. 760-766: Springer, 2011.
- [15] G. Pfurtscheller, and C. Neuper, "Motor imagery and direct brain-computer communication," *Proceedings of the IEEE*, vol. 89, no. 7, pp. 1123-1134, 2001.
- [16] R. O. Duda, P. E. Hart, and D. G. Stork, *Pattern classification*: John Wiley & Sons, 2012.
- control," *Clinical neurophysiology*, vol. 113, no. 6, pp. 767-791, 2002.
- [3] J. Wolpaw, and E. W. Wolpaw, *Brain-computer interfaces: principles and practice*: Oxford University Press, 2012.
- [4] H. Zhang, Z. Y. Chin, K. K. Ang, C. Guan, and C. Wang, "Optimum spatio-spectral filtering network for brain-computer interface," *IEEE Transactions on Neural Networks*, vol. 22, no. 1, pp. 52-63, 2011.
- [5] S. Lemm, B. Blankertz, G. Curio, and K.-R. Müller, "Spatio-spectral filters for improving the classification of single trial EEG," *IEEE Transactions on Biomedical Engineering*, vol. 52, no. 9, pp. 1541-1548, 2005.
- [6] G. Dornhege, B. Blankertz, M. Krauledat, F. Losch, G. Curio, and K.-R. Müller, "Combined optimization of spatial and temporal filters for improving brain-computer interfacing," *IEEE transactions on biomedical engineering*, vol. 53, no. 11, pp. 2274-2281, 2006.
- [7] K. K. Ang, Z. Y. Chin, H. Zhang, and C. Guan, "Filter bank common spatial pattern (FBCSP) in brain-computer interface." pp. 2390-2397.
- [8] R. Tomioka, G. Dornhege, G. Nolte, B. Blankertz, K. Aihara, and K.-R. Müller, "Spectrally weighted common spatial pattern algorithm for single trial EEG classification," *Dept. Math. Eng., Univ. Tokyo, Tokyo, Japan, Tech. Rep*, vol. 40, 2006.