

Dimensionality Reduction for Motor Imagery BCI System using Kron Reduction, Graph Fourier Transform and Differential Evolution

Khalili, Mohammad Davood ¹ / Abootalebi, Vahid ^{2*} / Saedi-Sourck, Hamid ²

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

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

ARTICLE INFO

DOI: 10.22041/ijbme.2022.551240.1761

Received: 2 April 2022

Revised: 12 May 2022

Accepted: 14 May 2022

KEYWORDS

Electroencephalogram (EEG)
Brain-Computer Interface (BCI)
Graph Signal Processing (GSP)
Kron Reduction
Differential Evolution (DE)


ABSTRACT

The human brain is one of the most complex and heterogeneous networks, and brain signals contain a lot of information, so researchers in this field are always looking for proper solutions to select meaningful features and reduce the dimension of this information appropriately to lead to better classification. Two of the new tools for brain signal processing are Graph Signal Processing (GSP) and Meta-heuristic and Evolutionary methods. In this paper, a geometric structure and a mixed structure are considered for the brain graph and the weights of the edges in the mixed structure are calculated by a combination of two measures: geometric distance and correlation. To reduce the graph dimension, the weighted degree metric and a combination of the Kron reduction method and Graph Fourier Transform (KG) are used to properly preserve the information of all vertices of the graph into the selected vertices. Feature extraction is performed by Ledoit-Wolf shrinkage estimation and Tangent Space Mapping (TSM) method. For dimension reduction of extracted features, Principal Component Analysis (PCA) method and feature selection based on Differential Evolution (DE) are used. The selected features are given to several well-known machine learning classifiers. To evaluate the performance of the proposed method, dataset IVa from BCI Competition III has been used. The results show that the average classification accuracy of the proposed KG-PCA method with SVM-RBF and DT classifiers, in the structural graph and the functional-structural graph, is higher than the TSM-GFT method expressed in previous studies, and the DT classifier has achieved an average accuracy of 91.15 ± 1.17 . Also, according to the obtained results, the performance of the proposed KG-DE method has been better compared to KG-PCA and in the best case, the average accuracy of the SVM-RBF classifier is equal to 95.50 ± 1.27 .

*Corresponding Author

Address	Department of Electrical Engineering, Yazd University, Yazd, Iran		
Postal Code	89158-18411	Tel	+98-35-31232398
E-Mail	abootalebi@yazd.ac.ir	Fax	+98-35-38200144





کاهش ابعاد برای سامانه‌ی واسط مغز-رایانه‌ی مبتنی بر تصور حرکتی با استفاده از کاهش کرون، تبدیل فوریه روی گراف و تکامل تفاضلی

خلیلی، محمدداود^۱ / ابوطالبی، وحید^{۲*} / سعیدی سورک، حمید^۲

^۱ - دانشجوی کارشناسی ارشد، بخش مخابرات، دانشکده‌ی مهندسی برق، دانشگاه یزد، یزد، ایران

^۲ - دانشیار، بخش مخابرات، دانشکده‌ی مهندسی برق، دانشگاه یزد، یزد، ایران

مشخصات مقاله

شناسه‌ی دیجیتال: 10.22041/ijbme.2022.551240.1761

پذیرش: ۲۴ اردیبهشت ۱۴۰۱

بازنگری: ۲۲ اردیبهشت ۱۴۰۱

ثبت در سامانه: ۱۳ فروردین ۱۴۰۱

چکیده	واژه‌های کلیدی
<p>مغز انسان جزو شبکه‌های پیچیده و ناهمگن محسوب می‌شود و سیگنال‌های مغز حاوی اطلاعات زیادی هستند، از این رو محققان این حوزه همواره در صدد یافتن راه‌حلهایی مناسب برای انتخاب ویژگی‌های معنادار و کاهش بعد مناسب این اطلاعات بوده تا به طبقه‌بندی بهتری دست یابند. دو مورد از ابزارهای نوین برای پردازش سیگنال‌های مغزی، پردازش سیگنال روی گراف (GSP) و روش‌های فراابتکاری و تکاملی هستند. در روش پیشنهادی این مقاله، دو ساختار هندسی و ترکیبی برای گراف مغز در نظر گرفته شده که در ساختار ترکیبی، وزن یال‌ها، ترکیب وزن‌دار دو معیار فاصله‌ی هندسی و همبستگی است. به منظور کاهش بعد گرافی، از معیار درجه‌ی وزن‌دار و ترکیب روش کاهش کرون با تبدیل فوریه روی گراف (KG) استفاده شده است تا به نحو مناسبی اطلاعات تمام راس‌های گراف در رئوس منتخب حفظ شود. استخراج ویژگی توسط تخمین لدویت-وولف و روش نگاشت فضای مماسی انجام شده و برای کاهش بعد ویژگی‌های مستخرج، از روش تحلیل مولفه‌های اصلی (PCA) و انتخاب ویژگی بر اساس تکامل تفاضلی (DE) استفاده شده است. ویژگی‌های منتخب به چندین طبقه‌بند معروف حوزه‌ی یادگیری ماشین داده شده است. برای ارزیابی عمل‌کرد روش پیشنهادی از دادگان IV-a مسابقات BCI-III بهره گرفته شده است. نتایج نشان می‌دهد که میانگین صحت طبقه‌بندی روش پیشنهادی KG-PCA با طبقه‌بندهای ماشین بردار پشتیبان با تابع پایه‌ی شعاعی (SVM-RBF) و درخت تصمیم (DT) در گراف ساختاری و گراف ساختاری-عمل‌کردی نسبت به روش TSM-GFT در مطالعات پیشین بالاتر بوده و طبقه‌بند DT به میانگین درصد صحت $91/15 \pm 1/17$ دست یافته است. همچنین طبق نتایج به دست آمده، عمل‌کرد روش پیشنهادی KG-DE در مقایسه با KG-PCA نیز بهتر بوده و در بهترین حالت، متوسط درصد صحت طبقه‌بند SVM-RBF برابر با $95/50 \pm 1/27$ به دست آمده است.</p>	<p>الکتروانسفالوگرام واسط مغز-رایانه پردازش سیگنال روی گراف کاهش کرون تکامل تفاضلی</p>

*نویسنده‌ی مسئول

بخش مخابرات، دانشکده‌ی مهندسی برق، دانشگاه یزد، یزد، ایران

نشانی

تلفن ۹۸-۳۵-۳۱۲۳۲۳۹۸

۸۹۱۵۸-۱۸۴۱۱

کد پستی

دورنگار ۹۸-۳۵-۳۸۲۰۰۱۴۴

abootalabi@yazd.ac.ir

پست الکترونیک



۱- مقدمه

الکتروانسفالوگرام^۱ (EEG) یا نوار الکتریکی مغز، سیگنال حاصل از ثبت پتانسیل‌های الکتریکی نورون‌های قشر^۲ مغز از طریق الکترودهای قرار گرفته روی سر است [۱]. یکی از زمینه‌هایی که در سال‌های اخیر بسیار مورد توجه محققان علوم مرتبط با مغز واقع شده، پردازش EEG در کاربرد واسط مغز-رایانه^۳ (BCI) است. سامانه‌ی BCI یک وسیله‌ی ارتباطی است که پیام‌ها یا دستورات فرد را به جهان خارج ارسال می‌کند، بدون آن که دستورات از مسیرهای خروجی طبیعی عصبی و عضلانی مغز عبور کنند [۲]. در BCI مبتنی بر تصور حرکتی^۴ از افراد خواسته می‌شود تا خود را در حال انجام یک عمل حرکتی ویژه تصور کنند، بدون آن که خودشان به صورت واقعی حرکتی را انجام دهند. بنابراین BCI با کمک تشخیص فعالیت ذهنی، نوعی رمزگذاری در سیگنال EEG ایجاد کرده که فرد حرکتی را در ذهن تصور کند و سیستم ثبت بتواند آن را تشخیص دهد و فرد بتواند نحوه‌ی انجام آن حرکت را یاد بگیرد.

یکی از ابزارهای نوین برای پردازش سیگنال مغز، پردازش سیگنال روی گراف^۵ (GSP) است. این روش ابزاری کاربردی برای تجزیه و تحلیل دادگانی با ساختار پیچیده و نامنظم بوده [۳] و در آن ساختار عناصر می‌تواند با توجه به برخی از ویژگی‌های ارتباطی به یک‌دیگر متصل و مرتبط شود [۴]. به عبارت دیگر در راستای پیشرفت حوزه‌ی پردازش سیگنال، یک دیدگاه گراف محور به پردازش‌های کلاسیک سیگنال‌های بر بستر شبکه داده شده تا نحوه و تاثیر ارتباطات سیگنال‌ها روی هم به نحو بهتری مورد بررسی قرار گیرد [۵]. در مطالعات اخیر از دیدگاه گرافی و GSP در زمینه‌های شناخت پدیده‌های مرتبط با مغز، تشخیص بهتر بیماری‌ها و اختلالات مغزی [۶]، [۷]، واسط مغز-رایانه [۸، ۹]، تفکیک فرکانسی سیگنال‌های مغزی مربوط به یادگیری [۱۰] و غیره استفاده شده است تا منجر به پیشرفت در شناخت بیشتر مغز، پدیده‌های مرتبط با آن و نیز ارتباطات و عمل کرده‌های نواحی مختلف مغزی شود. به طور خاص در چند سال اخیر تحقیقاتی به منظور کاهش بعد مناسب دادگان BCI-EEG با استفاده از ابزارهای پردازشی GSP صورت گرفته است. تاناکا و هم‌کارانش [۸] به کاهش ابعاد

ماتریس‌های کوواریانس نمونه^۶ (SCM) در کاربرد BCI پرداختند. گراف تعریف شده در این روش یک گراف هندسی^۷ است که بر اساس توزیع هندسی الکترودها روی سطح سر پدید آمده و با معیار فاصله‌ی جغرافیایی، تنها ارتباطات ساختاری^۸ بررسی می‌شود. سپس از روش نگاشت فضای مماسی^۹ (TSM) استفاده شده که نیازمند تخمینی مناسب از ماتریس‌های کوواریانس نمونه است. روش کاهش ابعاد مبتنی بر تبدیل فوری روی گراف^{۱۰} (GFT) برای دستیابی به تخمین‌های صحیح و کم‌بعد از ماتریس‌های کوواریانس نمونه به کار گرفته شده است. این روش پیشنهادی، ماتریس‌های کوواریانس نمونه را از روی نسخه‌ی کاهش بعد یافته‌ی دادگان X تخمین می‌زند. کاهش ابعاد فضای ستونی می‌تواند به صورت $Y=U_r^T X$ به دست آید که U_r ماتریس تصویر به دست آمده از بردار ویژه‌ی ابتدایی ماتریس لاپلاسیان گراف بوده و ویژگی‌های نهایی به ورودی طبقه‌بند ماشین بردار پشتیبان^{۱۱} (SVM) داده شده است. این پژوهش منجر به این نتیجه شد که با استفاده از روش کاهش بعد گرافی GFT می‌توان به نتایج بهتری از روش کاهش بعد سنتی تحلیل مولفه‌های اصلی^{۱۲} (PCA) دست یافت [۸].

کلانتر و هم‌کارانش [۹] به منظور بررسی ارتباطات ساختاری و ارتباطات عمل‌کردی^{۱۳} مغز، گراف هندسی را در دو حالت وزن‌دهی یال‌ها با معیار فاصله‌ی جغرافیایی و وزن‌دهی با ترکیب معیارهای فاصله‌ی جغرافیایی و ضریب همبستگی پیرسون^{۱۴} در کاربرد BCI ایجاد کرده و از GFT برای کاهش ابعاد خروجی نگاشت فضای مماسی و از PCA برای کاهش بعد نهایی بهره بردند تا ویژگی‌های نهایی را به ورودی طبقه‌بند SVM بدهند. آن‌ها به این نتیجه دست یافتند که با استفاده از ضرایب وزن‌دهی مناسب برای دو معیار همبستگی و فاصله، نسبت به استفاده از تک معیار فاصله، می‌توان ویژگی‌های بهتری را ساخت و درصد صحت طبقه‌بندی بالاتری را به دست آورد [۹]. دو چالش اساسی در بهبود نتایج مساله‌ی مطرح شده و نتایج مطالعات پیشین وجود داشته که شامل کاهش ابعاد مطلوب دادگان حجیم EEG روی ساختار پیچیده‌ی گراف مغز و تخمین مناسب ماتریس کوواریانس نمونه برای استخراج ویژگی و طبقه‌بندی مطلوب است. در این مقاله سعی شده است تا

^۱ Structural Connectivity^۲ Tangent Space Mapping (TSM)^۳ Graph Fourier Transform (GFT)^۴ Support Vector Machine (SVM)^۵ Principal Component Analysis (PCA)^۶ Functional Connectivity^۷ Pearson Correlation Coefficient^۱ Electroencephalogram (EEG)^۲ Cortex^۳ Brain-Computer Interface (BCI)^۴ Motor Imagery (MI)^۵ Graph Signal Processing (GSP)^۶ Sample Covariance Matrices (SCM)^۷ Geometric Graph

۱۰۰۰ هرتز و دقت ولتاژی ۰/۱ میکروولت به صورت دیجیتال در آمده است. این مجموعه‌ی داده‌ی عمومی شده، تنها شامل دادگان چهار بخش اولیه‌ی ثبت‌ها و بدون بازخورد است. برای هر تک‌ثبت^{۱۰} تصور حرکتی، یک محرک دیداری^{۱۱} به مدت ۳/۵ ثانیه به افراد نمایش داده شده است که افراد باید در این مدت به تصور حرکت دست راست یا پای راست می‌پرداختند. پس از نمایش محرک هدف^{۱۲}، افراد به طور تصادفی بین ۱/۷۵ ثانیه تا ۲/۲۵ ثانیه فرصت داشتند تا استراحت کنند. برای هر فرد ۲۸۰ ثبت گرفته شده است که ۱۴۰ تک‌ثبت مربوط به کلاس تصور حرکت دست راست و ۱۴۰ تک‌ثبت مربوط به کلاس تصور حرکت پای راست می‌باشد [۱۱، ۱۲].

در این پژوهش تعداد ثبت‌های آموزش و آزمون یک بار برای تمام افراد به طور ثابت به ترتیب برابر با ۱۱۲ و ۱۶۸ در نظر گرفته شده [۸] و بار دیگر مطابق مسابقات سوم BCI دسته‌ی IVa و جدول (۱) برای هر فرد متفاوت در نظر گرفته شده است [۹، ۱۱، ۱۲]. هم‌چنین چندین نتیجه نیز بر اساس ارزیابی متقابل^{۱۳} تمام قسمت‌های دادگان حاصل شده است.

جدول (۱) - تعداد ثبت‌های آموزش و آزمون افراد در مسابقات

سوم BCI دسته‌ی IVa

افراد	aa	al	av	aw	ay
ثبت‌های آموزش	۱۶۸	۲۲۴	۸۴	۵۶	۲۸
ثبت‌های آزمون	۱۱۲	۵۶	۱۹۶	۲۲۴	۲۵۲

۲-۲-۲- پردازش سیگنال روی گراف

در حالت کلی گراف یک سه‌تایی مرتب $G=(V,E,W)$ بوده که در آن V مجموعه‌ای غیرتهی از رئوس، E مجموعه‌ای شامل یال‌ها که رئوس را به هم وصل می‌کنند و W ماتریس مجاورت وزن‌دار^{۱۴} است که بیان‌گر وزن هر یک از این یال‌ها می‌باشد [۴]. در GSP، سه ماتریس مهم به نام‌های ماتریس مجاورت وزن‌دار، ماتریس لاپلاسیان^{۱۵} و ماتریس لاپلاسیان نرمالیزه^{۱۶} وجود دارد. ماتریس مجاورت وزن‌دار گراف G با N راس به صورت زیر تعریف می‌شود.

$$W = [w_{ij}]_{N \times N}$$

پاسخ‌های مناسبی برای این دو چالش مهم مطرح شود. در این پژوهش پاسخ پیشنهادی به چالش اول، استفاده از روش کاهش کرون^۱ در ترکیب با GFT (KG) به منظور کاهش بعد بهتر دادگان BCI با دیدگاه GSP و هم‌چنین بهره‌گیری از روش فراابتکاری^۲ تکامل تفضلی^۳ (DE) برای انتخاب ویژگی‌های برتر است. برای چالش دوم نیز از تخمین‌گر انقباضی لدویت-وولف^۴ برای برآورد مناسب ماتریس کوواریانس نمونه در حالت تعمیم یافته استفاده شده است. نتایج شبیه‌سازی بیان‌گر تاثیر به کارگیری دو پاسخ مذکور در روش پیشنهادی در گراف ساختاری^۵ (SG) و گراف ساختاری-عمل‌کردی^۶ (SFG) نسبت به روش‌های مطالعات پیشین است.

در ادامه ابتدا دادگان، شرایط ثبت آزمایش و توضیحات مقدماتی GSP و گراف مغز بیان شده و سپس روند کلی روش پیشنهادی شامل گام‌های پیش‌پردازش، استخراج ویژگی، کاهش بعد، انتخاب ویژگی و طبقه‌بندی شرح داده شده است. در بخش ۴ به ارائه‌ی نتایج شبیه‌سازی و بحث پیرامون یافته‌ها و در بخش ۵ به جمع‌بندی و نتیجه‌گیری پرداخته شده است.

۲- مواد و روش‌ها

۲-۱- دادگان و شرایط ثبت آزمایش

این پژوهش روی دادگان دسته‌ی IVa از مسابقات سوم BCI انجام شده که در آن فرایند ثبت سیگنال توسط محققان گروه‌های تحلیل داده و علوم اعصاب دانشگاه برلین آلمان به سرپرستی بنجامین بلانکرتز صورت گرفته است [۱۱]. دادگان شامل ثبت EEG فعالیت تصور حرکتی دو کلاسی دست راست و پای راست پنج فرد سالم به نام‌های aa، al، av، aw و ay است که در حالت آرامش، روی صندلی راحتی دسته‌دار نشسته‌اند. ثبت‌ها با استفاده از تقویت‌کننده‌های مخصوص مغز^۷ و کلاه الکتروود^۸ ۱۲۸ کاناله‌ی استاندارد گرفته شده است. با ۱۱۸ الکتروود از جنس نقره-نقره‌کلرید^۹، سیگنال‌های EEG در موقعیت‌های مکانی حالت تعمیم یافته‌ی سامانه‌ی بین‌المللی ۱۰-۲۰ اندازه‌گیری شده و مکان تمام الکتروودها از سه بعد به دو بعد نگاشت شده است. سیگنال‌های EEG با فیلتر میان‌گذر از ۰/۰۵ هرتز تا ۲۰۰ هرتز فیلتر شده و با فرکانس نمونه‌برداری

^۹ Ag/AgCl

^{۱۰} Trial

^{۱۱} Visual Cue

^{۱۲} Target Cue

^{۱۳} Cross-Validation

^{۱۴} Weighted Adjacency Matrix

^{۱۵} Laplacian Matrix

^{۱۶} Normalized Laplacian Matrix

^۱ Kron Reduction

^۲ Meta-Heuristic

^۳ Differential Evolution (DE)

^۴ Ledoit-Wolf Shrinkage Estimator

^۵ Structural Graph (SG)

^۶ Structural-Functional Graph (SFG)

^۷ BrainAmp

^۸ Electrode Cap

در این رابطه $\Lambda = \text{diag}(\lambda_i)$ ماتریس قطری با مقادیر ویژه‌ی ماتریس لاپلاسیان و $U = [u_0, u_1, \dots, u_{N-1}]$ ماتریسی بوده که ستون‌هایی شامل بردارهای ویژه‌ی متعامد یک‌ه‌ی مربوط به ماتریس لاپلاسیان دارد و رابطه‌ی $UU^T = I$ برای آن برقرار است. اگر بردار x به عنوان سیگنال گراف با مقادیر گسسته به صورت $x = [x(0)x(1)\dots x(N-1)]$ در نظر گرفته شود، برای تبدیل فوریه روی گراف با ماتریس لاپلاسیان از $\hat{x} = U^T x$ و برای معکوس تبدیل فوریه روی گراف^۸ با ماتریس لاپلاسیان از $x = U^T \hat{x}$ استفاده می‌شود [۴]. هر مولفه‌ی $\hat{x}(i)$ بیان‌گر مقدار GFT در فرکانس λ_i است. تبدیل فوریه روی گراف را می‌توان معادل تصویر سیگنال گراف بر بردار ویژه‌ی u_i تعریف کرد و فرکانس را می‌توان مقدار ویژه‌ی متناظر با بردار ویژه در نظر گرفت. در تبدیل فوریه با ماتریس لاپلاسیان، بردارهای ویژه‌ی $u_i^T(n)$ مرتبط با مقادیر ویژه‌ی $\lambda_i \geq 0$ بوده و فرکانس برای تمام سیگنال‌گراف‌ها در بازه‌ی نامنفی نگاشت می‌شود در حالی که در تبدیل فوریه با ماتریس لاپلاسیان نرمالیزه، بردارهای ویژه‌ی $v_i^T(n)$ مرتبط با مقادیر ویژه‌ی $0 \leq \gamma_i \leq 2$ هستند و فرکانس برای تمام سیگنال‌گراف‌ها بین صفر تا دو نگاشت می‌شود [۴].

۲-۳- گراف مغز

استخراج ویژگی، کاهش ابعاد و طبقه‌بندی سیگنال‌های مغزی از زمینه‌های مورد توجه در طراحی سامانه‌های واسط مغز-رایانه هستند. یکی از رویکردهای کلی استخراج ویژگی از سیگنال‌های مغزی با کمک گراف که در این مقاله نیز مورد توجه قرار گرفته آن است که ابتدا رئوس و ارتباطات بین رئوس گراف مغزی مورد نظر تعریف شده، سپس سیگنال روی گراف مغز معرفی شده و با استفاده از تکنیک‌های پردازش سیگنال روی گراف، عملیات استخراج و انتخاب ویژگی انجام شود. این رویکرد بیش‌تر در کاربردهایی مانند کاهش ابعاد داده‌ی مغزی [۸، ۹، ۱۷]، استنتاج توپولوژی گراف^۹ مغز [۱۰، ۱۸]، تحلیل طیفی سیگنال مغز با تبدیل موجک [۱۶، ۱۹]، تحلیل ارتباطات دینامیکی مغزی [۱۶، ۲۰] و طبقه‌بندی پتانسیل‌های وابسته به رخداد^{۱۰} [۱۰، ۲۱] مورد استفاده قرار گرفته است. عناصر حیاتی یک شبکه مانند گراف مغز که تحلیلی یک‌پارچه و متمرکز بر توصیف عمل‌کردی را بیان می‌کند شامل رئوس گراف مغز و ویژگی‌های آن‌ها، وزن یال‌های گراف مغز و

در این تعریف اگر یالی بین رئوس V_i و V_j باشد مقدار درایه‌ی W_{ij} غیرصفر و در غیر این صورت مقدار آن صفر است. ماتریس لاپلاسیان گراف G با N راس به صورت زیر تعریف می‌شود.

$$L = D - W \quad (1)$$

در این رابطه W ماتریس مجاورت وزن‌دار و D ماتریس قطری درجه است که به صورت زیر تعریف می‌شود.

$$[D]_{ii} = \sum_{k=1}^N [W]_{ik}$$

در واقع درجه‌ی هر راس برابر با تعداد یال‌های متلاقی با آن راس است [۴]. هم‌چنین تعریف ماتریس لاپلاسیان نرمالیزه‌ی گراف G با N راس به صورت زیر است.

$$L_N = D^{-\frac{1}{2}} L D^{-\frac{1}{2}} = I_N - W_N \quad (2)$$

در این رابطه D ماتریس درجه، L ماتریس لاپلاسیان، I_N ماتریس همانی و W_N ماتریس مجاورت وزن‌دار نرمالیزه است که به صورت زیر تعریف می‌شود [۴].

$$W_N = D^{-\frac{1}{2}} W D^{-\frac{1}{2}}$$

دو حوزه‌ی اصلی در پردازش کلاسیک سیگنال، حوزه‌های زمان^۱ و فرکانس^۲ بوده و در پردازش سیگنال روی گراف نیز به طور مشابه دو حوزه‌ی اصلی، حوزه‌های راس^۳ و طیف^۴ است [۱۳]. تا کنون روش‌های مختلفی در حوزه‌ی GSP مطرح شده است که از مهم‌ترین آن‌ها می‌توان به GFT [۳، ۵، ۱۴]، شیفت سیگنال گراف [۳، ۵]، فیلتر کردن سیگنال گراف [۴، ۵] و تبدیل موجک طیفی روی گراف^۵ (SGWT) [۱۵، ۱۶] اشاره کرد. از آن‌جا که برای یک گراف بدون جهت، ماتریس مجاورت وزن‌دار W متقارن است، ماتریس لاپلاسیان L نیز ماتریسی متقارن و نیمه‌معین مثبت^۶ با مقادیر ویژه‌ی نامنفی و حقیقی می‌باشد. در نتیجه برای تعمیم تبدیل فوریه به حوزه‌ی GSP باید به این نکته توجه کرد که ماتریس لاپلاسیان دارای بردارهای ویژه‌ی متعامد یک‌ه^۷ است. بنابراین تجزیه‌ی ویژه‌ی ماتریس لاپلاسیان به صورت زیر است.

$$L = U \Lambda U^T \quad (3)$$

^۶ Positive Semi-Definite (PSD)

^۷ Orthonormal

^۸ Inverse Graph Fourier Transform (IGFT)

^۹ Graph Topology Inference

^{۱۰} Event-Related Potential (ERP)

^۱ Time Domain

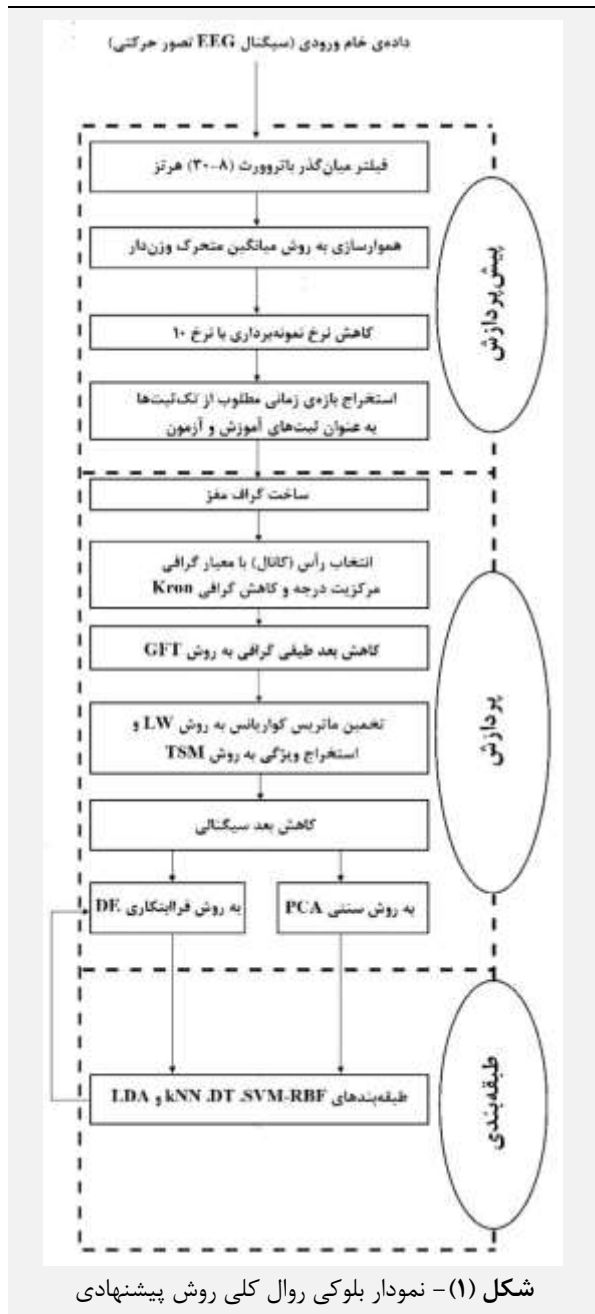
^۲ Frequency Domain

^۳ Vertex Domain

^۴ Spectral Domain

^۵ Spectral Graph Wavelet Transform (SGWT)

کلاسیک سیگنال و GSP استفاده شده که از پنج بخش اصلی شامل ساخت گراف مغز، کاهش بعد گرافی^{۱۲}، استخراج ویژگی، کاهش بعد سیگنالی^{۱۳} و در نهایت طبقه‌بندی تشکیل شده است. در این بخش از مقاله هر یک از گام‌های پیش‌پردازش، پردازش کلاسیک سیگنال، GSP و روش‌های به کار رفته در هر کدام به صورت کامل شرح داده شده است. نمودار بلوکی روال کلی روش پیشنهادی مقاله در شکل (۱) نمایش داده شده است.



معیارهای ارتباط^۱ بین رئوس گراف، توپولوژی گراف مغز و معیارهای توپولوژیکی گراف و تغییرات گراف مغز در طول زمان یا دینامیک گراف مغز می‌باشد [۲۲]. در حالت کلی، گراف مغز از دو بخش اصلی مجموعه‌ای از گره‌ها (بیان‌گر واحدهای آناتومیکی، عمل کردی و محاسباتی) و یال‌ها (بیان‌گر ارتباطات هر زوج گره) تشکیل می‌شود. سیگنال‌های EEG روی الکترودها یا رئوس گراف مغز سوار شده و گراف مغز را در مقیاس بزرگ و بین نواحی مغزی شکل‌دهی می‌کنند که در این مقاله نیز رئوس گراف مغز به همین صورت انتخاب شده است. برای گراف مغز سه نوع وزن‌دهی برای یال‌ها (ارتباطات) به نام‌های ارتباط ساختاری، عمل کردی و موثر^۲ وجود دارد که تعریف هر کدام از آن‌ها در جدول (۲) ارائه شده است. رایج‌ترین معیار ساخت گراف مغز از روی ارتباطات ساختاری، فاصله‌ی هندسی است. معیارهای ارتباطات عمل کردی به دو دسته‌ی بدون جهت و جهت‌دار تقسیم شده که همبستگی^۳ زمانی، همدوسی^۴ طیفی و اطلاعات متقابل^۵ جزو دسته‌ی معیارهای بدون جهت و واگرایی کولبک-لیبلر^۶، آنتروپی انتقال^۷ و شاخص شیب فاز^۸ جزو دسته‌ی معیارهای جهت‌دار محسوب می‌شوند. مطابق جدول (۲) سومین دیدگاه ارتباطی که اطلاعات جدیدی را در مورد گراف مغز ارائه می‌دهد، دیدگاه علیتی یا موثر است که دو روش مهم و کاربردی در دیدگاه ارتباطات موثر، روش علیت گرنجر^۹ و روش علیت دینامیکی^{۱۰} می‌باشد [۲۲].

جدول (۲) - ارتباطات مغزی و وزن‌دهی یال‌های گراف مغز

نام ارتباطات	تعریف
ساختاری	ارتباطات فیزیکی بین رئوس گراف مغز
عمل کردی	وابستگی‌های آماری و ارتباطات بین فعالیت رئوس گراف مغز بدون توجه به علیت
موثر	ارتباطات علت و معلولی بین فعالیت رئوس گراف مغز

۳- روش پیشنهادی

یکی از رویکردهای رایج برای تفکیک فعالیت‌های تصور حرکتی، استفاده از روش‌های بازشناسی الگو^{۱۱} است. در این تحقیق نیز پس از انجام پیش‌پردازش‌ها، از ترکیب یک سامانه‌ی بازشناسی الگو برای BCI مبتنی بر تصور حرکتی با دو دیدگاه پردازش

^۸ Phase Slope Index (PSI)

^۹ Granger Causality Modeling (GCM)

^{۱۰} Dynamic Causal Modeling (DCM)

^{۱۱} Pattern Recognition

^{۱۲} Graph Dimension Reduction

^{۱۳} Signal Dimension Reduction

^۱ Connectivity Measures

^۲ Effective Connectivity

^۳ Correlation

^۴ Coherence

^۵ Mutual Information (MI)

^۶ Kullback-Leibler Divergence (KLD)

^۷ Transfer Entropy (TE)

۳-۱- گام‌های پیش‌پردازش سیگنال

در ابتدا مطابق مطالعات پیشین [۹، ۲۳] از یک فیلتر فرکانسی میان‌گذر باتروورث^۱ مرتبه‌ی ۵ در بازه‌ی ۸-۳۰ هرتز استفاده شده است. این کار برای حفظ باندهای فرکانسی آلفا (۸-۱۳ هرتز) و بتا (۱۳-۳۰ هرتز) انجام شده زیرا در تحقیقاتی موثق نشان داده شده است که عمده‌ی انرژی سیگنال‌های مرتبط با تصور حرکتی در این باندها بوده و این دو باند در طبقه‌بندی تصور حرکتی از اهمیت بالایی برخوردار هستند [۲۳، ۲۴].

برای قیاس منصفانه‌ی روش پیشنهادی با روش مقاله‌ی [۹]، مطابق با آن از روش هموارسازی^۲ میانگین متحرک وزن‌دار^۳ (WMA) استفاده شده که با بررسی‌های انجام شده در مقاله‌ی [۹] عمل کرد بهتری نسبت به روش‌های هموارسازی میانگین متحرک ساده^۴ (SMA) و میانه‌ی متحرک^۵ داشته است. در این مقاله نیز با بررسی دقیق‌تر توابع مختلف برای میانگین متحرک وزن‌دار در این کاربرد، تابع مربعات نسبت به توابع خطی و دوجمله‌ای منجر به خطای بازسازی کم‌تر و نتایج بهتری شده است. در بررسی‌های انجام شده در برخی مطالعات [۲۳، ۲۴] نشان داده شده که فرکانس‌های نزدیک به ۳۰ هرتز نسبت به باند فرکانسی آلفا و سایر فرکانس‌های باند بتا در کاربرد طبقه‌بندی تصور حرکتی از اهمیت چندانی برخوردار نبوده که با شبیه‌سازی‌ها و بررسی‌های انجام شده، با اعمال هموارسازی WMA با تابع مربعات در فرایند پیش‌پردازش، فرکانس‌های نزدیک به ۳۰ هرتز حذف شده و نتایج نشان داده که هموارسازی WMA در این کاربرد، طبقه‌بندی را بهبود می‌دهد. گام بعدی پیش‌پردازش، مانند بسیاری از مطالعات حوزه‌ی BCI [۸، ۹، ۲۵]، کاهش نرخ نمونه‌برداری^۶ بوده که در این مقاله از کاهش نرخ نمونه‌برداری ثابت با نرخ ۱۰ استفاده شده که فرکانس نمونه‌برداری از ۱۰۰۰ به ۱۰۰ هرتز کاهش یافته است. گام نهایی پیش‌پردازش، استخراج زمان مفید فعالیت تصور حرکتی مغز است. در این گام با هدف جلوگیری از دخالت سیگنال پتانسیل برانگیخته‌ی^۷ افراد (در این آزمایش پتانسیل برانگیخته‌ی بینایی ناشی از نمایش محرک دیداری) که از لحاظ زمانی زودتر از سیگنال EEG بروز پیدا می‌کند، گاهی مرسوم است که ۰/۵ ثانیه پس از اعمال محرک به عنوان شروع زمان مفید بررسی سیگنال EEG ناشی از فعالیت تصور حرکتی در نظر گرفته شود [۱۲]. در این مقاله نیز برای استخراج بازه‌ی زمانی مفید حاصل از فعالیت تصور حرکتی افراد، مانند مقالات

[۸، ۹] در هر تک‌ثبت واکنش فرد در بازه‌ی زمانی ۰/۵-۴ ثانیه پس از نمایش محرک دیداری مورد بررسی قرار گرفته و بدین ترتیب سیگنال‌های مورد استفاده برای گام پردازش استخراج شده که شامل ۱۱۸ کانال و ۲۸۰ ثبت بوده و از هر کدام از تک‌ثبت‌ها ۳۵۰ نمونه‌ی مد نظر مورد استفاده قرار گرفته است.

۳-۲- گام‌های پردازش سیگنال

به طور کلی در سامانه‌ی BCI پس از انجام فرایند ثبت سیگنال، به منظور به دست آوردن دستورات کنترلی لازم برای کنترل وسایل مختلف از روی سیگنال EEG، باید پیش‌پردازش‌ها و پردازش‌هایی روی این سیگنال‌ها صورت گیرد که در این مقاله شامل پردازش‌های کلاسیک سیگنال و پردازش‌های نوین گرافی است. در ادامه روند گام‌ها و روش‌های به کار گرفته شده برای ساخت گراف، کاهش بعد گرافی، استخراج ویژگی، کاهش بعد سیگنالی و طبقه‌بندی بیان شده است.

۳-۲-۱- ساخت گراف مغز

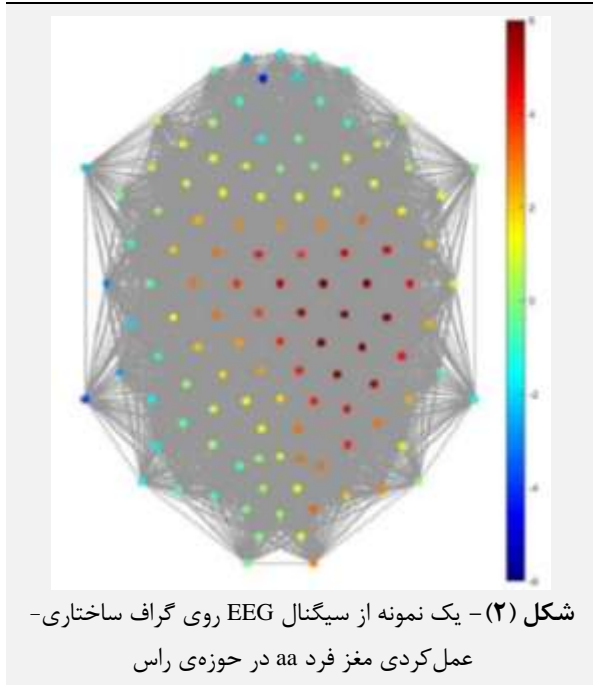
همان‌طور که در بخش گراف مغز توضیح داده شد، برای ساخت هر گونه گرافی از جمله گراف مغز، تعیین دو عنصر اولیه‌ی گراف یعنی رئوس گراف و نحوه‌ی لحاظ کردن ارتباطات بین رئوس، الزامی است. در این مقاله با توجه به استفاده از سیگنال EEG، دو گراف مغز از منظر مقیاس بزرگ بررسی شده و نوع آن‌ها هندسی و ترکیبی در نظر گرفته شده است. رئوس هر دو گراف همان الکترودها یا کانال‌های ثبت EEG هستند که در نتیجه گراف‌های مغز در این پژوهش ۱۱۸ راس دارند. در مورد وزن یال‌های گراف‌ها نیز مانند مقاله‌ی [۹] گراف مغز هم تنها از منظر ارتباطات ساختاری با معیار فاصله‌ی هندسی و هم از ترکیب دیدگاه‌های ارتباطات ساختاری با معیار فاصله‌ی هندسی و ارتباطات عمل‌کردی با معیار همبستگی ساخته شده است. معیار وزن گراف اول یا گراف ساختاری (SG)، فاصله‌ی اقلیدسی بوده و وزن یال‌ها از عبارت نمایی^۸ متناسب با حالت نرمالیزه شده‌ی توان دوم فاصله‌ی اقلیدسی ساخته شده که به ازای هر دو راس مجزای p و q به صورت زیر است.

$$D(p, q) = \sqrt{X^2(p, q) + Y^2(p, q)} \quad (۴)$$

$$W_{SG} = \begin{cases} \exp\left(-\frac{D(p, q)^2}{2\sigma_d^2}\right); & D(p, q) < k \\ 0; & \text{Otherwise} \end{cases} \quad (۵)$$

^۱ Moving Median (MM)^۲ Downsampling^۳ Evoked Potential (EP)^۴ Exponential Expression^۱ Butterworth Band-Pass Filter^۲ Smoothing^۳ Weighted Moving Average (WMA)^۴ Simple Moving Average (SMA)

گرفت. این گراف‌ها برای هر فرد به طور جداگانه اما برای دو نوع فعالیت تصور حرکتی فرد، به طور مشترک استخراج شده است. یک نمونه از سیگنال EEG روی گراف ساختاری-عمل کردی مغز فرد aa در حوزه‌ی راس در شکل (۲) نشان داده شده است.



در رابطه‌ی (۵) متغیر σ_d ضریب نرمالیزه کننده‌ی مربعات فاصله‌ی اقلیدسی و مقدار k حد آستانه‌ی فاصله‌ی اقلیدسی بین دو راس است که اگر فاصله‌ی دو الکتروود از حد آستانه‌ی k بیشتر باشد وزن یال یا میزان ارتباط ساختاری بین آن دو صفر در نظر گرفته شده و اگر فاصله‌ی دو الکتروود کم‌تر از k باشد وزن یال بین دو الکتروود مطابق رابطه‌ی (۵) محاسبه شده و بدین ترتیب گراف هندسی مغز به دست می‌آید. معیار وزن در گراف دوم یا گراف ساختاری-عمل کردی (SFG) ترکیبی از معیار ساختاری فاصله‌ی هندسی اقلیدسی و معیار عمل کردی همبستگی پیرسون در حوزه‌ی راس است و وزن یال‌ها نیز از حاصل ضرب دو عبارت نمایی متناسب با حالات نرمالیزه شده‌ی توان دوم فاصله‌ی اقلیدسی و توان دوم همبستگی ساخته شده که نحوه‌ی محاسبه‌ی همبستگی ρ و وزن گراف دوم به ازای هر دو راس مجزای p و q مطابق روابط زیر است.

$$\rho(p, q) = \frac{C_{pq}}{\sqrt{C_{pp}C_{qq}}} \quad (۶)$$

$$W_{SFG} = \exp\left(-\frac{D(p, q)^2}{2\sigma_d^2}\right) \cdot \exp\left(-\frac{(\|1 - \rho(p, q)\|)^2}{2\sigma_\rho^2}\right) \quad (۷)$$

در رابطه‌ی (۶) مقادیر C_{pp} ، C_{pq} و C_{qq} درایه‌های ماتریس کوواریانس نمونه هستند که در بخش استخراج ویژگی توضیح داده خواهد شد و به ترتیب بیان گر کوواریانس بین رئوس p و q ، واریانس راس p و واریانس راس q می‌باشند. همچنین در رابطه‌ی (۷) متغیر σ_d بیان گر ضریب نرمالیزه کننده‌ی مربعات فاصله‌ی اقلیدسی بین رئوس و متغیر σ_ρ بیان گر ضریب نرمالیزه کننده‌ی مربعات عبارت مرتبط با ضریب همبستگی بین رئوس است. در این مقاله مقادیر نرمالیزه کننده‌ی σ_d برای ماتریس فاصله‌ی اقلیدسی و σ_ρ برای ماتریس همبستگی در سه حالت واریانس درایه‌های ماتریس، درایه‌ی بیشینه‌ی ماتریس و اعداد ثابت مطالعه‌ی [۸] بررسی شده، متناسب با هر فرد، بهترین ضریب نرمالیزه کننده انتخاب شده و مقدار حد آستانه‌ی k نیز مطابق عدد ثابت پژوهش [۸] برابر با ۱ لحاظ شده است. بدین ترتیب با توجه به روابط (۵) و (۷) دو ماتریس وزن به ابعاد 118×118 برای گراف‌های ساختاری و ساختاری-عمل کردی محاسبه شده است. همچنین در گام بعدی به کمک رابطه‌ی (۱) دو ماتریس لاپلاسیان دو گراف نیز با ابعاد 118×118 به دست آمده که در پردازش‌های آتی مورد استفاده قرار خواهد

۳-۲-۲- کاهش بعد و GFT

یکی از پاسخ‌های این مقاله به چالش کاهش ابعاد مطلوب دادگان حجیم EEG، استفاده از روش‌های ساده‌سازی گراف^۱ است. روش‌های ساده‌سازی گراف به دو دسته‌ی کلی تقسیم می‌شوند. دسته‌ی اول تنک‌سازی گراف^۲ بوده که مربوط به کاهش تعداد یال‌های گراف است و از معروف‌ترین آن‌ها می‌توان به زیرگراف‌های فراگیر، برش و تنک‌سازهای طیفی^۳ [۲۶] و روش حل دستگاه معادلات خطی قطری غالب و متقارن^۴ [۲۷] اشاره کرد. دسته‌ی دوم کاهش گراف^۵ بوده که مربوط به کاهش تعداد رئوس گراف است و از معروف‌ترین آن‌ها می‌توان به زمخت‌سازی گراف^۶ [۲۸، ۲۹] و کاهش کرون [۳۰، ۳۱] اشاره کرد [۲۸]. در این مقاله از ترکیب انتخاب رئوس مهم^۷ از طریق معیار گرافی و کاهش کرون برای کاهش بعد راسی یا انتخاب کانال^۸ در گراف مغز و نیز از پردازش GFT برای کاهش بعد بردارهای ویژه و انتقال سیگنال‌های ثبت شده از حوزه‌ی راس به حوزه‌ی طیف استفاده شده است تا ویژگی‌های حوزه‌ی طیف سیگنال گراف مغز به عنوان ویژگی نهایی مد نظر قرار گیرند.

^۱ Graph Reduction

^۲ Graph Coarsening

^۳ Major Vertex

^۴ Channel Selection

^۱ Graph Simplification

^۲ Graph Sparsification

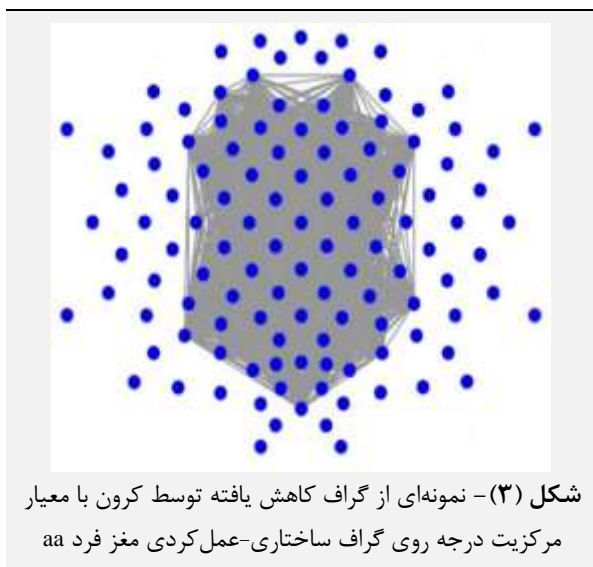
^۳ Spanners, Cut and Spectral Sparsifiers

^۴ Solve SDD Linear System

زیروند ستون آن در بلوک B است. در رابطه‌ی (۸) جمله‌ی اول مربوط به لاپلاسیان رئوس انتخابی بدون در نظر گرفتن تاثیر رئوس محذوف روی رئوس انتخابی و جمله‌ی دوم برای لحاظ کردن تاثیر لاپلاسیان رئوس محذوف روی لاپلاسیان رئوس انتخابی است و بدین ترتیب یکی از مزیت‌های کاهش کرون استفاده‌ی مناسب از وزن و اطلاعات رئوس محذوف، در ساخت ماتریس لاپلاسیان نهایی رئوس انتخابی می‌باشد. به طور یکتا و متناظر با ماتریس لاپلاسیان کاهش یافته با کرون، وزن یال‌های گراف جدید نیز به صورت زیر تعریف می‌شود [۳۰، ۳۱].

$$W_{ij}^{Kron} = \begin{cases} -L_{ij}^{Kron} & ; i \neq j \\ 0 & ; i = j \end{cases} \quad (9)$$

بدین صورت با معیار مرکزیت درجه در گراف مغز و با روش کاهش کرون طبق روابط (۸) و (۹) گراف ۱۱۸ راسی و ماتریس لاپلاسیان متناظر آن با ابعاد ۱۱۸×۱۱۸ به گراف ۵۹ راس برتر و ماتریس لاپلاسیان متناظر آن با ابعاد ۵۹×۵۹ در حوزه‌ی راس کاهش بعد یافته و می‌توان گفت با ادغام انتخاب ۵۹ راس برتر از میان ۱۱۸ راس و اعمال کاهش کرون روی ماتریس لاپلاسیان گراف در حوزه‌ی راس، به تعبیری نمونه‌برداری قدرتمندی در حوزه‌ی راس گراف با نرخ نمونه‌برداری ۲ انجام شده که یک نمونه از آن در شکل (۳) قابل مشاهده است.



در این مقاله نیز مانند پژوهش‌های [۸، ۹] به منظور توجه به ویژگی‌های طیفی گراف مغز، ابتدا تجزیه‌ی ویژه یا تجزیه‌ی طیفی ماتریس لاپلاسیان کاهش یافته با کرون طبق رابطه‌ی (۳)

انتخاب کانال یا کاهش تعداد کانال‌ها در گام پردازش سیگنال، کاهش پیچیدگی محاسباتی را در پی دارد که نکته‌ی شایان توجه در این مورد نحوه‌ی مناسب انتخاب کانال است. انتخاب کانال‌های مناسب از دیدگاه پردازش EEG به تعبیری همان انتخاب رئوس مهم از دیدگاه GSP به شبکه‌ی مغز است. در علم شبکه و گراف معیاری به نام مرکزیت^۱ وجود دارد که اهمیت نسبی یک راس یا یک یال را با توجه به ساختار و عمل‌کرد شبکه بررسی می‌کند و از مهم‌ترین معیارهای انتخاب رئوس مهم است. از مرکزیت درجه‌ی وزن‌دار^۲ یا به بیان ساده‌تر درجه‌ی وزن‌دار، مرکزیت نزدیکی^۳، مرکزیت بینابینی^۴، مرکزیت بردار ویژه^۵، مرکزیت آسیب‌پذیری^۶ و مرکزیت رتبه‌ی صفحه^۷ می‌توان به عنوان مهم‌ترین و پرکاربردترین انواع معیار مرکزیت در شبکه‌ی مغز و شبکه‌های اجتماعی نام برد [۳۲]. در این گام از مرحله‌ی پردازش، معیار ساده و پرکاربرد درجه‌ی وزن‌دار برای انتخاب رئوس مهم گراف مغز به کار گرفته شده و بدین ترتیب ۵۹ راس برتر از ۱۱۸ راس انتخاب شده و به عنوان ورودی به روش کاهش کرون داده شده است.

کاهش کرون از مهم‌ترین روش‌های ساده‌سازی گراف در حوزه‌ی راس بوده که در سال‌های اخیر به طور کاربردی در ساده‌سازی مدارات برق مرتبه‌ی اول و دوم [۳۳]، شبکه‌های برق قدرت [۳۰، ۳۳] و ساده‌سازی گرافی [۳۱] مورد استفاده قرار گرفته است. طبق مقاله‌ی [۳۱] اگر L ماتریس لاپلاسیان گراف وزن‌دار و بدون جهت G با مجموعه‌ی رئوس V بوده و مجموعه‌ی V₁ زیرمجموعه‌ای حداقل ۲ عضوی از مجموعه‌ی رئوس V باشد، آن‌گاه گراف کاهش یافته با روش کرون به صورت رابطه‌ی زیر تعریف می‌شود.

$$G^{Kron} = \{V_1, E^{Kron}, W^{Kron}\}$$

بنابراین اگر V₁ به عنوان رئوس انتخابی و مکمل آن V₁^c به عنوان رئوس محذوف در نظر گرفته شود، با توجه به قضیه‌ی مکمل شور^۸ [۳۴]، ماتریس لاپلاسیان کاهش یافته با روش کرون از روی مکمل شور بلوک رئوس محذوف ماتریس لاپلاسیان اولیه به صورت رابطه‌ی زیر است.

$$L^{Kron} = K(L^{original}, V_1) := L_{V_1, V_1} - L_{V_1, V_1^c} L_{V_1^c, V_1^c}^{-1} L_{V_1^c, V_1} \quad (8)$$

در این رابطه L_{A,B} بیان‌گر زیرماتریس |A|×|B| شامل تمام درایه‌های ماتریس L بوده که زیروند سطر آن در بلوک A و

^۱ Eigenvector Centrality (EC)

^۲ Vulnerability Centrality (VC)

^۳ PageRank Centrality (PRC)

^۴ Schur Complement Theorem

^۱ Centrality

^۲ Weighted Degree Centrality (WDC)


^۳ Closeness Centrality (CC)

^۴ Betweenness Centrality (BC)

در شکل (۴) یک نمونه از خروجی GFT سیگنال گراف فرد aa در حالت گراف ساختاری-عمل کردی به نمایش گذاشته شده است. ماتریس تصویر U_r^T دارای ابعاد 41×59 و ماتریس سیگنال در حوزه‌ی زمان X' دارای ابعاد 59×98000 بوده که از 98000 حاصل ضرب 280 ثبت 350 نمونه‌ای به دست آمده است. در نتیجه اگر زمان کلی تمام تک‌ثبت‌های سیگنال برابر با T در نظر گرفته شود، ماتریس سیگنال در حوزه‌ی طیف Y دارای ابعاد $r \times T$ یا 41×98000 است.

انجام شده که ماتریس بردارهای ویژه‌ی U با ابعاد 59×59 و ماتریس قطری مقادیر ویژه‌ی Λ با ابعاد 59×59 به دست آمده است. سپس مطابق مقاله‌های [۸، ۹] با انتخاب $r=41$ بردار ویژه‌ی ابتدایی مرتبط با فرکانس‌های پایین از ماتریس بردارهای ویژه‌ی U ، عملیات GFT مطابق رابطه‌ی زیر روی سیگنال‌های EEG 59 راس برتر اعمال شده است.

$$Y = U_r^T X' = [u_0, u_1, \dots, u_{r-1}]^T X' \quad (10)$$



شکل (۴) - یک نمونه از خروجی GFT از سیگنال ثبت اول EEG روی گراف ساختاری-عمل کردی مغز فرد aa در حوزه‌ی طیفی گراف

به دست آورد، در ادامه ابتدا به تعریف ماتریس کوواریانس نمونه‌ی حوزه‌ی راس و سپس به تعریف ماتریس کوواریانس نمونه در حوزه‌ی طیف پرداخته شده است. برای استفاده از ویژگی آمارگان مرتبه‌ی دوم کوواریانس، ماتریس کوواریانس نمونه‌ی دادگان هر ماتریس تک‌ثبت X'_i در حوزه‌ی زمان به صورت زیر تعریف می‌شود.

$$C_{X'_i} = \frac{1}{N_t - 1} (X'_i - \mu_{X'_i})(X'_i - \mu_{X'_i})^T \quad (11)$$

در این رابطه $\mu_{X'_i}$ میانگین ستونی X'_i بوده که به ازای هر یک از تک‌ثبت‌های ۱ تا 280 ماتریس X'_i دارای ابعاد 59×350 و بردار میانگین $\mu_{X'_i}$ دارای ابعاد 1×350 است که با 59 بار تکرار به صورت ردیفی زیر هم قرار گرفته و بدین ترتیب ماتریس کوواریانس نمونه برای تمام 280 تک‌ثبت محاسبه می‌شود. عبارت اول عددی، عبارت دوم 59×350 و عبارت سوم 350×59 بوده و در نتیجه ماتریس کوواریانس نمونه‌ی هر تک‌ثبت دارای ابعاد 59×59 است. از آنجا که ماتریس کوواریانس نمونه‌ی $c(n)$ با ابعاد $n \times n$ مثبت معین است، یک عنصر از خمینه‌ی ریمانی^۱ یا فضای ماتریس‌های مثبت معین متقارن $R(n)$ با ابعاد $n \times n$ (عضوی از ماتریس‌های مربعی $S(n)$ با ابعاد $n \times n$) می‌باشد.

$$C(n) = \{ C \in R(n), u^T C u > 0 \} \quad (12)$$

$$R(n) = \{ R \in S(n), R^T = R \} \quad (13)$$

۳-۲-۳- استخراج ویژگی با تخمین ماتریس کوواریانس لدویت-وولف و روش نگاشت فضای مماسی

در روش‌های بازشناسی الگو معمولاً به جای دسته‌بندی داده‌ها در فضای اطلاعات خام، از فضای ویژگی مناسبی که بازنمایی بهتری از اطلاعات داشته باشد استفاده می‌شود. یکی از ویژگی‌های مورد استفاده در تعدادی از پژوهش‌های پیشین BCI از نوع تصور حرکتی [۳۵، ۳۶]، یک ویژگی آماری مرتبه‌ی دوم به نام ماتریس کوواریانس بوده و یکی از روش‌های مرسوم برای استخراج مناسب این ویژگی روش نگاشت فضای مماسی است که در ادامه توضیح داده خواهد شد. هم‌چنین در ادامه یک چالش محاسباتی در روش نگاشت فضای مماسی بیان می‌شود که یکی از پاسخ‌های مناسب به آن بهره‌گیری از تخمین لدویت-وولف است. دادگان EEG تصور حرکتی پس از انجام پیش‌پردازش‌های لازم و کاهش بعد، به ازای هر یک از تک‌ثبت‌ها ($1 \leq i \leq 280$) به صورت ماتریس زیر است.

$$X'_i \in \mathbb{R}^{N_{ch} \times N_t}$$

در این رابطه \mathbb{R} بیان‌گر حوزه‌ی حقیقی، N_{ch} تعداد کانال‌های ثبت منتخب در مراحل قبل و N_t تعداد نمونه‌های زمانی جمع‌آوری شده از هر الکتروود در هر تک‌ثبت است که در دادگان این مقاله به ترتیب برابر با 59 و 350 هستند. از آنجا که مطابق مطالعات پیشین، ماتریس کوواریانس حوزه‌ی طیف را می‌توان بر حسب ماتریس کوواریانس حوزه‌ی راس به صورت راحت‌تری

^۱ Riemannian Manifold

تخمین گر لدویت-وولف، تخمین‌گری انقباضی است که به سمت مقدار تخمین‌گر اولیه‌ی ماتریس کوواریانس نمونه میل می‌کند. در واقع اگر ماتریس X شامل t مشاهده‌ی مستقل با توزیع یکسان^۱ به ابعاد $n \times t$ در نظر گرفته شود که t تعداد نمونه‌های تمام ثبت‌ها و n تعداد الکترودها باشد، تخمین‌گر اولیه‌ی ماتریس کوواریانس نمونه همان رابطه‌ی (۱۱) یا (۱۴) است. حال اگر S تخمین‌گر اولیه‌ی ماتریس کوواریانس نمونه باشد، F مدل تک‌شاخص در نظر گرفته می‌شود که به طور غیرمستقیم اطلاعات را از نمونه‌ها استخراج کرده و توسط رابطه‌ی زیر به دست می‌آید.

$$F = \frac{1}{n} \sum_{i=1}^n \text{diag}(S) \times I_{n \times n} \quad (15)$$

در رابطه‌ی (۱۵) $\text{diag}(S)$ بیان‌گر قطر اصلی ماتریس S است. با یافتن پارامترهای ϕ و γ از روابط (۱۶) و (۱۷)، ضریب انقباض از طریق رابطه‌ی (۱۸) محاسبه می‌شود.

$$\phi = \sum_{i=1}^n \sum_{j=1}^n \left(\left(\frac{X^2 \times (X^2)^T}{t} \right) - S^2 \right) \quad (16)$$

$$\gamma = \|S - F\|_{Fro}^2 \quad (17)$$

$$\alpha = \max \left(0, \min \left(1, \frac{\phi}{(\gamma \times t)} \right) \right) \quad (18)$$

در رابطه‌ی (۱۷) Fro نرم فروبینیوس^۲ ماتریس $S-F$ است. تخمین‌گر انقباضی لدویت-وولف برای ماتریس کوواریانس نمونه‌ی معکوس‌پذیر از طریق رابطه‌ی زیر حاصل می‌شود.

$$\Sigma = (1 - \alpha)S + \alpha F \quad (19)$$

در واقع تخمین LW به صورت ترکیب وزن‌داری از ماتریس مدل تک‌شاخص F و تخمین اولیه‌ی ماتریس کوواریانس نمونه‌ی S به دست می‌آید که وزن‌ها متناسب با ضریب انقباض α هستند [۳۸، ۳۷]. در روش لدویت-وولف پارامتر α به صورت بهینه برای هر فرد و هر نوع گراف به دست می‌آید. در روش پیشنهادی، با استفاده از رابطه‌ی (۱۹) که توسط لدویت و وولف ثابت شده و تخمینی قوی برای ماتریس کوواریانس نمونه است [۳۸، ۳۷] مشکل مقادیر ویژه‌ی نزدیک به صفر که باعث مختلط شدن مقادیر ویژه‌ی می‌شود برطرف شده و با استفاده از یک تخمین‌گر انقباضی، برآوردی مناسب از ماتریس کوواریانس نمونه‌ی حوزه‌ی طیفی گراف صورت گرفته و حال مقادیر ویژه‌یها برای گام‌های پسین روش TSM قابل قبول هستند.

ماتریس $C(n)$ اقلیدسی نیست و روش نگاشت فضای مماسی، یک فضای اقلیدسی مماسی در نقطه‌ی Q به صورت $T_Q C(n)$ ایجاد کرده که به صورت محلی خمینه‌ی ریمانی را به خوبی تقریب می‌زند. در نتیجه هدف از نگاشت فضای مماسی، نگاشت غیرخطی ماتریس کوواریانس نمونه‌ی C_{X_i} حاصل از رابطه‌ی (۱۲) در فضای خمینه‌ی ریمانی به فضای اقلیدسی است تا بتوان روش‌های انتخاب ویژگی، کاهش بعد و طبقه‌بندی در حوزه‌ی یادگیری ماشین را روی آن اعمال کرد. همان‌طور که بیان شد، فرایند استخراج ویژگی ماتریس کوواریانس نمونه از طریق TSM انجام می‌شود که گام‌های استفاده شده در این مقاله به صورت زیر است.

۳-۲-۳-۱- محاسبه‌ی ماتریس کوواریانس نمونه‌ی EEG برای هر تک‌ثبت در حوزه‌ی طیفی گراف

برای این کار با استفاده از رابطه‌ی (۱۲) و سیگنال در حوزه‌ی طیف Y ، کوواریانس نمونه‌ی هر تک‌ثبت در حوزه‌ی طیفی گراف به صورت زیر تعریف می‌شود.

$$C_{Y_i} = \frac{1}{N_t - 1} (Y_i - \mu_{Y_i})(Y_i - \mu_{Y_i})^T = U_r^T C_{X_i} U_r \quad (14)$$

در رابطه‌ی (۱۴) نیز مشابه رابطه‌ی (۱۱) میانگین ستونی Y_i است، اما به ازای هر یک از تک‌ثبت‌های ۱ تا ۲۸۰، ماتریس Y_i دارای ابعاد 41×350 و بردار میانگین μ_{Y_i} دارای ابعاد 1×350 بوده که با ۴۱ بار تکرار به صورت ردیفی زیر هم قرار گرفته و بدین ترتیب ویژگی ماتریس کوواریانس نمونه‌ی حوزه‌ی طیف برای تمام ۲۸۰ تک‌ثبت محاسبه می‌شود که ابعاد ماتریس کوواریانس نمونه‌ی هر تک‌ثبت برابر با 41×41 است. چالشی که در این بخش از استخراج ویژگی TSM وجود دارد این است که گاهی یکی از مقادیر ویژه‌ی برخی از ماتریس‌های کوواریانس نمونه بسیار نزدیک به صفر شده و باعث ایجاد مشکل می‌شود. در واقع در این حالت از لحاظ محاسباتی مقدار ویژه‌ی بسیار نزدیک به صفر باعث می‌شود که تعدادی از ماتریس‌های کوواریانس نمونه، معین مثبت تلقی نشده و نیمه‌معین مثبت تلقی شوند و از لحاظ عددی، نتایج خروجی نگاشت نیز مختلط شده و دیگر به عنوان ورودی روش‌های انتخاب ویژگی و طبقه‌بند در یادگیری ماشین قابل استفاده نباشند. راه حل مورد استفاده در این مقاله برای پاسخ‌گویی به این چالش، استفاده از روش تخمین انقباضی لدویت-وولف (LW) برای ماتریس کوواریانس نمونه است [۳۸، ۳۷].

^۲ Frobenius Norm

^۱ Independent and Identical Distribution (IID)

۳-۲-۴- کاهش بعد سیگنالی

همان‌طور که در بخش استخراج ویژگی بیان شد، ابعاد فضای اقلیدسی مماسی حاصل از TSM یا همان تعداد ویژگی‌های هر ثبت برابر با ۸۶۱ است که در مقایسه با ۲۸۰ ثبت دادگان، برای طبقه‌بندی بزرگ بوده و احتمال مواجهه با مشکل نفرین ابعاد^۵ زیاد می‌باشد. بدین منظور از دو روش استفاده شده که اولین آن‌ها روش مرسوم PCA بوده که در مقاله‌های [۸، ۹] نیز برای کاهش بعد مورد استفاده قرار گرفته است. ماتریس ویژگی‌های استخراجی از روش TSM را می‌توان به صورت زیر در نظر گرفت که در آن m تعداد ویژگی‌های هر ثبت و برابر با ۸۶۱ بوده و I تعداد ثبت‌ها و برابر با ۲۸۰ است.

$$S = [s_1, s_2, \dots, s_I] \in \mathbb{R}^{m \times I}$$

با استفاده از روش کلاسیک PCA، بردارهای مماسی S_i متعامد شده و ابعاد ماتریس ویژگی‌های جدید به صورت زیر بوده که در آن $I < m$ بوده و ابعاد ویژگی‌ها کاهش یافته است.

$$S_0 = U^T S \in \mathbb{R}^{l \times I}$$

هم‌چنین تعداد ویژگی r برای روش PCA برابر با ۱۰ انتخاب شده و در نهایت ۱۰ ویژگی برتر هر ثبت برای ورودی طبقه‌بندها در نظر گرفته شده است.

دومین روش انتخاب ویژگی و کاهش بعد سیگنالی مورد بررسی در روال پردازشی پیشنهادی این مقاله، روش تکامل تفاضلی بوده که یکی از روش‌های بهینه‌سازی تقریبی^۶ از نوع روش‌های فراابتکاری است. یکی از چالش‌های مهم در پیش‌رفت سامانه‌ی BCI بالا بودن ابعاد داده در فرایند استخراج ویژگی است [۳۹]. روش‌های فراابتکاری با انتخاب ویژگی بر اساس ارزیابی صحت طبقه‌بندی سامانه می‌توانند از راه حل‌های قوی برای حل این چالش باشند و از آن‌جا که در برخی از کاربردها در جست‌وجوی فضاهای ویژگی بزرگ برای یافتن پاسخ بهینه موفق بوده‌اند، روش‌هایی امیدوارکننده هستند. روش‌های فراابتکاری از جمله الگوریتم بهینه‌سازی ازدحام ذرات^۷ (PSO) [۳۹، ۴۰]، تکامل تفاضلی (DE) [۳۹، ۴۰]، کلونی زنبور عسل مصنوعی^۸ (ABC) [۳۹]، بهینه‌سازی کلونی مورچگان^۹ (ACO) [۳۹]، الگوریتم ژنتیک^{۱۰} (GA) [۴۰] و الگوریتم کرم شب‌تاب^{۱۱} (FA) [۴۱] در انتخاب ویژگی و کاهش بعد موفق عمل کرده‌اند [۴۲].

۳-۳-۲- محاسبه‌ی میانگین کوواریانس تک‌ثبت‌ها

در مقاله‌ی [۸] بیان شده که انتخاب معیار محاسبه‌ی میانگین فاصله در درصد صحت طبقه‌بندی EEG موثر است. در این گام می‌توان از چند نوع میانگین مانند میانگین فاصله‌ی اقلیدسی^۱، میانگین فاصله‌ی ریمانی^۲ [۳۵، ۹]، میانه‌ی فاصله‌ی ریمانی^۳ و میانگین فاصله‌ی لگاریتمی-اقلیدسی^۴ [۸] استفاده کرد [۳۵]. مرسوم‌ترین نوع محاسبه‌ی میانگین کوواریانس تک‌ثبت‌ها در مطالعات پیشین تصور حرکتی، میانگین فاصله‌ی ریمانی بوده و در این پژوهش نیز از این نوع میانگین فاصله استفاده شده است که به صورت زیر تعریف می‌شود.

$$\bar{C} = \frac{1}{N_{Trial}} \sum_{i=1}^{N_{Trial}} C_{Y_i} \quad (20)$$

در این رابطه متغیر N_{Trial} بیان‌گر تعداد تک‌ثبت‌ها بوده که در این دادگان برابر با ۲۸۰ است.

۳-۳-۲-۳- محاسبه‌ی نگاشت s_i از ماتریس کوواریانس $C(n)$

در فضای ریمانی به $T_Q C(n)$ در فضای اقلیدسی ($Q = \bar{C}$) در این گام، نگاشت s_i با نقطه‌ی مرجع \bar{C} مطابق با رابطه‌ی زیر انجام می‌شود.

$$s_i = Upper(\log(\frac{-1}{\bar{C}} C_{Y_i} \frac{-1}{\bar{C}})) \quad (21)$$

عمل‌گر upper عناصر بالامثلثی غیرقطری ماتریس را در $\sqrt{2}$ ضرب کرده، عناصر قطری ماتریس را مانند قبل نگه داشته و عناصر پایین‌مثلثی را حذف می‌کند. با توجه به عمل‌گر upper تعداد ویژگی‌های استخراج شده از روش TSM برای هر ثبت از طریق رابطه‌ی زیر به دست می‌آید.

$$m = \frac{n(n+1)}{2}$$

در این مقاله با توجه به ماتریس کوواریانس نمونه‌ی طیفی گراف با ابعاد 41×41 و میانگین فاصله‌ی ریمانی ماتریس کوواریانس تک‌ثبت‌ها با ابعاد 41×41 ، تعداد نقاط نگاشت یافته‌ی n برابر با ۴۱ بوده و تعداد ویژگی‌های مستخرج از TSM برای هر ثبت ۸۶۱ ویژگی است و در کل ابعاد ماتریس ویژگی‌ها مشابه مقالات [۸، ۹] برابر با ۲۸۰ ثبت در ۸۶۱ ویژگی برای هر ثبت می‌باشد.

^۷ Particle Swarm Optimization (PSO)

^۸ Artificial Bee Colony (ABC)

^۹ Ant Colony Optimization (ACO)

^{۱۰} Genetic Algorithms (GA)

^{۱۱} Firefly Algorithm (FA)

^۱ Mean Euclidean Distance

^۲ Mean Riemannian Distance

^۳ Median Riemannian Distance

^۴ Mean Log-Euclidean Distance

^۵ Curse of Dimensionality

^۶ Approximate Optimization Methods

در این رابطه $(x_q^t - x_r^t)$ بردار تفاضلی نامیده شده و پارامتر F وزن تفاضلی یا ضریب مقیاس بوده که در این پژوهش از بازه‌ی ۰ تا ۲ انتخاب شده است. همچنین مولفه‌ی i -ام بردار v در زمان $t+1$ یا شماره‌ی تکرار حلقه‌ی $t+1$ جدید است.

۳- گام توزیع

عملگر توزیع با پارامتر $CR \in [0,1]$ که پارامتر احتمال توزیع است کنترل می‌شود. به ازای تمام جمعیت $(i=1, \dots, n)$ رابطه‌ی زیر برقرار است.

$$j_{rand} = \lfloor rand[0,1) \times D \rfloor$$

به ازای تمام ابعاد $(j=1, \dots, D)$ ، مولفه‌ی j -ام از هر بردار جهش یافته‌ی v_i با اعمال احتمالی توزیع، به صورت زیر به‌روزرسانی می‌شود.

$$u_{j,i}^{t+1} = \begin{cases} v_{j,i}^t & ; \text{if } r_i \leq CR \text{ or } j = j_{rand} \\ x_{j,i}^t & ; \text{if } r_i > CR \text{ and } j \neq j_{rand} \end{cases} \quad (23)$$

در این رابطه r_i مقداری تصادفی از ۰ تا ۱ است. این گام توزیع مربوط به توزیع دوجمله‌ای^{۱۳} DE بوده که معادل توزیع تک‌نقطه‌ای در الگوریتم ژنتیک است. توزیع نمایی^{۱۴} DE نیز معادل توزیع دونقطه‌ای در الگوریتم ژنتیک تعریف شده که در روال پیشنهادی مقاله مورد استفاده قرار نگرفته است.

۴- گام انتخاب

به ازای تمام جمعیت $(i=1, \dots, n)$ با ارزیابی بردار آزمایشی u_i^{t+1} ، پاسخ x_i با بهینه‌سازی تابع هدف f از نوع بیشینه یا کمینه‌ی سراسری در رابطه‌ی زیر انتخاب شده و به‌روزرسانی می‌شود.

$$x_i^{t+1} = \begin{cases} u_i^{t+1} & ; \text{if } f(u_i^{t+1}) \leq f(x_i^t) \\ x_i^t & ; \text{otherwise} \end{cases} \quad (24)$$

در این رابطه $f(\cdot)$ تابع هدف بهینه‌سازی بوده که در این پژوهش نیز مشابه مقاله‌های [۳۹، ۴۰] در فرایند آموزش، درصد صحت طبقه‌بندی دادگان آموزشی در نظر گرفته شده و در فرایند آزمون، با دادگان آزمون مورد ارزیابی قرار گرفته است. این روند چهار گامی به ازای تمام نسل‌های مد نظر باید تکرار شود.

یکی از رایج‌ترین روش‌های بهینه‌سازی تکاملی، روش DE است. روش DE یک الگوریتم جست‌وجوی تصادفی ساده و قدرتمند مبتنی بر جمعیت^۱ بوده که برای حل مسائل بهینه‌سازی در حوزه‌های وسیعی از علوم پایه و مهندسی به کار گرفته شده و عمل‌کرد موفقی داشته است. در DE استراتژی‌های زیادی برای ایجاد بردار آزمایشی^۲ وجود دارد که تعداد کمی از آن‌ها راهی مناسب برای پاسخ به مساله‌ای خاص هستند. این روش شامل سه پارامتر کنترلی مهم اندازه‌ی جمعیت^۳ n ، ضریب مقیاس^۴ F و نرخ توزیع^۵ CR است که تاثیر چشم‌گیری در عمل‌کرد روش DE دارند. الگوریتم DE به صورت فرایندی تکاملی یک جمعیت با اندازه‌ی n از بردارهای پارامتری D -بعدی به نام افراد را مورد هدف قرار داده و راه حل‌های ممکن را رمزگذاری می‌کند یعنی به ازای $i=1, \dots, n$ جمعیت $X_{i,G} = \{x_{i,G}^1, \dots, x_{i,G}^D\}$ را به سمت بهینه‌ی سراسری^۶ هدایت می‌کند [۴۳].

روش بهینه‌سازی فراابتکاری DE مشابه روش الگوریتم ژنتیک، یک روش جست‌وجوی مبتنی بر بردار بوده که دو مزیت آن قدرت هم‌گرایی^۷ بالا و یافتن بهینه‌ی سراسری یا عبور از تله‌ی بهینه‌های محلی است. این روش یک الگوریتم جست‌وجوی تصادفی با توانایی خودسازمان‌دهی و بدون استفاده از اطلاعات مشتق است. مشابه الگوریتم ژنتیک، DE نیز از مفاهیم توزیع و جهش^۸ به عنوان عمل‌گر بهره می‌برد اما این عمل‌گرها تفاضلی^۹ بوده و دارای معادلات ضمنی به‌روزشونده^{۱۰} نیز هستند. فرایند طی شده در الگوریتم DE در شکل (۵) نشان داده شده و برای اجرای مرسوم‌ترین حالت DE که در این پژوهش از آن استفاده شده، گام‌های زیر به ترتیب اجرا شده است.

۱- گام آغاز

الگوریتم با یک پاسخ x_i $(i=1, \dots, n)$ که به طور تصادفی انتخاب شده، آغاز شده است.

۲- گام جهش

به ازای تمام جمعیت $(i=1, \dots, n)$ ، سه بردار متمایز x_p ، x_q و x_r به طور تصادفی انتخاب شده تا مطابق رابطه‌ی (۲۲) با اعمال جهش در مولفه‌ی i -ام بردار اهداکننده^{۱۱}، بردار اهداکننده‌ی جدید تولید شود.

$$v_i^{t+1} = x_p^t + F(x_q^t - x_r^t) \quad (22)$$

^۱ Mutation

^۲ Differential Operation

^۳ Explicit Updating Equation

^۴ Donor Vector

^۵ Iteration

^۶ Binomial Crossover

^۷ Exponential Crossover

^۱ Population-Based

^۲ Trial Vector

^۳ Population Size

^۴ Scaling Factor

^۵ Crossover Rate

^۶ Global Optimize

^۷ Convergence

بازشناسی الگوی مرتبط با سامانه‌ی BCI، تفکیک و تخصیص مناسب مجموعه‌ای از نمونه‌ها به دو یا چند کلاس است. در این تحقیق به منظور بررسی عمل‌کرد ساختار پیشنهادی و همچنین مقایسه‌ی عمل‌کرد آن با مطالعات پیشین از دیدگاه GSP محور [۸، ۹] و از دیدگاه انتخاب ویژگی فراابتکاری DE [۳۹]، ویژگی‌های برگزیده شده توسط دو روش PCA و DE به طبقه‌بندهای مرسوم و کاربردی ماشین بردار پشتیبان با تابع پایه‌ی شعاعی^۱ (SVM-RBF)، درخت تصمیم^۲ (DT)، K نزدیک‌ترین همسایه^۳ (KNN) و تحلیل تفکیک خطی^۴ (LDA) داده شده و برای ارزیابی و اعتبارسنجی از روش ارزیابی متقابل ۵ قسمتی^۵ و ۱۰ قسمتی استفاده شده است. در فرایند شبیه‌سازی، درصد صحت طبقه‌بند KNN با آزمودن اعداد مختلف K از مجموعه‌ی {۳، ۵، ۷، ۹، ۱۱، ۱۳} محاسبه شده که عدد ۱۱ منجر به بهترین درصد صحت شده و بدین ترتیب K بهینه برای طبقه‌بندی در این مقاله برگزیده شده است.

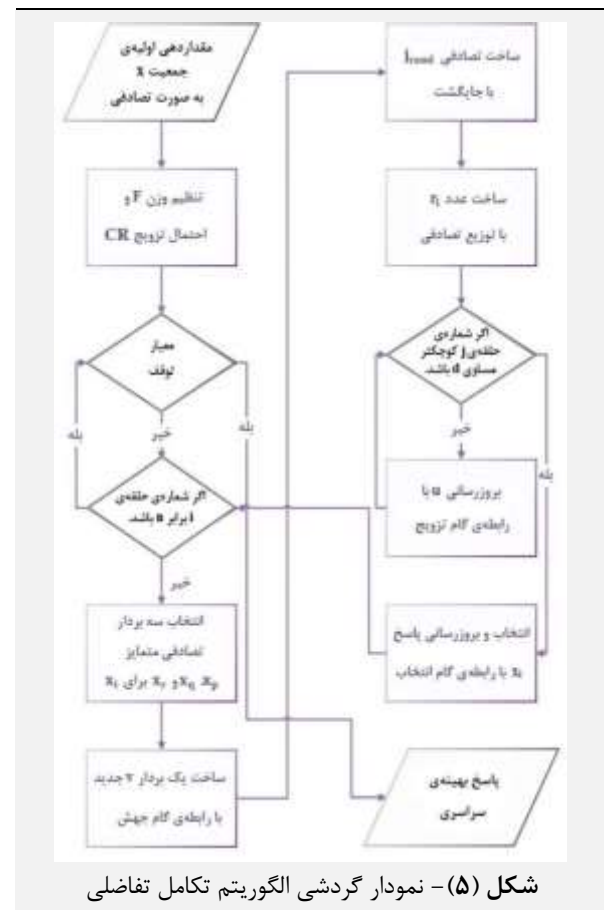
۴- یافته‌ها و بحث

در این بخش نتایج حالات مختلف روش پیشنهادی مقاله شامل تاثیر ساختاری بودن و ساختاری-عمل‌کردی بودن ماتریس وزن گراف، تاثیر کاهش کرون و تفاوت دو روش انتخاب ویژگی PCA و DE در تفکیک دو کلاس با معیار درصد صحت طبقه‌بندهای SVM-RBF، DT، KNN و LDA به صورت کمی و شهودی بیان شده و به تحلیل نتایج پرداخته شده است. روال یافتن تمام مقادیر بهینه‌ی مذکور در روش پیشنهادی، در حین فرایند آموزش سامانه‌ی واسط مغز-رایانه و تنها با استفاده از دادگان آموزش انجام شده و داده‌های آزمون در هیچ بخشی از فرایند بهینه‌سازی دخیل نشده و دلیل آن نیز به طور مشخص، ارزیابی صحیح و منصفانه‌ی کارایی روش پیشنهادی برای سامانه‌ی واسط مغز-رایانه‌ی مبتنی بر تصور حرکتی بوده تا در ادامه نیز هنگام مواجهه با دادگان جدید فرایند قابل تعمیم باشد و نتایج مطلوبی به دست آید. بنابراین به طور کلی در روش پیشنهادی، بهینه‌سازی‌ها در فرایند آموزش صورت گرفته و در فرایند آزمون از اعداد بهینه‌ی فرایند آموزش استفاده شده است.

۴-۱- اثر عمل گر کرون در ترکیب با GFT

جهت ارزیابی اثر افزودن عمل گر کرون به GFT (Kron-GFT) یا KG در مرحله‌ی کاهش بعد گرافی، نتایج روش پیشنهادی

مزیت شایان توجه DE استفاده از بردار تفاضلی یا تفاضل بین پاسخ‌ها است که با این کار اطلاعات مفید افراد کنار گذاشته شده در جمعیت نیز در نظر گرفته شده و به نحو مطلوبی از اطلاعات اعضای جمعیت استفاده می‌شود. در این پژوهش مقادیر بردارها به صورت حقیقی، درصد صحت طبقه‌بندی به عنوان تابع هدف، تعداد اعضای جمعیت (ابعاد بردار پاسخ) برابر با ۵۰، تعداد تکرار الگوریتم (تعداد نسل مورد بررسی) برابر با ۱۰۰، احتمال توزیع برابر با ۰/۵ و وزن‌های اولیه و نهایی به ترتیب برابر با ۰/۹۵ و ۰/۳۵ در نظر گرفته شده است. انتخاب ویژگی با الگوریتم DE شامل دو بخش ساخت زیرمجموعه‌ی ویژگی‌ها توسط DE و الگوریتم طبقه‌بندی استفاده شده برای ارزیابی اعتبار زیرمجموعه‌ی منتخب ویژگی‌ها است. در نهایت از خروجی روش DE یک دسته‌ی ده‌تایی از ویژگی‌های برتر استخراج شده و جهت آزمون به طبقه‌بندها داده شده است.



شکل (۵) - نمودار گردش الگوریتم تکامل تفاضلی

۳-۳- طبقه‌بندی و اعتبارسنجی

پس از استخراج ویژگی و انتخاب ویژگی‌های برتر، نوبت به بخش نهایی یعنی طبقه‌بندی می‌رسد. هدف نهایی در مسائل

^۱ Linear Discriminant Analysis (LDA)

^۵ 5-Fold Cross-Validation

^۱ SVM-Radial Basis Function (SVM-RBF)

^۲ Decision Tree (DT)

^۳ K-Nearest Neighbors (KNN)

هر فرد بوده و اعداد پررنگ شده بیان‌گر بهترین نتیجه برای هر فرد است. همچنین برای مقایسه‌ی شهودی‌تر نتایج، مقادیر میانگین و انحراف معیار درصد صحت طبقه‌بندی طبقه‌بندی‌های مذکور برای افراد مختلف به صورت نمودار میله‌ای در شکل‌های (۶) و (۷) رسم شده است.

مقاله در حالت گراف ساختاری (SG) با مقاله‌ی [۸] و در حالت گراف ساختاری-عمل‌کردی (SFG) با مقاله‌ی [۹] مقایسه شده که به صورت میانگین و انحراف معیار درصد صحت طبقه‌بندی به ترتیب در جدول‌های (۳) و (۴) ارائه شده است. در این جدول‌ها اعداد داخل پرانتز بیان‌گر تعداد ثبت آموزش و آزمون

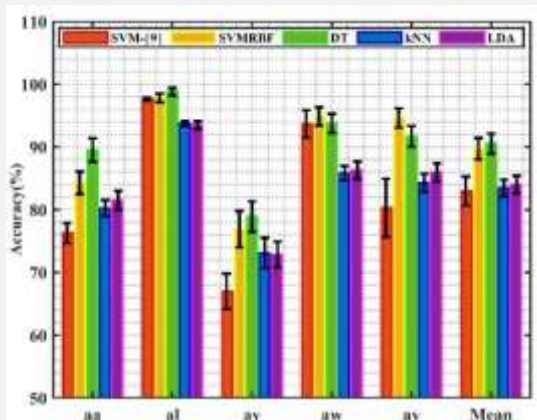
جدول (۳) - مقایسه‌ی نتایج درصد صحت طبقه‌بندی (میانگین±انحراف معیار) روش کاهش بعد پیشنهادی KG-PCA برای گراف ساختاری (SG) با روش TSM-GFT [۸]

[۸] SVM	LDA	KNN (K=11)	DT	SVM-RBF	SG-KG-PCA
۸۱/۴۳±۱۰/۹۰	۸۰/۶۰±۱/۶۲	۷۸/۹۳±۱/۷۰	۸۷/۵۰±۱/۸۱	۸۳/۲۱±۱/۹۷	(۱۶۸-۱۱۲) aa
۹۷/۵۰±۲/۹۸	۹۱/۹۰±۱/۲۷	۹۱/۱۹±۱/۵۸	۹۷/۹۸±۱/۸۰	۹۶/۴۳±۱/۶۲	(۱۶۸-۱۱۲) al
۶۹/۲۹±۵/۵۶	۷۱/۱۹±۱/۷۲	۷۲/۲۶±۱/۴۰	۷۷/۵۰±۲/۰۲	۷۵/۳۶±۱/۷۸	(۱۶۸-۱۱۲) av
۹۸/۵۷±۰/۷۹	۸۵/۸۳±۱/۰۳	۸۴/۵۲±۱/۳۲	۹۲/۶۲±۱/۷۳	۹۴/۶۴±۱/۷۷	(۱۶۸-۱۱۲) aw
۹۳/۹۳±۴/۳۰	۸۴/۵۲±۱/۴۵	۸۲/۹۸±۱/۸۴	۸۹/۶۴±۱/۷۴	۹۴/۲۹±۲/۲۱	(۱۶۸-۱۱۲) ay
۸۸/۱۴±۴/۹۱	۸۲/۸۱±۱/۴۲	۸۱/۹۸±۱/۵۷	۸۹/۰۵±۱/۸۲	۸۸/۷۹±۱/۸۷	میانگین نتایج

جدول (۴) - مقایسه‌ی نتایج درصد صحت طبقه‌بندی (میانگین±انحراف معیار) روش کاهش بعد پیشنهادی KG-PCA برای گراف ساختاری-

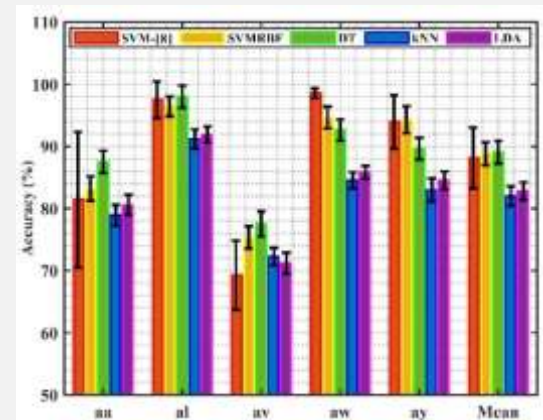
عمل‌کردی (SFG) با روش GD-BCI [۹]

[۹] SVM	LDA	KNN (K=11)	DT	SVM-RBF	SFG-KG-PCA
۷۶/۲۹±۱/۶۱	۸۱/۵۰±۱/۵۳	۸۰/۲۲±۱/۲۹	۸۹/۵۳±۱/۸۶	۸۴/۲۸±۱/۸۲	(۱۶۸-۱۱۲) aa
۹۷/۶۲±۱/۲۷	۹۳/۵۰±۰/۶۲	۹۳/۷۸±۰/۳۹	۹۸/۸۴±۱/۶۱	۹۷/۸۵±۱/۷۰	(۲۲۴-۵۶) al
۶۶/۹۹±۲/۸۳	۷۲/۸۵±۲/۰۷	۷۳/۰۸±۲/۴۳	۷۸/۹۱±۲/۴۵	۷۶/۹۰±۲/۹۱	(۸۴-۱۹۶) av
۹۳/۷۰±۲/۲۱	۸۶/۲۹±۱/۳۹	۸۵/۸۳±۱/۱۶	۹۳/۷۸±۱/۵۱	۹۴/۹۲±۱/۴۷	(۵۶-۲۲۴) aw
۸۰/۲۹±۴/۶۴	۸۵/۹۷±۱/۴۴	۸۴/۲۸±۱/۴۷	۹۱/۷۱±۱/۶۶	۹۴/۶۴±۱/۵۴	(۲۸-۲۵۲) ay
۸۲/۹۸±۲/۳۱	۸۴/۰۲±۱/۴۱	۸۳/۴۴±۱/۳۵	۹۰/۵۵±۱/۶۲	۸۲/۷۹±۱/۶۹	میانگین نتایج



شکل (۷) - میانگین و انحراف معیار درصد صحت طبقه‌بندی‌های

مختلف برای افراد مختلف با روش پیشنهادی KG-PCA و روش GD-BCI [۹] برای گراف ساختاری-عمل‌کردی (SFG)



شکل (۶) - میانگین و انحراف معیار درصد صحت طبقه‌بندی‌های

مختلف برای افراد مختلف با روش پیشنهادی KG-PCA و روش TSM-GFT [۸] برای گراف ساختاری (SG)

با مشاهده‌ی نتایج جدول (۳) و شکل (۶) می‌توان دریافت که بهترین نتایج برای افراد aa، al و av و نیز برای میانگین نتایج تمام افراد توسط روش پیشنهادی مقاله (KG-PCA) همراه با طبقه‌بند DT بوده، برای فرد aw توسط روش TSM-GFT [۸] با طبقه‌بند SVM به دست آمده و برای فرد ay با روش

در حالت مقایسه با مقاله‌ی [۸]، دادگان به دو دسته‌ی ثابت ۱۱۲ تک‌ثبت برای آموزش و ۱۶۸ تک‌ثبت برای آزمون تقسیم‌بندی شده و از روش انتخاب ویژگی PCA و ارزیابی متقابل ۵ قسمتی روی ۱۶۸ ثبت آزمون استفاده شده است. در این قیاس، گراف مغز گراف ساختاری است.

متوسط نتایج افراد در روش KG-PCA نسبت به GD-BCI در حالت گراف ساختاری-عمل کردی مغز و با طبقه‌بند یکسان SVM افزایشی به میزان ۶/۷۴٪ در میانگین همراه با کاهش به میزان ۰/۶۲٪ در انحراف معیار داشته است. هم‌چنین در مورد سه فرد aa، aw و ay که مطابق جدول (۱) داده‌ی آموزشی کمی داشتند، نتایج طبقه‌بندی به طور قابل توجهی مطلوب بوده و قابل قیاس با گروه‌های برتر مسابقه‌ی سوم BCI در دسته‌ی IVa است. هم‌چنین بهترین درصد صحت‌های متوسط روش پیشنهادی KG-PCA مطلوب بوده و در قیاس با نتایج سه گروه برتر مسابقه‌ی سوم BCI در دسته‌ی IVa که به ترتیب به درصد صحت متوسط ۹۴/۱۷٪، ۸۵/۱۲٪ و ۸۳/۴۵٪ دست یافته بودند [۱۲] قابل رقابت است.

۴-۲- اثر ماتریس وزن ساختاری و ساختاری-عمل کردی

به منظور بررسی تاثیر ساختاری بودن و ساختاری-عمل کردی بودن ماتریس وزن، نتایج روش پیشنهادی مقاله در حالت گراف ساختاری (SG) و در حالت گراف ساختاری-عمل کردی (SFG) به صورت منصفانه که تنها تفاوت نوع ماتریس وزن بوده بر حسب میانگین و انحراف معیار درصد صحت طبقه‌بندی به ترتیب در جداول (۵) و (۶) ارائه شده است.

پیشنهادی مقاله با طبقه‌بند SVM-RBF حاصل شده است. در روش پیشنهادی KG-PCA طبقه‌بندهای SVM و DT نسبت به KNN با $k=11$ و LDA درصد صحت بهتری را در پی داشته‌اند. متوسط انحراف معیار نتایج تمام طبقه‌بندهای روش پیشنهادی KG-PCA نسبت به روش TSM-GFT در مقاله‌ی [۸] بهبود یافته که نشان دهنده‌ی ثبات و اطمینان بیش‌تر به پاسخ‌های عددی این روش است. متوسط نتایج افراد در روش KG-PCA با طبقه‌بند DT نسبت به روش TSM-GFT در حالت گراف ساختاری مغز افزایشی به میزان ۰/۹۱٪ در میانگین همراه با کاهش به میزان ۳/۰۹٪ در انحراف معیار داشته است. در مقایسه با مقاله‌ی [۹] دادگان مطابق مسابقات سوم BCI دسته‌ی IVa و جدول (۱) برای آموزش و آزمون تقسیم‌بندی شده و از انتخاب ویژگی PCA و ۴۰۰ بار اجرای روش اعتبارسنجی متقابل ۵ قسمتی روی تعداد متغیری ثبت آزمون برای افراد مختلف استفاده شده است.

با مقایسه‌ی نتایج حاصل از جدول (۴) و نمودار میله‌ای شکل (۷) مشاهده می‌شود که بهترین نتایج برای افراد aa، al و av و هم‌چنین برای میانگین نتایج تمام افراد توسط روش پیشنهادی مقاله (KG-PCA) با طبقه‌بند DT بوده و برای افراد aw و ay نیز توسط روش پیشنهادی KG-PCA با طبقه‌بند SVM-RBF به دست آمده است.

جدول (۵) - درصد صحت طبقه‌بندی (میانگین \pm انحراف معیار) روش کاهش بعد پیشنهادی KG-PCA برای گراف ساختاری (SG)

LDA	KNN (K=11)	DT	SVM-RBF	SG-KG-PCA
۸۱/۰۷ \pm ۰/۷۳	۸۰/۰۰ \pm ۰/۸۴	۸۸/۵۷ \pm ۱/۰۸	۸۴/۲۹ \pm ۱/۰۸	aa
۹۲/۵۰ \pm ۰/۳۱	۹۲/۸۶ \pm ۰/۴۶	۹۸/۵۷ \pm ۰/۹۷	۹۷/۵۰ \pm ۰/۹۳	al
۷۱/۷۹ \pm ۰/۹۸	۷۳/۲۲ \pm ۰/۸۹	۷۷/۸۶ \pm ۱/۱۶	۷۶/۴۳ \pm ۱/۱۸	av
۸۶/۰۷ \pm ۰/۵۷	۸۶/۷۹ \pm ۰/۶۳	۹۳/۹۳ \pm ۰/۹۶	۹۵/۷۱ \pm ۰/۸۸	aw
۸۴/۶۴ \pm ۰/۴۹	۸۳/۵۷ \pm ۰/۷۱	۹۱/۰۷ \pm ۱/۰۲	۹۵/۳۶ \pm ۰/۸۵	ay
۸۳/۲۱ \pm ۰/۶۱	۸۳/۲۹ \pm ۰/۷۱	۹۰/۰۰ \pm ۱/۰۴	۸۹/۸۶ \pm ۰/۹۸	میانگین نتایج

جدول (۶) - درصد صحت طبقه‌بندی (میانگین \pm انحراف معیار) روش کاهش بعد پیشنهادی KG-PCA برای گراف ساختاری-عمل کردی (SFG)

LDA	KNN (K=11)	DT	SVM-RBF	SFG-KG-PCA
۸۱/۷۹ \pm ۰/۸۳	۸۰/۷۱ \pm ۰/۸۱	۹۰/۰۰ \pm ۱/۲۶	۸۴/۶۴ \pm ۱/۱۲	aa
۹۳/۹۳ \pm ۰/۴۸	۹۵/۰۰ \pm ۰/۴۳	۹۹/۲۹ \pm ۰/۵۲	۹۸/۵۷ \pm ۰/۶۴	al
۷۳/۲۱ \pm ۱/۰۸	۷۳/۵۷ \pm ۱/۲۰	۷۹/۲۹ \pm ۱/۸۴	۷۷/۸۶ \pm ۱/۲۲	av
۸۷/۱۴ \pm ۰/۵۹	۸۷/۱۴ \pm ۰/۶۴	۹۴/۲۹ \pm ۱/۱۰	۹۶/۰۷ \pm ۱/۰۳	aw
۸۶/۷۹ \pm ۰/۶۳	۸۵/۰۰ \pm ۰/۷۰	۹۲/۸۶ \pm ۱/۱۳	۹۵/۷۱ \pm ۱/۰۳	ay
۸۴/۵۷ \pm ۰/۷۲	۸۴/۲۸ \pm ۰/۷۶	۹۱/۱۵ \pm ۱/۱۷	۹۰/۵۷ \pm ۱/۰۱	میانگین نتایج

۰/۷۱٪، ۱/۱۵٪، ۰/۹۹٪ و ۱/۳۶٪ بهبود یافته و در نتیجه در روش پیشنهادی نیز با انتخاب بهینه‌ی ضرایب نرمالیزه کننده‌ی σ_d و σ_p و حد آستانه‌ی K و با استفاده‌ی بهینه از معیار عمل کردی همبستگی پیرسون در کنار فاصله‌ی هندسی، درصد

با مقایسه‌ی جدول‌های (۵) و (۶) مشاهده می‌شود که متوسط نتایج درصد صحت طبقه‌بندی افراد در روش KG-PCA برای گراف ساختاری-عمل کردی نسبت به گراف ساختاری برای طبقه‌بندهای SVM-RBF، DT، KNN و LDA به ترتیب

متقابل ۱۰ قسمتی روی تمام ۲۸۰ ثبت دادگان فقط در حالت SFG به ازای افراد مختلف و طبقه‌بندی‌های مختلف در جدول (۷) ارائه شده است. با مشاهده‌ی نتایج جدول (۷) می‌توان دریافت که بهترین متوسط درصد صحت برای افراد av، aa و aw و نیز برای میانگین نتایج تمام افراد توسط روش مقاله‌ی [۳۹] و برای افراد al و ay توسط روش پیشنهادی KG-DE با طبقه‌بند SVM-RBF حاصل شده است. البته مطابق جدول (۷) تعداد ویژگی انتخابی در مقاله‌ی [۳۹] برای تمام شرکت کنندگان، بیش از ۱۰ ویژگی انتخاب شده در این مقاله است. مجدداً در این حالت نیز ملاحظه می‌شود که در روش پیشنهادی، طبقه‌بندی‌های SVM و DT نسبت به KNN با $k=11$ و LDA درصد صحت بهتری را در پی داشته‌اند. به منظور بررسی تفاوت دو روش انتخاب ویژگی PCA و DE در قالب روش پیشنهادی مقاله و با معیار درصد صحت طبقه‌بندی، می‌توان نتایج جدول (۶) و (۷) را با یکدیگر مقایسه کرد.

صحت طبقه‌بندی می‌تواند نسبت به حالت گراف ساختاری افزایش یابد. از مقایسه‌ی نتایج جدول‌های (۳)، (۵) و (۶) نیز توانایی کاهش کرون در استفاده‌ی مناسب از اطلاعات گرافی و کاهش بعد موثر برای طبقه‌بندی دادگان مورد بررسی پژوهش مشاهده می‌شود به طوری که متوسط درصد صحت طبقه‌بندی‌ها در جدول‌های (۵) و (۶) از متوسط درصد صحت طبقه‌بندی‌ها در جدول (۳) نیز بالاتر بوده و در این جدول‌ها نتایج بهتری برای کاهش کرون حاصل شده است.

۴-۳- تفاوت اثر دو روش PCA و DE در رویکرد پیشنهادی مقاله

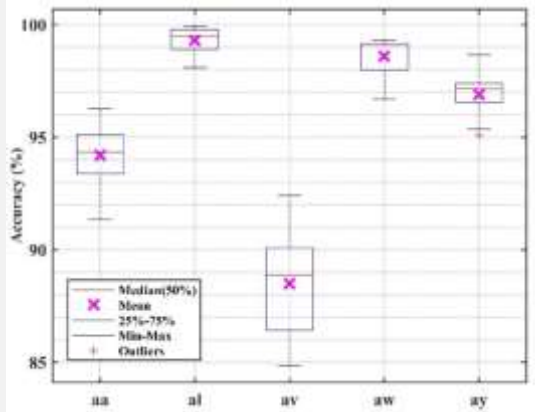
از آن‌جا که در این پژوهش متوسط درصد صحت در حالت SFG بهتر از SG بوده، نتایج درصد صحت طبقه‌بندی روش پیشنهادی KG-DE که کاهش کرون، تبدیل فوریه‌ی گرافی و انتخاب ویژگی تکامل تفاضلی را به کار می‌گیرد، با ارزیابی

جدول (۷) - مقایسه‌ی نتایج درصد صحت طبقه‌بندی (میانگین±انحراف معیار) روش کاهش بعد پیشنهادی KG-DE برای گراف ساختاری- عمل‌کردی (SFG) با روش پیشنهادی مقاله‌ی [۳۹] (اعداد داخل پرانتز بیان‌گر تعداد ویژگی انتخابی برای هر فرد است)

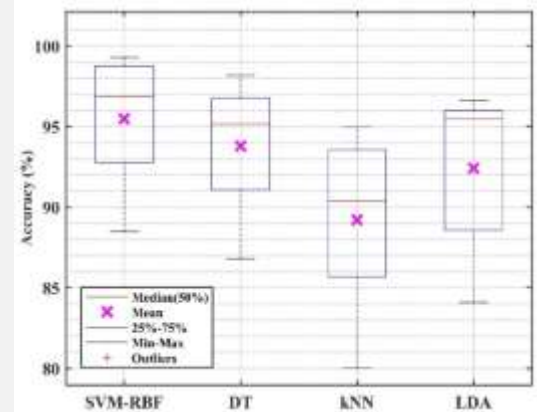
SVM [۳۹]	LDA (۱۰)	KNN (K=11) (۱۰)	DT (۱۰)	SVM-RBF (۱۰)	SFG-KG-DE
۹۵/۸۰±۲/۴۰ (۱۳)	۹۰/۱۰±۰/۸۹	۸۷/۶۰±۰/۸۳	۹۲/۵۰±۰/۹۹	۹۴/۲۰±۱/۳۶	aa
۹۸/۸۰±۰/۷۹ (۱۹)	۹۶/۶۰±۰/۶۵	۹۵/۰۰±۰/۴۱	۹۸/۲۰±۰/۸۲	۹۹/۳۰±۰/۶۱	al
۸۹/۸۰±۳/۳۶ (۲۰)	۸۴/۱۰±۱/۱۵	۸۰/۰۰±۱/۲۸	۸۶/۸۰±۱/۴۰	۸۸/۵۰±۲/۴۳	av
۹۹/۲۰±۰/۷۲ (۱۸)	۹۵/۵۰±۰/۵۱	۹۳/۱۰±۰/۶۶	۹۵/۲۰±۰/۹۱	۹۸/۶۰±۰/۹۴	aw
۹۶/۵۰±۱/۱۱ (۱۸)	۹۵/۸۰±۰/۵۲	۹۰/۴۰±۰/۷۲	۹۶/۳۰±۰/۹۴	۹۶/۹۰±۱/۰۳	ay
۹۶/۰۲±۱/۶۸	۹۲/۴۲±۰/۷۴	۸۹/۲۲±۰/۷۸	۹۳/۸۰±۱/۰۱	۹۵/۵۰±۱/۲۷	میانگین نتایج

صحت طبقه‌بندی افراد با طبقه‌بند DT قابل مشاهده است. شکل (۹) نیز مربوط به روش KG-DE با ارزیابی متقابل ۱۰ قسمتی بوده که به طور مشابه شامل نمودار جعبه‌ای طبقه‌بندی‌های مختلف به ازای متوسط نتایج تمام افراد و نمودار جعبه‌ای درصد صحت طبقه‌بندی افراد با طبقه‌بند SVM است. در هر دو نمودار جعبه‌ای مقادیر میانگین، میانه، چهارک اول و سوم و بیشینه و کمینه مشخص است تا به صورت شهودی نیز بتوان نسبت به تفاوت‌های آماری عمل‌کرد طبقه‌بندی‌ها، درصد صحت افراد توسط برترین طبقه‌بند و هم‌چنین عمل‌کرد دو روش KG-DE و KG-PCA تحلیل بهتری را داشت. هم‌چنین به صورت کلی ملاحظه می‌شود که مشابه نتایج اغلب مطالعات پیشین روی این دادگان، در این دو روش نیز طبقه‌بندی‌ها برای al بهترین عمل‌کرد و برای av بدترین عمل‌کرد را داشته و دو طبقه‌بند SVM-RBF و DT در هر دو روش از عمل‌کرد مطلوبی برخوردار بوده‌اند.

با ملاحظه و مقایسه‌ی این دو جدول می‌توان دریافت که در این چارچوب، روش بهینه‌سازی تکاملی DE با جست‌وجوی پاسخ بهینه جهت یافتن بهترین دسته‌ی ویژگی ۱۰-تایی برای طبقه‌بندی دادگان جدید آزمون نسبت به روش غیرنظارتی PCA به طور چشم‌گیری بهتر عمل کرده است. متوسط نتایج طبقه‌بندی‌های SVM-RBF، DT، KNN و LDA به ازای افراد مختلف در روش KG-DE نسبت به روش KG-PCA در حالت یکسان ارزیابی متقابل ۱۰ قسمتی و با گراف یکسان SFG به ترتیب ۴/۹۳٪، ۲/۶۵٪، ۴/۹۴٪ و ۷/۸۵٪ افزایش یافته است. هم‌چنین برای مقایسه‌ی شهودی‌تر نتایج، ویژگی‌های آماری مقادیر درصد صحت طبقه‌بندی طبقه‌بندی‌های مذکور برای افراد مختلف به صورت نمودار جعبه‌ای در شکل‌های (۸) و (۹) رسم شده است. شکل (۸) مربوط به روش KG-PCA با ارزیابی متقابل ۱۰ قسمتی بوده که در آن نمودار جعبه‌ای طبقه‌بندی‌های مختلف به ازای متوسط نتایج تمام افراد و نمودار جعبه‌ای درصد




ب

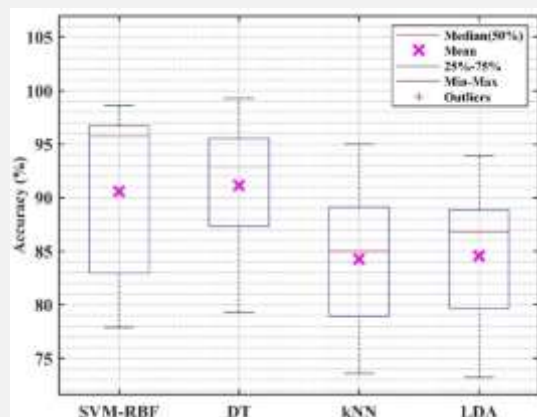


الف

شکل (۹) - الف) نمودار جعبه‌ای درصد صحت طبقه‌بندی طبقه‌بندی‌های مختلف با انتخاب ویژگی DE، ب) نمودار جعبه‌ای درصد صحت طبقه‌بندی افراد در بهترین طبقه‌بند با انتخاب ویژگی DE (طبقه‌بند SVM)



ب



الف

شکل (۸) - الف) نمودار جعبه‌ای درصد صحت طبقه‌بندی طبقه‌بندی‌های مختلف با انتخاب ویژگی PCA، ب) نمودار جعبه‌ای درصد صحت طبقه‌بندی افراد در بهترین طبقه‌بند با انتخاب ویژگی PCA (طبقه‌بند DT)

تمام تک‌ثبت مشخص می‌شود. تمام آزمایش‌ها در یک رایانه‌ی قابل حمل با پردازنده‌ی مرکزی Intel-Core-i7-6700-HQ (۲/۶-۳/۵ GHz)، حافظه‌ی دسترسی تصادفی ۱۶ GB و کارت نمایش NVIDIA-GTX-960M-4G و در نرم‌افزار متلب (R2018b) انجام شده است. با توجه به این موارد، زمان اجرای فرایند آزمون روش پیشنهادی در محدوده‌ای است که می‌تواند کارایی سامانه‌ی BCI را از لحاظ برخط بودن فراهم کند.

۵- نتیجه‌گیری

در این مقاله با هدف کاهش بعد و طبقه‌بندی مناسب سیگنال‌های EEG در کاربرد واسط مغز-رایانه‌ی مبتنی بر تصور حرکتی، یک روش جدید شامل ترکیب کاهش کرون و GFT (KG) جهت کاهش بعد ماتریس لاپلاسیان گراف و روش بهینه‌سازی تکامل تفاضلی به منظور انتخاب ویژگی و کاهش بعد سیگنالی ویژگی‌های مستخرج از دادگان، پیشنهاد شده

۴-۴- بررسی پیچیدگی روش پیشنهادی با معیار زمان اجرا

در روش پیشنهادی برای سیستم واسط مغز-رایانه، سیستم یک بار در فرایند آموزش، تمام پارامترهای بهینه‌سازی در گام‌های مختلف را برای هر فرد محاسبه می‌کند که اندکی زمان بر است اما برای تمام فرایندهای آزمون و آزمایش‌های بعدی به صورت ساده و با سرعت مناسب از ضرایب و پارامترهای بهینه‌ی به دست آمده در مرحله‌ی آموزش بهره می‌برد و بدین ترتیب زمان اجرای آزمون کم بوده و دقت بالایی هم به دست خواهد آمد. هم‌چنین سه طبقه‌بند KNN، LDA و DT ساده و سریع بوده و به خصوص DT به نتایج خیلی خوبی (جداول ۳ تا ۷) دست یافته و اجرای طبقه‌بند SVM-RBF نیز دارای سرعتی خوب و نتایجی مطلوب (جداول ۳ تا ۷) است. در روال این تحقیق برچسب طبقه‌بندی برای هر تک‌ثبت ۳/۵ ثانیه‌ای آزمون، در زمان‌برترین حالت، در بازه‌ی زمانی حدود ۷۰ میلی‌ثانیه پس از

- [6] J. Stam and J. C. Reijneveld, "Graph theoretical analysis of complex networks in the brain," *Nonlinear Biomedical Physics*, vol. 1, no. 3, 2007.
- [7] J. DelEtoile and H. Adeli, "Graph theory and brain connectivity in Alzheimer's disease," *The Neuroscientist*, vol. 23, no. 6, pp. 616-626, 2017.
- [8] T. Tanaka, T. Uehara and Y. Tanaka, "Dimensionality reduction of sample covariance matrices by graph Fourier transform for motor imagery brain-machine interface," in 2016 IEEE Statistical Signal Processing Workshop (SSP), Palma de Mallorca, Spain, pp. 1-5, 2016.
- [9] G. Kalantar, H. Sadreazami, A. Mohammadi and A. Asif, "Adaptive dimensionality reduction method using graph-based spectral decomposition for motor imagery-based brain-computer interfaces," in proc. 2017 IEEE Global Conference on Signal and Information Processing (GlobalSIP), Montreal, Canada, pp. 990-994, 2017.
- [10] W. Huang, L. Goldsberry, N. F. Wymbs, S. T. Grafton, D. S. Bassett and A. Ribeiro, "Graph frequency analysis of brain signals," *IEEE Journal of Selected Topics in Signal Processing*, vol. 10, no. 7, pp. 1189-1203, 2016.
- [11] Website of Berlin Institute of Technology, Charité-University Medicine Berlin, Available: https://www.bbci.de/competition/iii/desc_IVa.html
- [12] B. Blankertz, K. R. Muller, D. J. Krusienski, G. Schalk, J. R. Wolpaw, A. Schlogl, et al., "The BCI competition III: validating alternative approaches to actual BCI problems," in *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 14, no. 2, pp. 153-159, June 2006, doi: 10.1109/TNSRE.2006.875642.
- [13] S. K. Narang, and A. Ortega, "Perfect reconstruction two-channel wavelet filter banks for graph structured data," *IEEE Transactions on Signal Processing*, vol. 60, no. 6, pp. 2786-2799, 2012.
- [14] J. D. Medaglia, W. Huang, E. A. Karuza, A. Kelkar, S. L. Thompson-Schill, A. Ribeiro, and D. S. Bassett, "Functional alignment with anatomical networks is associated with cognitive flexibility," *Nature Human Behaviour*, vol. 2, no. 2, pp. 156-164, 2018.
- [15] D. K. Hammond, P. Vandergheynst and R. Gribonval, "Wavelets on graphs via spectral graph theory," *Applied and Computational Harmonic Analysis*, vol. 30, no. 2, pp. 129-150, 2011.
- [16] N. Leonardi and D. Van De Ville, "Tight wavelet frames on multislice graphs," *IEEE Transactions on Signal Processing*, vol. 61, no. 13, pp. 3357-3367, 2013.
- [17] L. Rui, H. Nejati and N.-M. Cheung, "Dimensionality reduction of brain imaging data using graph signal processing," in 2016 IEEE International Conference on Image Processing (ICIP), Phoenix, USA, pp. 1329-1333, 2016.

است. روش کاهش کرون با پشتوانه‌ی انتخاب رئوس مهم، اطلاعات ماتریس لاپلاسیین تمام رئوس گراف مغز از جمله رئوس محذوف را به صورت عبارتی وزن دار در لاپلاسیین کاهش یافته کرون مبتنی بر رئوس انتخابی لحاظ کرده و بدین ترتیب اطلاعات لاپلاسیین گراف به نحو مطلوبی کاهش بعد یافته است. روش GFT نیز با تجزیه‌ی مقادیر ویژه و اعمال بردارهای پایه‌ی متعامد یکه به نحو مطلوبی اطلاعات ویژگی ماتریس کوواریانس نمونه را در حوزه‌ی طیفی گراف بر این پایه‌ها تصویر کرده و با تنظیم مقادیر ویژه یا فرکانس‌های مهم برای تبدیل فوریه، اطلاعات مهم حوزه‌ی طیف گراف محفوظ می‌ماند.

مطابق نتایج، میانگین درصد صحت روش پیشنهادی KG-PCA با طبقه‌بندهای SVM-RBF و DT از روش TSM-GFT برای گراف ساختاری در مقاله‌ی [۸] و گراف ساختاری-عمل‌کردی در مقاله‌ی [۹] عمل‌کرد بهتری داشته و در بهترین حالت، روش پیشنهادی با طبقه‌بند DT توانسته است به میانگین درصد صحت $91/15 \pm 1/17$ دست یابد. طبق میانگین نتایج به دست آمده، روش پیشنهادی KG-DE هم از لحاظ درصد صحت افراد و هم از لحاظ درصد صحت طبقه‌بندها به طور مشخصی نسبت به KG-PCA بهتر عمل کرده است. هم‌چنین بهترین طبقه‌بند در روش پیشنهادی KG-DE طبقه‌بند SVM-RBF بوده که در بهترین حالت، متوسط درصد صحت تفکیک دو کلاس در آن برابر با $95/50 \pm 1/27$ بوده است.

۶- مراجع

- [1] P. L. Nunez, and R. Srinivasan, "The Physics-EEG Interface" in *Electric fields of the brain: The neurophysics of EEG*, 2nd ed. New York, USA: Oxford University Press, 2006.
- [2] J. R. Wolpaw, N. Birbaumer, D. J. McFarland, G. Pfurtscheller, and T. M. Vaughan, "Brain-computer interfaces for communication and control," *Clinical Neurophysiology*, vol. 113, no. 6, pp. 767-791, 2002.
- [3] Ortega, P. Frossard, J. Kovačević, J. M. Moura and P. Vandergheynst, "Graph signal processing: Overview, challenges, and applications," *Proceedings of the IEEE*, vol. 106, no. 5, pp. 808-828, 2018.
- [4] D. I. Shuman, S. K. Narang, P. Frossard, A. Ortega and P. Vandergheynst, "The emerging field of signal processing on graphs: Extending high-dimensional data analysis to networks and other irregular domains," *IEEE Signal Processing Magazine*, vol. 30, no. 3, pp. 83-98, 2013.
- [5] Sandryhaila and J. M. Moura, "Big data analysis with signal processing on graphs," *IEEE Signal Processing Magazine*, vol. 31, no. 5, pp. 80-90, 2014.

- [30] F. Dorfler, and F. Bullo, "Kron reduction of graphs with applications to electrical networks," *IEEE Transactions on Circuits and Systems I: Regular Papers*, vol. 60, no. 1, pp. 150-163, 2012.
- [31] D. I. Shuman, M. J. Faraji, and P. Vandergheynst, "A multiscale pyramid transform for graph signals," *IEEE Transactions on Signal Processing*, vol. 64, no. 8, pp. 2119-2134, 2015.
- [32] M. P. Van Den Heuvel, and O. Sporns, "Network hubs in the human brain," *Trends in Cognitive Sciences*, vol. 17, no. 12, pp. 683-696, 2013.
- [33] S. Y. Caliskan, and P. Tabuada, "Towards Kron reduction of generalized electrical networks," *Automatica*, vol. 50, no. 10, pp. 2586-2590, 2014.
- [34] F. Zhang, "Basic Properties of the Schur Complement," in *The Schur complement and its applications (Vol. 4)*, ed. New York, USA: Springer Science & Business Media., 2006.
- [35] Barachant, S. Bonnet, M. Congedo, and C. Jutten, "Multiclass brain-computer interface classification by Riemannian geometry," *IEEE Transactions on Biomedical Engineering*, vol. 59, no. 4, pp. 920-928, 2011.
- [36] D. Bartz, and K. R. Müller, "Covariance shrinkage for autocorrelated data," *Advances in Neural Information Processing Systems*, vol. 27, pp. 1592-1600, 2014.
- [37] O. Ledoit, and M. Wolf, "A well-conditioned estimator for large-dimensional covariance matrices," *Journal of Multivariate Analysis*, vol. 88, no. 2, pp. 365-411, 2004.
- [38] O. Ledoit, and M. Wolf, "Nonlinear shrinkage estimation of large-dimensional covariance matrices," *The Annals of Statistics*, vol. 40, no. 2, pp. 1024-1060, 2012.
- [39] M. Z. Baig, N. Aslam, H. P. Shum, and L. Zhang, "Differential evolution algorithm as a tool for optimal feature subset selection in motor imagery EEG," *Expert Systems with Applications*, vol. 90, pp. 184-195, 2017.
- [40] R. N. Khushaba, A. Al-Ani, and A. Al-Jumaily, "Feature subset selection using differential evolution and a statistical repair mechanism," *Expert Systems with Applications*, vol. 38, no. 9, pp. 11515-11526, 2011.
- [41] Liu, K. Chen, Q. Liu, Q. Ai, Y. Xie, and A. Chen, "Feature selection for motor imagery EEG classification based on firefly algorithm and learning automata," *Sensors*, vol. 17, no. 11, November, 2017.
- [42] N. Padfield, J. Zabalza, H. Zhao, V. Masero, and J. Ren, "EEG-based brain-computer interfaces using motor-imagery: Techniques and challenges," *Sensors*, vol. 19, no. 6, March, 2019.
- [43] K. Qin, V. L. Huang, and P. N. Suganthan, "Differential evolution algorithm with strategy adaptation for global numerical optimization," *IEEE transactions on Evolutionary Computation*, vol. 13, no. 2, pp. 398-417, 2008.
- [18] G. Mateos, S. Segarra, A. G. Marques and A. Ribeiro, "Connecting the dots: Identifying network structure via graph signal processing," *IEEE Signal Processing Magazine*, vol. 36, no. 3, pp. 16-43, 2019.
- [19] H. Behjat, N. Leonardi, L. Sörnmo and D. Van De Ville, "Anatomically-adapted graph wavelets for improved group-level fMRI activation mapping," *NeuroImage*, vol. 123, pp. 185-199, 2015.
- [20] Q. Yu, Y. Du, J. Chen, J. Sui, T. Adalé, G. D. Pearlson and V. D. Calhoun, "Application of graph theory to assess static and dynamic brain connectivity: Approaches for building brain graphs," *Proceedings of the IEEE*, vol. 106, no. 5, pp. 886-906, 2018.
- [21] T. P. Moran, E. M. Bernat, S. Aviyente, H. S. Schroder and J. S. Moser, "Sending mixed signals: worry is associated with enhanced initial error processing but reduced call for subsequent cognitive control," *Social Cognitive and Affective Neuroscience*, vol. 10, no. 11, pp. 1548-1556, 2015.
- [22] J. Faber, P. C. Antoneli, G. Via, N. S. Araújo, D. J. Pinheiro and E. Cavalheiro, "Critical elements for connectivity analysis of brain networks," in V. Yamamoto and N. Zhong (Eds.), "Functional Brain Mapping: Methods and Aims," University of Illinois at Chicago, Chicago, USA: Springer, pp. 67-106, 2020.
- [23] H. Ramoser, J. Muller-Gerking, and G. Pfurtscheller, "Optimal spatial filtering of single trial EEG during imagined hand movement," *IEEE Transactions on Rehabilitation Engineering*, vol. 8, no. 4, pp. 441-446, 2000.
- [24] G. Pfurtscheller, C. Neuper, D. Flotzinger, and M. Pregenzer, "EEG-based discrimination between imagination of right and left hand movement," *Electroencephalography and Clinical Neurophysiology*, vol. 103, no. 6, pp. 642-651, 1997.
- [25] B. Blankertz, G. Curio, and K. R. Müller, "Classifying single trial EEG: Towards brain computer interfacing," *Advances in Neural Information Processing Systems 14 (NIPS)*, Vancouver, Canada, pp. 157-164, 2001.
- [26] D. A. Spielman, and S. H. Teng, "Spectral sparsification of graphs," *SIAM Journal on Computing*, vol. 40, no. 4, pp. 981-1025, 2011.
- [27] Koutis, G. L. Miller, and R. Peng, "A nearly-m log n time solver for sdd linear systems," in *2011 IEEE 52nd Annual Symposium on Foundations of Computer Science*, Palm Springs, USA, pp. 590-598, October, 2011.
- [28] Loukas, "Graph Reduction with Spectral and Cut Guarantees," *Journal of Machine. Learning Research*, vol. 20, no. 116, pp. 1-42, 2019.
- [29] Y. Jin, A. Loukas, and J. JaJa, "Graph coarsening with preserved spectral properties," in *International Conference on Artificial Intelligence and Statistics (PMLR)*, Palermo, Italy, pp. 4452-4462, June, 2020.