

Using Visibility Graph to Analyze Brain Connectivity

Hoda Majdi, Mahdi Azarnoosh*, Majid Ghoshuni, Vahid Reza Sabzevari

Department of Biomedical Engineering, Mashhad Branch, Islamic Azad University, Mashhad, Iran

Article Info:

Received: 5 Mar 2022

Revised: 30 Apr 2022

Accepted: 6 June 2022

ABSTRACT

Introduction: Recognition of mental activities in brain-computer interface systems based on motor imagery has attracted the attention of many researchers. A visibility graph is a powerful method for analyzing the function and connectivity of different areas of the brain. The aim of this study is to improve and develop the visibility graph method for analyzing brain behavior and detecting motor imagery. **Materials and Methods:** First, brain signals including four motor imagery classes of left-handed, right-handed, foot, and tongue were transformed into three types of visibility graphs, and important features of these graphs were extracted. Then, to reduce features, the method of analysis of variance was used. To classify the motor imagery classes, the support vector machine was used. In most investigations, graph degree distribution has been used to extract information and graph weighting. In the present study, amplitude difference distribution has been used so shorter time series are required. To analyze the function and connectivity of different areas of the brain and to obtain the direction of information flow, a new method called weighted horizontal visibility graph-transfer entropy has been proposed. **Results:** Increasing the kappa value compared to other studies showed that a weighted horizontal visibility graph is a suitable method for processing brain signals based on motor imagery. A comparison of brain graphs and the direction of information flow in the four classes of motor imagery showed a significant difference between them. **Conclusion:** Temporal networks provide a better understanding of brain dynamics in brain-computer interface systems based on motor imagery.

Keywords:

1. Electroencephalography
2. Brain-Computer Interfaces
3. Brain Mapping

*Corresponding Author: Mahdi Azarnoosh

Email: M_Azarnoosh@mshdiau.ac.ir

استفاده از گراف پدیداری جهت تحلیل ارتباطات مغزی

هدی مجدی، مهدی آذرنوش*، مجید قشونی، وحیدرضا سبزواری

گروه مهندسی پزشکی، واحد مشهد، دانشگاه آزاد اسلامی، مشهد، ایران

اطلاعات مقاله:

پذیرش: ۱۶ خرداد ۱۴۰۱

اصلاحیه: ۱۰ اردیبهشت ۱۴۰۱

دریافت: ۱۴ اسفند ۱۴۰۰

چکیده

مقدمه: تشخیص فعالیت‌های ذهنی در سیستم‌های واسط مغز- رایانه مبتنی بر تصور حرکتی، توجه بسیاری از محققان را به خود جلب کرده است. گراف پدیداری روش قدرتمندی جهت تحلیل عملکرد و ارتباطات نواحی مختلف مغزی می‌باشد. هدف این پژوهش، بهبود و توسعه روش گراف پدیداری برای تحلیل رفتار مغز و تشخیص تصور حرکتی می‌باشد. **مواد و روش‌ها:** ابتدا سیگنال‌های مغزی شامل چهار کلاس تصور حرکتی دست چپ، دست راست، دو پا و زبان به سه نوع گراف پدیداری تبدیل و ویژگی‌های مهم گراف‌ها استخراج گردیده است. سپس جهت کاهش ویژگی‌ها از روش تحلیل واریانس استفاده شده است. برای طبقه‌بندی کلاس‌های تصور حرکتی از ماشین بردار پشتیبان استفاده گردیده است. در اکثر تحقیقات برای استخراج اطلاعات و وزن‌دهی گراف از توزیع درجه گراف استفاده شده است. اما در پژوهش حاضر، از توزیع اختلاف دامنه بهره گرفته شده، بنابراین سری‌های زمانی کوتاه‌تری مورد نیاز است. برای تحلیل عملکرد و ارتباطات نواحی مختلف مغزی و بدست آوردن جهت جریان اطلاعات، روش جدیدی به نام گراف پدیداری افقی وزن‌دار- آنتروپی انتقال، ارائه شده است. **یافته‌ها:** افزایش مقدار کاپا در مقایسه با تحقیقات دیگر، نشان می‌دهد که گراف پدیداری افقی وزن‌دار روش مناسبی جهت پردازش سیگنال‌های مغزی مبتنی بر تصور حرکتی است. مقایسه گراف‌های مغزی و جهت جریان اطلاعات در چهار کلاس تصور حرکتی، تفاوت معنی‌دار بین آن‌ها را نشان داد. **نتیجه‌گیری:** شبکه‌های زمانی، درک بهتری در مورد دینامیک‌های مغزی در سیستم‌های واسط مغز- رایانه مبتنی بر تصور حرکتی را ارائه می‌دهند.

واژه‌های کلیدی:

- ۱- الکتروانسفالوگرافی
- ۲- واسط‌های مغز- رایانه
- ۳- نقشه‌برداری مغز

*نویسنده مسئول: مهدی آذرنوش

پست الکترونیک: M_Azarnoosh@mshdiau.ac.ir

مقدمه

مراحل خواب، تشخیص حملات صرع، بررسی ارتباطات مؤثر مغزی پس از سکتۀ مغزی و بعد از توانبخشی، تشخیص احساسات مبتنی بر سیگنال مغزی می‌باشد (۷-۱۳). همچنین در تحقیقات اخیر، روش‌های جدید و توسعه‌یافته‌ی گراف پدیداری نیز ارائه شده است (۱۴). ارتباطات میان فعالیت نواحی مختلف مغزی به دو شاخه اصلی تقسیم می‌شوند، ارتباطات عملکردی که وابستگی‌های آماری و بدون جهت مغزی را دربردارند و ارتباطات مؤثر که ارتباطات علی و جهت‌دار مغزی را شامل می‌شوند (۱۵). ارتباطات عملکردی اطلاعاتی در مورد جهت انتقال اطلاعات بین نورون‌های عصبی ارائه نمی‌دهد. بنابراین برای اندازه‌گیری استحکام و جهت ارتباطات، روش‌های جهت‌دار توسعه یافته است. نظریۀ علیت وینر، بستر مناسبی برای بررسی ارتباطات علت و معلولی ایجاد کرده است؛ ولی فاقد چهارچوبی قاعده‌مند برای کمی کردن ارتباطات علی موجود در یک سیستم است (۱۶). در روش علیت گرنجر، سیگنال X علل گرنجر سیگنال Y است اگر و فقط اگر، نتیجۀ پیش‌بینی سیگنال Y بر اساس گذشتۀ خود و گذشتۀ X ، بهتر از نتیجۀ پیش‌بینی سیگنال Y بر اساس گذشتۀ خود به تنهایی باشد (۱۷). علیت گرنجر به نوبت و هدایت حجمی حساس است و همچنین تعامل بین جفت مناطق مغزی که غیرخطی می‌باشد، نمی‌تواند به خوبی توسط آن اندازه‌گیری شود، زیرا علیت گرنجر از مدل اتورگرسیو خطی استفاده می‌کند (۱۸-۱۹). برای حل این مشکلات، معیارهای مبتنی بر فاز برای بررسی ارتباطات جهت‌دار معرفی شده است. اما تحقیقات نشان داده است که وجود اختلاف فاز ثابت لزوماً نشان‌دهندۀ جهت صحیح جریان اطلاعات نیست. همچنین روش‌های تخمین فاز، بستگی به نسبت سیگنال به نویز سری زمانی، روش‌های حذف نویز و نمونه‌برداری دارند. رویکردهای نظری اطلاعات، روش‌های کارآمد و قدرتمندی برای تعیین کمیت جهت جریان اطلاعات بین سری‌های زمانی ارائه می‌دهد. آنتروپی انتقال یا TE^2 از نظر ریاضی معادل اطلاعات متقابل شرطی است. برخلاف علیت گرنجر، TE بدون مدل است و هیچ‌گونه فرضیه‌ای در مورد سیگنال و ساختار تعاملات ندارد. برای سری زمانی غیر گوسی، TE نسبت به علیت گرنجر برتر است. همچنین در مقابل هدایت حجمی نیز پایدار است. با این حال، تخمین آنتروپی انتقال نیاز به نمونه‌های کافی، نرخ سیگنال به نویز بالا و همچنین تنظیم دقیق پارامترهایی مانند تأخیر زمانی دارد (۲۰، ۲۱). در اکثر تحقیقات گذشته از شبکه‌های مکانی جهت بررسی ارتباطات مؤثر مغزی استفاده شده است اما در این تحقیق شبکه‌های

سیستم واسط مغز- رایانه (BCI) به‌منظور ارتباط مغز با محیط بیرون، فعالیت‌های مغزی را مستقیماً به یک سری سیگنال‌های ارتباطی کنترلی تبدیل می‌کند. پیشرفت‌های صورت گرفته در زمینه ارتباط مغز انسان و رایانه امکان شناسایی و طبقه‌بندی فعالیت‌های الکتریکی و متابولیک مغز و تبدیل آن‌ها به یک فرمان کنترلی برای رایانه و یا یک دستگاه مخصوص را فراهم می‌نماید (۱). علیرغم پتانسیل‌های بالایی که BCI دارد، با چالش‌هایی مانند رمزگشایی صحیح افکار انسان نیز مواجه است. BCI شامل تغییرات دینامیکی پیچیده‌ای می‌باشد که مرتبط با انعطاف‌پذیری عصبی در محدوده متنوعی از مقیاس‌های مکانی و زمانی می‌باشد (۲). یکی از روش‌های بررسی ساختار مغز و ارتباطات عملکردی آن، استفاده از شبکه‌های پیچیده زمانی یا مکانی می‌باشد. با نداشت سری‌های زمانی به شبکه‌های پیچیده، می‌توان رفتارهای میکروسکوپی و ماکروسکوپی سیستم زیستی را مورد بررسی قرار داد. از روش‌های مناسب برای تحلیل سیستم‌های دینامیکی، بازآرایی سری زمانی استخراج شده از سیستم بر پایه‌ی گراف است. به طوری که رئوس گراف نشان‌دهندۀ مؤلفه‌های سری زمانی و یال‌های بین رئوس گراف نشان‌دهندۀ ارتباط مؤلفه‌های سری زمانی استخراج شده از سیستم دینامیکی می‌باشد (۳). با توجه به این که شبکه‌های پیچیده مکانی وابسته به تعداد کانال‌های ثبت هستند و سرعت پردازش پایینی دارند، برای ثبت‌های تک کاناله و پردازش‌های آنلاین مناسب نیستند. علاوه بر این، شبکه‌های پیچیده مکانی برای تحلیل تصاویر پزشکی کاربرد دارند و تحلیل سیگنال‌های مغزی با استفاده از شبکه‌های پیچیده زمانی مطلوب‌تر است. شبکه‌های پیچیده زمانی با وجود اینکه اطلاعات ساختاری سیستم را از دست می‌دهند، اما می‌توانند به خوبی رفتارهای دینامیکی سیستم را نشان دهند و وابسته به تعداد کانال‌های ثبت نیستند (۴). گراف پدیداری (VG) به‌عنوان یک شبکه پیچیده زمانی، برای اولین بار توسط لاکاسا و همکاران معرفی شد. VG یک روش محاسباتی ساده و سریع است که سری زمانی را به شبکه نگاشت می‌دهد و شبکه ساخته شده، خصوصیات سری زمانی را در ساختار خود نشان می‌دهد (۵). ساختار این گراف وابسته به میزان خودمشابهی و پیچیدگی سری زمانی است. درجه‌ی گراف پدیداری میزان پیچیدگی سری زمانی مربوطه را نشان می‌دهد و نیازی به نمونه‌های زمانی زیاد ندارد (۶). برخی از کاربردهای VG در حوزه پزشکی شامل، تشخیص افسردگی، تشخیص بیماری آلزایمر، طبقه‌بندی

¹ Visibility graphs

² Transfer Entropy

پیچیده زمانی و گراف پدیداری وزن دار بهبودیافته، جهت تجزیه و تحلیل و طبقه بندی سیگنال های مغزی ناشی از تصور حرکت چندکلاسه، ارائه شده است. اغلب تحقیقات قبلی به دنبال یافتن نواحی مجزای مغزی بر پایه نظریه تخصیص عملکردی مغز بودند، که هر قسمت مسئولیت انجام یکی از فعالیت های مشخص مغزی را عهده دارد. اما در این پژوهش، نظریه یکپارچگی عملکردی مغز مورد توجه قرار گرفته است و برای بررسی جهت جریان اطلاعات در مغز، از روش جدید گراف پدیداری افقی وزن دار و آنتروپی انتقال بین توالی درجه گراف، استفاده شده است (۲۲). همچنین با بررسی تحقیقات قبلی، کاربردی ترین ویژگی های گراف پدیداری استخراج و با استفاده از آنالیز تحلیل واریانس مهم ترین آن ها انتخاب شده است. روش معمول برای استخراج اطلاعات و وزن دهی گراف پدیداری، استفاده از توزیع درجه گراف می باشد، اما در این پژوهش از توزیع اختلاف دامنه بهره گرفته شده است (۲۳).

پیش پردازش سیگنال مغزی

در ابتدا از فیلتر میان گذر ۸-۳۰ هرتز استفاده شده است و سپس آنالیز مؤلفه های مستقل (ICA) روی سیگنال های فیلتر شده اعمال و اجزای مستقل هر سیگنال استخراج می شوند (۲۵).

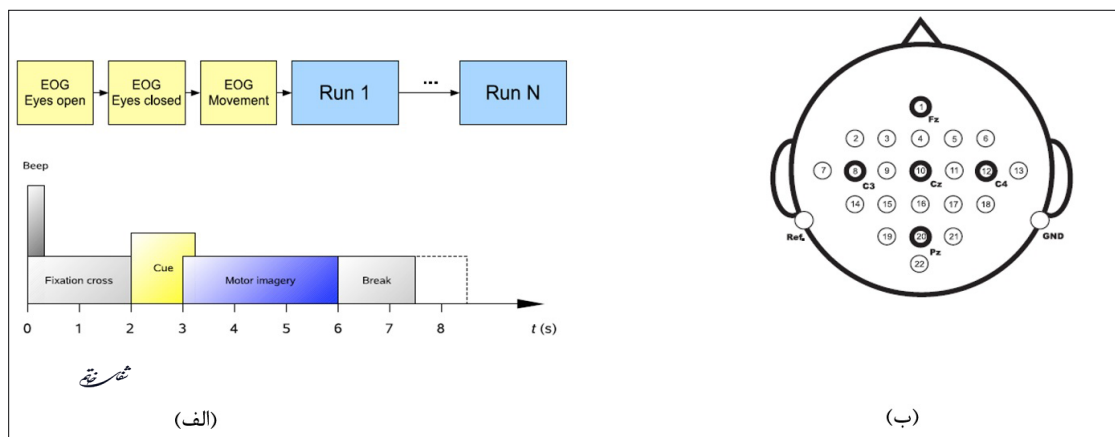
نگاشت سیگنال مغزی به شبکه های پیچیده

در این بخش، هدف تفکیک چهار کلاس تصور حرکتی مختلف (دست راست، دست چپ، دوپا و زبان) با استفاده از ویژگی های گراف پدیداری می باشد. ابتدا سیگنال های پیش پردازش شده به انواع مختلف گراف

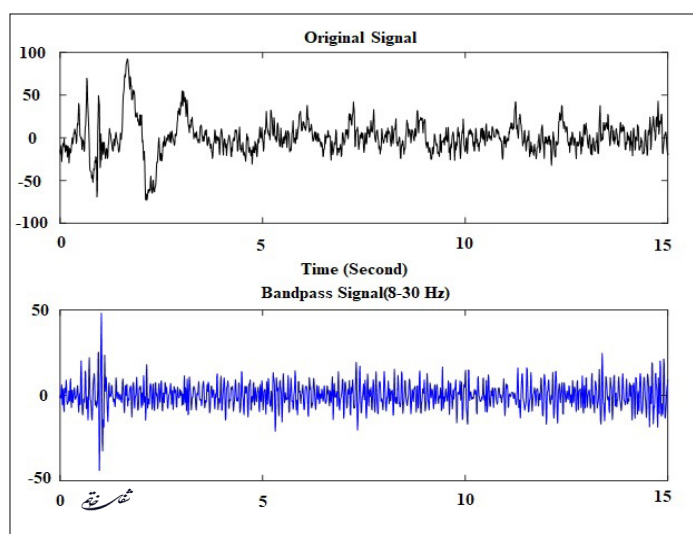
مواد و روش ها

پایگاه داده

روش پیشنهادی بر روی پایگاه داده ی رقابت چهارم



تصویر ۱- الف) الگوی زمان بندی تصور حرکت. ب) محل ۲۲ الکترود ثبت (۲۴)



تصویر ۲- سیگنال اصلی و سیگنال فیلتر شده نفر اول

افقی را با t و محور عمودی را با نشان می‌دهیم. اگر نوک میله عمودی به وسیله یک خط مستقیم و بدون هیچ مانعی بتواند به نوک میله عمودی دیگر متصل شود، این دو گره از طریق یک یال غیرجهت‌دار در شبکه‌ی گراف پدیداری، به همدیگر متصل خواهند شد. بنابراین دو گره $v_j(i, x_j)$ و $v_i(i, x_i)$ در گراف پدیداری متصل هستند اگر و فقط اگر معادله‌ی زیر برقرار باشد:

$$\forall k \in (i, j), \frac{x_j - x_k}{j - k} > \frac{x_i - x_k}{i - k}$$

i و j محل نقطه در سری زمانی را نشان می‌دهند. x_j و x_i مقدار نقطه را نشان می‌دهند. شبکه‌ی گراف پدیداری به این صورت قابل نمایش خواهد بود $G_{VG}(V, E)$ که V و E به ترتیب گره و یال‌های گراف هستند. درجه هر گره نیز همان تعداد یال‌های متصل به آن است (۲۶، ۲۷). گراف پدیداری افقی (HVG) که نوع توسعه‌یافته‌ی گراف پدیداری (VG) می‌باشد، می‌تواند به خوبی رفتارهای آشوبی سیگنال EEG و تفاوت آشوب و رفتارهای تصادفی غیرهمبسته را نشان دهد. در شبکه‌ی HVG، دو گره $v_j(i, x_j)$ و $v_i(i, x_i)$ به یکدیگر متصل هستند اگر و فقط اگر:

$$\forall k \in (i, j); x_k < x_i \text{ and } x_k < x_j$$

دو میله عمودی با ارتفاع X_j و X_i به یکدیگر متصل

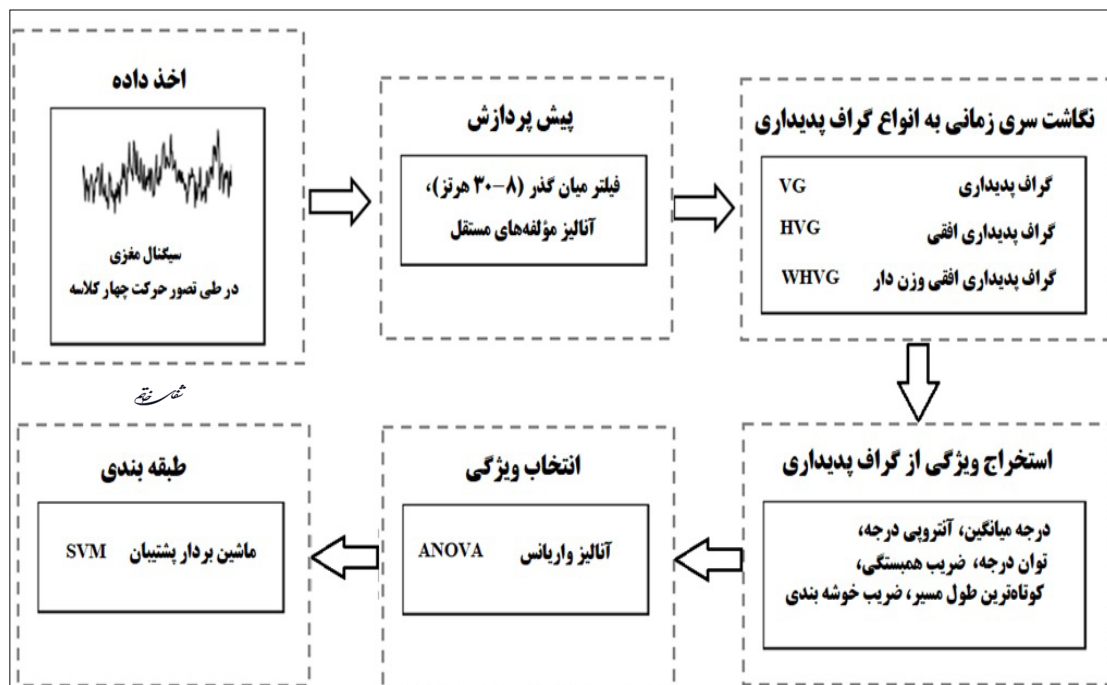
پدیداری ($WHVG^4, VG, HVG^3$) تبدیل می‌شوند. سپس به‌طور جداگانه از هر کدام از انواع گراف ویژگی‌هایی مانند آنتروپی درجه، کوتاه‌ترین طول مسیر، ضریب خوشه‌بندی استخراج می‌شود و با استفاده از روش تحلیل واریانس، ویژگی‌های بهینه انتخاب و به طبقه‌بندی کننده ماشینی بردار پشتیبان داده می‌شود. بلوک دیاگرام مراحل کار در تصویر ۳ مشاهده می‌شود.

گراف پدیداری

گراف پدیداری (VG) سری زمانی را به شبکه نگاشت می‌دهد و به موجب آن سری‌های نوسانی به شبکه‌های منظم، سری‌های تصادفی به شبکه‌های تصادفی و سری‌های فرکتالی به شبکه‌های مقیاس-آزاد تبدیل می‌شوند. وقتی سیگنال EEG به گراف پدیداری دو بعدی تبدیل می‌شود، ویژگی‌های هندسی این گراف در حوزه زمان و فرکانس، در مقابل واریانس‌ها مقاوم‌تر خواهد بود. فرض می‌کنیم سری زمانی شامل n نقطه باشد:

$$\{x_t\}, t = (1, \dots, n)$$

هر نقطه را به‌عنوان یک گره در نظر می‌گیریم. محور



تصویر ۳- بلوک دیاگرام روش پیشنهادی

³ Horizontal Visibility Graph

⁴ Weighted Horizontal Visibility Graph

اکثر جفت گره‌ها با حداقل یک مسیر کوتاه به هم متصل شده‌اند و این ویژگی نیز به دلیل کم بودن میانگین طول کوتاه‌ترین مسیر بین دو گره می‌باشد.

انتخاب ویژگی

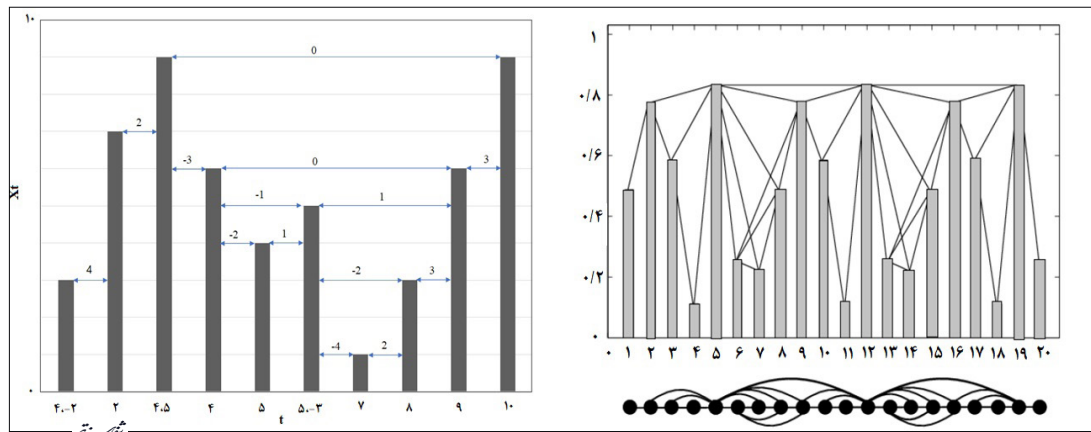
این گام به منظور کاهش حجم و زمان محاسبات بوده و هدف از این فرآیند انتخاب ویژگی‌هایی است که به ازاء فعالیت‌های ذهنی متفاوت، بیشترین تمایز را داشته باشند (۲۹). برای این کار از روش تحلیل واریانس^۵ (ANOVA) استفاده خواهد شد. سعی بر این است که اختلاف بین چند جامعه آماری، ارزیابی شود. با توجه به پراکندگی کل داده‌ها، تجزیه واریانس بین گروه‌های مختلف در این روش امکان‌پذیر است. به این ترتیب می‌توان

هستند اگر هر میله‌ای که بین آن دو است، از هر دو (و) کوچکتر باشد (۱۳). برای وزن‌دهی گراف، اختلاف دامنه بین دو گره محاسبه شده است، تصویر (۴).

استخراج ویژگی

پس از اخذ سیگنال و پیش‌پردازش، سری زمانی به شبکه نگاشت می‌شود. در اینجا از تئوری گراف و به‌طور خاص گراف پدیداری استفاده خواهد شد. برخی از مهم‌ترین ویژگی‌های استخراج شده از گراف، در جدول ۱ ذکر شده است (۲۸، ۱۱).

در بسیاری از شبکه‌های پیچیده دنیای واقعی، میانگین طول کوتاه‌ترین مسیر، کم است و همچنین ضریب خوشه‌بندی بیشتری نسبت به یک گراف تصادفی دارند.



تصویر ۴- سمت راست- گراف پدیداری. سمت چپ- اختلاف دامنه گراف

جدول ۱- ویژگی‌های استخراج شده از گراف پدیداری

درجه میانگین	مقدار متوسط درجه هر گره در شبکه
آنتروپی درجه	$H_G = - \sum_{\delta_i \in S} P_G(\delta_i) \log_2(P_G(\delta_i)) \quad (4)$
توان درجه	$p(k) = k^{-r} \quad (5)$
ضریب همبستگی	$\zeta = \frac{M^{-1} \sum_i \alpha_i \beta_i - \left[M^{-1} \sum_i \frac{1}{2} (\alpha_i + \beta_i) \right]^2}{M^{-1} \sum_i \frac{1}{2} (\alpha_i^2 + \beta_i^2) - \left[M^{-1} \sum_i \frac{1}{2} (\alpha_i + \beta_i) \right]^2} \quad (6)$ نشان دهنده ساختار اتصال کلی یک شبکه
طول کوتاه‌ترین مسیر	$d_{ij} = \sum_N a_{uv} \quad (7)$ کوتاه‌ترین مسیر برای رفتن از هر گره به سایر گره‌ها
ضریب خوشه‌بندی	$c_i = \frac{2E}{k_i(k_i - 1)} \quad (8)$ نشان دهنده احتمال همسایگی هر گره

⁵ Analysis of variance

جریان اطلاعات در گراف پدیداری جهت‌دار- وزن دار

در این بخش به منظور بدست آوردن جهت جریان اطلاعات در مغز از روش جدید گراف پدیداری افقی وزن دار- آنتروپی انتقال WHVG-TE^v استفاده شده است. ابتدا سیگنال پیش پردازش شده در هر کانال به WHVG نگاهت می‌شود. سپس با محاسبه توالی درجه‌ها، آنتروپی انتقال بین کانال‌ها، بدست می‌آید. آنتروپی انتقال، استحکام و جهت جریان اطلاعات را محاسبه می‌نماید. گراف نهایی وزن دار و جهت دار خواهد بود. وزن این گراف، میزان قدرت و استحکام ارتباط بین کانال‌ها را نشان می‌دهد. همچنین با استفاده از جهت جریان اطلاعات، می‌توان دو طرفه بودن این ارتباط را بررسی نمود. اگر β_i و α_i دو گره مورد نظر باشند، برای آنتروپی انتقال داریم:

$$TE_{\alpha_i \rightarrow \beta_i} = \sum p(\beta_{t+\tau}, \beta_t, \alpha_t) \log \left(\frac{p(\beta_{t+\tau}, \beta_t, \alpha_t) p(\beta_t)}{p(\beta_{t+\tau}, \beta_t) p(\beta_t, \alpha_t)} \right)$$

$$dTE_{\alpha_i \rightarrow \beta_i} = \frac{TE_{\alpha_i \rightarrow \beta_i}}{TE_{\alpha_i \rightarrow \beta_i} + TE_{\beta_i \rightarrow \alpha_i}}$$

برابر بودن میانگین را بین گروه‌های مختلف آزمود.

طبقه بندی و ارزیابی

جهت تفکیک کلاس‌های تصور حرکتی مختلف، از طبقه‌بندی کننده ماشین بردار پشتیبان^۶ (SVM) بهبود یافته برای مسائل چند کلاسه استفاده (۳۰)، و نتایج طبقه بندی بر اساس ضریب کاپا بیان شده است. در کاپا صحبت از درست و غلط بودن نیست بلکه صحبت از این است که دو تست و یا دو نفر چقدر در تشخیص یک چیز بخصوص با هم توافق دارند. برای محاسبه این ضریب کافی است دو آزمایش را به این صورت در نظر بگیریم که یکی مقدار واقعی و دیگری مقدار اندازه‌گیری شده را نشان می‌دهد که به صورت احتمال بیان شده است.

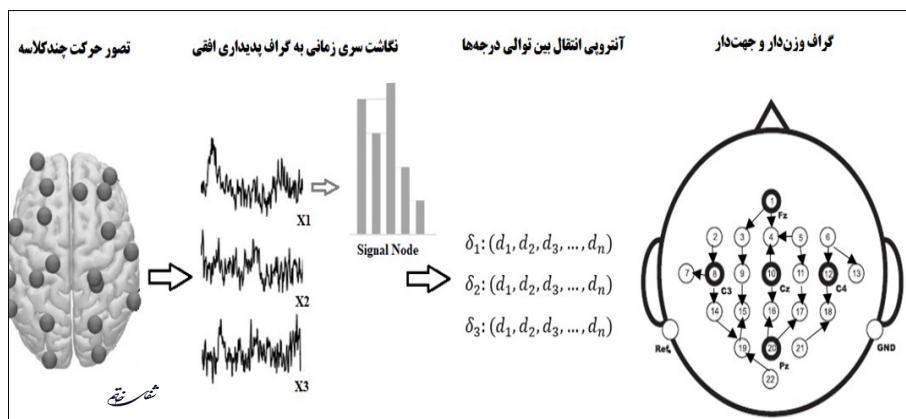
$$P_o = \frac{P_{11}}{P_{11} + P_{22}} \quad , P_e = P_{12}P_{21} + P_{21}P_{12}$$

$$K_c = \frac{P_o - P_e}{1 - P_e}$$

در اینجا P_o توافق کلی و P_e احتمال توافق را نشان می‌دهند. حداکثر مقدار کاپا برابر است با یک و زمانی است که تمام آزمایشات به درستی طبقه‌بندی شوند.

جدول ۲- محاسبه ضریب کاپا

		Rater #1		
		1	2	Total
Rater #2	1	P_{11}	P_{12}	$P_{1.}$
	2	P_{21}	P_{22}	$P_{2.}$
	Total	$P_{.1}$	$P_{.2}$	1



تصویر ۵- جریان اطلاعات در گراف پدیداری جهت‌دار- وزن دار

⁶ Support vector machine

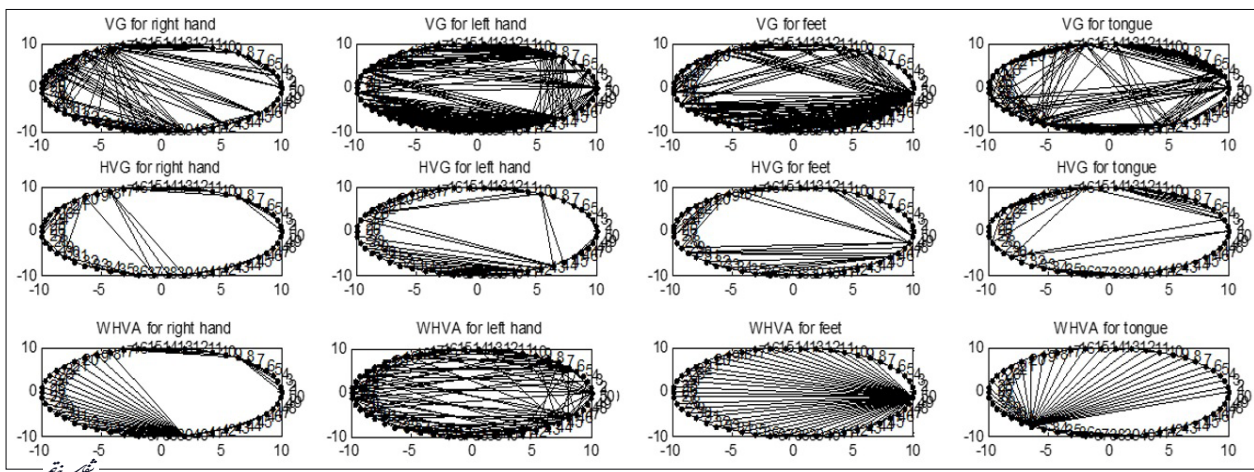
⁷ Weighted Horizontal Visibility Graph- Transfer Entropy

یافته‌ها

تصویر ۶ انواع گراف پدیداری مربوط به هر کلاس تصور حرکتی مشاهده می‌گردد (۵۰ نمونه اول کانال FP).

با مشاهده گراف‌ها مشخص می‌شود که هر کلاس تصور حرکتی دارای گراف متفاوتی است و مناطق خاصی از مغز فعال شده‌اند. جدول ۱ نشان می‌دهد که گراف پدیداری افقی وزن دار WHVG عملکرد بهتری نسبت به دو گراف دیگر دارد. همچنین در مقایسه با روش‌هایی که در مقالات دیگر بیان شده است، WHVG مقدار کاپا (۰/۶۱) بیشتری دارد. در بخش دوم تحقیق، جهت بررسی جریان اطلاعات و بدست آوردن گراف جهت‌دار، از روش آنروپی انتقال استفاده گردیده است. این روش فقط بر روی WHVG اعمال و با بدست آوردن آنروپی انتقال بین توالی درجه‌ها، جریان اطلاعات در گراف بررسی شد.

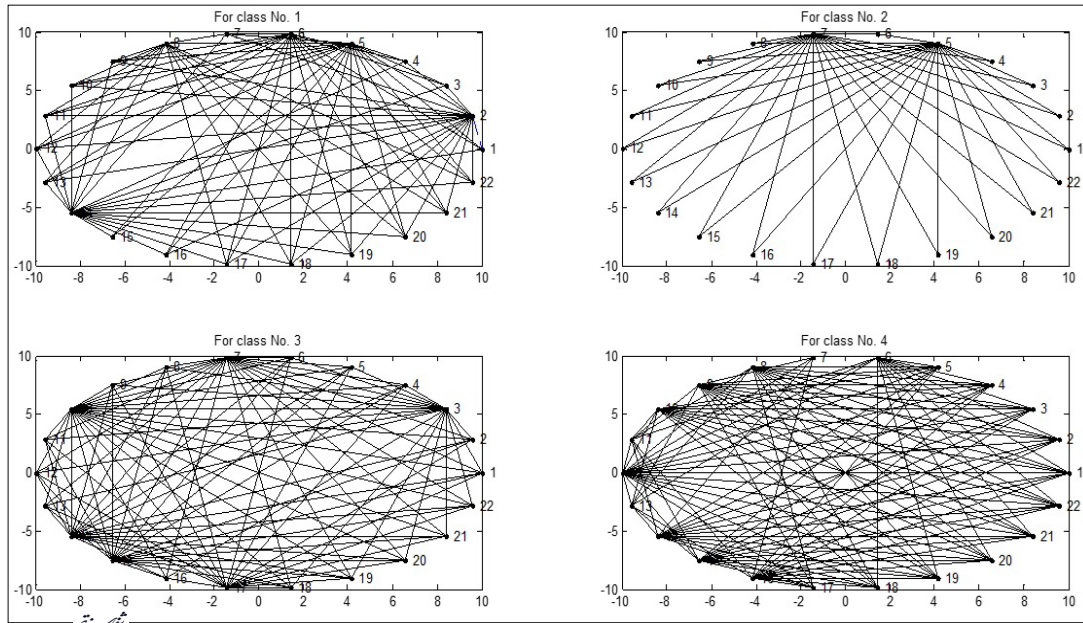
در بخش اول، پس از پیش‌پردازش، برای هر نفر، سری زمانی هر کانال (مربوط به سیگنال EEG هر کلاس تصور حرکتی) به گراف پدیداری تبدیل می‌شود. ۲۲ کانال موجود است و از هر گراف، ۶ ویژگی ذکر شده استخراج می‌گردد. بنابراین برای هر فرد و هر کلاس تصور حرکتی، ۱۳۲ ویژگی استخراج می‌گردد. با استفاده از ANOVA، ویژگی‌ها به تعداد ۱۰ کاهش می‌یابد. ۹ نفر داریم که هر کدام ۴ کلاس تصور حرکتی دارند. بنابراین ۳۶ بردار ویژگی با بعد ۱۰ بدست می‌آید. سپس ماشین بردار پشتیبان آموزش می‌بیند و در نهایت طبقه بندی ۴ کلاس تصور حرکتی دست چپ، دست راست، دو پا و زبان انجام می‌شود. در



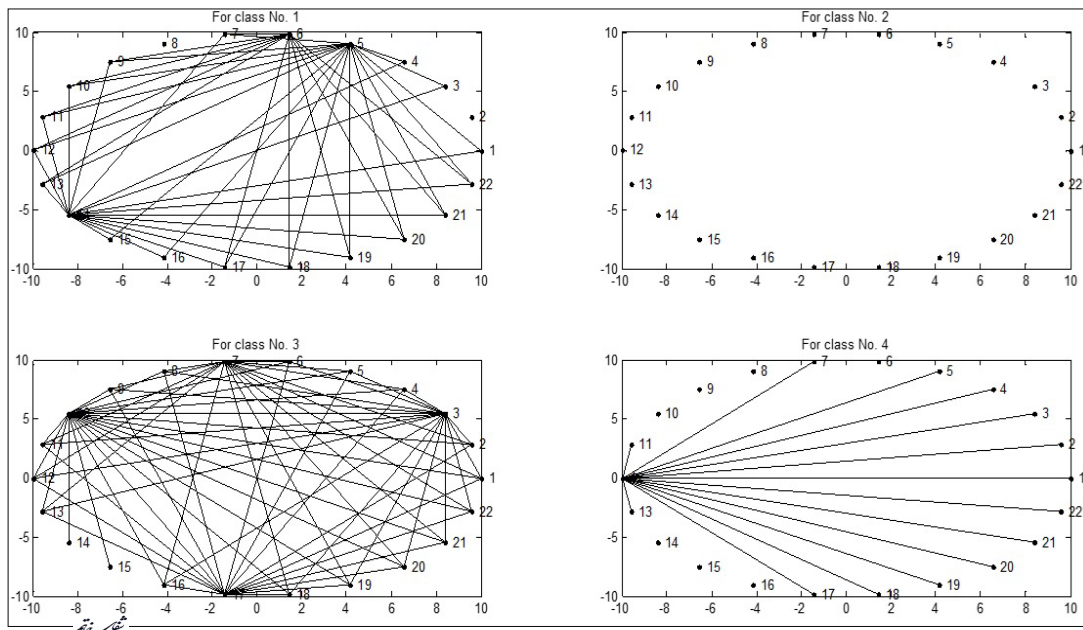
تصویر ۶- انواع گراف پدیداری در طی تصور حرکت ۴ کلاس (۵۰ نمونه اول کانال FP) ردیف‌ها: کلاس‌های متفاوت تصور حرکتی. ستون‌ها: انواع گراف‌های پدیداری برای هر کلاس

جدول ۳- ارزیابی نتایج طبقه‌بندی گراف‌های مختلف

Kappa	F1_score	Precision	Specificity	Sensitivity	Accuracy	Graph
0.5211	0.8148	0.8147	0.9498	0.8194	0.8267	VG
0.5656	0.8364	0.8339	0.9548	0.8410	0.8433	HVG
0.6100	0.8522	0.8478	0.9613	0.8646	0.8600	WHVG



تصویر ۷- WHVG-TE مربوط به ۴ کلاس تصور حرکتی با آستانه ۰/۱



تصویر ۸- WHVG-TE مربوط به ۴ کلاس تصور حرکتی با آستانه ۰/۲

حرکتی، کمتر از ۰/۰۵ می‌باشد. این نتیجه نشان می‌دهد که بین ویژگی‌های ۴ کلاس، اختلاف زیادی وجود دارد و با روش WHVG-TE به خوبی قابل تفکیک هستند.

سپس برای ارزیابی تفاوت گراف‌ها، از روش ANOVA استفاده و P-Value محاسبه شده است. مشاهده می‌گردد که P-Value تمام کلاس‌های تصور

جدول ۴- P-Value بین ویژگی‌های استخراج شده از WHVG-TE در کلاس‌های تصور حرکتی مختلف

	Class 1	Class 2	Class 3	Class 4
Class 1	-	0.0453	0.0379	0.0347
Class 2	0.0453	-	0.0483	0.0392
Class 3	0.0379	0.0483	-	0.0357
Class 4	0.0347	0.0392	0.0357	-

شماره ۶۵

مربوط به الگوریتم الگوهای مکانی مشترک بانک فیلتر و مقدار ۰/۵۷ می‌باشد اما در این تحقیق با استخراج مهم‌ترین ویژگی‌های گراف از جمله کوتاه‌ترین طول مسیر، ضریب همبستگی و ضریب خوشه‌بندی و به کار بردن طبقه‌بندی‌کننده SVM چندکلاس، مقدار کاپا ۰/۶۱ به دست آمد که نشان می‌دهد گراف پدیداری با نگاشت سری زمانی و حفظ اطلاعات آن، درصد صحت بالایی دارد. همچنین برای بررسی جهت جریان اطلاعات در مغز از روش جدید WHVG-TE استفاده گردید و مقدار P کمتر از ۰/۰۵ مشاهده شد (۳۲). با توجه به فعالیت‌های ذهنی مختلف، نواحی متفاوتی در مغز فعال می‌شوند و جهت جریان اطلاعات متغیر خواهد بود. نشان داده شد که TE، روشی کارآمد برای تعیین کمیت جهت جریان اطلاعات بین سری‌های زمانی ارائه می‌دهد (۲۰، ۲۱). در این روش، آستانه وزنی یک عدد ثابت تعیین می‌شود و می‌توان آن را با الگوریتم تکاملی مانند الگوریتم ژنتیک در تحقیقات آتی بهینه کرد. همچنین در تحقیقات آینده می‌توان با ترکیب ویژگی‌های مکانی، زمانی و آشوبی با ویژگی‌های اصلی گراف به نتایج با صحت بیشتری دست یافت.

بحث و نتیجه‌گیری

بیمارانی که دچار فلج عضلانی یا ناراحتی‌های شدید حرکتی هستند، برای کنترل وسایل جانبی و ارتباط با محیط اطراف، به یک کانال ارتباطی نیاز دارند که وابسته به کنترل ماهیچه‌ها نباشد (۳۱). در صورت حرکتی، رخدادهایی در مغز اتفاق می‌افتد و سیستم BCI با استخراج این رخدادهای از سیگنال EEG، نوع حرکت را تشخیص می‌دهد. روش پردازش سیگنال جهت استخراج و یا انتخاب ویژگی، تاثیر زیادی در کارایی این سیستم دارد. در این پژوهش نشان داده شد که با استفاده از نگاشت سیگنال‌های EEG به انواع گراف پدیداری، می‌توان رفتارهای آشوبی و دینامیک غیرخطی سیگنال مغزی را به خوبی تشخیص داد و فعالیت‌های مختلف ذهنی را تفکیک نمود. روش معمول در گراف پدیداری جهت استخراج اطلاعات و وزن‌دهی گراف، استفاده از توزیع درجه می‌باشد. اما در اینجا از توزیع اختلاف دامنه بهره گرفته شد زیرا سری‌های زمانی کوتاه‌تری مورد نیاز بود. نتایج مقالات دیگر بر روی داده‌های 2a رقابت چهارم BCI نشان می‌دهد که بالاترین مقدار کاپا

منابع

- Sadiq MT, Yu X, Yuan Z, Aziz MZ, ur Rehman N, Ding W, et al. Motor Imagery BCI Classification Based on Multivariate Variational Mode Decomposition. *IEEE Transactions on Emerging Topics in Computational Intelligence*. 2022.
- Ghafourian P, Ghoshuni M, Vosough I. Evaluation of Exam Anxiety in Healthy Subjects using Brain Signals Analysis. *The Neuroscience Journal of Shafayeh Khatam*. 2020; 8(3): 61-9.
- Fallani FDV, Bassett DS. Network neuroscience for optimizing brain-computer interfaces. *Physics of life reviews*. 2019; 31: 304-9.
- Zhu G. Analysis of EEG signals using complex brain networks: University of Southern Queensland; 2014.
- Lacasa L, Luque B, Ballesteros F, Luque J, Nuno JC. From time series to complex networks: The visibility graph. *Proceedings of the National Academy of Sciences*. 2008; 105(13): 4972-5.
- Lacasa L, Luque B, Luque J, Nuno JC. The visibility graph: A new method for estimating the Hurst exponent of fractional Brownian motion. *EPL (Europhysics Letters)*. 2009; 86(3): 30001.
- Bashiri F, Mokhtarpour A. Depression classification and recognition by graph-based features of EEG signals. *International Journal of Medical Engineering and Informatics*. 2022; 14(3): 252-63.
- Altundogan TG, Karaköse M, editors. EEG Signal Classification with Deep Neural Networks using Visibility Graphs. 2022 26th International Conference on Information Technology (IT); 2022.
- Zhang X, Landsness EC, Chen W, Miao H, Tang M, Brier LM, et al. Automated sleep state classification of wide-field calcium imaging data via multiplex visibility graphs and deep learning. *Journal of neuroscience methods*. 2022; 366: 109421.
- Zhu G, Li Y, Wen P. Analysis and classification of sleep stages based on difference visibility graphs from a single-channel EEG signal. *IEEE journal of biomedical and health informatics*. 2014; 18(6): 1813-21.
- Olamat A, Ozel P, Akan A. Synchronization Analysis In Epileptic EEG Signals Via State Transfer Networks Based On Visibility Graph Technique. *International journal of neural systems*. 2021: 215.
- Bajaj S, Butler AJ, Drake D, Dhamala M. Brain effective connectivity during motor-imagery and execution following stroke and rehabilitation. *NeuroImage: Clinical*. 2015; 8: 572-82.
- Kong T, Shao J, Hu J, Yang X, Yang S, Malekian R. EEG-Based Emotion Recognition Using an Improved Weighted Horizontal Visibility Graph. *Sensors*. 2021; 21(5): 1870.
- Xuan Q, Zhou J, Qiu K, Xu D, Zheng S,

- Yang X. CLPVG: Circular limited penetrable visibility graph as a new network model for time series. *Chaos: An Interdisciplinary Journal of Nonlinear Science*. 2022; 32(1): 013130.
15. Jirsa VK, McIntosh AR. *Handbook of brain connectivity*: Springer; 2007.
16. Wiener N. *The theory of prediction*. Modern mathematics for engineers. New York. 1956; 165.
17. Granger CW. Investigating causal relations by econometric models and cross-spectral methods. *Econometrica: journal of the Econometric Society*. 1969: 424-38.
18. Kaminski M, Liang H. Causal influence: advances in neurosignal analysis. *Critical Reviews™ in Biomedical Engineering*. 2005; (33): 4.
19. Marinazzo D, Liao W, Chen H, Stramaglia S. Nonlinear connectivity by Granger causality. *Neuroimage*. 2011; 58(2): 330-8.
20. Repper-Day C. *Mapping dynamic brain connectivity using EEG, TMS, and Transfer Entropy*: The University of Manchester (United Kingdom); 2017.
21. Schreiber T. Measuring information transfer. *Physical review letters*. 2000; 85(2): 461.
22. Moslemi B, Azmodeh M, Tabatabaei M, Alivandi Vafa M. The Effect of Transcranial Direct Current Stimulation on Dorsolateral Prefrontal Cortex: a Review of its Role on Cognitive Functions. *The Neuroscience Journal of Shefaye Khatam*. 2019; 8(1): 129-44.
23. Li S, Shang P. Analysis of nonlinear time series using discrete generalized past entropy based on amplitude difference distribution of horizontal visibility graph. *Chaos, Solitons & Fractals*. 2021; 144: 110687.
24. Brunner C, Leeb R, Müller-Putz G, Schlögl A, Pfurtscheller G. BCI Competition 2008–Graz data set A. Institute for Knowledge Discovery (Laboratory of Brain-Computer Interfaces), Graz University of Technology. 2008; 16: 1-6.
25. Ghumman MK, Singh S, Singh N, Jindal B. Optimization of parameters for improving the performance of EEG-based BCI system. *Journal of Reliable Intelligent Environments*. 2021; 7(2): 145-56.
26. Ahmadlou M, Adeli H, Adeli A. New diagnostic EEG markers of the Alzheimer's disease using visibility graph. *Journal of neural transmission*. 2010; 117(9): 1099-109.
27. Ballesteros F, Luque F, Lacasa L, Luque B, Nuno J. From time series to complex networks: the visibility graphs. *Proc Natl Acad Sci USA*. 2008; 105: 4972.
28. Song Z, Zhan G, Lin Y, Fang T, Niu L, Zhang X, et al. Electroacupuncture Alters BCI-Based Brain Network in Stroke Patients. *Computational intelligence and neuroscience*. 2022.
29. Hasani H, Jafari M. Dimension Reduction in fMRI Images based on Metaheuristic Algorithm to Diagnose Autism. *The Neuroscience Journal of Shefaye Khatam*. 2021; 9(3): 1-11.
30. Mohammadpoor M, Alizadeh A. Using Support Vector Machines as an Intelligent Algorithm for Detecting Seizures from EEG Signals. *The Neuroscience Journal of Shefaye Khatam*. 2021; 9(2): 1-9.
31. Heyrani A aN. The Effects of Bilateral Motor Training on the Power of Grip in Affected Hand of Children with Spastic Hemiplegic Cerebral Palsy. *The Neuroscience Journal of Shefaye Khatam*. 2021; 9(3): 27-35.
32. Ang KK, Chin ZY, Zhang H, Guan C, editors. Filter bank common spatial pattern (FBCSP) in brain-computer interface. 2008 IEEE international joint conference on neural networks (IEEE world congress on computational intelligence); 2008.