

طبقه بندی سیگنال های مغز در سیستم BCI با استفاده از تبدیل موجک

حمیده موسوی^۱، محمد هادی شاهرخ آبادی^۲، حمیدرضا توکلی^۳

^۱ دانشجوی کارشناسی ارشد، دانشکده برق و کامپیوتر دانشگاه حکیم سبزواری، سبزوار، ایران

^۲ دانشیار دانشکده برق و کامپیوتر دانشگاه حکیم سبزواری، سبزوار، ایران

^۳ استادیار دانشکده برق و کامپیوتر دانشگاه حکیم سبزواری، سبزوار، ایران

چکیده

رابط مغز و رایانه (BCI) مبتنی بر الکتروانسفالوگرافی (EEG) در دو دهه اخیر بسیار مورد توجه قرار گرفته است. در این مطالعه رویکرد ابتکاری بکارگرفته شده تا بتوان سیگنالهای EEG مبتنی بر تصور حرکتی را به دو دسته تصور دست راست و دست چپ دسته بندی کرد. در این راستا ابتدا باندهای مرتبط با تصور حرکتی از سیگنال EEG جدا و با اعمال تابع تبدیل موجک روی آنها ویژگی های آماری و ضرایب اتورگرسیون از آن استخراج شده است. سپس از بین ویژگیهای استخراج شده با روش SFFS بهترین ویژگیها انتخاب و آنها به کلاس بندهای LDA، KNN، NB و SVM اعمال کردیم. نتایج بدست آمده نشان می دهند که کلاس بند SVM با دقت ۸۷/۱۴٪ نسبت به سایر کلاس بندها از دقت بالاتری برخوردار است.

واژه های کلیدی: BCI، EEG، تصور حرکتی، تبدیل موجک، اتورگرسیون، SVM، SFFS

۱. مقدمه

مغز ما عملکردهای مختلف بدن را کنترل می کند. هر ناحیه از مغز وظیفه خاص مانند کنترل حرکات دست و پا، بینایی، شنوایی و تفکر را بر عهده دارد. از این رو، بیمارانی که از مشکل ناتوانی حرکتی رنج می برند و برای بهبود توانایی خود در انجام حرکات به پشتیبانی زیادی نیاز دارند. تاکنون برای انجام این موضوع روش های گوناگونی ارائه شده که یکی از آنها رابط مغز-رایانه (BCI)^۱ می باشد [۱]. رابط مغز-رایانه ارتباط مستقیمی بین مغز انسان و سیستم رایانه ای است بدون آنکه درگیر فعالیت عضلات یا فعالیت های عصبی- حرکتی باشد. BCI می تواند با رمزگشایی سیگنالهای مغزی دستورات کنترل سیستم عصبی را جایگزین، بهبود و بازیابی کند. در بین تمام روشهای اندازه گیری فعالیت مغز، الکتروانسفالوگرافی (EEG)^۲ به دلیل وضوح خوب مکانی و زمانی، مقرون به صرفه و قابل حمل بودن در بین محققان متداول تر است [۲]. در سال ۱۹۶۰ محققان ایده کنترل سیستم الکترونیکی با استفاده از فعالیت های مغزی را معرفی کردند و سپس در سال ۱۹۷۳ محققان اولین آزمایش را بر روی انسان انجام دادند. در آزمایش بعد یک سیستم کنترل الکترونیکی از طریق فعالیت مغزی بود که توسط EEG اندازه گیری شد [۱]. سیگنالهای EEG در طیف وسیعی از فعالیت های پزشکی از جمله تشخیص و پیش بینی صرع، طبقه بندی تصور حرکتی (MI)^۳، طبقه بندی احساسات، وضعیت خواب و تشخیص اثرات دارو کاربرد دارند. EEG سیگنالی با دامنه کوچک است که با استفاده از آن فعالیت های الکتریکی مغز ناشی از نورون های عصبی که معمولاً حاوی آرتیفکت های فیزیولوژیکی و غیر فیزیولوژیکی است اندازه گیری می شود. این آرتیفکت ها به طور معمول دامنه بسیار بالاتری نسبت به سیگنالهای مغزی دارند و بنابراین مشکل بزرگی در تفسیر سیگنال EEG ایجاد می کنند. استفاده از سیگنال های EEG ناشی از تصور حرکتی را می توان به عنوان روشی جدید برای ارتباط افرادی که از معلولیت شدید جسمی رنج می برند معرفی کرد. تصور حرکتی یک فعالیتی ذهنی است که در آن شخص تصور می کند که عملی را انجام می دهد بدون اینکه عضلات خود را حرکت دهد. امروزه بیشتر تحقیقات روی تمایز بین سیگنالهای EEG مثل حرکت دست راست و چپ، انگشتان پا و حرکت زبان انجام می شود. در سیگنال EEG، ERP^۴ پتانسیل مربوط به رویداد، ارتباط نزدیکی با فعالیت عصبی روی قشر حرکتی مغز دارد. هنگامی که سیستم حسی انسان تحریک خارجی خاصی را تجربه یا احساس می کند، مناطقی از قشر مغز تغییراتی در پتانسیل های خود ایجاد می کنند. محققان نشان داده اند که هر دو نیمکره مغز باند فرکانس مثل ریتم های میو و بتا سیگنال ERP را دارند و طیف توان EEG را تقویت می کند. این در حالی است که سیگنالهای ERS^۵ و ERD^۶ در هنگام تصور انسان در انجام تصور حرکات دست راست و چپ تضعیف می شوند [۳].

الگوریتم های استخراج ویژگی مبتنی بر موجک (WT)^۷، اتورگرسیون (AR)^۸، BP^۹، FFT^{۱۰}، CSP^{۱۱}، MVAR^{۱۲}، ICA^{۱۳} نیز برای استخراج ویژگی مورد استفاده قرار می گیرد [۴]. انواع مختلفی از روش های طبقه بندی نیز برای سیستم های BCI ارائه

^۱ Brain Computer Interface^۲ Electroencephalogram^۳ Motor Imagery^۴ Event Related Potential^۵ Event Related Synchronization^۶ Event Related Desynchronization^۷ Wavelet Transform^۸ Autoregression^۹ Band Power^{۱۰} Fast Fourier Transform^{۱۱} Common Spatial Pattern^{۱۲} Multivariate Autoregression^{۱۳} Independent Component Analysis

شده مانند تجزیه و تحلیل جدا کننده خطی (LDA)^{۱۴}، ماشین بردار پشتیبان (SVM)^{۱۵}، K نزدیکترین همسایه (KNN)^{۱۶} [۵]، بیزین (NB)^{۱۷} [۶] نمونه های از طبقه بندیهای هستند که در این زمینه استفاده می شوند [۱].

هومری و همکارانش^{۱۸} [۴] از روش های استخراج ویژگی مبتنی بر تابع های مختلف موجک مثل Coiflet^{۱۹}، Db^{۲۰} و Symlet^{۲۱} استفاده کرده و با کلاس بند SVM به دقت ۹۰ درصد رسیده اند. نتایج طبقه بندی بستگی به تمرکز فرد در طول آزمایش دارد. سولین دوان^{۱۹} و همکارانش [۷] از تجزیه و تحلیل بسته موجک^{۲۰} همراه با روش تجزیه و تحلیل مؤلفه های مستقل (ICA) استفاده کرده، (WPICA) که می تواند به طور موثر باعث افزایش تصور ERD/ERS مشخصات سیگنالهای EEG شود و الگوهای EEG مربوط به دو نوع حرکت دست راست و چپ را تشخیص دهد. آنها به طور میانگین به دقت طبقه بندی ۸۶/۳٪ رسیده اند که نسبت به الگوریتم ICA نتایج بهتری دارد.

براگا و همکارانش^{۲۱} [۸] که گروه برنده در رقابت BCI می باشند، از موجک Morlet به عنوان استخراج ویژگی و تجزیه و تحلیل چند متغیر برای طبقه بندی استفاده کرده اند. میانگین دقت ۸۹٪ است و زمان طبقه بندی ۷/۵۹ ثانیه است. نتایج این گروه نسبت به گروه های دیگر بهتر است. آنکیتا داتا و همکارانش^{۲۲} [۲] سه نوع معماری را طبقه بندی سیگنالهای EEG بررسی کرده اند. انرژی مبتنی بر موجک و آنتروپی (EngEnt) با BP و AAR بررسی شده است. معماری نوع سوم با مجموعه ویژگی ها و با طبقه بند KNN بهترین نتیجه ۸۶/۸۲٪ را در بین هر سه معماری به دست آورده است. در این پژوهش در مقایسه با این مقاله با دیتای مشابه به همراه موجک و اتورگرسیون به عنوان استخراج ویژگی و طبقه بند SVM با میانگین دقت ۸۷/۱۴٪ بهتر عمل کرده است. در ادامه به بررسی تبدیل موجک، ضریب اتورگرسیون، و روش طبقه بندی می پردازیم.

تبدیل موجک

این تبدیل روشی کارآمد است که می تواند با یک طرح فیلتر بازگشتی ساده اجرا و بازسازی سیگنال اصلی را با یک فیلتر معکوس انجام دهد [۹]. رابطه (۱) تبدیل موجک شامل یک موجک مادر با تنوع فرکانسی زیاد است که در نتیجه می تواند تغییرات زیادی را دنبال کند. در این رابطه $\Psi(t)$ موجک مادر، a پارامتر مقیاس و τ پارامتر شیفت است. مهم ترین انواع موجک ها شامل Haar، Daubechies، Coiflet، Symlet و Morlet می باشند.

(۱)

$$W_f(a, \tau) = \frac{1}{\sqrt{a}} \int_R f(t) \Psi^* \left(\frac{t - \tau}{a} \right) dt \quad \text{ضرایب اتورگرسیون (AR)}$$

در این ویژگی سیگنال EEG را به عنوان خروجی یک فیلتر خطی میتوان در نظر گرفت به طوری که خروجی برابر با ترکیب خطی چند لحظه قبل است و ضرایب AR را می توان به کمک رابطه (۲) که در آن p مرتبه ای از مدل و $x(n)$ سیگنال در نمونه n است، تخمین زد، همچنین $a_p(i)$ ضریب AR و $\varepsilon(n)$ میانگین نویز سفید است که صفر در نظر گرفته می شود [۱۰] و سپس از آنها می توان به عنوان ویژگی استفاده کرد.

$$x(n) = - \sum_{i=1}^p a_p(i) x(n-i) + \varepsilon(n) \quad (2)$$

^{۱۴} Linear Discriminant Analysis

^{۱۵} Support Vector Machine

^{۱۶} K-Nearest Neighbor

^{۱۷} Naive Bayes

^{۱۸} Homri Ines

^{۱۹} Suolin Duan

^{۲۰} Wavelet Packed

^{۲۱} Braga

^{۲۲} Ankita Datta

طبقه بند SVM

ماشین بردار پشتیبان، یک الگوریتم یادگیری با نظارت می باشد که در فرآیندهای کلاس بندی و رگرسیون استفاده می شود. در این الگوریتم داده های نقطه ای که در فضا رسم می شوند توسط یک خط، صفحه و یا فوق صفحه به صورت کلاس های متفاوت از هم جدا می شوند. مجموعه آموزش x را در نظر بگیرید. $\{x_i, i=1,2,\dots,n\}$ که متعلق به دو کلاس w_1 و w_2 با در نظر گرفتن برجسب های $y = \pm 1$ است. تابع $\gamma(x) = w^T x + w_0$ که w^T بردار وزن ضریب و w_0 آستانه را مشخص می کند که قانون طبقه بندی طبق رابطه (۳) و (۴) است [۵]. در رابطه (۵) b حاشیه است.

(۳)

$$w^T x + w_0 > 0 \Rightarrow x \in w_1; y_i = +1$$


(۴)

$$w^T x + w_0 < 0 \Rightarrow x \in w_2; y_i = -1$$

(۵)

$$y_i (w^T x + w_0) \geq b$$

در نتیجه خطی که داده های دو کلاس را بهتر از هم جدا می کند و بیشترین فاصله را نسبت به نزدیکترین نمونه ها در هر دو کلاس داشته باشد بهترین خط است، که در شکل ۱ نشان داده شده است.




شکل ۱: طبقه بند SVM [۵]

در اینجا پردازش سیگنال های مغز شامل مراحل ثبت اطلاعات، انتخاب کانال، پیش پردازش، استخراج ویژگی، انتخاب ویژگی و طبقه بندی است.


۲. روش انجام کار

در اینجا از دو روش برای پردازش استفاده شده است تا بتوان سیگنالهای EEG تصور حرکتی را به تصور دست راست و دست چپ دسته بندی کرد.

در این پژوهش مجموعه اطلاعات ارائه شده از رقابت جهانی BCI Competition II ۲۰۰۳ که توسط دانشگاه صنعتی Graz اتریش تهیه شده برای ثبت و اندازه گیری سیگنالهای مغز مورد استفاده قرار می گیرند. این مجموعه شامل اطلاعاتی از شخصی سالم ۲۵ ساله است. این آزمایش شامل ۷ مرحله با ۴۰ آزمایش (trial) است یعنی ۲۸۰ آزمایش از ۹ ثانیه داده شده است که در شکل ۲ مشخص شده است. سه کانال EEG دو قطبی از Cz، C۳ و C۴ مورد اندازه گیری قرار گرفته اند که در شکل ۳ مشخص شده اند. فرکانس نمونه برداری ۱۲۸ هرتز است و بین ۰/۵ تا ۳۰ هرتز آزمایش ها برای آموزش و تست به طور تصادفی انتخاب شده است. برجسب کلاسه های '۱' و '۲' به ترتیب برای دست چپ و راست است [۱۱].



شکل ۲: زمان بندی طرح [۱۱]



شکل ۳: موقعیت قرارگیری الکترودها برای انجام آزمایش [۱۱]

۱-۲ روش اول

در مرحله اول کانالهای بهینه در نظر گرفته شده است سپس در مرحله دوم که پیش پردازش است باند فرکانسی بهینه که تصور حرکتی در آن رخ می دهد را مشخص کرده و داده را در حوزه فرکانس فیلتر کرده تا اطلاعات مرتبط با تصور حرکتی را از سیگنال EEG جدا کند. روندنما رویکرد ابتکاری در شکل ۴ نشان داده شده است.



شکل ۴: روندنمای روش تبدیل موجک و AR

۲-۱-۱ انتخاب کانالهای بهینه

اطلاعات دریافتی شامل سه کانال می باشد C₃, C_z و C₄ با استفاده از روش Cross - validation ترکیب های مختلفی در نظر گرفته شده و دو کانال C₄ و C_z بیشترین عملکرد را در این تحقیق نشان دادند.

۲-۱-۲ پیش پردازش

مجموعه داده ها شامل ۲۸۰ آزمایش است که نیمی از آنها برای آموزش و نیمی دیگر برای تست به کار گرفته شده اند. از یک فیلتر میان گذر باترورث برای استخراج باندهای فرکانس مورد نظر ۸-۳۰ هرتز یعنی باندهای میو و بتا استفاده شده است. پنج باند فرکانس شناخته شده یعنی دلتا (۵-۴ هرتز)، تتا (۴-۷ هرتز)، آلفا (۷-۱۳ هرتز)، میو (۸-۱۳ هرتز)، بتا (۱۳-۳۰ هرتز) و شکل موج گاما (۳۰-۵۰ هرتز) برای انجام این آزمایش در نظر گرفته می شود.

۲-۱-۳ استخراج ویژگی


بعد از اینکه دو سیگنال EEG از روی سیگنال اصلی بازسازی شد بطوریکه هر کدام اطلاعات یکی از ریتمهای میو و بتا را داشته باشند، روی هر کدام تبدیل موجک انجام می شود و به یک سطح تجزیه می شود. تعداد سطوح تجزیه بر اساس اجزای فرکانس غالب سیگنال انتخاب می شود. در انجام این آزمایش از نوع موجک Daubechies، با مرتبه ۴ استفاده شده است.

ویژگی های آماری میانگین، واریانس و ضرایب اتورگرسیون مربوط به مجموعه ضرایب موجک برای محاسبه ابعاد کل بردارهای ویژگی انجام شده و از کل این ویژگی ها تعداد ۴۰ بردار ویژگی استخراج می شود.

۲-۱-۴ انتخاب ویژگی

انتخاب ویژگی را می توان به عنوان فرآیند شناسایی ویژگی های مرتبط و حذف ویژگی های غیر مرتبط و تکراری با هدف مشاهده زیر مجموعه ای از ویژگی ها که موضوع را به خوبی و با کاهش حداقل درجه کارایی تشریح می کند تعریف کرد. اما ممکن است یک سری از این ویژگیها مناسب نباشند و باعث کاهش عملکرد کلاسیک شوند که برای برطرف کردن این اثر در این تحقیق از روش انتخاب ویژگی مبتنی بر جستجو (SFFS)^{۲۳} استفاده شده است [۱۲].

در داده آموزش ترکیب ۱۷ تایی مناسب است که این انتخاب ویژگی حدود ۸/۹۶ ثانیه طول می کشد همانطور که در شکل ۵ نشان داده می شود، براساس ارزیابی انجام شده می توان به این نتیجه رسید که برای داده تست ترکیب ۱۵ تایی مناسب است.



شکل ۵: نمودار دقت در مرحله انتخاب ویژگی

^{۲۳} Sequential Forward Feature Selection

۵-۱-۲ طبقه بندی

در بحث کلاس بندی هدف این است که یک نمونه که توسط یک سری ویژگی ها و پارامترها مشخص می شود، در یکی از کلاس ها طبقه بندی شود. اگر مسأله دو کلاسه باشد، مدل یادگیری ماشین از روی ویژگی های آن نمونه مشخص می کند که نمونه به کلاس ۱ (دست چپ) یا کلاس ۲ (دست راست) تعلق دارد. در این پژوهش از کلاس بندی های KNN، LDA، SVM و NB استفاده می شود.

۲-۲ روش دوم

روندنمای انجام مراحل روش دوم در شکل ۶ نشان داده می شود. مراحل انتخاب کانال و پیش پردازش در این روش مشابه روش اول است. در مرحله سوم برای Source Localization با استفاده از فیلتر مکانی High Laplacian داده را در حوزه مکان فیلتر کرده تا اطلاعات هر کانال برجسته شده و از سایر کانالها متمایز شود. در مرحله چهارم که استخراج ویژگی است با استفاده از الگوریتم CSSP^{۲۴} (الگوریتم بهبود یافته CSP) داده از فضای غیر خطی به فضای خطی منتقل شده و واریانس هر کانال جدید به عنوان ویژگی استخراج می شود. سپس با استفاده از الگوریتم FDR^{۲۵} ویژگی های بهینه انتخاب شده و در نهایت با استفاده از کلاس بندی ها داده ها به دو دسته کلاس بندی می شوند.



شکل ۶: روندنمای الگوریتم CSP

۱-۲-۲ الگوریتم CSP

روش CSP، با اعمال فیلترهای فضایی به ورودی ها، واریانس سیگنالها را در کلاس اول حداکثر و به طور همزمان در کلاس دیگر حداقل می کند. سپس از سیگنالهای فیلترشده ویژگیهای کلاس اول را استخراج می کند. این کار به طور معکوس نیز انجام می شود. در این روش، تعدادی از فیلترهای فضایی، واریانس سیگنال را در کلاس دوم حداکثر و به طور همزمان در کلاس اول حداقل می کنند. سپس با استفاده از سیگنالهای فیلترشده، ویژگیهای کلاس دوم استخراج می شود [۱۳]. تعداد ویژگیهای استخراج شده در این روش ۷۰ ویژگی می باشد.

۲-۲-۲ الگوریتم FDR

در این الگوریتم برای انتخاب ویژگی از روش نرخ تفکیک پذیری فیشر، رابطه (۶)، استفاده می شود [۱۴]. در این آزمون از میانگین بین کلاسی و واریانس درون کلاسی استفاده می شود. نحوه رتبه بندی در این روش به این صورت است که اگر یک

^{۲۴} Common Spatial -Spectral Pattern^{۲۵} Fisher Discriminant Ratio

ویژگی میانگین بین کلاسی بیشتر و در عین حال واریانس درون کلاسی کمتری داشته باشد ارزش بیشتری دارد زیرا که تفکیک پذیری دو کلاس از هم بیشتر می شود. در رابطه زیر m میانگین و δ واریانس است.

$$fdr = \frac{(m_1 - m_2)^2}{\delta_1^2 + \delta_2^2} \quad (6)$$

بکارگیری الگوریتم CSP برای انتخاب ویژگی بر روی این داده به دلیل تعداد کم کانالهای داده و عدم توانایی در استخراج الگوهای مکانی مشترک مناسب نیست.

۳. نتایج و بحث

الگوریتم های ارائه شده در این پژوهش برای هر طبقه بندی با دو کلاس مناسب است در این مقاله، یک روش طبقه بندی جدید EEG تصور حرکتی ارائه شده است. روش های طبقه بندی همانطور که در این کار شرح داده شده است، امکان توسعه یک سیستم تحلیل سیگنال EEG تصور حرکتی کاملاً خودکار را فراهم می کند که دقیق، ساده و به اندازه کافی قابل استفاده در سیستم های BCI است. با طبقه بندیهای مختلف و با کمک معیارهای ارزیابی Accuracy, Confusion Matrix که با رابطه (۷) مشخص شده انجام می شود. در روش اول طبقه بند SVM با ۸۷/۱۴٪ و زمان انتخاب ویژگی که ۸/۹۶ ثانیه است که می تواند بهبود پیدا کند و در روش دوم طبقه بند SVM با ۷۵/۷۱٪ دقت های بهتری بدست آمده اند. جداول ۱ و ۲ و شکل ۸ نتایج دقت بین طبقه بندیهای مورد استفاده را نشان می دهند. نشان می دهد که تغییر ویژگی های استخراج شده منجر به بهینه سازی نوع انتخاب می شود. در روش اول که با انتخاب کانال های بهینه و سپس استخراج ویژگی موجب در یک سطح و با استفاده از نوع db۴، ویژگی های آماری و ضرایب AR انجام شده و در طبقه بند SVM که مناسب برای داده های دو کلاسه است و با استفاده از پارامتر خطی Linear Kernel انجام شده با دقت ۸۷/۱۴٪ درصد بهتری از مرجع [۲] که با دیتای مشابه انجام شده را دارد.


$$Accuracy = \frac{N_{correct}}{N_{total}} \times 100 \quad (7)$$

جدول ۱: نتایج دقت طبقه بندی روش موجه و AR

طبقه بند	Accuracy۱	Accuracy۲	Mean Accuracy
SVM	۸۶٪/۱۱	۸۸٪/۲۳	۸۷٪/۱۴
LDA	۸۵٪/۷۱	۸۵٪/۷۱	۸۵٪/۷۱
KNN, k=۳	۷۵٪	۷۶٪/۴۷	۷۵٪/۷۱
NB	۶۹٪/۰۴	۵۸٪/۱۶	۶۱٪/۴۲

جدول ۲: نتایج دقت طبقه بندی روش الگوریتم CSP

طبقه بند	Accuracy ^۱	Accuracy ^۲	Mean Accuracy
SVM	۷۴٪/۳۲	۷۷٪/۲۷	۷۵٪/۷۱
LDA	۷۳٪/۳۳	۷۶٪/۹۲	۷۵٪
KNN, k = ۳	۷۲٪/۸۵	۷۲٪/۸۵	۷۲٪/۸۵
NB	۷۲٪/۱۵	۷۸٪/۶۸	۷۵٪



شکل ۷: مقایسه بین کلاس بندها

منابع

- [۱] R. Bousseta, I. El Ouakouak, M. Gharbi, and F. Regragui, "EEG Based Brain Computer Interface for Controlling a Robot Arm Movement Through Thought," *IRBM*, vol. ۳۹, no. ۲, pp. ۱۲۹-۱۳۵, ۲۰۱۸.
- [۲] Ankita Datta and Rajdeep Chatterjee, "Comparative Study of Different Ensemble Compositions in EEG Signal Classification Problem." ۲۰۱۹.
- [۳] P. R. N. Rinkal G. Shah, "Hand Movement Classification Using Motor Imaginary EEG." ۲۰۱۶.
- [۴] H. Ines, Y. Slim, and E. Noureddine, "EEG Classification using Support Vector Machine," pp. ۳-۶, ۲۰۱۳.
- [۵] M. Z. Baig, E. Javed, Y. Ayaz, W. Afzal, and S. O. Gillani, "Classification of Left / Right Hand Movement from EEG Signal by Intelligent Algorithms," pp. ۱۶۳-۱۶۸, ۲۰۱۴.

- [۶] R. Y. Karimoi, M. A. Khalilzadeh, A. A. Hossinezhadeh, and A. Yaghoobi, "EEG signal classification using Bayes and Naïve Bayes Classifiers and extracted features of Continuous Wavelet Transform," vol. ۳, no. ۱, pp. ۱-۷, ۲۰۱۴.
- [۷] D. M. Suolin Duan, Tingting Xu, Wei Zhuang, "The Feature Extraction of ERD / ERS Signals Based on the Wavelet Package and ICA," pp. ۵۶۲۱-۵۶۲۵, ۲۰۱۴.
- [۸] and T. B. R. B. Braga, C. D. Lopes, "Round Cosine Transform Based Feature Extraction of Motor Imagery EEG Signals." ۲۰۱۸.
- [۹] Y. M. and Y. A. Muhammad Zeeshan Baig, "A BCI System Classification Technique Using Median Filtering and Wavelet Transform." ۲۰۱۵.
- [۱۰] B.-G. X. & A.-G. S. School, "Pattern recognition of motor imagery EEG using." ۲۰۰۸.
- [۱۱] <http://www.bbc.de/competition/ii/>
- [۱۲] R. Djemal, A. G. Bazyed, K. Belwafi, S. Gannouni, and W. Kaaniche, "Three-Class EEG-Based Motor Imagery Classification Using Phase-Space Reconstruction Technique," no. Mi, ۲۰۱۶.
- [۱۳] T. Uktveris and V. Jusas, "Comparison of Feature Extraction Methods for EEG BCI Classification," pp. ۸۱-۹۲, ۲۰۱۵.
- [۱۴] A. Malekmohammadi, H. Mohammadzade, A. Chamanzar, M. Shabany, and B. Ghogh, "An Efficient Hardware Implementation for a Motor Imagery Brain Computer Interface System," pp. ۱-۲۵, ۲۰۱۹.
- [۱۵] T. K. Onder AYDEMIR, "Investigation of the most appropriate mother wavelet for characterizing imaginary EEG signals used in BCI systems." ۲۰۱۶.