

انتخاب کانال برای سیگنال های EEG با استفاده از

اطلاعات متقابل جهت دسته‌بندی تصور حرکات

مهدی کامندار*، عصمت راشدی و آیین صنعتی جوان

دانشکده مهندسی برق و کامپیوتر، دانشگاه تحصیلات تکمیلی صنعتی و فناوری پیشرفته، کرمان، ایران

چکیده

سامانه‌های واسط مغز و رایانه، مبتنی بر دسته‌بندی تصور حرکات با استفاده از سیگنال‌های چندکاناله EEG، نقش عمده‌ای در کنترل اندام‌های مصنوعی و ارتباط با ماشین‌ها توسط افراد معلول دارند. مشکل اساسی این سامانه‌ها، بیش‌برازش دسته‌بند به دلیل تعداد زیاد کانال‌ها و نمونه‌های آموزشی کم و نوفه‌ای است. در این مقاله روشی برای انتخاب کانال‌های مرتبط، مبتنی بر پیشینه‌سازی اطلاعات متقابل کانال‌های منتخب و تصور حرکت مدنظر ارائه شده‌است. توان زیرباندی با پهنای دو هرتز در باند هشت تا سی هرتز و در فواصل ۲۵۰ میلی‌ثانیه‌ای در بازه نیم تا دو و نیم ثانیه پس از شروع تصور حرکت به‌عنوان ویژگی برای هر کانال استخراج شده‌است. بعد ویژگی‌های استخراج‌شده با ترکیب روش‌های L1-PCA و NWFE به ده کاهش یافت‌است. صحت کل دسته‌بند SVM برای نمونه‌های آزمایش دو شخص aa و al از داده‌های مسابقات BCI III به ترتیب ۹۴/۸۷ و ۹۶/۵۱ درصد است در حالی که تعداد کانال‌ها از ۱۱۸ به ۷ کاهش یافته‌است.

واژگان کلیدی: سامانه‌های واسط مغز و رایانه، سیگنال‌های EEG، دسته‌بندی تصور حرکات، انتخاب کانال، اطلاعات متقابل، تخمین آنترپی kpn.

Channel Selection for EEG Signals Using Mutual Information for Motor Imagery Classification

Mehdi Kamandar*, Esmat Rashedi, and Aeen Sanati Javan

Faculty of Electrical and Computer Engineering, Graduate University of advanced technology, Kerman, Iran

Abstract: Brain-computer interface systems based on classification of the motor imageries (MI) using multi-channel EEG signal play a major role in the control of artificial limbs and machines by people with disabilities. One of the main problems in classifying these signals to classify different MI tasks is the large number of channels. The large number of channels causes a lot of cost and hassle during the measurement process, increasing computational load of the preprocessing, feature extraction, and classification, difficulty of interpretation of results, and over-fitting of the classifier due to the limited number and noisy training samples. Since, not all measured channels for classifying a particular MI task have useful information, it would be beneficial to select the relevant channels for classifying desired MI tasks. Channel selection methods are categorized into wrapper, filtered, hybrid, and embedded. In this paper, a filtering method is used due to less computational cost and the independence of the classifier. The criterion is very important in filtering methods. Criteria based on first- and second-order data moments are less efficient for non-Gaussian classes. The proposed method uses mutual information between candidate channels and class label as a comprehensive criterion and sequential forward selection search strategy. One of the problems in using this criterion is the accurate estimation of mutual information in the high dimensional spaces. The kpn entropy estimator is used to accurately estimate the

* Corresponding author

* نویسنده عهده‌دار مکاتبات



mutual information in high dimensional space with limited number of training samples. The power of 2 Hz non overlapping sub-bands in the 8-30 Hz band and in 250 milliseconds non overlapping intervals in half to two and a half seconds after the onset of MI are extracted as features for each channel. The extracted features are reduced to 10 for each channel by combining the unsupervised L1-PCA and supervised NWE dimensionality reduction methods. The reported results show the ability of the proposed method to select effective channels for classifying left and right hand and feet MI tasks. The overall accuracy of the SVM classifier on test samples for two subjects labeled aa and al from the BCI III competition dataset is 94.87% and 96.51%, respectively, while the number of channels is reduced from 118 to 7 channels.

Keywords: Brain Computer Interface, EEG Signals, Motor Imagery Classification, Channel Selection, Mutual Information, kpn Entropy Estimation.

۳۰ هرتز) و تحلیل مؤلفه‌های مستقل (ICA) برای حذف تداخل‌های مربوط به حرکات ماهیچه‌ها و چشم‌ها استفاده شده‌است.

دسته‌بندی سیگنال‌های EEG جهت شناسایی تصور حرکت اندام‌های مختلف بدن در سامانه‌های BCI بسیار متداول است. چالش اصلی پیش رو، تعداد زیاد کانال‌های اندازه‌گیری شده‌است. تعداد زیاد کانال‌ها باعث پرهزینه‌بودن اندازه‌گیری و ثبت سیگنال می‌شود؛ حجم محاسبات پیش‌پردازش، استخراج ویژگی و دسته‌بندی افزایش می‌یابد؛ بعد بالای بردار ویژگی در حضور تعداد نمونه‌های آموزشی کم و نوفه‌ای، دسته‌بندی را دچار بیش‌برازش (تعمیم‌دهی ضعیف) می‌کند و درنهایت تعداد زیاد کانال‌ها تفسیر نتایج را دشوار می‌سازد. برای دسته‌بندی تصور یک حرکت خاص، تمام کانال‌های اندازه‌گیری شده فعال نبوده و در نتیجه دارای اطلاعات مفید دسته‌بندی نیستند؛ بنابراین با حذف کانال‌های غیر فعال و حفظ کانال‌های با اطلاعات مرتبط با تصور حرکات مورد نظر می‌توان این مشکلات را کاهش داد. روش‌های انتخاب کانال از منظر نحوه ارزیابی کانال‌های نامزد انتخاب به پیچشی، فیلتری، ترکیبی، جاسازی شده و مبتنی بر تجربه دسته‌بندی می‌شوند [۵]. این روش‌ها از منظر رویکرد جستجو در بین کانال‌های اندازه‌گیری شده نیز به جستجوی کامل، متوالی و تصادفی دسته‌بندی می‌شوند [۵]. در مراجع [۶] و [۷] از رویکرد پیچشی جهت انتخاب کانال استفاده شده‌است. در این روش‌ها معیار ارزیابی کانال‌ها، صحت یک دسته‌بندی از پیش انتخاب شده‌است. عیب روش‌های پیچشی، بار محاسباتی زیاد حاصل از برآورد صحت دسته‌بندی با استفاده از اعتبارسنجی متقاطع و وابستگی کانال‌های منتخب به دسته‌بندی مورد استفاده و مزیت آن‌ها صحت خوب کانال‌های منتخب است. در مرجع [۸] جستجوی بین کانال‌ها با استفاده از الگوریتم فرا ابتکاری گرانشی و معیار ارزیابی کانال‌ها صحت دسته‌بندی SVM است. در مراجع [۹-۱۱] از رویکرد

۱- مقدمه

سامانه‌های واسط مغز و رایانه (BCI)^۱ با خواندن ذهن انسان از طریق سیگنال‌های مغزی، ارتباط با دیگران، کنترل اندام‌های مصنوعی و ماشین‌ها را بدون حرکات فیزیکی برای بیماران مبتلا به اختلالات شدید حرکتی مانند اسکروز جانبی آمیوتروفیک ممکن می‌سازند [۴-۱]. پرکاربردترین سیگنال مغزی در این سامانه‌ها سیگنال‌های الکتروانسفالوگرام (EEG)^۲ به دلیل سادگی اندازه‌گیری و تفکیک‌پذیری زمانی بالا هستند. این سیگنال‌ها به‌طور معمول با استفاده از کاشت آرایه‌ای متشکل از تعدادی الکتروود روی سطح سر شخص اندازه‌گیری می‌شوند. دسته‌بندی فعالیت‌های مختلف مغز با استفاده از سیگنال‌های EEG به‌عنوان یکی از ابزارهای اساسی در سامانه‌های BCI در طول نیم‌قرن گذشته به کار گرفته شده است، اما ماهیت نوفه‌ای، غیرخطی و غیرایستاد این سیگنال‌ها این امر را با چالش‌های زیادی مواجه می‌سازد.

سیگنال‌های EEG ضبط‌شده از سطح سر ضعیف‌ترین و اغتشاش‌پذیرترین سیگنال‌های حیاتی هستند؛ چون با کوچک‌ترین تغییر در حالت بدن، دچار اعوجاج شده و به‌طور معمول با تعدادی سیگنال مزاحم در طی فرآیند اندازه‌گیری ترکیب می‌شوند. ضروری است که در پیش‌پردازش، سیگنال‌های مزاحم حذف و سیگنال به نوفه افزایش یابد تا درنهایت بتوان تفسیر درستی از این سیگنال‌ها به‌دست آورد. فیلترهای زمانی، فیلترهای فرکانسی (بالاگذر و میانگذر)، و فیلترهای مکانی (مرجع مشترک متوسط، لاپلاس و ...) و جداسازی منابع کور از جمله ابزارهای کاهش این اعوجاجات و افزایش سیگنال به نویز هستند [۴]. در اینجا از یک فیلتر میانگذر با باند عبور مرتبط با حرکت و تصور حرکت (۸ تا

¹ Brain-Computer Interface

² Electroencephalograph

توان این امواج در منطقه مربوطه حرکت تصور شده در ناحیه حسی حرکتی مغز به دلیل نا هم‌زمانی فعالیت نورون‌ها نسبت به قبل از شروع تصور حرکت کاهش می‌یابد. این کاهش برای افراد مختلف در کانال‌ها، زیرباند‌ها و فواصل زمانی گوناگونی از شروع حرکت صورت می‌گیرد. تاکنون پژوهش‌های زیادی جهت انتخاب زیرباند‌ها و فواصل زمانی مرتبط با تصور حرکات مورد نظر برای شخص صورت گرفته‌است [۱۳-۱۷]. زیرباند‌ها به‌طور معمول با پهنای یک تا ۴ هرتز با هم‌پوشانی و یا بدون هم‌پوشانی در باند ۸ تا ۳۰ هرتز و فواصل زمانی نیز ۵ تا ۱ ثانیه پس از اعلام شروع تصور حرکت به مدت ۲.۵ تا ۲ ثانیه با هم‌پوشانی یا بدون هم‌پوشانی در نظر گرفته می‌شوند. پس از استخراج این ویژگی‌ها، با استفاده از روش انتخاب ویژگی حداقل مربعات متعامد تنک به انتخاب زیرباند‌ها و فواصل زمانی با اطلاعات جداسازی بیشتر می‌پردازند. در این مقاله توان زیرباند‌های با پهنای ۲ هرتز بدون هم‌پوشانی در باند ۸ تا ۳۰ هرتز و فواصل زمانی به مدت ۲.۵ ثانیه بدون هم‌پوشانی در فاصله ۵ تا ۲.۵ ثانیه پس از شروع حرکت به عنوان ویژگی انتخاب شده‌است. ویژگی‌های استخراج‌شده تجزیه زمان - فرکانسی از سیگنال با جدایی‌پذیری خوبی بین دسته‌های مختلف را به دست می‌دهند. با توجه به تعداد بالای ویژگی‌های استخراج‌شده، در دو مرحله توسط روش‌های کاهش بُعد خطی بدون نظارت (L1-PCA)^۲ و با نظارت (NWFE)^۳ به ۱۰ ویژگی تبدیل می‌شوند. از این ۱۰ ویژگی جهت انتخاب کانال‌های مرتبط برای هر شخص و نهایتاً از کانال‌های منتخب جهت دسته‌بندی استفاده می‌شود. نتایج گزارش‌شده توانایی کانال‌های منتخب توسط روش پیشنهادی در جداسازی تصور حرکات مورد نظر را نشان می‌دهد.

در قسمت بعد، روش انتخاب کانال پیشنهادی تشریح می‌شود. در قسمت سوم، نتایج انتخاب کانال روی داده‌های مربوط به دسته‌بندی تصور حرکات دست چپ، راست و پا گزارش خواهد شد. جمع‌بندی مطالب نیز در قسمت چهارم بیان شده‌است.

۲- روش پیشنهادی انتخاب کانال با استفاده از اطلاعات متقابل

معیار دلخواه برای انتخاب کانال، خطای کمینه بیز کانال‌های نامزد انتخاب است، به گونه‌ای که خطای

² L1-Principal Component Analysis

³ Nonparametric Weighted Feature Extraction

فیلتری جهت انتخاب کانال‌های مرتبط استفاده شده‌است. معیار ارزیابی کانال‌ها در روش‌های فیلتری یک معیار مرتبط با جدایی‌پذیری دسته‌ها، تقریبی از خطای کمینه بیز و یا یک کران بالا از خطای کمینه بیز است. معیارهای مبتنی بر ممان‌های مرتبه نخست و دوم داده‌ها، چندان برای دسته‌های با توزیع غیرگوسی کارآمد نیستند؛ اگر چه دقت تخمین آن‌ها با نمونه آموزشی کم قابل قبول است، معیارهای مبتنی بر ممان‌های مرتبه بالای داده‌ها برای دسته‌های غیرگوسی نیز معتبر هستند، اما با وجود تعداد نمونه‌های آموزشی کم و کانال‌های زیاد دقت تخمین آن‌ها پایین و در نتیجه کانال‌های منتخب دچار بیش‌برازش هستند.

در این مقاله جهت انتخاب کانال‌های مرتبط از یک روش فیلتری به دلیل بار محاسباتی کمتر، مستقل بودن کانال‌های منتخب از دسته‌بند و مقیاس‌پذیری خوب استفاده شده‌است. اطلاعات متقابل کانال‌های نامزد انتخاب و تصور حرکات به‌عنوان یک معیار جامع و رویکرد جستجوی حریصانه متوالی انتخاب پیشرو استفاده شده‌است. یکی از مشکلات استفاده از معیار اطلاعات متقابل، تخمین نادقیق آن در فضاهای بُعد بالا با تعداد نمونه‌های آموزشی محدود است. جهت رفع این مشکل معیار ابتکاری بیشینه ارتباط-کمینه افزونگی (mRMR)^۱ ارائه شده است که متوسط اطلاعات متقابل بین هر کدام از ویژگی‌ها و تصور حرکات مدنظر و متوسط اطلاعات متقابل بین جفت ویژگی‌ها را به ترتیب جهت اندازه‌گیری میزان مرتبط بودن ویژگی‌ها و افزونگی موجود در ویژگی‌ها استفاده می‌کند [۱۲]. تخمین اطلاعات متقابل بین متغیرهای اسکالر با تعداد نمونه آموزشی محدود دقت بهتری خواهد داشت. مشکل معیار mRMR عدم ارتباط نزدیک با خطای بهینه بیز است.

در این مقاله از اطلاعات متقابل استفاده شده‌است که ارتباط نزدیکی با خطای کمینه بیز دارد. برای تخمین اطلاعات متقابل از تخمین ناپارامتریک آنتروپی kpn استفاده شده‌است [۲]. تخمین kpn با فرض توزیع محلی غیریک‌نواخت در همسایگی نمونه‌ها، تخمین دقیق‌تری از آنتروپی در بُعد‌های بالا به دست می‌دهد. نتایج گزارش‌شده صحت بالای کانال‌های منتخب روش پیشنهادی را نشان می‌دهد.

یکی از عوامل اصلی در کارایی روش‌های انتخاب کانال و دسته‌بندی تصور حرکات، استخراج ویژگی‌های مرتبط با این تصورات است. از پرکاربردترین ویژگی‌ها، توان امواج α/μ (۸ تا ۱۳ هرتز)، β (۱۳ تا ۳۰ هرتز) در منطقه حسی حرکتی مغز به هنگام تصور حرکت است.

¹ Maximum Relevance-Minimum Redundancy



در ویژگی‌ها کمینه می‌شود. در این معیار از اطلاعات متقابل بین متغیرهای اسکالر استفاده شده است که تخمین دقیق آن‌ها با نمونه‌های آموزشی محدود ممکن است. مشکل معیار mRMR، عدم ارتباط نزدیک با خطای بهینه بیز مانند رابطه (۱) است. در روش پیشنهادی از معیار $I(c, x)$ برای انتخاب کانال استفاده شده است. این معیار را می‌توان با استفاده از رابطه (۳) بر حسب آنتروپی نوشت:

$$I(c, x) = H(x) - H(c|x) = H(x) - \sum_{i=1}^K P_i H(x|c_i) \quad (3)$$

که $H(x)$ آنتروپی x ، $H(x|c_i)$ آنتروپی x برای دسته نام، P_i احتمال دسته نام و K تعداد دسته‌هاست. با این رابطه تخمین اطلاعات متقابل به تخمین آنتروپی تبدیل می‌شود. آنتروپی مطابق رابطه (۴) تعریف می‌شود:

$$H(x) = -E\{\log f(x)\} \quad (4)$$

که $E\{\cdot\}$ امید ریاضی و $f(x)$ توزیع x است. آنتروپی امید ریاضی $-\log f(x)$ است که تخمین گر بیشینه درست-نمایی آن به صورت رابطه (۵) است:

$$\hat{H}(x) = -\frac{1}{N} \sum_{i=1}^N \log \hat{f}(x^{(i)}) \quad (5)$$

که $x^{(i)}$ بردار ویژگی نمونه آموزشی نام و N تعداد نمونه‌های آموزشی است. مسئله‌ی تخمین آنتروپی تبدیل به تخمین $f(x^{(i)})$ ها می‌شود. برای تخمین آن‌ها از تخمین نا پارامتریک k -نزدیک‌ترین همسایه استفاده می‌شود که مطابق رابطه (۶) است.

$$P(x \in B(x^{(i)}, k)) = \int_{B(x^{(i)}, k)} f(x) dx \cong \frac{k}{N} \quad (6)$$

که $B(x^{(i)}, k)$ کوچک‌ترین ابرمکعب به مرکز $x^{(i)}$ و شامل k -نزدیک‌ترین همسایه آن است. با فرض ثابت بودن $f(x)$ در همسایگی $x^{(i)}$ خواهیم داشت:

$$\hat{f}(x^{(i)}) = \frac{k}{N(2\varepsilon(i))^d} \quad (7)$$

که d بعد x ، $\varepsilon(i)$ فاصله چپی شرف $x^{(i)}$ تا k مین نزدیک‌ترین همسایه‌اش و در نتیجه $(2\varepsilon(i))^d$ حجم ابرمکعب $B(x^{(i)}, k)$ است. با جایگزینی (۷) در رابطه (۵)، تخمین به صورت رابطه (۸) حاصل می‌شود.

$$\hat{H}(x) = \log(N) - \log(k) + d + \frac{d}{N} \sum_{i=1}^N \log(\varepsilon(i)) \quad (8)$$

کمینه بیز کانال‌های منتخب کمترین افزایش ممکن را نسبت به خطای کمینه بیز همه کانال‌ها داشته باشد. تخمین این خطا به صورت پارامتریک یا ناپارامتریک با تعداد نمونه‌های آموزشی محدود در یک فضای با بعد بالا بسیار دشوار و دچار بایاس و واریانس قابل توجه است. این دشواری محاسبه، معیارهای ساده‌تر دیگری را که ارتباط خوبی با این خطا داشته باشند، مورد توجه قرار داده است. می‌توان این معیارها را به دو دسته معیارهای مبتنی بر تحلیل ممیز (بر پایه ماتریس هاس پراکندگی) و معیارهای مرتبط با کران‌های بالای خطای کمینه بیز مانند فاصله باتاچریا دسته‌بندی کرد. این معیارها اغلب پیچیدگی کمتری دارند و اغلب بر حسب ممان‌های مرتبه اول و دوم داده‌ها هستند که برای دسته‌های با توزیع غیرگوسی معتبر نیستند. استفاده از معیارهای مبتنی بر تئوری اطلاعات جهت رفع این نقص می‌تواند کارآمد باشد [۳]. معیار اطلاعات متقابل ویژگی‌های استخراج شده از کانال‌های نامزد انتخاب و برچسب دسته‌ها (c) ارتباط خوبی به صورت یک کران بالای محکم با خطای کمینه بیز دارد. این ارتباط در رابطه (۱) آورده شده است [۱۲]:

$$P_e^B(x) \leq \frac{1}{2} ((H(c) - I(c, x))) \quad (1)$$

که $P_e^B(x)$ خطای کمینه بیز، $H(c)$ آنتروپی c و $I(c, x)$ اطلاعات متقابل بین c و x است. رابطه بالا نشان می‌دهد یک کران بالا برای خطای کمینه بیز بر حسب اطلاعات متقابل وجود دارد که با بیشینه‌کردن اطلاعات متقابل کمینه می‌شود؛ بنابراین می‌توان انتظار داشت خطای کمینه بیز برای کانال‌های منتخب کمتر و یا دست کم کران بالای آن کوچک‌تر باشد.

برای تخمین $I(c, x)$ نیاز به تخمین توزیع دسته‌ها در یک فضای بعد بالا است که با تعداد نمونه‌های آموزشی محدود بسیار دشوار است و بیش‌تر کانال‌های منتخب صحت خوبی ندارند. برای حل این مشکل از معیار ابتکاری mRMR (رابطه (۲)) استفاده شده است [۱۲]:

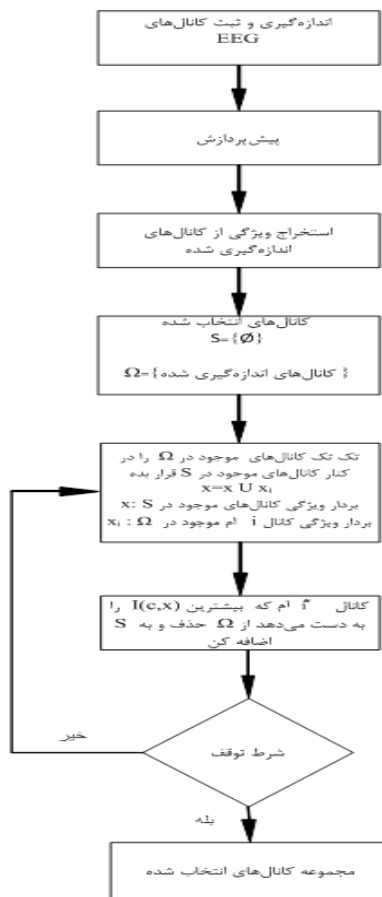
$$\frac{1}{d} \sum_{i=1}^d I(x_i, c) - \frac{2}{d(d-1)} \sum_{i=1}^{d-1} \sum_{j=i+1}^d I(x_i, x_j) \quad (2)$$

که x_i ویژگی نام و d تعداد ویژگی‌های استخراج شده از کانال‌های نامزد انتخاب است. در رابطه (۲)، عبارت اول متوسط میزان ارتباط ویژگی‌ها با تصور حرکات مدنظر و عبارت دوم متوسط افزونگی موجود در جفت ویژگی‌ها را اندازه‌گیری می‌نماید. با بیشینه سازی عبارت بالا ارتباط ویژگی‌ها با تصور حرکت مدنظر بیشینه و افزونگی موجود

در شکل (۱)، نمودار جعبه‌ای مراحل روش پیشنهادی انتخاب کانال با استفاده از اطلاعات متقابل و جستجوی متوالی انتخاب پیشرو آورده شده است. شرط توقف در روش‌های فیلتری به‌طور معمول رسیدن به تعداد مشخصی کانال و یا رسیدن به صحت مشخصی برای دسته‌بند است.

۳- پیش‌پردازش

همان‌گونه که در شکل (۲) مشاهده می‌شود سیگنال‌های خام EEG پس از اندازه‌گیری و ثبت، نیاز به پیش‌پردازش جهت حذف تداخل‌های احتمالی و اعوجاجات ناشی از اندازه‌گیری دارند. تداخل‌ها اغلب ناشی از حرکات چشم^۱ (EOG)، پلک‌زدن، حرکات ماهیچه^۲ (EMG)، ضربان قلب^۳ (ECG)، حرکات صورت و برق شهر هستند.



(شکل ۱): نمودار جعبه‌ای انتخاب کانال با استفاده از روش پیشنهادی مبتنی بر اطلاعات متقابل.

(Figure 1): Block diagram of proposed channel selection method based on mutual information.

مرحله پیش‌پردازش جهت داشتن سیگنال EEG با SNR بالا جهت تفاسیر بعدی از اهمیت خاصی برخوردار است، در نتیجه با اعمال فیلترهای زمانی، فرکانسی و مکانی و

¹ Electrooculogram
² Electromyogram
³ Electrocardiogram

عیب اصلی تخمین‌گر بالا فرض یک‌نواخت بودن توزیع در این فرض در فضاهای با بُعد بالا با تعداد نمونه‌های آموزشی کم به‌ویژه هنگام وجود متغیرهای به‌شدت همبسته و یا واریانس‌های به‌شدت متفاوت دور از واقعیت است و باعث بایاس زیاد تخمین می‌شود. راه حل این مشکل، استفاده از توزیع غیریک‌نواخت برای توزیع محلی نمونه‌ها در $B(x^{(i)}, k)$ است [۲۱]. در این روش ابتدا توزیع p نمونه همسایه نزدیک‌تر $x^{(i)}$ با یک توزیع غیریک‌نواخت مانند گوسی تخمین زده شده، سپس توزیع به‌دست‌آمده به‌گونه‌ای مقیاس‌بندی می‌شود که مقدار توزیع کل نمونه‌ها و توزیع محلی با یکدیگر در $x^{(i)}$ برابر باشند؛ بنابراین توزیع محلی در $B(x^{(i)}, k)$ به‌صورت زیر محاسبه می‌شود:

$$f_x(x) = f_x(x^{(i)}) \frac{g(x)}{g(x^{(i)})}, \quad x \in B(x^{(i)}, k) \quad (9)$$

$g(x) = e^{-\frac{1}{2}(x-\mu)^t \Sigma^{-1}(x-\mu)}$ (۱۰)
که Σ و μ به ترتیب بردار میانگین و ماتریس کوواریانس p همسایه نزدیک‌تر $x^{(i)}$ است. می‌توان گفت تخمین‌گر (۸) با فرض $g(x)$ ثابت به‌دست آمده است. با جایگذاری (۱۰) در رابطه (۹) خواهیم داشت:


$$\hat{f}(x^i) = \frac{k \times g(x^i)}{NG_i}, \quad G_i = \int_{B(x^i, k)} g(x) dx \quad (11)$$

با جایگذاری (۱۱) در رابطه (۵) رابطه تخمین‌گر به‌صورت رابطه (۱۲) نوشته می‌شود:

$$\hat{H}(x) = \log(N) - \log(k) - \frac{1}{N} \sum_{i=1}^N \log(g(x^{(i)})) + \frac{1}{N} \sum_{i=1}^N \log(G_i) \quad (12)$$

در رابطه (۱۲) مقدار انتگرال توزیع گوسی روی ابرمکعب شامل k -نزدیک‌ترین همسایه نمونه \hat{a}_m است. در روابط بالا p حداقل ۳ تا ۴ برابر ابعاد فضا انتخاب می‌شود. در آزمایش‌های انجام شده k های ۳، ۴ و ۵ در اغلب موارد بهترین نتایج را ارائه می‌دهند. بدون شک تخمین‌گر (۱۲) در فضاهای بُعد بالا با متغیرهای همبسته یا واریانس‌های متفاوت، دقت بیشتری نسبت به تخمین‌گر (۸) دارد. تخمین $H(x|c_i)$ نیز با استفاده از رابطه (۱۲) و فقط با استفاده از نمونه‌های آموزشی دسته \hat{a}_m صورت می‌گیرد. حال با استفاده از آنتروپی‌های تخمین زده شده $I(c, x)$ از رابطه (۳) تخمین زده می‌شود. مقدار $I(c, x)$ تخمین زده شده به‌عنوان شایستگی کانال‌های نامزد انتخاب در نظر گرفته می‌شود.

روش‌های جداسازی منابع کور به این مهم پرداخته می‌شود. در روش پیشنهادی، ابتدا از یک فیلتر میانگذر با باند عبور ۸ تا ۳۰ هرتز برای حذف نوفه‌های خارج از باند سیگنال EEG مرتبط با تصور حرکت استفاده شده است. سپس با استفاده از جعبه ابزار (AAR) ^۱ تداخل‌های EOG و EMG با استفاده از روش ICA حذف شده است [۲۲]. در شکل (۲) بخشی از یک سیگنال EEG و پیش پردازش آن با استفاده از روش ذکر شده، نمایش داده شده است.



(شکل - ۲): بخشی از سیگنال EEG کانال C3 مربوط به شخص با برچسب G از مجموعه داده 1 - BCI IV و بهبود یافته آن با استفاده از یک فیلتر میانگذر ۸ تا ۳۰ هرتز و ICA.
(Figure 2): A segment of channel C3 of subject G and it's enhanced by band pass filtering and ICA.

۴- استخراج ویژگی

پس از پیش‌پردازش، نوبت به استخراج ویژگی‌های مرتبط با تصور حرکات مورد نظر می‌رسد. بیش‌تر اطلاعات مفید در مورد وضعیت عملکرد مغز انسان در پنج موج مغزی بزرگ تشخیص داده شده است. هر کدام از این امواج باند فرکانسی خاص خود را دارند و از یکی از حالات فعالیت مغز حاصل می‌شوند. این امواج با نام‌های δ (۰/۵ تا ۴ هرتز)، θ (۴ تا ۸ هرتز)، α/μ (۸ تا ۱۳ هرتز)، β (۱۳ تا ۳۰ هرتز) و γ (بیشتر از ۳۰ هرتز) شناخته می‌شوند. امواج α/μ و β اطلاعات خوبی برای دسته‌بندی حرکات واقعی یا تصور حرکات دارند. توان این امواج در فاصله زمانی کوتاهی پس از شروع تصور حرکت در منطقه مرتبط با تصور حرکت انجام‌شده در ناحیه حسی حرکتی مغز کاهش می‌یابد که این پدیده به دلیل ناهم‌زمانی فعالیت نورون‌های منطقه مرتبط با تصور حرکت انجام‌شده است. این پدیده ناهم‌زمانی وابسته به رخداد (ERD) ^۲ نامیده می‌شود [۴]. در این مقاله توان زیرباندهای با پهنای ۲ هرتز بدون هم‌پوشانی در باند ۸ تا ۳۰ هرتز و فواصل زمانی به مدت ۲۵ ثانیه بدون هم‌پوشانی در فاصله ۵ تا

۲۵ ثانیه پس از شروع حرکت به‌عنوان ویژگی انتخاب شده است (۸۸ ویژگی برای هر کانال).
با توجه به وجود افزونگی‌های احتمالی موجود در ویژگی‌های استخراج‌شده و نامرتب‌بودن تعداد زیادی از این ویژگی‌ها، کاهش بُعد این ویژگی‌ها به دلیل محدود بودن و نویزی بودن نمونه‌های آموزشی در دسترس جهت انتخاب کانال و دسته‌بندی ضروری است. بُعد ویژگی‌های استخراج‌شده، در دو مرحله توسط روش استخراج ویژگی بدون نظارت تحلیل مولفه‌های اصلی-نرم ۱ (L1-PCA) از ۸۸ به ۴۰ و سپس توسط روش با نظارت استخراج ویژگی ناپارامتریک وزندار (NWFE) از ۴۰ به ۱۰ ویژگی کاهش می‌یابد. در روش کاهش ویژگی پیشنهادی (L1-PCA + NWFE) ابتدا توسط L1-PCA زیرفضای داده‌ها از نویز جدا شده و بُعد ویژگی‌ها از ۸۸ به ۴۰ کاهش می‌یابد، این کاهش بُعد باعث کاهش مشکلات اعمال روش با نظارت NWFE از جمله تکنیکی ماتریس پراکندگی درون دسته‌ای، حجم محاسباتی بالا و بیش‌برازش می‌شود. ۴۰ ویژگی استخراج‌شده توسط L1-PCA، ۹۰ درصد واریانس ویژگی‌های اولیه را حفظ می‌کند. روش L1-PCA نسبت به PCA معمول به دلیل استفاده از معیار میانگین قدر مطلق خطا به جای میانگین مربع خطا، مقاومت بیشتری نسبت به نمونه‌های پرت و نوفه‌ای موجود در داده‌ها دارد که وجود آن‌ها در داده‌های EEG بسیار محتمل است. روش استخراج ویژگی با نظارت NWFE با تعریف ماتریس‌های پراکندگی درون دسته‌ای و بین دسته‌ای ناپارامتریک برای دسته‌های با توزیع ناگوسی به‌خصوص چندمنده هم عملکرد بسیار خوبی دارد. در این روش همچنین با وزن دادن به نمونه‌ها، نقش نمونه‌های نزدیک مرزهای تصمیم‌گیری در محاسبه ماتریس‌های پراکندگی افزایش می‌یابد که باعث حفظ اطلاعات مرتبط با دسته‌بندی در حین کاهش بُعد می‌شود. روش NWFE با مشخصات بیان‌شده، مشکلات روش استخراج ویژگی با نظارت تحلیل ممیز خطی (LDA) را برطرف می‌سازد [۲۳]. نمونه‌های پرت تأثیر زیادی روی عملکرد NWFE و در نهایت دسته‌بند خواهند داشت. با استفاده از نسخه تک‌دسته‌ای SVM (DDSV)، ۵ درصد از نمونه‌های پرت موجود در ۴۰ مؤلفه اصلی هر دسته شناسایی و حذف می‌شود. پس از کاهش بُعد ویژگی‌ها بوسیله L1-PCA و حذف نمونه‌های پرت دسته‌ها، توسط NWFE زیرفضایی با بُعد ۱۰ که نمونه‌های دو دسته بیشترین تفکیک‌پذیری را دارند استخراج می‌شود. در شکل (۳) پراکندگی

¹ Automated Artifact Removal

² Event Related Desynchronization

با توجه به تعداد نمونه‌های آموزشی موجود برای هر شخص در داده‌های استفاده شده، تعداد ۱۰ ویژگی برای هر کانال برای جلوگیری از بیش برآزش مناسب است. بردار ویژگی نهایی از کنار هم قرار گرفتن ۱۰ ویژگی مربوط به کانال‌های مورد نظر تشکیل و به روش انتخاب کانال پیشنهادی و نهایتاً دسته‌بند اعمال می‌شود.


۵- شبیه‌سازی و نتایج

در این مقاله جهت ارزیابی روش انتخاب کانال پیشنهادی از دو مجموعه داده استاندارد استفاده شده است. مجموعه داده اول از ۴ شخص سالم (A, B, F, G) و سه داده ساختگی (C, D, E) در چهارمین مسابقات بین‌المللی BCI (BCI IV – Data set 1) گرفته شده است. این داده‌ها شامل ۵۹ کانال طبق استاندارد ۲۰-۱۰ بوده و فرکانس نمونه‌برداری هزار هرتز است که پس از اعمال فیلتر پایین‌گذر با فرکانس قطع ۴۹ هرتز و میانگین‌گیری ۱۰ نمونه‌ای به ۱۰۰ هرتز کاهش یافته است. هر یک از اشخاص دو مورد از سه تصور حرکتی (تصور حرکات دست چپ، دست راست، پا) را انتخاب و در هر آزمایش یکی از آنها را طبق علامت نشان داده شده روی نمایشگر روبرویش به مدت چهار ثانیه انجام می‌دهد. شخص در بین هر دو آزمایش به مدت چهار ثانیه استراحت می‌کند. اشخاص A و F تصور حرکات دست چپ و پا و بقیه اشخاص تصور حرکات دست چپ و راست را انجام می‌دهند. هرکدام از اشخاص در مجموع ۲۰۰ آزمایش (۱۰۰ برای هر تصور) انجام می‌دهد که به عنوان نمونه‌های آموزشی استفاده می‌شوند. تعدادی آزمایش هم برای هر شخص به عنوان نمونه‌های ارزیابی فراهم شده است که به عنوان نمونه‌های آموزشی برای هر شخص در نظر گرفته شده است. موقعیت ۵۹ کانال در سطح سر طبق شکل (۴) است.

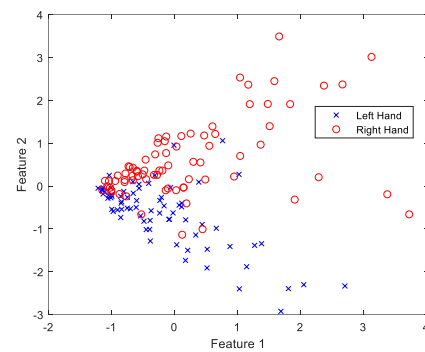
مجموعه داده دوم، مربوط به سومین مسابقات بین‌المللی BCI^۱ است. این داده دارای ۱۱۸ کانال طبق استاندارد بین‌المللی ۲۰-۱۰ برای انجام تصور حرکات دست راست، چپ و پای راست است که در دانشگاه پزشکی برلین از پنج شخص سالم (aa, al, av, aw, ay) ضبط شده است. فرکانس نمونه‌برداری صد هرتز است. هر یک از اشخاص دو مورد از سه تصور حرکتی (تصور حرکت دست چپ، تصور حرکت دست راست یا پای راست) را انتخاب می‌کند.

^۱ BCI III – Data set IVa


نمونه‌ها برای دو ویژگی برتر استخراج شده از کانال C3 با روش های L1-PCA و L1-PCA+NWFE برای داده‌های مربوط به دسته‌های تصور حرکات دست چپ و راست شخص E از مجموعه داده‌های مسابقات BCI IV نمایش داده شده است. همان‌گونه که مشاهده می‌شود روش L1-PCA+NWFE توانسته است ویژگی‌هایی با تفکیک‌پذیری بسیار بالاتری نسبت به L1-PCA تولید کند. نقشه پراکندگی نمونه‌های آزمایشی نیز نشان می‌دهد روش L1-PCA+NWFE برخلاف بعد بالای داده‌ها صحت بسیار خوبی دارد.



(الف)



(ب)



(ج)

(شکل ۳): نقشه پراکندگی دو ویژگی استخراج شده توسط روش های الف) L1-PCA، ب) L1-PCA+NWFE برای نمونه های آموزشی ج) L1-PCA+NWFE برای نمونه های آزمایشی شخص E.

(Figure 3): Scatter plot of two extracted features by a) L1-PCA, b) L1-PCA+NWFE for training Samples and c) L1-PCA + NWFE for testing samples of subject E.

متقابل بردار ویژگی کانال‌های منتخب و تصور حرکات مدنظر به عنوان معیار انتخاب کانال استفاده شد. جهت تخمین دقیق اطلاعات متقابل در فضاهای بعد بالا از روش تخمین آنتروپی kpn استفاده شد که پایداری آن در فضاهای بعد بالا اثبات شده است. روش kpn از توزیع محلی غیریک‌نواخت نمونه‌ها برای تخمین توزیع استفاده می‌کند که در این پژوهش از توزیع گوسی استفاده شد. در این پژوهش از روش حریصانه جستجوی متوالی انتخاب پیشرو به دلیل بار محاسباتی کمتر استفاده شد. روش انتخاب کانال پیشنهادی توانست با حذف تعداد زیادی کانال نامرتب با تصور حرکات مورد نظر، صحت بالایی نیز ارائه دهد.

6-Refrence

۶- مراجع

- [1] Ortiz-Rosario A, Adeli H, Brain-computer interface technologies: from signal to action. Rev Neurosci, vol. 24, no. 5, pp. 537-552, 2013.
- [2] A. Bashashati, M. Fatourehchi, R. K. Ward, and G. E. Birch, A survey of signal processing algorithms in brain-computer interfaces based on electrical brain signals, J. Neural Eng., vol. 4, no. 2, pp. R32-R57, Jun.2007.
- [3] Hudspeth, A.J., Jessell, T.M., Kandel, E.R., Schwartz, J.H. and Siegelbaum, S.A. eds., 2013. Principles of neural science, McGraw-Hill, Health Professions Division.
- [4] Wolpaw JR, Birbaumer N, Heetderks WJ, McFarland DJ, Peckham PH, Schalk G, Donchin E, Quatrano LA, Robinson CJ, Vaughan TM, Brain-computer interface technology: a review of the first international meeting, IEEE Trans Rehabil Eng, vol. 8, no. 2, pp. 164-173, 2000.
- [5] Alotaiby, T., El-Samie, F.E.A., Alshebeili, S.A. et al. A review of channel selection algorithms for EEG signal processing, EURASIP J. Adv. Signal Process. 2015.
- [6] Yang, Yuan, Olexiy Kyrgyzov, Joe Wiart, and Isabelle Bloch. Subject-specific channel selection for classification of motor imagery electroencephalographic data, In 2013 IEEE International Conference on Acoustics, Speech and Signal Processing, pp. 1277-1280. IEEE, 2013.
- [7] Wei Qingguo, and Yanmei Wang. Binary multi-objective particle swarm optimization for channel selection in motor imagery based brain-computer interfaces, In 2011 4th International conference on biomedical engineering and informatics (BMEI), vol. 2, pp. 667-670. IEEE, 2011.
- [8] A. Ghaemi, E. Rashedi, A. M. Pourrahimi, M. Kamandar, and F. Rahdari. Automatic channel selection in EEG signals for classification of left or right hand movement in Brain Computer Interfaces using improved binary gravitation search algorithm, Biomedical Signal Processing and Control 33, pp. 109-118, 2017.
- [9] Shan, Haijun, Han Yuan, Shanan Zhu, and Bin He. EEG-based motor imagery classification accuracy improves with gradually increased channel number, In 2012 Annual International Conference

سپس تعدادی کانال با رتبه بالاتر برای هر تصور انتخاب می‌شوند. ویژگی‌های استخراج شده توسط CSP از کانال‌های منتخب توسط دسته‌بند SVM دسته‌بندی می‌شوند. این روش CSP- L_1 نام‌گذاری شده است. در مرجع [۲۲] از روش CSP جهت انتخاب کانال مبتنی بر نرم L_1 و مقدار γ^2 استفاده، سپس CSP جهت استخراج ویژگی از کانال‌های منتخب استفاده شده است. همچنین یانگ و همکارانش یک روش انتخاب کانال فیلتری بر اساس رتبه‌بندی کانال‌ها بر اساس معیار فیشر ویژگی‌های حوزه زمان (TDP) استخراج شده در باند ۸ تا ۳۰ هرتز و در فواصل زمانی کوتاه ارائه داده‌اند. این روش، یک روش انتخاب کانال فیلتری است که جهت دسته‌بندی تصور حرکات دست راست و پای راست استفاده شده است [۶]. در جدول (۶) مقایسه‌ی روش پیشنهادی و روش‌های مطرح شده در مراجع [۱۸]، [۲۲] و [۶] ارائه شده است.

همان‌گونه که جدول (۶) نشان می‌دهد، روش پیشنهادی توانسته صحت کل دسته‌بندی بیشتری نسبت به روش‌های یادشده برای شخص aa و نزدیکی برای شخص al به دست آورد. با بررسی نتایج به دست آمده، این مهم حاصل می‌شود که زیرمجموعه کوچکی از کانال‌های سیگنال EEG (بین ۱۰ تا ۳۰ درصد از کانال‌های موجود)، اطلاعات مرتبط با دسته‌بندی تصور حرکات را در بر می‌گیرند. انتخاب این کانال‌ها می‌تواند زحمت، هزینه و صحت سامانه BCI مورد نظر را به طرز قابل توجهی بهبود دهد.

(جدول ۶-): مقایسه‌ی روش پیشنهادی و روش‌های مطرح شده در مراجع [۲۱]، [۲۲] و [۶].

(Table 6): Comparison of the proposed method and [6], [21], and [22].

شخص	روش پیشنهادی		-norm L_1 [۲۲]]۲۱-CSP[L_1]۶TDP[
	تعداد کانال	صحت کل	تعداد کانال	صحت کل	تعداد کانال	صحت کل	تعداد کانال	صحت کل
aa	۷	۹۴/۸۷	۷	۸۲/۴۰	۷	۹۲/۳۴	۸	۶۷
al	۷	۹۶/۵۱	۸	۹۸/۶۰	۸	۹۴/۳۶	۶	۸۸

۵- جمع بندی

در این مقاله روشی برای انتخاب کانال با استفاده از اطلاعات متقابل در سیگنال‌های EEG جهت دسته‌بندی تصور حرکات مختلف پیشنهاد شد. پیشنهادی‌سازی اطلاعات

مشهد و دکترای خود را در مهندسی مخابرات سامانه از دانشگاه تربیت مدرس دریافت کرده‌اند. ایشان هم‌اکنون استادیار دانشگاه تحصیلات تکمیلی صنعتی و فناوری پیشرفته کرمان هستند. زمینه‌های پژوهشی وی پردازش سیگنال دیجیتال و بازشناسی آماری الگو است.

نشانی رایانامه ایشان عبارت است از:
Email: m.kamandar@kgut.ac.ir



عصمت راشدی مقاطع تحصیلی خود را در رشته مهندسی برق مخابرات سامانه در دانشگاه شهید باهنر کرمان گذرانده‌اند. ایشان هم‌اکنون دانشیار دانشگاه تحصیلات تکمیلی صنعتی و فناوری پیشرفته کرمان هستند. زمینه‌های پژوهشی وی بازشناسی الگو - بهینه‌سازی است. نشانی رایانامه ایشان عبارت است از:

Email: e.rashedi@kgut.ac.ir



آیین صنعتی جوان کارشناسی خود را در رشته مهندسی برق مخابرات از دانشگاه شهید باهنر کرمان و کارشناسی ارشد خود را در رشته مهندسی مخابرات سامانه از دانشگاه تحصیلات تکمیلی صنعتی و فناوری پیشرفته کرمان دریافت کرده‌اند. زمینه‌های پژوهشی وی پردازش سیگنال دیجیتال و بازشناسی آماری الگو است. نشانی رایانامه ایشان عبارت است از:

Email: sanati javan.aeen@yahoo.com

of the IEEE Engineering in Medicine and Biology Society, pp. 1695-1698. IEEE, 2012.

- [10] He, Lin, Youpan Hu, Yuanqing Li, and Daoli Li. Channel selection by Rayleigh coefficient maximization based genetic algorithm for classifying single-trial motor imagery EEG, *Neurocomputing*, pp. 423-433, 2013
- [11] Muhammad Zeeshan Baig, Nauman Aslam, Hubert P. H. Shum. Filtering techniques for channel selection in motor imagery EEG applications: a survey, *Arti Intel Rev*, vol. 53, pp.1207-1232, 2020.
- [12] LemmS, BlankertzB, CurioG, MullerK-R. Spatio-spectral filters for improving the classification of single trial EEG, *IEEE Trans Biomed Eng*, vol. 52, pp. 1541-1548, 2005.
- [13] AngKK, ChinZY, ZhangH, GuanC. Filter bank common spatial pattern (FBCSP) in brain-computer interface, In: *IEEE world congress on computational intel-ligence. IEEE international joint conference on neural networks*. IEEE, pp. 2390-7, 2008.
- [14] ZhangY, ZhouG, JinJ, WangX, CichockiA. Optimizing spatial patterns with sparse filter bands for motor-imagery based brain-computer interface, *J Neu-roscei Methods*, pp. 85-91, 2015.
- [15] ZhangY, NamCS, ZhouG, JinJ, WangX, CichockiA. Temporally constrained sparse group spatial patterns for motor imagery BCI, *IEEE Trans Cybern*, 48, pp. 3322-32, 2018.
- [16] FarquharJ, HillJ, LalTN, SchölkopfB. Regularised CSP for sensor selection in BCI, In: *Proceedings of the 3rd international brain-computer interface work-shop and training course*; 2006.
- [17] WuW, ChenZ, GaoX, LiY, BrownEN, GaoS. Probabilistic common spatial patterns for multichannel EEG analysis, *IEEE Trans Pattern Anal Mach Intell*, 37, pp. 639-53, 2015.
- [18] Gómez-Herrero G. Automatic artifact removal (AAR) toolbox v1. 3 (Release 09.12. 2007) for MATLAB, Tampere University of Technology, 2007. [cited 2017 Aug 1]. Available from: <http://germangh.github.io/pubs/aardoc07.pdf>.
- [19] Bor-Chen Kuo and D. A. Landgrebe, Nonparametric weighted feature extraction for classification, in *IEEE Transactions on Geoscience and Remote Sensing*, vol. 42, no. 5, pp. 1096-1105, May 2004, doi: 10.1109/TGRS.2004.825578.
- [20] Li, Mingai, Jianyong Ma, and Songmin Jia. Optimal combination of channels selection based on common spatial pattern algorithm, In *2011 IEEE International Conference on Mechatronics and Automation*, pp. 295-300. IEEE, 2011.
- [21] J. Meng, G. Liu, G. Huang and X. Zhu, Automated selecting subset of channels based on CSP in motor imagery brain-computer interface system, *2009 IEEE International Conference on Robotics and Biomimetics (ROBIO)*, Guilin, 2009, pp. 2290-2294, doi: 10.1109/ROBIO.2009.5420462.



مهدی کاماندار مدرک کارشناسی خود را در مهندسی برق الکترونیک از دانشگاه شهید باهنر کرمان، کارشناسی ارشد در مهندسی مخابرات سامانه از دانشگاه فردوسی

