

بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ



دانشکده : کامپیوتر و فناوری اطلاعات
گروه : هوش مصنوعی

شناسایی حرکات ارادی انسان با استفاده از سیگنال‌های EEG

معصومه اسمعیلی

استاد راهنما :

دکتر مرتضی زاهدی

استاد مشاور:

دکتر علیرضا احمدی فرد

پایان نامه جهت اخذ درجه کارشناسی ارشد

بهمن ۹۱

دانشگاه صنعتی شاهرود

دانشکده : کامپیوتر و فناوری اطلاعات

گروه : هوش مصنوعی

پایان نامه کارشناسی ارشد خانم معصومه اسمعیلی

تحت عنوان:

شناسایی حرکات ارادی انسان با استفاده از سیگنال های EEG

در تاریخ
توسط کمیته تخصصی زیر جهت اخذ مدرک کارشناسی ارشد
مورد پذیرش قرار گرفت.
ارزیابی و با درجه

امضاء	اساتید مشاور	امضاء	اساتید راهنما
	دکتر علیرضا احمدی فرد		دکتر مرتضی زاهدی

امضاء	نماینده تحصیلات تکمیلی	امضاء	اساتید داور
	نام و نام خانوادگی :		نام و نام خانوادگی :
			نام و نام خانوادگی :
			نام و نام خانوادگی :

این پایان نامه را با نهایت سپاس پیشکش می‌کنم به

آستان قدس امام هشتم امام رضا (ع) که

همواره از برکات وجود ایشان بهره‌مند بوده‌ام،

و تقدیم می‌کنم به

پدر عزیزم،

که همواره از ابتدای راه زندگی با راهنمایی‌ها و پشتیبانی‌های خود مسیر پیشرفت و

خوشبختی را برایم هموار کرده است

و به مادر مهربانم،

دریای بی‌کران فداکاری و عشق که دعای خالصانه‌اش بدرقه راه و وجودش دلگرمی

من است ...

تشکر و قدردانی

حال که به لطف و رحمت لایتناهی حضرت حق مراحل این پایان نامه رو به اتمام نهاده بر خود لازم می‌دانم تا از همه کسانی که در پیشبرد اهداف این پایان نامه من را یاری نمودند سپاس و قدردانی به عمل آورم.

ابتدا از زحمات و پشتیبانی بی دریغ و بی شائبه استاد ارجمندم جناب آقای دکتر زاهدی که راهنمایی این تحقیق را بر عهده داشتند کمال تشکر را دارم. بی شک بدون حمایت و راهنمایی ایشان انجام این پایان نامه مقدور نبود. همچنین از جناب آقای دکتر احمدی فرد که مشاوره این تحقیق را بر عهده داشتند تشکر و قدردانی می‌کنم.

در پایان از اساتید گرانقدر جناب آقای دکتر پویان و جناب آقای دکتر حسن پور که افتخار شاگردی ایشان را در دوره کارشناسی ارشد داشته‌ام قدردانی کرده و از خداوند متعال برای این دو بزرگوار موفقیت و بهروزی مسألت دارم.

تعهد نامه

اینجانب **معصومه اسمعیلی** دانشجوی دوره کارشناسی ارشد رشته **هوش مصنوعی** دانشکده کامپیوتر و فناوری اطلاعات دانشگاه صنعتی شاهرود نویسنده پایان نامه **شناسایی حرکات ارادی انسان با استفاده از سیگنال EEG** تحت راهنمایی **دکتر مرتضی زاهدی** متعهد می شوم .

- تحقیقات در این پایان نامه توسط اینجانب انجام شده است و از صحت و اصالت برخوردار است .
- در استفاده از نتایج پژوهشهای محققان دیگر به مرجع مورد استفاده استناد شده است .
- مطالب مندرج در پایان نامه تاکنون توسط خود یا فرد دیگری برای دریافت هیچ نوع مدرک یا امتیازی در هیچ جا ارائه نشده است .
- کلیه حقوق معنوی این اثر متعلق به دانشگاه صنعتی شاهرود می باشد و مقالات مستخرج با نام « دانشگاه صنعتی شاهرود » و یا « Shahrood University of Technology » به چاپ خواهد رسید .
- حقوق معنوی تمام افرادی که در به دست آمدن نتایج اصلی پایان نامه تأثیرگذار بوده اند در مقالات مستخرج از پایان نامه رعایت می گردد.
- در کلیه مراحل انجام این پایان نامه ، در مواردی که از موجود زنده (یا بافتهای آنها) استفاده شده است ضوابط و اصول اخلاقی رعایت شده است .
- در کلیه مراحل انجام این پایان نامه، در مواردی که به حوزه اطلاعات شخصی افراد دسترسی یافته یا استفاده شده است اصل رازداری ، ضوابط و اصول اخلاق انسانی رعایت شده است .

تاریخ

امضای دانشجو

مالکیت نتایج و حق نشر

- کلیه حقوق معنوی این اثر و محصولات آن (مقالات مستخرج ، کتاب ، برنامه های رایانه ای ، نرم افزار ها و تجهیزات ساخته شده است) متعلق به دانشگاه صنعتی شاهرود می باشد . این مطلب باید به نحو مقتضی در تولیدات علمی مربوطه ذکر شود .
- استفاده از اطلاعات و نتایج موجود در پایان نامه بدون ذکر مرجع مجاز نمی باشد.

چکیده

در این مطالعه کاربردی، کلاسه‌بندی پنج تصور ذهنی اندازه‌گیری شده توسط EEG بررسی و پیاده‌سازی خواهد شد. سیگنال‌های EEG در حوزه زمان دارای حجم بالائی هستند، و از این گذشته ممکن است این سیگنال‌ها حاوی مصنوعات باشند که از منابعی غیر از مغز ثبت شده باشند، از قبیل پلک‌زدن و یا حرکت چشم. بنابراین کاهش اطلاعات زائد و استخراج مفیدترین اطلاعات ضروری به نظر می‌رسد. در روش پیشنهادی از روش‌های کاهش ابعاد، یعنی تحلیل مؤلفه‌های اصلی^۱ (PCA) و الگوهای فضائی مشترک^۲ (CSP) برای حذف اطلاعات زائد استفاده می‌شود. اما باز هم قسمت‌هایی از سیگنال شامل مصنوعات است که با این روش‌ها قابل حذف نیستند. برای همین ابتدا سیگنال‌ها را پنجره کرده و سپس بر روی هر پنجره به صورت مجزا روش‌های استخراج ویژگی PCA یا CSP را اعمال می‌کنیم. سپس ویژگی‌های استخراج‌شده از پنجره‌های آلوده را از بردار ویژگی نهائی حذف می‌کنیم. اما به دلیل اینکه مصنوعات در مؤلفه‌های زمانی سیگنال واضح نیستند، نمی‌توان به صورت دقیق پنجره‌های آلوده را تشخیص داد. بنابراین می‌توان با استفاده از الگوریتم‌های بهینه‌سازی جستجو از قبیل الگوریتم ژنتیک^۳ (GA) و الگوریتم بهینه‌سازی ذرات^۴ (PSO)، و همچنین روش انتخاب ویژگی رو به جلو^۵، راه‌حل‌های حاوی بهترین پنجره‌ها را جستجو کرد. اما مسئله‌ای که وجود دارد این است که پنجره‌هایی که حذف می‌شوند، ممکن است شامل ویژگی‌های مفید نیز باشند. زیرا در پنجره‌بندی با ابعاد ثابت، مرز مصنوعات به صورت دقیق مشخص نمی‌شود. راه حل این است که این الگوریتم را در چند مرحله بر روی پنجره‌های با ابعاد متفاوت آزمایش کنیم و در نهایت بهترین ابعاد را انتخاب کنیم. الگوریتم پیشنهادی را بر روی یک مجموعه داده حاوی پنج کار ذهنی ثبت شده در دانشگاه کلرادو،

¹ Principle Component Analysis

² Common Spatial Pattern

³ Genetic Algorithm

⁴ Particle Swarm Optimization

⁵ Feed Forward Feature Selection

اعمال کردیم. با به کار بردن روش پیشنهادی بر روی سیگنال‌های حاوی ۵۰ پنجره، با تقسیم ۷۰ به ۳۰ برای مرحله آموزش و تست، توانستیم به نرخ موفقیت ۱۰۰ درصد دست پیدا کنیم.

کلمات کلیدی: سیگنال EEG، رابط مغز کامپیوتر (BCI)، پنجره، حذف مصنوعات، تحلیل مؤلفه‌های اصلی (PCA)، الگوهای فضائی مشترک (CSP)، الگوریتم ژنتیک (GA)، الگوریتم بهینه‌سازی ذرات (PSO)، انتخاب ویژگی رو به جلو، منطق فازی

مقالات مستخرج از پایان نامه

۱. معصومه اسمعیلی، مرتضی زاهدی، "دسته بندی کارهای ذهنی با به کارگیری مؤلفه‌های زمانی سیگنال‌های EEG توسط الگوریتم ژنتیک و تحلیل مؤلفه‌های اصلی (PCA) با تحلیل انواع معیارهای شباهت در روش نزدیک‌ترین همسایه"، (submitted in Iranian Journal of Biomedical Engineering, 2012)

2. Masoome Esmaili, Morteza Zahedi, "Performance Analysis of PSO and GA for Classifying EEG Data", Accepted in International Journal of Computer Applications, 2012.

3. Masoome Esmaili, Morteza Zahedi, "Static Partitioning of EEG Signals by GA Using Multi_CSP", Accepted in International Journal of Computer Applications, 2012.

فهرست

فصل اول	۱۸
۱-۱- مغز بشر	۲
۱-۱-۱- بخش‌های مختلف مغز	۳
۱-۲-۱- اکتساب سیگنال مغز	۳
۱-۲-۱- سیگنال مغزنگاری الکتریکی (EEG)	۶
۱-۲-۱-۱- قرارگیری الکترودها بر اساس سیستم ۱۰-۲۰	۷
۱-۳-۱- مجموعه داده	۸
فصل دوم	۱۵
۱-۲-۱-۲-۱- رابط مغز-کامپیوتر (BCI)	۱۵
۲-۲-۱- کاربردهای BCI	۱۷
۱-۱-۲-۱-۲- ارتباطات	۱۷
۲-۲-۲-۱- کنترل طبیعی	۱۸
۲-۲-۲-۲- کنترل حرکت	۱۸
۲-۲-۲-۳- تحرک	۱۸
۲-۲-۲-۴- توانبخشی	۱۹
۲-۲-۳- معرفی چند BCI و نحوه عملکرد آن	۱۹
۲-۴-۲-۱- مروری بر روش‌های به کار رفته جهت طراحی BCI	۲۱
۲-۴-۲-۱- تبدیل فوریه سریع (FFT)	۲۱
۲-۴-۲-۲- تکنیک‌های رگرسیون خودکار (AR)	۲۳
۲-۴-۲-۳- تبدیل موجک	۲۵

۲۷.....	۴-۴-۲- ابعاد فرکتال
۲۸.....	۵-۴-۲- تحلیل مؤلفه‌های اصلی (PCA)
۲۸.....	۶-۴-۲- الگوهای فضائی مشترک (CSP)
۲۹.....	۷-۴-۲- استفاده از P300 و باندهای فرکانسی برای استخراج ویژگی
۱۵.....	فصل سوم
۳۴.....	۱-۳- استخراج ویژگی
۳۵.....	۲-۳- کاهش ابعاد داده جهت حذف مصنوعات اضافه شده به سیگنال
۳۶.....	۱-۲-۳- الگوهای فضایی مشترک (CSP)
۳۸.....	۱-۱-۲-۳- اسلوب CSP دو کلاسه
۴۰.....	۲-۱-۲-۳- تعمیم CSP برای کلاسه‌بندی پنج کلاسه
۴۳.....	۳-۱-۲-۳- روش پیشنهادی برای استخراج ویژگی با استفاده از CSP
۴۶.....	۲-۲-۳- تحلیل مؤلفه‌های اصلی (PCA)
۴۶.....	۱-۲-۲-۳- روش پیشنهادی کاهش ویژگی توسط PCA
۴۸.....	۳-۲-۳- ویژگی ماکزیمم و میانگین
۴۹.....	۳-۳- روش پیشنهادی برای فازی کردن
۴۹.....	۴-۳- دسته بندی
۵۰.....	۱-۴-۳- شبکه‌های عصبی پرسپترون چندلایه (MLP)
۵۱.....	۲-۴-۳- استفاده از LDA جهت کلاسه‌بندی
۵۱.....	۳-۴-۳- نزدیک ترین همسایه (1-NN)
۵۲.....	۱-۳-۴-۳- معیار شباهت
۵۲.....	۱-۱-۳-۴-۳- معیار شباهت کسینوسی
۵۳.....	۲-۱-۳-۴-۳- معیار شباهت چبیشف
۵۳.....	۳-۱-۳-۴-۳- فاصله اقلیدسی
۳۴.....	فصل چهارم
۶۱.....	۱-۴- انتخاب ویژگی

۶۱.....	۲-۴- حذف مصنوعات از سیگنال
۶۲.....	۲-۴-۱ رایج ترین مصنوعات EEG
۶۲.....	۲-۴-۱-۱- مصنوع پلک زدن
۶۳.....	۲-۴-۱-۲- مصنوع حرکات چشم
۶۴.....	۲-۴-۱-۳- نویز خطی
۶۴.....	۲-۴-۱-۴- مصنوع کنش ماهیچه ای
۶۵.....	۲-۴-۱-۵- مصنوع پالس
۶۵.....	۲-۴-۲- کارهای قبلی برای حذف مصنوعات
۶۷.....	۴-۳- روش پیشنهادی
۷۰.....	۴-۳-۱- الگوریتم انتخاب ویژگی رو به جلو
۷۱.....	۴-۳-۱-۱- الگوریتم روبه جلو حریصانه برای یافتن بهترین ترکیب از پنجره ها
۷۴.....	۴-۳-۲- الگوریتم ژنتیک
۷۵.....	۴-۳-۱- روند الگوریتم پیشنهادی GA برای انتخاب سازگارترین پنجره ها
۸۰.....	۴-۳-۱-۳- روند الگوریتم پیشنهادی PSO برای انتخاب سازگارترین پنجره ها
۶۱.....	فصل پنجم
۸۵.....	۵-۱- مقدمه
۸۵.....	۵-۲- مراحل روش پیشنهادی
۸۶.....	۵-۳- پارامترهای مهم در روش پیشنهادی
۸۷.....	۵-۴- ارزیابی روش پیشنهادی
۸۸.....	۵-۴-۱- پارامتر تعداد پنجره ها
۸۹.....	۵-۴-۲- مقایسه کلاسه بندها
۹۰.....	۵-۴-۲-۱- کلاسه بند نزدیک ترین همسایه (1-NN)
۹۱.....	۵-۴-۲-۲- بررسی کارایی شبکه عصبی MLP

۹۳	 LDA بررسی کارائی
۹۶	 LDA و MLP و 1-NN مقایسه‌ای بین کلاسه‌بندهای
۹۹	 ۳-۴-۵ بررسی روش‌های استخراج ویژگی
۹۹	 PCA بررسی کارائی روش
۱۰۲	 CSP بررسی کارائی روش
۱۰۴	 ۳-۳-۴-۵ بررسی کارائی ویژگی‌های ماکزیمم و میانگین
۱۰۴	 ۴-۳-۴-۵ مقایسه کارائی PCA و CSP و ویژگی‌های ماکزیمم و میانگین
۱۰۵	 ۴-۴-۵ بررسی الگوریتم‌های انتخاب ویژگی
۱۰۵	 ۱-۴-۴-۵ بررسی روش GA
۱۰۷	 ۲-۴-۴-۵ بررسی روش PSO
۱۰۸	 ۳-۴-۴-۵ بررسی کارائی الگوریتم انتخاب ویژگی رو به جلو
۱۱۰	 ۴-۴-۴-۵ مقایسه GA، PSO و روش انتخاب ویژگی روبه‌جلو
۱۱۲	 ۵-۴-۵ بررسی کارائی الگوریتم‌های پیشنهاد شده
۱۱۶	 ۶-۴-۵ بررسی زمان مصرفی الگوریتم‌های پیشنهاد شده
۱۱۸	 ۵-۵ مقایسه روش پیشنهادی با روش‌های دیگر
۸۵	 فصل ششم
۱۲۲	 ۱-۶ - نتیجه‌گیری
۱۲۶	 ۲-۶ - پیشنهادات ادامه کار
۱۲۷	 منابع

فهرست شکل‌ها

- شکل (۱-۱) توپولوژی سلول عصبی..... ۲
- شکل (۲-۱) نواحی وظایف مغز..... ۳
- شکل (۳-۱) مکان قرارگیری انواع تکنیک‌های ثبت سیگنال بر روی مغز..... ۵
- شکل (۴-۱) تجهیزات MEG..... ۵
- شکل (۵-۱) تجهیزات هجوم‌آورنده..... ۶
- شکل (۶-۱) یک سیستم EEG قابل حمل..... ۷
- شکل (۷-۱) سیستم بین المللی الکتروود ۲۰-۱۰، دید از کنار و بالای سر..... ۸
- شکل (۸-۱) نمایش مؤلفه‌های زمانی سیگنال EEG در شش کانال به صورت مجزا..... ۱۰
- شکل (۱-۲) سیکل رابط مغز-کامپیوتر (BCI)..... ۱۶
- شکل (۲-۲) یک BCI مبتنی بر دسته‌بندی دو کار ذهنی..... ۱۷
- شکل (۳-۲) یک کی‌بورد مجازی BCI از نوع ABI..... ۱۷
- شکل (۴-۲) الگوهای P300 به کار برده شده برای تحرک..... ۱۹
- شکل (۵-۲) نگاشت ERD بر روی سطح غشائی یک مدل سر واقعی..... ۲۰

- شکل (۲-۶) پیاده‌سازی تبدیل گسسته موجک یک بعدی..... ۲۵
- شکل (۲-۷) ساختار شبکه عصبی..... ۲۷
- شکل (۲-۸) مثالی از کاربرد یک BCI..... ۳۱
- شکل (۳-۱) طریقه ساخت بردار ویژگی نهائی با استفاده از اعمال CSP بر روی هر پنجره..... ۴۴
- شکل (۳-۲) پنجره کردن سیگنال و استخراج ویژگی‌های مناسب از هر پنجره توسط روش CSP..... ۴۵
- شکل (۳-۳) استخراج ویژگی مناسب توسط روش PCA..... ۴۷
- شکل (۳-۴) توزیع داده‌ها حول مؤلفه‌های اصلی در روش PCA..... ۴۸
- شکل (۳-۵) بخشی از شبکه عصبی MLP..... ۵۱
- شکل (۴-۱) مصنوع پلک زدن..... ۶۳
- شکل (۴-۲) داده EEG ثبت شده از کانال EOG و شش کانال دیگر..... ۶۳
- شکل (۴-۳) مصنوع پلک زدن..... ۶۳
- شکل (۴-۴) نویز خطی با فرکانس 50 هرتز..... ۶۴
- شکل (۴-۵) مصنوع کنش ماهیچه‌ای..... ۶۴
- شکل (۴-۶) مصنوع پالس..... ۶۵
- شکل (۴-۷) پنجره کردن ایستا و تطبیقی سیگنال‌های EEG..... ۶۷

- شکل (۴-۸) نمایش اولین پنجره از سیگنال EEG برای پنج کانال متفاوت..... ۶۸
- شکل (۴-۹) قدرت جداکنندگی هر یک از پنجره‌های یک سیگنال EEG..... ۶۹
- شکل (۴-۱۰) نرخ دسته‌بندی پنجره‌ها به صورت مرتب‌شده ۷۲
- شکل (۴-۱۱) سیگنال اصلی و سیگنال جدید که پنجره‌های آن بر اساس نرخ موفقیت به صورت مرتب شده قرار گرفته‌اند..... ۷۳
- شکل (۴-۱۲) بلاک‌دیاگرام الگوریتم رو به جلو برای انتخاب سازگارترین پنجره‌ها در کلاسه‌بندی... ۷۴
- شکل (۴-۱۳) سیگنال EEG مربوط تصور ذهنی عمل ضرب، و سیگنال منقبض‌شده بر طبق کروموزوم اول و کروموزوم دوم..... ۷۸
- شکل (۴-۱۴) بلاک دیاگرام انتخاب بهترین پنجره‌ها با استفاده از الگوریتم ژنتیک..... ۷۸
- شکل (۴-۱۵) بلاک‌دیاگرام اجزاء الگوریتم PSO..... ۸۰
- شکل (۴-۱۶) تعامل بین ذرات با بهترین ذره..... ۸۱
- شکل (۴-۱۷) بلاک‌دیاگرام انتخاب سازگارترین پنجره‌ها برای یافتن بهینه‌ترین شکل سیگنال بر اساس الگوریتم PSO..... ۸۳
- شکل (۵-۱) بلاک دیاگرام مراحل روش پیشنهاد شده..... ۸۶

- شکل (۲-۵) مقایسه نرخ موفقیت و زمان مصرفی روش پیشنهادی ۸۹
- شکل (۳-۵) مقایسه‌ی بین چهار معیار شباهت به کار رفته در روش 1-NN ۹۰
- شکل (۴-۵) خطای شبکه MLP با در نظر گرفتن ۳۰۰ مرحله آموزشی ۹۲
- شکل (۵-۵) مقایسه کلاسه‌بند MLP در روش CSP ۹۳
- شکل (۶-۵) نرخ موفقیت کلاسه‌بند LDA به ازای توابع جداساز ۹۴
- شکل (۷-۵) نمودار میله‌ای نرخ موفقیت کلاسه‌بند LDA به ازای توابع جداساز مختلف ۹۵
- شکل (۸-۵) مقایسه زمان مصرفی سه تابع جداساز مختلف ۹۶
- شکل (۹-۵) مقایسه سه روش دسته‌بندی MLP، LDA و 1-NN ۹۷
- شکل (۱۰-۵) نمایش کیفیت سه کلاسه‌بند بر اساس معیار Ratio ۹۸
- شکل (۱۱-۵) نمایش مقادیر ویژه ۱۰۰
- شکل (۱۲-۵) تاثیر تعداد بردارهای ویژه انتخاب شده بر نرخ موفقیت PCA ۱۰۱
- شکل (۱۳-۵) ارتباط تعداد بردارهای ویژه انتخاب شده (PC) در PCA ۱۰۲
- شکل (۱۴-۵) بررسی تاثیر تعداد الگوهای فضائی انتخاب شده در CSP بر نتیجه نهائی ۱۰۳
- شکل (۱۵-۵) بررسی نرخ موفقیت ویژگی ماکزیمم و میانگین در روش GACSP خطی ۱۰۴
- شکل (۱۶-۵) مقایسه نرخ موفقیت PCA، CSP، و ویژگی ماکزیمم و میانگین ۱۰۵
- شکل (۱۷-۵) عملکرد کروموزوم‌ها در طی ۵۰ دوره آموزشی در روش GACSPLDA ۱۰۶
- شکل (۱۸-۵) مقایسه عملکرد انتخاب ویژگی به روش GA با روش بدون انتخاب ویژگی ۱۰۷

- شکل (۵-۱۹) استفاده از PSO برای انتخاب ویژگی در CSPLDA..... ۱۰۸
- شکل (۵-۲۰) استفاده از الگوریتم رو به جلو در مقایسه با بدون انتخاب ویژگی..... ۱۰۹
- شکل (۵-۲۱) روند انتخاب پنجره در الگوریتم رو به جلو در CSPLDA..... ۱۱۰
- شکل (۵-۲۲) مقایسه الگوریتم CSPLDA برای الگوریتم‌های PSO، GA و رو به جلو..... ۱۱۱
- شکل (۵-۲۳) مقایسه زمان مصرفی الگوریتم CSPLDA برای الگوریتم‌های انتخاب ویژگی GA، PSO و رو به جلو..... ۱۱۲
- شکل (۵-۲۴) بررسی کارایی روش‌های به کار رفته در دسته‌بندی سیگنال‌ها ۱۱۵
- شکل (۵-۲۵) مقایسه الگوریتم‌های پیشنهاد شده بر اساس تعداد پنجره‌ها..... ۱۱۷

فهرست جداول

جدول (۱-۱) توزیع کلاسی نمونه‌ها در دو مجموعه آموزش و تست..... ۱۰

جدول (۱-۲) فرکانس‌های منطبق با سطوح متفاوت از تجزیه تبدیل موجک گسسته..... ۲۷

جدول (۱-۴) نمایش بهترین کروموزوم‌ها به طول ۵۰ و پنجره‌های انتخاب شده توسط آنها..... ۷۷

جدول (۱-۵) بیشینه نرخ موفقیت هر یک از الگوریتم‌های پیشنهاد شده..... ۱۱۴

جدول (۲-۵) مقایسه نرخ موفقیت روش پیشنهادی با روش‌های پیشنهاد شده..... ۱۱۹


فصل اول

ساختار مغز و اندازه‌گیری

سیگنال‌های EEG

۱-۱- مغز بشر


مغز یک انسان تقریباً از ۱۰۰ میلیون سلول عصبی تشکیل شده است. یک سلول عصبی احتمالاً متنوع‌ترین سلول در تمام بدن از لحاظ شکل و اندازه است که دارای ۲۰۰۰ اتصال یا بیشتر با بقیه سلول‌های عصبی است. این سلول عصبی از طریق آکسون و دندریت‌های خود با بقیه سلول‌ها اتصال برقرار می‌کند، بنابراین هر سلول عصبی یک بخش بهم متصل شده در شبکه سیستم اعصاب است. سلول‌های عصبی نسبت به وظایفشان انواع متفاوتی دارند که شامل سلول‌های عصبی حسی، حرکتی، داخل عصبی و سلول‌های هرمی هستند. در این میان پراهمیت‌ترین سلول در قشر تازه مخ سلول هرمی است، زیرا انتقال‌دهنده عصبی آن یک انتقال‌دهنده تحریکی قدرتمند است. سلول هرمی تعداد زیادی ورودی را از سلول‌های ستاره مانند دریافت می‌کند که آنها هم تحریکی هستند. به این دلیل، تصور می‌شود سلول‌های هرمی باعث ایجاد بخش قوی‌تری در سیگنال EEG می‌شوند. در شکل (۱-۱) (۱) بخش‌های اصلی یک سلول عصبی را می‌بینید.



شکل (۱-۱) توپولوژی سلول عصبی

۱-۱-۱- بخش‌های مختلف مغز

غشای مغزی می‌تواند به دو نیم‌کره تقسیم شود و هر نیم‌کره می‌تواند به چهار قوس تقسیم شود. که قوس وابسته به پیشانی، قوس پس‌سری، قوس جداری و قوس گیجگاهی نامیده می‌شوند. غشای مغزی عهده‌دار بسیاری از وظایف مشکل از قبیل حل کردن مسئله، قوه درک زبان و پردازش اطلاعات بصری پیچیده است. غشای مغزی می‌تواند به چندین ناحیه تقسیم شود، که هر کدام عهده‌دار وظایف متفاوتی هستند (شکل (۲-۱)) در این شکل ناحیه شنوایی وظیفه پردازش پیچیده اطلاعات شنوایی، و مرکز گفتار تولید و تلفظ شمرده گفتار، و ناحیه ورنیکه فهم زبان را بر عهده دارند. حرکت اعضای بدن غشای حرکتی مغز را فعال می‌کند. حتی اگر فرد حرکت را به عنوان سیگنال‌های مربوط به حرکت، تصور کند، سیگنال‌های اکتسابی از این ناحیه نسبت به نوع واقعی آن آماده‌کننده هستند. این دانش در BCI‌های مبتنی بر شناسایی الگو به کار برده می‌شود. در هر BCI کارهای ذهنی به روشی انتخاب می‌شوند که بخش‌های مختلف از غشای مغزی را فعال‌سازی کنند.



شکل (۲-۱) نواحی وظایف مغز [۱]

۲-۱- اکتساب سیگنال مغز

فعالیت الکتریکی سلول‌های عصبی مغز باعث ایجاد پتانسیل‌هایی می‌شود که اندازه‌گیری این پتانسیل‌ها کاربردهای زیادی در تحقیقات BCI دارد. این فعالیت‌ها توسط میلیون‌ها سلول‌های عصبی

که نرون نامیده می‌شوند، تولید می‌شوند. هر نرون به میلیون‌ها نرون دیگر متصل می‌شود. سیگنال‌های بقیه نرون‌ها در مکان ورودی این نرون جمع می‌شوند، هنگامی که این مجموع از یک سطح پتانسیل معین که حد آستانه نامیده می‌شود تجاوز کند، نرون، تحریک عصب را آتش می‌کند. تعدادی از اتصالات آن هم تحریکی هستند، و بنابراین با آتش گرفتن یک عصب، عصب‌های متصل به آن هم آتش می‌شوند.

امروزه تکنیک‌های متفاوتی برای اکتساب سیگنال الکتریکی مغز وجود دارد که به دو دسته تکنیک‌های هجوم آورنده و غیرهجوم آورنده^۱ تقسیم می‌شوند. در تکنیک‌های غیرهجوم آورنده از قبیل مغزنگاری الکتریکی (EEG) و مغزنگاری مغناطیسی (MEG)، فعالیت مغناطیسی الکتریکی مغز توسط الکترودهایی که بر روی جمجمه قرار داده می‌شوند، اندازه‌گیری می‌شود. در روش‌های هجوم آورنده از قبیل الکتروکورتیکوگرافی^۲ (ECoG) (شکل (۵-۱) الف)، میکرو الکتروده^۳ (ME)، آرایه میکروالکتروده^۴ (MEA) (شکل (۵-۱) ب) و پتانسیل‌های میدان محلی^۵ (LFPs)، الکترودها با شکافتن جمجمه مستقیماً بر روی مغز قرار داده می‌شوند تا فعالیت غشایی مغز را اندازه‌گیری کنند [۲]. این الکترودها ممکن است بر روی مغز قرار گیرند (ECoG) و یا ممکن است با استفاده از تکنیک‌های کاشت (القا) درون قشر تازه مخ فرو شوند تا سیگنال‌ها را شناسایی کنند (LFP). این تکنیک‌ها نسبت سیگنال به نویز بالاتری دارند و وضوح فضایی بالاتری در مقایسه با EEG دارند [۳]، و نقش مهمی را در تحقیقات مغزی مربوط به BCI بازی می‌کنند [۴]. اما با اینکه الکترودهای کاشته‌شده سیگنال‌های خالص را برای یک BCI تهیه می‌کنند، تکنیک‌های مهاجم معایب آشکاری دارند و به دلیل ریسکی که برای عمل جراحی وجود دارد، خیلی پرکاربرد نیستند.


¹ invasive and non-invasive

² Electrocorticography

³ Micro-electrode

⁴ micro-electrode array

⁵ local field potentials




شکل (۳-۱) مکان قرارگیری انواع تکنیک‌های ثبت سیگنال بر روی مغز

از میان تمام این روشها، MEG و EEG یک ثبت آنی و پیوسته را از فعالیت مغز می‌دهند (تفکیک‌پذیری زمانی در حدود 1ms)، که این یک شرط لازم برای BCI برخط است [۵]. اما از آنجایی که سیگنال‌های MEG دامنه کمی دارند، اندازه‌گیری‌ها باید در یک اتاق با پوشش مغناطیسی انجام گیرد تا از تحریف شدن سیگنال جلوگیری شود. همچنین معمولاً نیاز به یک جزء خنک‌سازی بزرگ برای سنسورهای آن است. بنابراین، سیستم‌های MEG نسبتاً گران و غیرقابل حمل هستند (شکل (۴-۱) [۵]).



شکل (۴-۱) تجهیزات MEG (الف) بیمار در زیر یک MEG (ب) ورود به اتاق با پوشش مغناطیسی MEG [۲]



(ب)

(الف)

شکل (۱-۵) تجهیزات هجوم آورنده (الف) الکترودهای ECoG بر روی غشای مغز، (ب) آرایه میکروالکترودهای غشایی (MEA) [۲]

۱-۲-۱- سیگنال مغزنگاری الکتریکی (EEG)

EEG در سال ۱۹۲۹ توسط برگر اختراع شد. در این روش فعالیت الکتریکی مغز به صورت غیرتهاجمی، از روی سطح جمجمه و با به کارگیری الکترودهای لوح مانند فلزی کوچک، ثبت می شود [۶]، [۷]. این الکترودها توسط تبدیل جریان یونی روی پوست به جریان الکتریکی سیم ها، یک تماس الکتریکی را بین پوست و اسباب ثبت داده EEG برقرار می کنند. به منظور بهبود ثبات سیگنال و برقراری یک تماس الکتریکی خوب، یک ژل الکترولیت بین الکترودها و پوست به کار برده می شود [۱]. در این روش سیگنال نویزی و با دامنه کم (از مرتبه 10^{-4} ولت) با در نظر گرفتن خصوصیات فرکانسی سیگنال، فیلتر و تقویت می شود تا شناسایی شده و نویز آن (یعنی 50HZ نویز موجود) خنثی گردد. سپس سیگنال بعد از دیجیتالی شدن ثبت می شود (شکل (۱-۶)). در کاربردهای بلادرنگ، EEG دارای وضوح و دقت زمانی به اندازه کافی بالا می باشد. اما وضوح فضایی آن به دلیل تاثیر بافت سر، کم بوده و وابسته به تعداد الکترودها است. ماکزیمم تفکیک پذیری آن در محدوده سانتی متر است، درحالی که برای مثال در MEG در محدوده میلیمتر است. همچنین سیگنال EEG اندازه گیری شده، ممکن است توسط منابع تولید مصنوعات از قبیل حرکت الکترودها، پلک زدن، و فعالیت ماهیچه ای آلوده شود، که باعث پائین آوردن کیفیت آن می شود. با این حال EEG به دلیل کم هزینه بودن، خطر کمتر و قابلیت حمل آسان، در بسیاری از مطالعات BCI ترجیح داده می شود [۵]. EEG پیوسته


توسط دامنه و فرکانس مشخص می‌شود. دامنه سیگنال‌های EEG نوعاً بین ۱۰ و ۱۰۰ میکرو ولت متغیر است که در بزرگسالان بیشتر بین ۱۰ و $50\mu V$ است [۲].



شکل (۱-۶) یک سیستم EEG قابل حمل با کلاه‌ای که الکترودها در بالای آن قرار داده شده‌اند، یک تقویت کننده بیو پتانسیل، و یک دستگاه ثبت/نظارت [۲].

۱-۱-۲-۱- قرارگیری الکترودها بر اساس سیستم ۱۰-۲۰

به منظور ساختن سیگنال‌هایی که قابل قیاس با سیگنال‌های مربوط به مطالعات دیگر در طول زمان باشد، یک سیستم برای قرارگیری الکترودها، که سیستم بین‌المللی ۱۰-۲۰ نامیده می‌شود به کار می‌رود. این سیستم برای مکان‌یابی ۲۱ الکترود است. فاصله بین نقاط برجسته آناتومیک بخصوص (بینی و برآمدگی پشت سر، شکل (۱-۸)) اندازه‌گیری می‌شود و الکترودها با فواصل بین الکترودی ۱۰ و ۲۰٪ بر روی مجموعه قرار می‌گیرند. موقعیت هر الکترود با یک کاراکتر که قوس اساسی مغز را مشخص می‌کند و همچنین یک عدد و یا یک کاراکتر دیگر که مکان نیم‌کره را تعیین می‌کند، مشخص می‌شود. عددهای زوج در طرف راست هستند و عددهای فرد در طرف چپ. Z (Zero) یا همان صفر) به مکان الکترودهای واقع بر روی خط میانی ارجا می‌کند.



شکل (۷-۱) سیستم بین المللی الکترود ۲۰-۱۰، دید از کنار و بالای سر: سیگنال‌های دریافت شده از مغز در کانال‌هایی که نام و مکانشان در شکل مشخص است، ذخیره می‌شوند [۱]

۱-۳- مجموعه داده

کارهای ذهنی مورد استفاده در سیستم‌های BCI به روشی انتخاب می‌شوند که بتوانند نواحی غشائی مغز را در محدوده‌های متفاوت فعال کنند (شکل ۱-۲). مجموعه داده استفاده شده در این مطالعه، از آزمایشگاه CEBL دانشگاه کلرادو^۱ گرفته شده است. برای تهیه این مجموعه داده، هفت انسان مأمور شدند تا پنج کار ذهنی را انجام دهند. یک کلاه الکترود الاستیکی^۲ به کاربرده شد تا سیگنال‌های EEG مغز را از طریق شش الکترود جایگذاری شده در مکان‌های O1, C3, C4, P3, P4, O2 ثبت کند (شکل ۱-۸). نرخ نمونه‌برداری 250 Hz بر ثانیه می‌باشد و داده‌ها در طی 10 ثانیه تولید شدند و بنابراین هر سیگنال حاوی ۲۵۰۰ نمونه است. در این مجموعه داده هر کار ذهنی پنج بار به ازای هر آزمایش^۳، تکرار شد. این مجموعه داده شامل پنج کار ذهنی به صورت زیر می‌باشد:

عمل ذهنی راحت بودن: اولین کار ذهنی، عمل ذهنی baseline است که تنها به عنوان سنجشی برای قیاس دیگر کارهای ذهنی به شمار می‌رود. افراد چشم‌های خود را باز یا بسته نگاه می‌دارند و سعی می‌کنند تا راحت باشند.

^۱Colorado

^۲electrod-cap elastic

^۳session

نامه‌نگاری: کار ذهنی دوم، عمل ذهنی نامه‌نگاری^۱ است که در آن از افراد خواسته می‌شود تا به صورت ذهنی و بدون درآوردن صدا، نامه‌ای را به دوست یا خویشاوند خود بنویسند.

ریاضیات: کار ذهنی سوم، عمل ذهنی ریاضی^۲ است که در آن به افراد مسائل غیر ساده ضرب داده می‌شود و از آنها خواسته می‌شود تا آن را به صورت ذهنی حل کنند.

شمارش بصری: کار ذهنی چهارم، عمل ذهنی شمارش بصری^۳ است که در آن افراد به صورت ذهنی-بصری تصور می‌کردند که یک مجموعه ترتیبی از اعداد بر روی تخته سیاه نوشته می‌شود، بدین صورت که قبل از اینکه عدد جدید نوشته شود، عدد قبلی پاک می‌شود.

چرخش شکل سه‌بعدی: کار ذهنی پنجم، عمل ذهنی چرخش یک شکل سه‌بعدی^۴ است که در این حالت از افراد خواسته می‌شود تا یک شکل سه بعدی پیچیده را برای سی ثانیه بررسی کنند. سپس این شکل سه‌بعدی برداشته شده و از آنها خواسته می‌شود تا به آن را صورت بصری در ذهنشان حول یک محور بچرخانند.


توجه کنید که در همه این حالات به جز حالت راحت بودن، چشم فرد باید باز بماند. شکل (۱-۹) سیگنال‌های EEG مربوط به این پنج کار ذهنی را برای یک فرد نشان می‌دهد. مجموعه داده به کار رفته در این مقاله، شامل سیصد و بیست و پنج سیگنال است که از دویست و سی سیگنال جهت آموزش و از نود و پنج سیگنال دیگر جهت تست استفاده کردیم. جدول (۱-۲) جزئیات این مجموعه داده را نشان می‌دهد.

¹letter task

²math task

³ visual counting task

⁴ Figure Rotation task



شکل (۸-۱) نمایش مؤلفه‌های زمانی سیگنال EEG در شش کانال به صورت مجزا

جدول (۱-۱) توزیع کلاسی نمونه‌ها در دو مجموعه آموزش و تست

تعداد کل	مجموعه تست	مجموعه آموزش	کلاس
۶۶	۱۹	۴۷	راحت بودن
۶۶	۱۹	۴۷	شمارش
۶۶	۱۹	۴۷	نوشتن نامه
۶۶	۱۹	۴۷	ریاضیات
۶۶	۱۹	۴۷	چرخش شکل سه‌بعدی
۳۲۵	۹۵	۲۳۵	کل

ادامه این پایان‌نامه به صورت زیر سازماندهی شده است. در فصل دوم مروری بر انواع BCI ها و روش‌های پردازش سیگنال به کار رفته برای آن، آورده شده است. پردازش سیگنال می‌تواند در سه گام تحلیل شود. اولین گام استخراج ویژگی از سیگنال است که در فصل سوم، انواع روش‌های استخراج ویژگی در حوزه زمان، معرفی می‌شوند. گام بعدی انتخاب ویژگی برای بالا بردن نرخ دسته‌بندی است، که در فصل چهارم بررسی می‌شود. آخرین گام، دسته‌بندی است که یک مدل ریاضی با به کار گیری ویژگی‌های که در گام‌های قبل استخراج شده‌اند، ساخته می‌شود. مدل ساخته شده برای تولید سیگنال‌های کنترلی مرتبط با کاربرد BCI به کار می‌رود که در فصل سوم انواع

روشهای دسته‌بندی معرفی خواهند شد. در فصل پنجم نتایج تجربی استراتژی‌های به کار رفته برای دسته‌بندی پنج کار ذهنی هفت فرد بررسی خواهد شد. در انتها هم نتیجه‌گیری و پیشنهادات آینده آورده می‌شود.

فصل دوم

رابط مغز – کامپیوتر (BCI) و


کاربردهای آن

۲-۱- رابط مغز- کامپیوتر (BCI)

رابط های مغز- کامپیوتر (BCI) سیستم هایی هستند که سیگنال های مغز را به سیگنال های کنترلی که برای تعامل با جهان بیرون مورد نیازند، تبدیل می کنند. بر طبق این تعریف، یک BCI باید قادر به شناسایی خواسته ها و دستورات کاربر هنگامی که او ساکت و بی حرکت باقی مانده است، باشد. بنابراین BCI می تواند یک راه ارتباطی جدید را برای آن دسته از افراد که از لحاظ فیزیکی کاملاً فلج بوده و قادر به گفتگو نیستند، اما از لحاظ ذهنی هنوز سالم و هوشیار هستند، فراهم کند [۲]. به این منظور، فعالیت مغزی او باید نظارت و بازبینی شود. یعنی وقتی کاربر کارهای تعریف شده در یک BCI را تصور می کند (به عنوان مثال تصور حرکت دست چپ و راست) سیگنال EEG مغز او اندازه گیری و نمونه برداری شده و تبدیل به فرامین کنترلی می شود. اولین علائم از تحقیقات BCI به سال ۱۹۶۰ برمی گردد، اما در سال ۱۹۹۰ بود که با پیشرفت کامپیوترها و تجهیزات، تحقیقات BCI واقعاً شروع شد. بزرگترین چالش مربوط به ساختن یک BCI دقت، سرعت و قابلیت استفاده از آن است. تحقیقات BCI مبتنی بر EEG می تواند به دو دسته کلی تقسیم شود:


۱. بیوفیدبک (آموزش دادن فرد): در این روش، یک الگوریتم سازگار به کار برده می شود تا داده EEG خام را به شکل تعدادی فیدبک درآورد (مثلاً حرکت نشانه گر بر روی مانیتور کامپیوتر). سپس از افراد خواسته می شود تا حالت های ذهنی خود را به منظور رسیدن به یک هدف خاص (یعنی حرکت دادن نشانه گر به یک مکان معین شده)، تغییر دهند. در این شیوه کاربر مجبور است تا یاد بگیرد که پاسخ EEG خود را منطبق با خود تعدیل کند، به عنوان مثال شدت ریتم μ مغز خود را تغییر دهد [۱]. بر خلاف روش قبل، BCI خودش را آموزش نمی دهد بلکه برای تغییرات ویژه در سیگنال EEG جستجو می کند (مثلاً شدت ریتم میو). معمولاً این به یک دوره آموزشی طولانی نیاز دارد، زیرا همه بار آموزش بر دوش کاربر است.

۲. روش شرطی‌سازی مؤثر یا تشخیص الگوی حالت‌های ذهنی (روش‌های آموزش کامپیوتر): در این روش‌ها، حالت‌های ذهنی سازگار متنوعی توسط کامپیوتر پردازش می‌شوند تا با به‌کارگیری تکنیک‌های تشخیص الگو آنها را تفکیک کنند. به عبارت دیگر در شیوه شناسایی الگو (به عنوان مثال ABI) فرد بر روی کارهای از پیش تعریف شده تمرکز می‌کند و بنابراین مغز او برای هر یک از کارها سیگنال‌های متفاوتی را تولید می‌کند. حال BCI می‌تواند آموزش داده شود تا این الگوها را جداسازی نماید.



شکل (۱-۲) سیکل رابط مغز-کامپیوتر (BCI) [۲]

شکل (۲-۲) یک تصویر الگووار از BCI را نشان می‌دهد، که مبتنی بر شیوه شناسایی الگو است. این BCI می‌تواند دو کار ذهنی را دسته‌بندی کند و یک بازخورد را به شکل کنترل نشانه‌گر فراهم سازد. به عنوان مثال کاربر کار شماره ۲ را تصور می‌کند و BCI آن را به درستی دسته‌بندی کرده و یک بازخورد را به شکل حرکت نشانه‌گر فراهم می‌کند.



شکل (۲-۲) یک BCI مبتنی بر دسته‌بندی دو کار ذهنی

۲-۲- کاربردهای BCI

در این قسمت، انواع کاربردهای BCI بررسی خواهند شد.

۲-۱-۱- ارتباطات

در این نوع BCI کاربر سعی دارد تا با محیط پیرامون ارتباط برقرار کند. به عنوان مثال با تایپ کلماتی که دوست دارد ادا کند. در این نوع BCI یک صفحه‌کلید مجازی به کاربر نشان داده می‌شود و کاربر می‌تواند به جای فشردن کلید تنها با تمرکز بر روی آن، مورد نظر خود را تایپ کند (شکل (۲-۳)).



شکل (۲-۳) یک کی‌بورد مجازی BCI از نوع ABI [۱]

۲-۲-۲- کنترل طبیعی

کنترل دستگاه هایی از قبیل رختخواب برقی، تلویزیون، لامپ و غیره می توانند کیفیت زندگی یک بیمار با ناتوانایی حرکتی شدید را تا حد زیادی بهبود دهند. به همین منظور سیستم های BCI پیاده سازی و ارزیابی شده است تا به افراد ناتوان اجازه دهند تا ارتباطات و حرکات خود را پیرامون محیط بهبود دهد.


۲-۲-۳- کنترل حرکت

بسیاری از تحقیقات بر روی ترمیم کنترل حرکت با ربات و دستگاه های اعضای مصنوعی برای افراد فلج وجود دارد. به عنوان مثال اخیرا یک آرایه ۹۶ میکروالکترودی در غشای اصلی یک انسان با فلج شدگی چهارگانه^۱، کار گذاشته شد تا فعالیت عصبی او را اندازه بگیرد. در این مطالعه، بیمار موفق به باز و بسته کردن یک دست مصنوعی شد و همچنین موفق شد تا عمل های ابتدایی را با بازوی رباتی چند بند، اجرا کند.

۲-۲-۴- تحرک

بسیاری تحقیقات برای راندن ویلچیر با BCI مبتنی بر EEG انجام شده اند تا حرکت را برای بیماران فراهم کنند. در یک شبیه سازی انجام شده توسط گالان و همکاران او، تصور حرکتی دست چپ برای چرخش ویلچیر به چپ، تصور ذهنی استراحت برای راندن آن به جلو، و انشای کلمات برای چرخش آن به راست به کار برده شد. آنها همچنین اطلاعاتی را که توسط حسگرهای ویلچیر فراهم شده بود، نیز به کار بردند. در بعضی از مطالعات از الگوی P300 برای کنترل ویلچیر در جهت های بخصوص استفاده شده است (شکل (۲-۴) الف)) [۲]

¹ Tetraplegic human



ب

الف

شکل (۴-۲) الگوهای P300 به کار برده شده برای تحرک [۲]

۲-۲-۵- توانبخشی^۱

هدف همه کاربردهائی که در بالا برای BCI ذکر شد، بهبود کیفیت زندگی بیمار با وسایل کمکی بود. اما هدف کاربردهای BCI برای توانبخشی این است که به بیمار کمک کنیم تا فعالیت تصویری خود را پس از ضربه یا در دیگر صدمات جراحی شدید یا بیماری مربوط به سیستم اعصاب مرکزی (CNS)، بازیابی کنند. دو استراتژیک برای این هدف وجود دارد. در اولین استراتژیک، بیمار آموزش می بیند تا فعالیت نرمال مغزی بیشتری را تولید نماید که توسط ویژگی های EEG اندازه گیری می شوند. در استراتژیک دوم، بیمار دستگاهی را به کار می برد که حرکت وابسته به فعالیت مغز را مساعدت می کند. این استراتژیک دستورالعمل تصویری موجب شونده ورودی حسی را که باعث انعطاف پذیری CNS می شود بهبود می دهد [۲].

۲-۳- معرفی چند BCI و نحوه عملکرد آن


انواع BCI ها بر اساس نوع تصورات ذهنی می توانند به دو گروه تقسیم شوند. چهار BCI، یعنی آلبرتا، آکسفورد، ABI، Graz BCI مبتنی بر روش تشخیص پترن هستند و کارهای ذهنی را به کار می برند. دو BCI دیگر (TTD و BCI Wadsworth) مبتنی بر روش شرطی سازی مؤثر هستند و نیاز به خود

¹ Neurorehabilitation


تنظیمی پاسخ EEG دارند. یعنی هیچ کار ذهنی از پیش تعریف شده‌ای وجود ندارد و کاربر باید به شیوه بدون نظارت کنترل BCI را بدست بگیرد.

اگرچه BCI آلبرتا مبتنی بر شیوه شناسایی الگو بود، اما در آن هیچ کار ذهنی از پیش تعریف شده‌ای وجود نداشت. بلکه افراد باید کاری را که تمایل داشتند برای کنترل حرکت نشانه‌گر به کار برند، انتخاب می‌کردند. این امکان‌پذیر بود، زیرا در روش شناسایی الگو، سیستم BCI می‌تواند آموزش ببیند تا الگوهای EEG مرتبط با کارهایی که فرد انتخاب کرده است را کلاسه‌بندی نماید. اما در بقیه BCI های مبتنی بر روش تشخیص الگو، فرد با کارهای ذهنی از پیش تعریف شده آماده می‌شود. در آزمایشات Graz BCI و BCI آکسفورد، کارهای ذهنی برای همه افراد یکسان است. Graz BCI مبتنی بر شناسایی ERD و ERS مربوط به باندهای ریتمی μ و β ، در طی تصور حرکتی دست راست و چپ است. از کاربردهای Graz BCI می‌توان به کنترل یک بازوی مصنوعی اشاره کرد. BCI آلبرتا هم به عنوان دستگاه کنترل محیط به کار برده شده است.

تصور حرکتی چپ



تصور حرکتی راست



شکل (۲-۵) نگاشت ERD مربوط به یک فرد بر روی سطح غشائی یک مدل سر واقعی. ERD مربوط به توزیع باند آلفا (۱۳-۹ هرتز) برای تصور حرکتی راست و چپ به دست آمده‌اند [۱].

در ABI شش کار ذهنی از پیش تعریف شده وجود دارد (راحت بودن، تفریق، چرخش مکعب، حرکت دست راست و چپ و وابسته‌سازی کلمات)، اما فرد می‌تواند سه کاری را که تمایل دارد انتخاب کند.

اگرچه کارهای ذهنی در این گونه BCI ها از پیش تعریف شده است، تعاریف خیلی صریح نیستند، و ممکن است فرد فنون ذهنی متفاوتی را هنگام اجراکردن آنها به کار برد.

در نوع TTD افراد می‌توانند فنون ذهنی متفاوت و دلخواه خود را به کار برند، تا کنترل دامنه SCP خود را بدست آورند. اما از معایب این BCI این است که فرد ممکن است با تغییر فنون شناختی خود، کنترل SCP خود را از دست بدهد. در این صورت هرگز نخواهد توانست آن را دوباره بدست بیاورد مگر پس از چندین روز آموزش جدید. TTD توسط بیماران افراد با ناتوانی شدید (ALS) به عنوان وسیله برقراری ارتباط با زبان برنامه پشتیبان به کار برده می‌شود. کاربردهای اخیر شامل دستگاه کنترل محیط و کاوشگر اینترنت "دسکارتس"^۱ هستند. در BCI از نوع Wadsworth به کاربران مشاوره داده می‌شود که انواع متنوع تصورات حرکتی در آغاز بدست آوردن کنترل، کمک‌کننده خواهد بود. کنترل Wadsworth BCI ممکن است کم‌کم تقریباً خودکار شود [۱] و اغلب کاربران گزارش می‌کنند که به مرور تصور را کم و کمتر به کار می‌برند. Wadsworth به کار برده شده است تا جواب سئوال‌های ساده بلی و خیر را بدهد. ABI نیز به عنوان کی‌بورد مجازی به کار برده شده است [۱].

۲-۴- مروری بر روش‌های به کار رفته جهت طراحی BCI

در این بخش مهمترین روش‌هایی که برای طراحی یک BCI با استفاده از سیگنال EEG به کار رفته است، همراه با کاربرد آنها در جدیدترین مطالعات به صورت مختصر ذکر خواهد شد.

۲-۴-۱- تبدیل فوریه سریع^۲ (FFT)

تبدیل فوریه سیگنال EEG را از حوزه زمان به حوزه فرکانس انتقال می‌دهد. همانند داده خام، سیگنال در حوزه فرکانس نیز شامل مقادیر زیادی از داده است که می‌تواند تکنیک‌های تشخیص الگو

^۱ Descartes

^۲ Fast Fourier Transform

را با شکست مواجه کند. بنابراین، مطالعات BCI توسط استخراج بخش‌های مفید از این داده در حوزه فرکانس اداره شده است. یکی از این روشها ERD در ریتم میو (۸-۱۲ هرتز) است. زیرا ریتم میو برای تصورات ذهنی مختلف، متفاوت است. برای اندازه‌گیری ERD، توان ۸-۱۲ هرتزی مربوط به یک پنجره زمانی ۲ ثانیه‌ای با دو پنجره ۲ ثانیه‌ای مجاور، مقایسه می‌شود. روش دیگر اعمال تبدیل لاپلاس و سپس انجام تبدیل FFT بر روی داده EEG است.

در مرجع [۸] پژوهشی ارائه شد تا این مسئله را که الگوهای فعالیت مغز در ارتباط با عواطف و شخصیت است را مورد بررسی قرار دهد. به این منظور ابتدا تبدیل FFT برای انتقال سیگنال EEG از حوزه زمان به حوزه فرکانس، انجام شد. زیرا در حوزه فرکانس مختصات دامنه بر حسب زمان است که با انتقال آن به حوزه فرکانس مختصات دامنه بر حسب فرکانس بدست می‌آید. لذا توان مطلق و نسبی هر یک از امواج ریتمیک مغز از جمله توان مطلق آلفا را می‌توان در هر ناحیه محاسبه کرد. توان مطلق آلفا با فعالیت مغز رابطه معکوس دارد. یعنی توان مطلق آلفا در هر ناحیه نشان‌دهنده فعالیت پایین‌تر در آن ناحیه است و بالعکس. بنابراین می‌تواند یک ویژگی خوب را در اختیار قرار دهد. این ویژگی استفاده شد تا هر یک از حالات چهارگانه آرامش، شادی، اضطراب، غم را دسته‌بندی نماید.

در تحقیق [۹]، هدف طراحی یک BCI برای کنترل ویلچیر با استفاده از تصورات غیرحرکتی برای افراد با ناتوانایی‌های شدید است. در این تحقیق برای دسته‌بندی تصورات غیرحرکتی از ویژگی PSD و یک کلاسه‌بند ANN استفاده شده است. ویژگی PSD یا همان چگالی طیفی توان، توسط مربع تبدیل فوریه سریع (FFT) بر روی هر سگمنت از سیگنال، استخراج می‌شود و به عنوان ورودی به شبکه عصبی داده می‌شود.

در تحقیق [۱۰] نیز هدف طراحی یک BCI برای کنترل ویلچیر با استفاده از تصورات حرکتی می‌باشد. سیگنال‌های EEG بدست آمده از تصورات حرکتی دست چپ و راست برای ایجاد چهار فرمان به کار رفته‌اند. در این تحقیق قدرت سه روش استخراج ویژگی برای دسته‌بندی سیگنال‌ها با استفاده از

شبکه عصبی آزمایش شده است. روش اول MEIG است، که در این روش ابتدا سیگنال را سگمنت کرده، و سپس سیگنال سگمنت شده را در ترانهاده آن ضرب می‌کند، و بردارهای ویژه ماتریس حاصل را به عنوان ویژگی‌های مناسب استخراج می‌کند. روش بعدی Parseval است که این روش ویژگی‌های چگالی انرژی را از هر سگمنت از سیگنال بدست می‌آورد. در روش سوم توان باند برای پنج باند فرکانسی (۸-۱۰ هرتز)، (۱۰-۱۲ هرتز)، (۱۳-۱۵ هرتز)، (۱۶-۱۸ هرتز) و (۱۹-۳۰ هرتز) محاسبه شده و برای هر کانال بدست می‌آید. سپس ویژگی‌های استخراج شده در کنار هم قرار می‌گیرند تا بردار ویژگی نهائی بدست را بسازند. در نهایت توسط شبکه‌های عصبی، به دسته‌بندی سیگنال‌ها می‌پردازد. نتایج نشان می‌دهد که ویژگی MEIG دارای قدرت دسته‌بندی بالاتری نسبت به دو ویژگی دیگر می‌باشد.

۲-۴-۲- تکنیک‌های رگرسیون خودکار (AR)

در تکنیک‌های رگرسیون خودکار (AR)، یک مدل زمانی تولید می‌شود که بتوان یک ولتاژ را از N ولتاژ گذشته آن پیش‌بینی کرد که در آن مرتبه مدل N است. بنابراین مدل می‌تواند به صورت زیر بیان شود:

$$x_{i,e}(t) = -\sum_{i=1}^N a_{i,e} x_{i,e}(t-i) \quad (1-2)$$

در این رابطه $a_{i,e}$ ، i امین مرتبه ضرایب AR را برای الکتروود e نشان می‌دهد. همین ضرایب AR می‌توانند به عنوان ویژگی به کار برده شوند. برای بدست آوردن این ضرایب، عموماً داده EEG به بلاک‌هائی پنجره‌بندی می‌شود. سپس هنگامیکه مقدار t در سرتاسر پنجره داده جابه‌جا می‌شود، معادلات مدل بیشمار بدست می‌آید، که به ما اجازه می‌دهد تا ضرایب بهینه AR را محاسبه کنیم. بنابراین ضرایب AR می‌تواند برای بیان حالت ذهنی در طی این پنجره زمانی به کار برده شود.

هاپینگ در [۱۱] به منظور دسته‌بندی کارهای ذهنی، ابتدا برای استخراج ویژگی مناسب، ضرایب مدل AR را به عنوان بردار ویژگی مناسب در نظر می‌گیرد. سپس این بردارهای ویژگی را به شبکه PNN داده تا پس از آموزش، دقت این شبکه را در دسته‌بندی کارهای ذهنی بسنجد. نتایج تحلیل و آزمایشات نشان داد که این روش می‌تواند نرخ دسته‌بندی بالایی را بدست آورد.

در [۱۲] هم به صورت مشابه، از روش AR برای استخراج ویژگی استفاده شده است. در این مقاله سیگنال‌های EEG با استفاده از تکنیک‌های رگرسیون اتوماتیک (AR) تک کاناله و چندکاناله، مدل می‌شوند. ویژگی‌های استخراج شده برای دسته‌بندی دو کار ذهنی متفاوت به کار برده شد. برای این کار یک شبکه عصبی آموزش داده شد تا این کارها را کلاسه‌بندی کند. با بررسی و تحلیل نتایج این مقاله به این نتیجه می‌رسیم که AR چندمتغیره بهتر از تک‌متغیره عمل می‌کند.

لیانگ^۱ [۱۳] برای دسته بندی پنج کار ذهنی، ابتدا سیگنال‌ها را به صورت ایستا سگمنت می‌کند. سپس با اعمال روش AR تک‌متغیره بر روی هر سگمنت، ویژگی مناسب را از آن سگمنت استخراج می‌کند. بنابراین برای هر سیگنال یک بردار ویژگی به طول (تعداد کانال‌ها * تعداد سگمنت‌ها) بدست آمد. سپس بردارهای ویژگی استخراج شده را به شبکه عصبی می‌دهد تا با استفاده از یادگیری ELM در مقابل یادگیری برگشت رو به عقب (BP) سیستم را آموزش دهد.

تحقیق [۱۴] از خصوصیات منحصر بفرد سیگنال‌های EEG هر فرد، جهت تشخیص هویت افراد استفاده کرده است. او از روش مدل کردن رگرسیون خودکار با تغییر فرکانس^۲ (FZ-AR) برای استخراج ویژگی استفاده کرده است. برای استخراج ویژگی، ابتدا فرکانس مناسب بر اساس باند فرکانسی مطلوب ۸-۱۳ هرتز انتخاب می‌شود. فرکانس مطلوب $f_m=10.5$ هرتز انتخاب شد. سپس AR استاندارد بر روی آن اعمال می‌شود. بردار ویژگی نهائی از کنار هم قرار دادن ویژگی‌های بدست آمده از هر سگمنت بدست می‌آید. پس از بدست آوردن بردار ویژگی از سیگنال‌های EEG همه افراد


¹ LIANG

² Frequency-Zooming Auto-Regression modeling

توسط AR، توسط فاصله ماهالانوبیس، به دسته‌بندی و تشخیص هویت افراد می‌پردازد. نتایج روش دقت بالایی (حدود ۹۳٪) را برای شناسایی افراد در بردارد.

۲-۴-۳- تبدیل موجک^۱

امروزه، کمتر کاری با به کارگیری تبدیل موجک به عنوان روش استخراج ویژگی برای سیستم BCI منتشر شده است. تبدیل موجک‌ها ضرورتاً یک سازش بین حوزه زمان و فرکانس هستند تا به کاربر اجازه دهند تغییر باند فرکانسی را در طی زمان ببینند. البته تفکیک‌پذیری آن کمتر از حوزه زمان یا حوزه فرکانس به تنهایی است. تبدیل گسسته موجک^۲ (DWT) می‌تواند به عنوان مجموعه‌ای از فیلترهایی که در شکل (۶-۲) نشان داده شده است محاسبه شود.



این زیرنمونه‌گیری نشان داده شده، تا زمانی می‌تواند تکرار شود که تنها یک نمونه باقی بماند. بنابراین، بیشترین تعداد ضرایب DWT برابر با تعداد نمونه‌ها در سیگنال اولیه است. یک روش گسسته دیگر که بسته‌های تبدیل موجک^۳ نام دارد، به باندهای فرکانسی DWT اجازه می‌دهد (مقیاس‌های ضرایب) تا بیشتر تقسیم شوند. برای مثال، در EEG اگر DWT مقیاسی داشته باشد که همه باند β را بپوشاند، در این صورت با به کارگیری بسته‌های تبدیل موجک، فرد می‌تواند آن را به باندهای جداگانه β_1 و β_2 بشکند.

¹ Wavelet

² Discrete Wavelet Transform


³ Wavelet Packets

ساباسی در [۱۵] روشی ارائه می‌دهد که از ضرایب تبدیل موجک گسسته برای استخراج ویژگی مناسب از سیگنال EEG مغز یک بیمار صرعی استفاده می‌کند. این ضرایب یک نمایش فشرده‌تر از سیگنال است که بیان‌کننده سیگنال در حوزه زمان و فرکانس است. در این روش، تبدیل موجک گسسته پنج بار بر روی سیگنال اعمال می‌شود. در نهایت از ضرایب D1 تا D5 (details) و یک ضریب (Approximate) A برای استخراج ویژگی توسط رگرسیون استدلالی^۱ (LR) استفاده می‌شود. همانطور که در جدول (۱-۲) می‌بینید ضریب A5 در محدوده فرکانسی باند دلتا (۴-۱ هرتز) است و بقیه ضرایب نیز در محدوده باندهای فرکانسی بیان‌شده در جدول هستند. در نهایت ویژگی‌های استخراج شده توسط شبکه‌های عصبی دسته‌بندی خواهند شد.

جدول (۱-۲) فرکانس‌های منطبق با سطوح متفاوت از تجزیه تبدیل موجک گسسته

ریتم‌های امواج	محدوده فرکانسی	سیگنال تجزیه شده
	۵۰-۱۰۰	D1
	۲۵-۵۰	D2
باند بتا	۱۲,۵-۲۵	D3
باند آلفا	۶,۲۵-۱۲,۵	D4
باند تتا	۳,۱۲۵-۶,۲۵	D5
باند دلتا	۰-۳,۱۲۵	A5

¹ Logistic Regression



شکل (۷-۲) ساختار شبکه عصبی به کار رفته در [۱۵]

در تحقیق [۱۶] برای خالص سازی سیگنال از مصنوع پلک زدن (EOG)، از روش تحلیل مؤلفه های مستقل^۱ (ICA) استفاده شده است. سپس با استفاده از تبدیل موجک و کلاسه بند ماشین بردار پشتیبان (SVM)، سیگنال های EEG مربوط به دو تصور حرکتی دست چپ و راست کلاسه بندی شده اند.

۲-۴-۴- ابعاد فرکتال

ابعاد فرکتال یک روش برای تخمین پیچیدگی سیگنال است. بدین ترتیب که تصورات ذهنی مختلف دارای بعدهای فرکانسی مختلف نیز می باشند. اگر بتوانیم بعد مربوط به هر تصور ذهنی را تخمین بزنیم، می توانیم به راحتی تصورات ذهنی را دسته بندی کنیم. همچنین می توان با مشخص کردن ابعاد فرکتالی مصنوعات، آنها را به راحتی حذف کرد. چندین الگوریتم برای تخمین ابعاد فرکتال سیگنال EEG امتحان شده است [۱۷] که الگوریتم بیان شده توسط هیگوچی [۱۸] ظاهراً پرکاربردترین الگوریتم است. بر طبق الگوریتم هیگوچی، ابعاد فرکتال D_f ، توسط بهترین معیاری که دارای کمترین مربعات خطی است، پیدا می شود.

¹ Independent component analysis

۲-۴-۵- تحلیل مؤلفه‌های اصلی (PCA)

تحلیل مؤلفه‌های اصلی (PCA) می‌تواند به عنوان یک روش استخراج ویژگی نیز در نظر گرفته شود، در حالیکه همانند تحلیل مؤلفه‌های مستقل (ICA) هدف اصلی آن کاهش ابعاد است. این روش ممکن است عموماً به عنوان آخرین گام قبل از تشخیص الگو به کار برده شود. به عنوان مثال، ممکن است فردی ضرایب تبدیل موجک را از داده EEG بدست آورده باشد، سپس PCA را بر روی آن اعمال کند تا ابعاد را کاهش دهد. کاهش ابعاد یک سیگنال، جداسازی داده‌ها به کلاس‌های آنها را برای روش تشخیص الگو آسان‌تر می‌سازد. عیب PCA این است که ممکن است مقداری از اطلاعات مفید در فرایند کاهش ابعاد آنها دور ریخته شوند.

در تحقیق [۱۹] هدف اصلی دسته‌بندی فعالیت‌های چندگانه مغزی توسط کلاسه‌بند PNN است تا فعالیت‌های مغزی مرتبط با تصور حرکتی را پیدا کند. در این مقاله، مقایسه‌ای بین دو روش استخراج ویژگی PCA و LDA، با اندازه‌گیری زاویه بین جهت‌های اصلی بدست آمده توسط این دو روش، انجام شده است.

در تحقیق [۲۰]، هدف دسته‌بندی تصورات حرکتی سیگنال‌های EEG در حوزه فرکانس است. این مقاله ابتدا از روش تحلیل مؤلفه‌ها اصلی (PCA)، برای کاهش ویژگی استفاده کرده است. سپس در حوزه فرکانس، انرژی‌های ماکزیمم و مینیمم را به عنوان ویژگی استخراج می‌کند. برای دسته‌بندی از شبکه‌های عصبی چندلایه^۱ (MLP) با نرخ‌های یادگیری و ممنتوم^۲ متفاوت استفاده می‌شود.

۲-۴-۶- الگوهای فضائی مشترک^۳ (CSP)

الگوهای فضائی مشترک (CSP)، یک تبدیل خطی را برای تصویر کردن داده چندکاناله EEG به زیرفضای با ابعاد کمتر، توسط یک ماتریس تصویر به کار می‌برد. هر سطر از ماتریس تصویر شامل

^۱ Multilayer perceptron

^۲ Momentum.

^۳ Common Spatial Pattern

وزن‌های کانال‌ها است. این تبدیل می‌تواند واریانس ماتریس‌های سیگنال دو کلاسه را بیشینه کند. این روش به کرات در کاربردهای BCI برای دسته‌بندی دوکلاسه و چندکلاسه به کار رفته است.

در [۲۱] دسته‌بندی تصورات حرکتی مطالعه شده است. این مقاله پیشنهاد می‌دهد که، اگر دقیق بدانیم در حین تصور حرکتی^۱ (MI) کدام قسمت از مغز بیشتر درگیر می‌شود، با گذاشتن الکترودها در همان بخش و گرفتن سیگنال از آن، می‌توانیم سیگنال خالص‌تری را برای هر یک از MI ها بدست آوریم. او پیشنهاد می‌کند که ابتدا تا جایی که می‌توانیم تعداد الکترودها را بالا ببریم تا از همه نواحی مغز سیگنال دریافت کنیم. سپس برای یافتن بهترین کانال‌ها از روش PSO باینری برای انتخاب کانال‌ها استفاده می‌کنیم.

در تحقیق [۲۲] کلاسه بندی تصورات ذهنی برای پایگاه داده Graz BCI استفاده شده است. در این مقاله دسته‌بندی چهار تصور حرکتی زبان، دست چپ و راست و حرکت پا مورد بررسی قرار گرفته است. برای استخراج ویژگی مناسب، روش CSP دو کلاسه به CSP چندکلاسه BCSP بسط داده شده است. در این روش جدید، CSP با الگوریتم جستجوی دودویی ترکیب شده است. برای اینکه جستجوی دودویی را برای CSP چهارکلاسه به کار ببریم، ابتدا فیلترهای CSP (W_i) را برای هر کلاس بدست آورده و آنها را در یک آرایه مرتب می‌کنیم. سپس آنها را در یک درخت جستجوی باینری درج می‌کنیم. حال در هر دسته‌بندی به جای محاسبه C تا CSP، (C: تعداد کلاس)، تنها نیاز به محاسبه $\log C$ تا CSP خواهیم داشت.

۲-۴-۷- استفاده از P300 و باندهای فرکانسی برای استخراج ویژگی

بسیاری از BCI ها بر مبنای P300 طراحی می‌شوند. در این گونه BCI ها فرد با یک محرک ناآشنا به گونه‌ای تحریک می‌شود که سیگنال مغز او یک قله P300 تولید کند. در استعمال BCI مبتنی بر P300، هر محرک منطبق با یک سمبل دارای یک مفهوم ویژه است (مثلا در نوشتن نامه‌ها یا

¹ Motor Imagery

فرمان‌های سطح بالا). در میان این سمبل‌ها، هدف فرد وابسته به زمان رویداد پیک P300، شناسایی می‌شود.


در مرجع [۲۳] هدف بهبود BCI های مبتنی بر P300 است. در این مقاله بر روی BCI ای کار شده است که یک کی‌بورد مجازی لب‌تاپ را شبیه‌سازی کرده است. این BCI برای افراد با ناتوانایی شدید حرکتی، که تنها قادر به حرکت دادن چشم خود هستند، می‌تواند مفید باشد. با تشدید تصادفی و پی‌درپی کاراکترهای روی کی‌بورد مغز فرد تحریک می‌شود تا یک P300 با دامنه متفاوت در سیگنال EEG او ظاهر شود. در این مطالعه، هدف نویسنده نشان دادن این مسئله است که اگر فواصل بین فلش‌ها (TTI) طولانی تر شود، دقت دسته‌بندی بالا می‌رود. او کار خود را به ازای فواصل ۱۶، ۱۸، و ۲۱ امتحان کرد تا تاثیر TTI را بر روی BCI P300 بسنجد. او هر بار دامنه P300 را به ازای هر یک از آنها اندازه گرفت و با استفاده از تحلیل جداساز خطی-بیزین^۱ (BLDA) به دسته‌بندی پرداخت. نتیجه شد که فاصله ۲۱ که بیشینه فاصله است، بهترین دقت جداسازی را داشته است.

در مرجع [۲۴] نیز یک نوع P300 BCI ساده‌تر برای افراد با ناتوانی شدید (ALS) طراحی شده است که تنها از حروف الفبا و ارقام تشکیل شده است. هدف دسته‌بندی سیگنال‌های EEG با استفاده از سه نوع ویژگی متفاوت است. ویژگی اول دامنه مربعات میانگین ریشه (TRMS) است. دومین ویژگی مبتنی بر قله معکوس ERP مربوط به هر یک از کانال‌ها است. و ویژگی سوم توان باند فرکانسی تتا به ازای کانال‌های مختلف است.

پالانیپان [۲۵] از توان طیفی هر یک از چهار باند فرکانسی تتا، دلتا، آلفا و گاما برای استخراج بردار ویژگی مناسب استفاده کرده است. در نهایت توان طیفی و همچنین اختلاف توان طیفی به عنوان ویژگی به شبکه عصبی داده می‌شود تا یک دسته‌بندی پنج کلاسه را انجام دهد. پالانیپان خروجی شبکه عصبی را برای کنترل یک نشانه‌گر بر روی صفحه نمایش استفاده کرد. بدین ترتیب که نشانه‌گر

¹ Bayesian linear discriminant analysis

وقتی حرکت می‌کرد که فرد مشغول فکر کردن به یک کار ذهنی خاص بود. در نمایش‌گر دو نماد مربع و دایره وجود داشت. نشانه‌گر هنگام حرکت به یکی از این دو نماد تماس پیدا می‌کرد و بدین ترتیب در تماس با مربع نماد خط تیره و در تماس با دایره نماد نقطه انتخاب می‌شد. ترتیبی از این نمادهای انتخاب شده را به کد مورس می‌دهیم تا به کاراکترهای مناسب تبدیل شود. با این روش فرد معلول می‌تواند با جهان بیرون ارتباط برقرار نماید. در شکل (۸-۲) روند کار را می‌بینید:



شکل (۸-۲) مثالی از کاربرد یک BCI

مکیگ در [۲۶] یک روش را برای تحلیل داده EEG مرتبط با رویداد را توسعه داد که آن را "پویایی شناسی مرتبط با رویداد مغز"^۱ نامید. این روش بر تجزیه طیفی هر یک از آزمایش‌های مرتبط با رویداد EEG تکیه دارد تا تغییرات مرتبط با رویداد را در بزرگی و فاز نوسان در یک فرکانس معین، آزمایش کند. می‌توان گفت این روش، یک مقدار پالایش‌تر شده و جزئی‌تر را از فعالیت نوسانی عصب مرتبط با رویداد نسبت به شیوه ERP سنتی فراهم می‌کند. همچنین با این روش دید ایستاتری نسبت به شیوه ERP سنتی فراهم می‌شود.

در مرجع [۲۷] از تحلیل سیگنال‌های EEG جهت تشخیص بیماری اسکیزوفرنی استفاده شده است. در این مقاله روشی ارائه شده است که با حذف نویز سعی در بالا بردن تفکیک‌پذیری تحلیل ERP دارد. زیرا ERP های مربوط به یک سیگنال پیوسته EEG، با توزیع‌های فاز و دامنه که کاملاً با

¹ event-related brain dynamics

پردازش کارهای ذهنی غیرمرتبط هستند، و نويز نام دارند، مخلوط و ناپيدا هستند. پيشنهاد اين مقاله اين است كه از آزيمايشات يك سيگنال در حوزه زمان-فضا متوسط گيري كنيم. در اين صورت اين نوسانات فاز همگام شده (نويز) در طی متوسط گيري آزيمايشات بی تغيير می مانند و بنابراین موج آنها در میانگين ERP مشهود است، و به سادگی قابل حذف هستند.

شاهراه اصلی تحقیقات آینده، می تواند استفاده بسیار زیاد از شبکه های عصبی باشد. این شیوه تشخیص الگو می تواند هزاران ابعاد را کنترل کند، اما در این حالت نیاز به دهها هزار مجموعه مثال و همچنین نیاز به زمان و/یا توان محاسباتی زیاد برای انجام آموزش، خواهد بود. بعلاوه احتمالاً سیستم های آینده بتوانند با به کارگیری الکترودهای کاشتنی یا تکنولوژی های ابداعی غیرتهاجمی که سریعتر باشد و ابعاد چندگانه داشته باشد، پیاده سازی شوند.

فصل سوم

استخراج ویژگی و دسته‌بندی سیگنال‌های

EEG در رابط مغز-کامپیوتر (BCI)

در این فصل، تکنیک‌های پردازش سیگنال در BCI با تمرکز بر روشهایی که در این مطالعه به کار رفته‌اند، با جزئیات تحلیل خواهد شد. این روشها به صورت زیر خلاصه می‌شوند:

➤ استخراج ویژگی توسط روشهای:

- الگوی فضایی مشترک^۱ (CSP)
- تحلیل مؤلفه‌های اصلی (PCA)
- ویژگی میانگین، ماکزیمم هر پنجره

➤ دسته بندی کارها با استفاده از روشهای:

- شبکه عصبی پرسپترون چندلایه (MLP)
- تحلیل مجزاساز خطی (LDA)
- روش نزدیک‌ترین همسایه (1-NN) با استفاده از معیارهای شباهت فاصله اقلیدسی^۲، فاصله کسینوسی^۳، فاصله مربعی^۴ (ماهالانوبیس) و فاصله چبیشف^۵

۳-۱- استخراج ویژگی

تحلیل دقیق سیگنال‌های EEG می‌تواند بینش و دید ارزشمندی را جهت فهم و شناسایی مکانیزم‌های EEG در کاربردهای BCI فراهم کند. به دلیل اینکه سیگنال‌های EEG غیرایستا هستند، روشهایی که این سیگنال‌ها را در حوزه فرکانس بررسی می‌کنند چندان موفق نیستند. اما تکنیک‌هایی که در حوزه زمان یا حوزه زمان-فرکانس به استخراج ویژگی می‌پردازند، می‌توانند نتایج

¹ Common Spatial Pattern

² Euclid Distance

³ Cosine Distance

⁴ CityBlock Distance

⁵ Chebishev

امیدوارکننده‌ای را تولید کنند [۲۸،۲۹]. در این فصل روش‌هایی را برای استخراج ویژگی از مؤلفه‌های زمانی سیگنال‌های EEG معرفی خواهیم کرد.

استخراج ویژگی خلاصه می‌شود به توصیف و اندازه‌گیری داده با دقت کافی که برای یک مسئله دسته بندی نیاز است. در این فرایند، ابعاد بالا و داده زائد به مجموعه‌ای کاهش یافته از بردارهای ویژه انتقال می‌یابد. در کاربردهای BCI چندین روش استخراج ویژگی، وابسته به الگویی که روی آن کار می‌شود، مورد استفاده قرار می‌گیرند. مثلاً برای کاربرد مبتنی بر P300، یک حد آستانه ولتاژ در یک زمان آنی بخصوص ممکن است یک ویژگی باشد، و در یک کاربرد مبتنی بر SMR، خصوصیات فرکانس سیگنال در یک باند بخصوص ممکن است پراهمیت‌تر باشد. در این پژوهش به منظور توصیف اطلاعات زمانی سیگنال‌های EEG و استخراج ویژگی مناسب که همزمان هم حاوی اطلاعات زمانی مناسب و کاهش یافته برای عمل دسته‌بندی باشد، و هم قابلیت حذف مصنوعات اضافه‌شده به سیگنال را داشته باشد، دو تکنیک CSP و PCA بررسی و پیاده‌سازی شده و قدرت آنها در جداسازی با یکدیگر مقایسه می‌شود. در این فصل این تبدیلات خطی، معرفی شده و معادلات ریاضی آنها آورده می‌شود.

۳-۲- کاهش ابعاد داده جهت حذف مصنوعات اضافه شده به سیگنال

داده EEG می‌تواند دارای ناخالصی‌هایی باشد که در طی فرایند ثبت به آن اضافه شده باشد. این ناخالصی‌ها توسط منابع خارج از مغز تولید می‌شوند، از قبیل پلک‌زدن، حرکت ماهیچه‌های اطراف چشم که نزدیک الکترودها اتفاق بیفتد، سیگنال تپش قلب که از طریق رگ‌های خونی منتشر می‌شود و سایر منابع تولید نویز. تکنولوژی بهبود سیگنال می‌تواند مصنوعات اضافه شده به سیگنال EEG از قبیل نویز خطی را بهبود دهد. شناسایی مصنوعات پلک‌زدن و حرکت چشم عموماً توسط شناسایی یک ولتاژ که در کانال EOG از یک حد آستانه‌ای بالاتر رود، عموماً $100\mu s$ ، انجام می‌شود. دیگر

مصنوعات، یا عموماً نادیده گرفته می شوند و یا توسط یک فرد آگاه به صورت دستی علامت زده و حذف می شوند.

در این پژوهش ویژگی‌های CSP و PCA برای جداسازی و حذف سیگنال نویز از فعالیت مغزی مطلوب به کار رفته‌اند. این روش‌ها، با کاهش ابعاد داده می‌توانند تا حد زیادی ناخالصی‌هایی را که از منابع سیگنالی اطراف توسط الکترودها ثبت شده‌است، را کاهش دهند. همچنین با کاهش ویژگی‌ها می‌توانند فرایند دسته‌بندی را سریع‌تر و آسان‌تر نمایند. روش PCA فرض می‌کند که سیگنال‌ها از نظر زمانی و فضایی غیرجمع پذیرند. در یک تکنیک PCA که از [۳۰] SVD استفاده می‌کند، برای اینکه یک سیگنال مصنوع توسط SVD قابل جداسازی باشد، باید پراکندگی زیادی داشته باشد و یا با دیگر اجزاء ترکیب شود. برای مصنوع پلک‌زدن این شرط ممکن است در بعضی دامنه‌های بزرگ دیده شود، اما SVD عموماً در حذف دیگر سیگنال‌های مصنوع کم‌دامنه موفق نخواهد بود. در این پژوهش از PCA از نوع کواریانس استفاده شده است. در ادامه روش‌های استخراج ویژگی PCA، CSP، و ویژگی ماکزیمم و میانگین به کار رفته در این مطالعه معرفی می‌شوند.

۳-۲-۱- الگوهای فضایی مشترک (CSP)

یکی از موفق‌ترین شیوه‌ها برای تشخیص الگوهای مغزی، روش الگوهای فضایی مشترک (CSP) است که توسط مولر- گرکینگ طرح ریزی شده است [۳۱]. CSP یک تبدیل خطی را برای تصویر کردن داده EEG چندکاناله به یک زیرفضای فاصله‌ای با ابعاد کم به کار می‌برد. این تبدیل می‌تواند تغییرات ماتریس‌های سیگنال دو کلاسه را ماکزیمم کند. روش CSP مبتنی بر قطری‌سازی ماتریس‌های کواریانس کلاس‌ها است. در واقع CSP با ترکیب خطی سیگنال از همه کانال‌ها، واریانس را برای یک کلاس خاص ماکزیمم کرده و برای بقیه مینیمم می‌کند. بنابراین این روش در مواقعی که داده خیلی متراکم باشد (به دلیل زیاد بودن تعداد کانال‌ها)، و یا مواقعی که تعداد داده‌های آموزشی خیلی کم باشد، ناموفق خواهد بود. از طرفی این الگوریتم به مصنوعات اضافه شده به سیگنال که از منابع بیرونی

نشأت می‌گیرند، حساس است. زیرا در این الگوریتم ماتریس کواریانس محاسبه می‌شود که این ماتریس به مصنوعات حساس است، اگرچه مقدار آن ناچیز باشد [۳۲]. بنابراین در این مطالعه روشی پیشنهاد می‌شود که با پنجره کردن سیگنال و حذف پنجره‌های نویزی، سعی در بالا بردن دقت دسته‌بندی دارد. این روش ابتدا سیگنال را پنجره می‌کند و سپس بر روی هر پنجره به صورت جداگانه CSP را اعمال می‌کند. سپس بردار ویژگی نهائی را از کنار هم گذاشتن این ویژگی‌ها بدست می‌آورد [۳۳]. با حذف پنجره‌های زائد دقت ویژگی‌های استخراج شده توسط CSP بالا می‌رود و می‌توان از آنها برای دسته‌بندی با اطمینان بالا استفاده کرد. یکی از مهمترین عواملی که باعث استفاده وسیع این نوع ویژگی در کاربردهای BCI شده است، علاوه بر نرخ موفقیت (TP) بالای آن، کاهش چشمگیر داده‌ها است. زیرا سیگنال دارای حجم وسیعی از داده است، بنابراین روشی که بتواند از این حجم وسیع، ویژگی‌های مناسب را که به خوبی بیانگر آن سیگنال باشند، استخراج نماید، بسیار عالی خواهد بود. تعداد ویژگی‌های استخراج شده وابسته به تعداد الگوهای فضائی انتخاب شده است. این الگوهای فضائی، بردارهای ویژه ای هستند که جهت پراکندگی داده‌ها را به خوبی مشخص می‌کنند. تعداد ویژگی‌ها دو برابر تعداد الگوهای فضائی انتخاب شده است. بنابراین تعداد کل ویژگی‌ها برابر است با:

$$N = 2 * M * W \quad (۱-۳)$$

در این رابطه M بیانگر تعداد الگوهای فضائی است و W تعداد پنجره‌ها را نشان می‌دهد.

در ابتدا CSP برای تشخیص مسائل دوکلاسی طرح‌ریزی شد، سپس مولر گرکینگ بسط چندکلاسه CSP را که مبتنی بر دسته بندی دوتائی و رأی‌گیری است، پیشنهاد داد [۳۴]. دورن هگ نیز دو الگوریتم جدید برای CSP چندکلاسه پیشنهاد داد که دقت دسته بندی را بهبود داد [۳۵]. بسط چندکلاسه CSP می‌تواند یکی از مشکل ترین مسائل را در BCI حل کند. در مرجع [۳۶] یک الگوریتم جدید برای CSP سه کلاسه پیشنهاد شده است که می‌تواند مستقیماً در چندکلاسه به کار

برده شود. در این پایان نامه آن را به پنج کلاسه تعمیم داده‌ایم که در ادامه، بیان ریاضی وار این الگوریتم را بیان می‌کنیم.

۳-۲-۱-۱- اسلوب CSP دو کلاسه

برای اینکه بتوانیم روش CSP را بر مسائل دو کلاسه اعمال کنیم، باید مراحل زیر را دنبال کنیم:

۱. ابتدا ماتریس‌های EEG هر کلاس را تحت دو ماتریس X_a و X_b با ابعاد $N \times K$ تفکیک می‌کنیم، که در آن N تعداد کانال‌ها و K تعداد نمونه‌ها در بازه زمانی مربوط به هر کانال است. سپس ماتریس کواریانس فضائی سیگنال EEG را برای هر کلاس به صورت زیر محاسبه می‌کنیم.

$$R_a = \frac{X_a X_a^i}{\text{Trace}(X_a X_a^i)} \quad R_b = \frac{X_b X_b^i}{\text{Trace}(X_b X_b^i)} \quad (2-3)$$

در اینجا تابع $\text{Trace}(X_a)$ برابر با مجموع عناصر قطری ماتریس X_a است.

۲. گام بعد محاسبه ماتریس کواریانس فضائی مرکب است. اگر متوسط کواریانس نرمالیزه شده یعنی $\overline{R_a}$ و $\overline{R_b}$ را توسط متوسط‌گیری از همه آزمایشات^۱ هر کلاس بدست آوریم، در آن صورت کواریانس فاصله‌ای مرکب می‌تواند به صورت زیر فاکتورگیری شود:

$$R = \overline{R_a} + \overline{R_b} = U_0 \Sigma U_0^t \quad (3-3)$$

که در اینجا Σ ماتریس قطری از مقادیر ویژه است و U_0 ماتریس بردارهای ویژه است.

۳. ماتریس تبدیل سفید کردن، برای حذف ویژگی‌های وابسته، به صورت زیر به کار می‌رود:

$$P = \Sigma^{-1/2} U_0^t \quad (4-3)$$

حال برای حذف ویژگی‌های وابسته ماتریس کواریانس، میانگین را به صورت زیر سفیدسازی می‌کنیم:

¹ trial

$$S_a = P \overline{R_a} P^t \quad (5-3)$$

۴. S_a و S_b بردارهای ویژه یکسانی را به اشتراک می‌گذارند و مجموع مقادیر ویژه منطبق برای دو ماتریس همیشه برابر با یک خواهد بود:

$$S_a = U \Sigma_a U^t \quad S_b = U \Sigma_b U^t \quad (6-3)$$

$$\Sigma_b + \Sigma_a = 1 \quad (7-3)$$

بردارهای ویژه منطبق با بیشترین مقادیر ویژه S_a ، دارای کمترین مقادیر ویژه برای S_b هستند و به صورت معکوس. تبدیل EEG سفیدشده بر روی بردارهای ویژه منطبق با بیشترین مقادیر ویژه موجود در Σ_a و Σ_b برای واریانس جداسازی دو ماتریس سیگنال بهینه است.

۶. ماتریس تصویرکننده W به صورت زیر مشخص می‌شود:

$$W = U^t P \quad (8-3)$$

۷. با داشتن ماتریس تصویرکننده W ، ماتریس EEG اولیه می‌تواند به اجزاء غیرجمع‌پذیر تبدیل شود.

$$Z = WX \quad (9-3)$$

Z می‌تواند به عنوان اجزاء منبع EEG، شامل اجزاء مشترک و مخصوص هر کلاس باشد.

۸. بنابراین داده EEG اولیه X می‌تواند توسط رابطه زیر بازسازی شود:

$$X = W^{-1} Z \quad (10-3)$$

در این رابطه W^{-1} معکوس ماتریس W است. ستون‌های W^{-1} الگوهای فضائی هستند که می‌توانند به عنوان بردارهای توزیع منبع در نظر گرفته شوند. اولین و آخرین ستون، مهمترین الگوهای فضائی

هستند که بزرگترین تغییرپذیری یک کلاس و کوچکترین تغییرپذیری دیگر کلاسها را توضیح می‌دهند.

۳-۲-۱-۲- تعمیم CSP برای کلاسه‌بندی پنج کلاسه

با تئوری اینکه دسته بندی دو کلاسی با چند کلاسی یکسان است، الگوریتم جدیدی در مرجع [۳۶] برای سه کلاسه پیشنهاد شده است. با توجه به این الگوریتم و بدون از دست دادن عمومیت، الگوریتمی را برای نوع پنج کلاسه مشتق خواهیم کرد.

ابتدا ماتریس‌های EEG را تحت وضعیت پنج ماتریس X_a, X_b, X_c, X_d و X_e با ابعاد $N \times K$ تفکیک می‌کنیم که N تعداد کانال‌ها و K تعداد نمونه‌های زمانی است. سپس ماتریس کواریانس فضائی سیگنال EEG را برای هر کلاس، به صورت زیر محاسبه می‌کنیم:

$$R^{(i)} = \sum_{k=1}^K (x_k^{(i)} - \frac{1}{K} \sum_{k=1}^K x_k^{(i)}) \quad (۱۱-۳)$$

در اینجا $x_k^{(i)}$ یک بردار N بعدی در زمان k است و i کلاس‌های a, b, c, d و e را بیان می‌کند. ماتریس‌های کواریانس نرمال شده به صورت زیر هستند:

$$R_i = \frac{1}{l} \sum_{i=1}^l \frac{R^{(i)} R^{(i)}}{\text{Trace}(R^{(i)} R^{(i)})} \quad (۱۲-۳)$$

در این رابطه R ماتریس کواریانس نرمال شده است و l تعداد آزمایشات را بیان می‌کند. R' ترانهاده ماتریس R را بیان می‌کند. همانند CSP دوتایی، ماتریس کواریانس مرکب را می‌توانیم به صورت زیر بسازیم:

$$R = R_a + R_b + R_c + R_d + R_e \quad (۱۳-۳)$$

حال بردارهای ویژه و مقادیر ویژه ماتریس R را استخراج می‌کنیم:

$$R = U_0 \Sigma U_0^T \quad (۱۴-۳)$$

سپس ماتریس Whitening را با فرمول زیر محاسبه می‌کنیم:

$$W = \Sigma^{-\frac{1}{2}} U_0^T \quad (۱۵-۳)$$

برای استخراج الگوهای فضایی مشترک مربوط به کلاس a، ابتدا R'_a را با استفاده از ماتریس کواریانس سایر کلاس‌ها بدست می‌آوریم:

$$R'_a = R_b + R_c + R_d + R_e \quad (۱۶-۳)$$

حال همانند روش دو کلاسی، ماتریس‌های کواریانس تبدیل شده S_a و S'_a را برای کلاس a می‌توانیم به صورت زیر ارزیابی کنیم:

$$S_a = W R_a W^T \quad (۱۷-۳)$$

$$S'_a = W R'_a W^T \quad (۱۸-۳)$$

بر طبق شاخص آمار، S_a و S'_a بردارهای ویژه مشترک را به اشتراک می‌گذارند، و مجموع مقادیر ویژه منطبق با این ماتریس‌ها برابر با مقدار یک خواهد شد. بنابراین S_a و S'_a می‌توانند به صورت زیر تجزیه شوند:

$$S_a = U \Sigma_a U^T \quad (۱۹-۳)$$

$$S'_a = U \Sigma'_a U^T \quad (۲۰-۳)$$

که در آن شرط روبرو برقرار است:

$$\Sigma_a + \Sigma'_a = I \quad (۲۱-۳)$$

در نتیجه توسط ماتریس تصویر W خواهیم داشت:

$$SF_a = UW \quad (22-3)$$

SF_a می‌تواند به عنوان فیلتر فضایی یک کلاس دیده شود. فرض کنید بردارهای ویژه U به صورت نزولی نسبت به مقادیر ویژه Σ_a مرتب شده باشند (یا به صورت افزایشی نسبت به Σ_a'). حال وقتی کلاس a و a' هر دو در اولین بردار ویژه U_1 ضرب می‌شوند، در اینصورت کلاس a سبب بیشینه واریانس و کلاس a' سبب مینیمم واریانس می‌شود. در حالیکه هنگامی که کلاس‌ها در آخرین بردار ویژه U_N ضرب می‌شوند، در اینصورت کلاس a موجب مینیمم واریانس و کلاس a' موجب بیشینه واریانس می‌شود. بنابراین، نگاشت هر یک از آزمایشات $^1 EEG$ را به صورت زیر بدست می‌آوریم:

$$Z_a = SF_a X_a \quad (23-3)$$

در عمل، تنها تعداد کمی از بردارهای ویژه انتخاب می‌شوند، یعنی $U_m = (U_1, \dots, U_m, U_{N-m+1}, \dots, U_N)$ که در اینجا m کوچک است ($m \ll N$). در نتیجه خواهیم داشت:

$$SF_a^s = U_m W \quad (24-3)$$

ماتریس تصویر شده نهایی به صورت زیر تعریف می‌شود:

$$Z_a^s = SF_a^s X_a \quad (25-3)$$

همانند بالا، می‌توانیم بردارهای $Z_e^s, Z_d^s, Z_c^s, Z_b^s, Z_a^s$ را که منطبق بر شرطهای متفاوت از a, b, c, d و e هستند، بدست آوریم. به این ترتیب می‌توانیم هر یک از الگوهای فضایی را بدست آوریم. برای استخراج ویژگی جهت دسته بندی، لگاریتم تبدیل یافته واریانس نرمال شده Z را محاسبه می‌کنیم:

¹ Trial

$$f_i^k = \log\left(\frac{\text{var}(Z_{pi}^k)}{\sum_{p=1}^{2m} \text{var}(Z_p)}\right) \quad (3-26)$$

هر سطر از ماتریس f_i^k یکی از داده‌های کاهش‌یافته مرتبط با i امین کلاس است. تعداد ویژگی‌های کاهش‌یافته دو برابر بردارهای ویژه انتخاب شده است (آرگومان m).


۳-۲-۱-۳- روش پیشنهادی برای استخراج ویژگی با استفاده از CSP

در این مطالعه از روش CSP پنج‌کلاسه برای استخراج ویژگی مناسب از مؤلفه‌های زمانی سیگنال‌های EEG استفاده شده است. به دلیل حجم بالای مؤلفه‌های زمانی سیگنال، ابتدا سیگنال را به صورت ایستا پنجره‌بندی می‌کنیم و سپس با اعمال CSP بر روی هر یک از این پارتیشن‌ها، ویژگی‌های مناسب را برای هر یک از آنها استخراج می‌کنیم. پس از اینکه ویژگی‌های مناسب از هر یک از پنجره‌ها بدست آمد، باید یک بردار ویژگی واحد را برای هر یک از سیگنال‌ها بدست آوریم. بنابراین از کنار هم قرار دادن بردارهای ویژگی هر یک از پنجره‌ها بردار ویژگی نهائی را بدست می‌آوریم. در شکل (۳-۱) چگونگی ساختن بردار ویژگی نهائی را مشاهده می‌کنید. در این شکل CSP_i نشان‌دهنده بردار ویژگی استخراج شده از پنجره i ام می‌باشد. همانطور که می‌بینید طول بردار ویژگی استخراج شده از حاصلضرب تعداد پنجره‌ها در تعداد ویژگی‌های استخراج شده از هر پنجره است. تعداد ویژگی‌های استخراج شده نیز برابر با دو برابر تعداد بردارهای ویژه انتخاب شده است. بنابراین اگر تعداد بردارهای ویژگی انتخاب شده d باشد، با داشتن n پنجره، بردار ویژگی نهائی برابر با $2 \times d \times n$ خواهد بود.


CSP1	CSP2	CSP3	...	CSPn
------	------	------	-----	------

شکل (۳-۱) طریقه ساخت بردار ویژگی نهائی با استفاده از اعمال CSP بر روی هر پنجره


یکی از پارامترهائی که در CSP مطرح می‌شود، انتخاب تعداد الگوهای فضائی یا همان m است. همانطور که گفتیم اولین و آخرین الگوهای فضائی هر کلاس مهمترین الگوهای فضائی هستند و بزرگترین تغییرپذیری یک کلاس و کوچکترین تغییرپذیری دیگر کلاس‌ها را توضیح می‌دهند. اما برای انتخاب یک بردار ویژه، باید به مقدار ویژه متناظر با آن توجه کنیم. در واقع باید در نظر داشته باشیم که اگر بردارهای ویژه متناظر با یک مقدار ویژه خیلی کوچک را انتخاب کنیم، در نتیجه نهائی تاثیر منفی می‌گذارد. اما اگر مقادیر ویژه را مرتب کنیم خواهیم دید که در همان ابتدا یک کاهش شدید را از خود نشان می‌دهند. در این مطالعه تعداد الگوهای فضائی $m=2$ و $m=3$ آزموده شده است. در شکل (۲-۳) (الف) سیگنال‌های EEG مربوط به پنج تصور ذهنی را مشاهده می‌کنید. در قسمت (ب) و (ج) این سیگنال‌ها توسط روش CSP به ترتیب با انتخاب دو و سه الگوی فضائی، به ویژگی‌های مفید و مرتبط کاهش یافته‌اند، که در این حالت از هر پنجره به ترتیب چهار و شش ویژگی استخراج خواهد شد.



(الف)



(ب)



(ج)

شکل (۲-۳) پنجره کردن سیگنال و استخراج ویژگی‌های مناسب از هر پنجره توسط روش CSP، (الف) سیگنال اصلی مربوط به پنج تصور ذهنی (ب) انتخاب دو الگوی فضایی (ج) انتخاب سه الگوی فضایی

۳-۲-۲- تحلیل مؤلفه‌های اصلی (PCA)

PCA یک تکنیک سنتی کاهش ابعاد است که توسط پیرسون در سال ۱۹۰۱ ابداع شده است [۳۷] و کاربردهایی در تحقیقات BCI دارد [۳۸]، [۳۹]. PCA یک تابع ریاضی است که یک تبدیل متعامد را برای تبدیل مجموعه‌ای از مشاهدات با متغیرهای همبسته، به یک مجموعه از مقادیر با متغیرهای غیرهمبسته، که مؤلفه‌های اصلی^۱ نامیده می‌شوند، به کار می‌برد. تعداد این مؤلفه‌های اصلی کمتر و یا مساوی با متغیرهای اصلی است. این تبدیل در روشی تعریف می‌شود که اولین مؤلفه اصلی دارای بالاترین واریانس ممکن است و سبب بالاترین تغییرپذیری ممکن در داده‌ها می‌شود. هر یک از اجزای بعدی به نوبت، بالاترین واریانس ممکن را دارند، با این محدودیت که باید متعامد یا غیرجمع شونده با اجزای قبلی باشند. با به کارگیری PCA، داده از فضای d بعدی (d تعداد ویژگی‌ها است) به یک فضای ویژگی با ابعاد کمتر (k)، تصویر می‌شود. هر داده در ابعاد جدید از ترکیب k بردار ویژه تشکیل می‌شود و در این روش اطلاعات ویژگی‌ها نگه داشته می‌شود. روش PCA به مقیاس‌گذاری مرتبط با متغیرهای اصلی حساس است و انتخاب تعداد مؤلفه‌های اصلی یعنی k در نتیجه آخر تأثیر مستقیم دارد [۴۰].


۳-۲-۲-۱- روش پیشنهادی کاهش ویژگی توسط PCA

در این پژوهش از PCA برای استخراج ویژگی مناسب استفاده کرده‌ایم. ابتدا باید سیگنال‌های EEG آموزشی را به صورت بردارهایی که برای تحلیل PCA مناسب باشند، درآوریم. چون باید PCA را بر روی هر پنجره به صورت مجزا اعمال کنیم، ابتدا پنجره i ام از سیگنال را به صورت برداری درمی‌آوریم. این پنجره شامل هفت کانال می‌باشد. بنابراین داده‌های این هفت کانال را در کنار هم قرار داده و بردار ویژگی اولیه را بدست می‌آوریم. سپس هر یک از این بردارهای آموزشی را در هر یک از

^۱PC

ستون‌های ماتریس اولیه p قرار می‌دهیم. بنابراین تعداد ستون‌های این ماتریس برابر با تعداد داده‌های آموزشی و تعداد سطرهای آن برابر با طول بردار ویژگی اولیه (d) می‌باشد. حال PCA را بر روی آن اعمال می‌کنیم [۴۱]. نتیجه بردارهای ویژگی کاهش یافته از پنجره مربوط خواهند بود. از کنار هم قرار دادن بردارهای ویژگی استخراج شده از هر پنجره، بردار ویژگی نهایی ساخته می‌شود. طول بردار ویژگی نهایی برابر با ضرب تعداد پنجره‌ها در تعداد ویژگی‌های استخراج شده از هر پنجره خواهد بود.


در شکل (۳-۳) سیگنال‌های اصلی و سیگنال‌های کاهش یافته توسط PCA را در پنجره کردن ۲۵ تایی را مشاهده می‌کنید. با انتخاب دو بردار ویژه به عنوان جهت‌های اصلی، طول بردار ویژگی 50 بدست می‌آید.



شکل (۳-۳) (الف) سیگنال EEG مربوط به پنج کار ذهنی، (ب) استخراج ویژگی مناسب توسط روش PCA با انتخاب ۲ بردار ویژه بهتر

انتخاب بردارهای ویژه بستگی به مقادیر ویژه متناظر دارد. زیرا اگر ماتریس مقادیر ویژه را که قطری است، به صورت نزولی مرتب کنیم مشاهده خواهیم کرد که از یک نقطه به بعد این مقادیر بسیار کوچک می‌شوند و قابل صرفنظر کردن هستند. بنابراین تنها بردارهای ویژه‌ای انتخاب می‌شوند که مقادیر ویژه متناظر با آنها به قدر کافی بزرگ باشند. این بردارها اصلی‌ترین جهت داده‌ها را نشان می‌دهند. در شکل (۴-۳) توزیع داده‌ها را به ترتیب حول ۲ و ۳ بردار ویژه انتخاب شده، می‌بینید.

همانطور که می‌بینید، با انتخاب دو بردار ویژه جهت اصلی داده‌ها کاملاً مشخص است، و بنابراین انتخاب دو بردار ویژه بهترین انتخاب خواهد بود.



شکل (۳-۴) توزیع داده‌ها حول مؤلفه‌های اصلی در روش PCA. (الف) انتخاب بردارهای ویژه اول و دوم به عنوان مؤلفه‌های اصلی (ب) انتخاب بردارهای ویژه اول و دوم و سوم به عنوان مؤلفه‌های اصلی

۳-۲-۳- ویژگی ماکزیمم و میانگین^۱

در بسیاری از کاربردهای پردازش سیگنال همچون سیستم پردازش خودکار سیگنال EEG، نیاز به پنجره‌بندی سیگنال EEG به فریم‌های تشکیل‌دهنده آن است [۴۲-۴۴]. در این کاربردها پنجره‌کردن پنجره‌کردن سیگنال می‌تواند دقت عملکرد روش‌های پردازش سیگنال EEG را بهبود بخشد. در این پایان‌نامه روشی برای استخراج ویژگی پیشنهاد کرده‌ایم، که ابتدا سیگنال را به حوزه زمان برده و آن را به روش ایستا، پنجره می‌کند. سپس به ازای هر پنجره یک ویژگی را به عنوان نماینده آن پنجره استخراج می‌کنیم. در استخراج ویژگی ماکزیمم، به ازای هر پنجره بیشترین مقدار سیگنال را محاسبه کرده و آن را به عنوان ویژگی استخراج شده از آن پنجره در نظر می‌گیریم. برای تشکیل بردار ویژگی نهائی، ویژگی‌های بدست آمده از تمامی پنجره‌ها را در کنار هم قرار می‌دهیم و یک بردار ویژگی نهائی واحد به طول تعداد پنجره‌ها بدست می‌آوریم. برای استخراج ویژگی میانگین نیز به همین ترتیب عمل

¹ Maximum and Median Feature

می‌کنیم، با این تفاوت که در هر پنجره، میانگین سیگنال را به عنوان ویژگی استخراج شده از آن پنجره در نظر می‌گیریم.

این روش را با تعداد پنجره‌های متفاوت آزمایش کرده و نتایج را مقایسه خواهیم کرد. ابتدا سیگنال را به ۲۰ پنجره تقسیم کرده و بردار ویژگی به طول ۲۰ بدست می‌آوریم. سپس در مراحل بعد آن را با ۲۵، ۵۰، ۱۰۰ و ۱۲۵ پنجره نیز آزمایش نمودیم.

۳-۳- روش پیشنهادی برای فازی کردن

برای دسته‌بندی سیگنال‌های EEG، یک روش استفاده از فازی کردن است. برای فازی کردن یک سیگنال در حوزه زمان، می‌توان شدت ولتاژ در هر پنجره زمانی را به عنوان ویژگی در نظر بگیریم. روش پیشنهادی در این مطالعه این است که پس از تقسیم سیگنال به پنجره‌هایی با طول یکسان، ویژگی‌های ماکزیمم را از هر پنجره استخراج می‌کنیم. بنابراین برای هر سیگنال یک بردار ویژگی به طول تعداد پنجره‌ها خواهیم داشت. در واقع هر یک از این ویژگی‌ها شدت ولتاژ سیگنال را در هر پنجره نشان می‌دهند. سپس برای فازی کردن، وابسته به شدت ولتاژ هر ویژگی، عددی بین ۱ تا ۳ را به آن نسبت می‌دهیم. در اینجا عدد ۱ (low) شدت ولتاژ پائین، عدد ۲ (mid) شدت ولتاژ متوسط، عدد ۳ (high) شدت ولتاژ بالا را نشان می‌دهند. برای این کار، ابتدا بازه‌ای را برای این سه low، mid، high تعریف می‌کنیم و سپس شدت ولتاژ هر پنجره را بر اساس بازه‌ای که در آن قرار می‌گیرد، طبقه‌بندی می‌کنیم. البته می‌توان تعداد این بازه‌ها را بیشتر در نظر گرفت تا نتیجه کار دقیق‌تر شود.


۳-۴- دسته بندی

دسته بندی یعنی نسبت دادن یک کلاس به هر یک از بردارهای ویژگی که توسط اندازه‌گیری از هر یک از سمپل‌های یک مسئله خاص بدست آمده‌اند. این نسبت دادن کلاس می‌تواند با یک روش

یادگیری بانظارت یا بدون نظارت انجام شود. در یادگیری بدون نظارت، هیچ اطلاعاتی در مورد برچسب‌های کلاس‌های اندازه‌گیری شده قابل دسترس نیست. اما در یادگیری با نظارت، یک مجموعه داده وجود دارد که در آن اندازه‌گیری‌ها دارای برچسب هستند. در یک فرایند یادگیری با نظارت، مجموعه داده به دو دسته آموزش و تست تقسیم می‌شود. با به کارگیری مجموعه آموزشی، یک کلاسه‌بند ساخته می‌شود. سپس کارایی کلاسه‌بند با به کارگیری مجموعه داده تست ارزیابی می‌شود. پس از بهینه‌سازی، کلاسه‌بند آماده است تا برچسب‌های کلاس را به ویژگی‌های با برچسب نامعلوم نسبت دهد [۴۵]. در BCI‌های از نوع شناسایی الگو، بیشتر یادگیری با نظارت ترجیح داده می‌شود. در این مطالعه، به منظور نشان دادن کارایی ویژگی‌های پیشنهاد شده در کاربردهای BCI، انواع روش‌های کلاسه‌بند با نظارت، معرفی شده و قدرت آنها در دسته‌بندی با یکدیگر مقایسه خواهد شد.

۳-۴-۱- شبکه‌های عصبی پرسپترون چندلایه (MLP)

شبکه‌های عصبی مصنوعی (ANN) از الگوریتم‌های کلاسه‌بند غیرخطی هستند. در این مطالعه یک شبکه عصبی چندلایه روبه‌جلو (MLP) با یک لایه مخفی پیاده‌سازی شده است. این شبکه دو وجه عملیات دارد. اولین آن وجه جلورونده است، که متشکل از بیان یک الگو توسط نودهای ورودی و عبور سیگنال‌ها از طریق شبکه به منظور گرفتن خروجی است. وجه دوم عملیات یادگیری است که متشکل است از بیان الگوهای ورودی و یافتن پارامترهای شبکه (وزن‌ها)، به نحوی که فاصله بین خروجی محاسبه شده و خروجی مطلوب مینیمم شود. در شکل (۳-۵) قسمتی از یک شبکه MLP با یک لایه مخفی را مشاهده می‌کنید.



شکل (۵-۳) بخشی از شبکه عصبی MLP

۳-۴-۲ استفاده از LDA جهت کلاسه‌بندی

تحلیل مجزاساز خطی یا LDA یک تکنیک مشهور کاهش ویژگی خطی است [۴۶]. این تکنیک برای یافتن یک ترکیب خطی از ویژگی‌هایی که بهتر می‌توانند جداسازی بین دو کلاس یا بیشتر را انجام دهند، به کار می‌رود. این روش نرخ واریانس بین-کلاسی به واریانس درون-کلاسی را در هر مجموعه داده ماکزیمم می‌کند و در نتیجه ماکزیمم تفکیک‌پذیری را تضمین می‌کند [۴۷]. مهمترین تفاوتی که بین LDA و PCA در کاهش ویژگی وجود دارد این است که در PCA هنگامی که داده به یک فضای متفاوت برده می‌شود، شکل و مکان مجموعه داده‌های اصلی تغییر می‌کند، در حالیکه LDA مکان را تغییر نمی‌دهد، بلکه تنها سعی می‌کند تا جداسازی بین کلاسی بیشتری را تولید کند و یک ناحیه تصمیم بین کلاس‌های داده شده ترسیم می‌کند [۴۸]، [۴۹]. به عبارتی LDA جهت‌هایی را که ماکزیمم جداسازی خطی بین کلاسی را تولید می‌کنند، می‌یابد. در این مطالعه الگوریتم LDA را برای دسته‌بندی سیگنال‌های EEG به کار برده‌ایم [۵۰]، [۵۱].

۳-۴-۳ نزدیک‌ترین همسایه (1-NN)

روش نزدیک‌ترین همسایه 1-NN یک روش کلاسه‌بند غیرخطی نسبتاً ساده است. ایده اصلی این تکنیک این است که به یک داده تست مشاهده‌نشده^۱، کلاس مربوط به نزدیک‌ترین همسایه موجود در

¹ unseen

داده آموزشی را نسبت دهیم. الگوریتم‌های KNN در کاربردهای EEG و ارتباطات BCI خیلی مشهور نیستند، شاید به این دلیل که به این شناخته شده‌اند که به فضای ویژگی با ابعاد بالا خیلی حساس هستند [۵۲]، که این باعث شکست آنها در چندین آزمایش BCI شده است [۵۳]، [۵۴]. بنابراین ممکن است در یک فضای ویژگی با ابعاد کم، یک روش مؤثر برای دسته‌بندی باشند [۵۵]. در این مطالعه برای اندازه‌گیری فاصله داده تست از داده‌های آموزشی، از معیار شباهت‌های مختلف استفاده شده است که در ادامه معرفی می‌شوند.

۳-۴-۱- معیار شباهت

کرائی الگوریتم 1-NN وابسته به انتخاب یک تابع مناسب برای اندازه‌گیری فاصله است [۵۶]. در این مطالعه فاصله بین k امین داده تست (بردار p) و j امین داده آموزشی (بردار q) هر کدام با طول n ، از طریق چهار معیار شباهت که در ادامه معرفی می‌شوند، بدست آمده‌اند.

۳-۴-۱-۱- معیار شباهت کسینوسی

معیار شباهت کسینوسی یک تابع فاصله برداری است که فاصله بین دو بردار (X, Y) را براساس زاویه بین آنها محاسبه می‌کند. این معیار شباهت که برای اولین بار توسط هیرست به کار برده شد (۱۹۹۷) [۵۷]، هنگامی به کار می‌رود که داده تنک، پراکنده و نامتقارن باشد [۵۸]. محاسبه کسینوس زاویه بین دو بردار مشخص می‌کند که آیا این دو بردار تقریباً در جهت یکسانی نقطه‌گذاری شده‌اند یا نه. نتایج معیار شباهت کسینوسی هنگامی برابر با ۱ است که زاویه اندازه‌گیری شده ۰ باشد، باشد، که در این صورت این دو بردار به جز در مقدار بزرگی‌شان، با یکدیگر یکسان هستند. هنگامی این فاصله کمتر از ۱ است که این زاویه هر مقدار دیگری داشته باشد. مقدار این معیار شباهت وقتی ۰ است که دو بردار با هم زاویه ۹۰ درجه تشکیل دهند و این یعنی اینکه آنها هیچ جمله‌ای را به

اشتراک نمی‌گذارند. این فاصله با به کارگیری یک ضرب نقطه‌ای و مقدار بزرگی به صورت زیر بیان می‌شود:

$$\text{Cosin_Metric}(k, j) = \cos \theta = \frac{p \cdot q}{\|p\| \|q\|} = \frac{\sum_{i=1}^n p_i * q_i}{\sqrt{\sum_{i=1}^n (p_i)^2} * \sqrt{\sum_{i=1}^n (q_i)^2}} \quad (28-3)$$

۳-۴-۳-۱-۲- معیار شباهت چبیشف^۱

در ریاضیات، فاصله چبیشف یا متریک ماکزیمم، متریکی است بر روی فضای برداری، که در آن فاصله بین دو بردار از اختلافشان در اروشاد هر یک از ابعاد دستگاه مختصات بزرگتر است [۵۷]. این فاصله از رابطه زیر بدست می‌آید [۵۹]:

$$D_{chebyshev}(k, j) := \max_i (|p_i - q_i|) \quad (29-3)$$

۳-۴-۳-۱-۳- فاصله اقلیدسی^۲

پرکاربردترین معیار شباهت برای اندازه‌گیری فاصله، معیار شباهت اقلیدسی است. هنگامی که داده متراکم یا پیوسته است، این فاصله بهترین معیار جهت اندازه‌گیری فاصله است. در واقع با داشتن دو بردار p و q در صفحه xy ، اگر این دو برار در راستای محورها باشند، فاصله اقلیدسی بین آنها برابر با طول وتر مثلث قائم‌الزاویه خواهد بود. این فاصله از رابطه زیر بدست می‌آید [۵۸]:

$$\text{EuclidDistance}(k, j) = \sqrt{\sum_{i=1}^n (p_i - q_i)^2} \quad (30-3)$$

¹ Chebyshev

² Euclidean Distance

۳-۴-۳-۱-۴- معیار فاصله مربعی^۱ (فاصله ماهالانوبیس)

فاصله مربعی به عنوان فاصله در محور افقی بعلاوه فاصله در محور عمودی محاسبه می‌شود [۶۰]. [۶۱]. فاصله مربعی همیشه بزرگتر و یا مساوی با صفر است. اندازه این فاصله برای نقاط همانند صفر و برای نقاطی که شباهت کمی را نشان می‌دهند، مقدار آن بالا خواهد بود. در بسیاری از موارد، این اندازه‌گیری فاصله موجب نتایجی مشابه با فاصله اقلیدسی می‌شود. توجه کنید، در فاصله مربعی، تاثیر یک اختلاف زیاد در یک مورد یک‌بعدی تضعیف می‌شود (زیرا فواصل مربعی نیستند). این فاصله از رابطه زیر محاسبه می‌شود:

$$D_{cityBlock}(k, j) = \sum_{i=1}^n |p_i - q_i| \quad (۳-۳۱)$$

^۱ City block

فصل چهارم

روش پیشنهادی

۴-۱- انتخاب ویژگی

اصطلاح انتخاب ویژگی برای اشاره به الگوریتمی به کار برده می‌شود که خروجی آن زیرمجموعه‌ای از مجموعه ویژگی‌های ورودی است. به عبارت دیگر الگوریتم‌هایی هستند که زیرمجموعه‌ای از ویژگی‌های مفید را برای استفاده در ساخت مدل انتخاب می‌کنند. هنگام به کار بردن این تکنیک فرض اصلی این است که داده شامل ویژگی‌های زائد یا ویژگی‌های بیهوده است. ویژگی‌های زائد، ویژگی‌های هستند که اطلاعات بیشتری را نسبت به ویژگی‌های انتخاب شده کنونی در اختیار قرار نمی‌دهند، و ویژگی‌های اضافی هیچ اطلاعات مفیدی را در هیچ زمینه‌ای فراهم نمی‌کنند. تکنیک‌های انتخاب ویژگی یک زیرمجموعه از زمینه کلی‌تر، یعنی استخراج ویژگی هستند. روش‌های استخراج ویژگی، ویژگی‌های جدیدی را تولید می‌کنند، در حالیکه انتخاب ویژگی زیرمجموعه‌ای از ویژگی‌ها را برمی‌گرداند. انتخاب ویژگی نه تنها با کاهش ویژگی‌ها هزینه تشخیص کلاسی را کاهش می‌دهد، بلکه در بعضی موارد می‌تواند دقت کلاسه‌بند را به دلیل تاثیر حجم کم اطلاعات و حذف ویژگی‌های وابسته و زائد، افزایش دهد. تکنیک‌های انتخاب ویژگی در زمینه‌هایی به کار می‌روند که تعداد زیادی ویژگی وجود دارد، ولی در مقابل تعداد کمی نمونه آموزشی وجود دارد [۶۲]. در این مطالعه از روش‌های انتخاب ویژگی GA، PSO و انتخاب ویژگی رو به جلو استفاده شده است.

۴-۲- حذف مصنوعات از سیگنال

داده EEG قبل از اینکه بتواند دسته‌بندی شود، نیاز به کاهش ابعاد دارد، تا تجسم و بیان آن آسان شود. همچنین یک همبستگی بین کانال‌های مختلف می‌تواند وجود داشته باشد، که این همبستگی‌ها ممکن است از نظر زمانی تفکیک‌پذیر باشند. در نتیجه با حذف ویژگی‌های وابسته، می‌توان قدرت کلاسه‌بند را افزایش داد [۶۳]. همچنین به دلیل بالا بودن حجم سیگنال در مدل اجزاء زمانی و در

مقابل کم بودن نمونه‌های آموزشی، الگوریتم‌های انتخاب ویژگی با انتخاب بهترین پنجره‌ها، می‌توانند در نرخ موفقیت کلاسه‌بند بسیار مؤثر باشد.

دلیل دیگر برای کاهش ویژگی‌ها این است که ممکن است سیگنال‌های EEG نویزی باشند. ناخالصی داده EEG می‌تواند در نقاط زیادی در طی فرایند ثبت اتفاق بیفتد. این ناخالصی‌ها می‌توانند توسط منابع خارج از مغز تولید شوند [۶۴]. همچنین به دلیل اینکه فعالیت الکتریکی مغز از طریق حجم سر منتشر می‌شود، امکان همبستگی زیاد وجود دارد. کاهش ابعاد ممکن است این همبستگی‌ها را حذف کند [۶۳]. تکنولوژی بهبود سیگنال می‌تواند مصنوعات اضافه شده به سیگنال EEG از قبیل نویز خطی را بهبود دهد. اما حذف مصنوعات باید پس از فرایند ثبت انجام شود.

۴-۲-۱ رایج‌ترین مصنوعات EEG

در ادامه رایج‌ترین مصنوعات EEG توصیف خواهند شد و فرم موجی آنها نشان داده می‌شود [۶۵].


۴-۲-۱-۱ مصنوع پلک زدن

نویز اضافه شده به داده EEG توسط پلک زدن، خیلی مرسوم است. این مصنوع یک سیگنال با دامنه زیاد تولید می‌کند که می‌تواند چندین برابر بزرگتر از سیگنال‌های EEG مطلوب باشد (شکل (۴-۱)). یک عمل پلک‌زدن به دلیل دامنه زیاد آن می‌تواند داده همه الکترودها را خراب کند، حتی الکترودهائی که پشت سر نصب می‌شوند (شکل (۴-۲)). مصنوعات چشم اغلب مستقیماً توسط الکترواوکولارگرام^۱ (EOG)، یعنی جفت الکترودهائی که بالا و اطراف چشم‌ها قرار می‌گیرند، ثبت می‌شوند. متأسفانه، این اندازه‌گیری‌ها سیگنال EEG مطلوب را آلوده می‌کنند و با وجود مدل واقعی انتشار EOG در سراسر جمجمه، حذف آنها کار ساده‌ای نیست.

¹ electrooculargram




شکل (۴-۱) مصنوع پلک زدن [۶۵]



شکل (۴-۲) داده EEG ثبت شده از کانال EOG و شش کانال دیگر

۴-۲-۱-۲- مصنوع حرکات چشم


مصنوعات حرکات چشم (شکل (۴-۳) (الف)) توسط جهت‌گیری مجدد دوقطبی قرنیه [۶۶]، [۶۷] تولید می‌شوند. انتشار این مصنوعات در سراسر مجموعه قوی‌تر از انتشار مصنوعات پلک‌زدن است. پلک‌زدن و حرکات چشم اغلب در فواصل زمانی نزدیک اتفاق می‌افتند که اثری را ایجاد می‌کنند که در شکل (۴-۳) قسمت (ب) آورده شده است.



شکل (۴-۳) (الف) مصنوع پلک زدن، (ب) اثر روی هم افتادگی مصنوعات پلک زدن و حرکات چشم [۶۵]

۴-۲-۱-۳- نویز خطی


سیگنال‌های قوی از منابع قدرت A/C نیز می‌توانند داده EEG را آلوده کنند (شکل (۴-۴)). این نویز از الکترودهای مجسمه به وسایل ثبت سیگنال انتقال داده می‌شود. این مصنوع اغلب توسط فیلترهای شکاف^۱ فیلتر می‌شود. اما برای نویز خطی و هارمونیک‌های با فرکانس پائین‌تر اغلب این روش مطلوب نیست، زیرا اگر نویز خطی یا هارمونیک‌ها در باندهای فرکانسی مطلوب اتفاق بیفتند، با داده EEG که در همان باند فرکانسی اتفاق می‌افتد، تداخل پیدا می‌کنند [۶۶]. بنابراین در این فرکانس‌ها فیلترهای شکاف ممکن است اطلاعات مفید را نیز حذف کنند. نویز خطی می‌تواند داده ثبت شده از همه الکترودها و یا از بعضی از آنها که وابسته به سرچشمه این مشکل هستند را آلوده کند.



شکل (۴-۴) نویز خطی با فرکانس 50 هرتز [۶۵]

۴-۲-۱-۴- مصنوع کنش ماهیچه‌ای

کنش ماهیچه‌ای (شکل (۴-۵)) نویزی است که می‌تواند توسط فعالیت در گروه‌های ماهیچه‌ای مختلف شامل ماهیچه‌های گردن و صورت ایجاد شود. این سیگنال‌ها یک محدوده فرکانسی عریض دارند و می‌توانند در سراسر مجموعه‌های متفاوت از الکترودها، وابسته به مکان ماهیچه‌های سرچشمه نویز، انتشار یابند.



شکل (۴-۵) مصنوع کنش ماهیچه‌ای که توسط فعالیت ماهیچه‌های صورت و گردن ایجاد می‌شود [۶۵]

¹ Notch filter

۴-۲-۱-۵- مصنوع پالس

مصنوع پالس یا تپش قلب هنگامی اتفاق می‌افتد که یک الکتروود بر روی یک رگ خونی یا نزدیک آن قرار گیرد. وسعت و انقباض رگ، تغییرات ولتاژ درون داده ثبت‌شده را نشان می‌دهد. سیگنال مصنوع، فرکانسی نزدیک ۱,۲ هرتز دارد، اما می‌تواند با حالت بیمار متفاوت باشد. این مصنوع می‌تواند به عنوان یک قله تیز و یا یک موج یکنواخت ظاهر شود. شکل (۴-۶) این مصنوع را نشان می‌دهد.



شکل (۴-۶) مصنوع پالس که از قرار گرفتن یک الکتروود کنار یا بر روی یک رگ خونی ایجاد می‌شود [۶۵]


۴-۲-۲- کارهای قبلی برای حذف مصنوعات

اولین تلاش‌ها برای حذف مصنوعات، بر روی پلک‌زدن متمرکز بود. زیرا مصنوعات پلک‌زدن و حرکت چشم عموماً توسط بالا رفتن ولتاژ از یک حد آستانه‌ای بالاتر، عموماً $100\mu s$ ، در کانال EOG، شناسایی می‌شوند. تکنیک‌های رگرسیون رایج‌ترین نوع حذف مصنوعات در کاربرد است، که با استفاده از کانال EOG در حوزه زمان فرکانس انجام می‌شود. همه این تکنیک‌ها بر روی اندازه‌گیری خالص سیگنال از سیگنال مصنوع، از طریق کم کردن آن از سیگنال ثبت‌شده EEG تکیه دارند. به دلیل اینکه سیگنال EEG با سیگنال‌های EOG آلوده می‌شود، رگرسیون مصنوعات وابسته به چشم و سایر مصنوعات اثر نامطلوبی بر حذف آنها از سیگنال‌های EEG مربوط به مشاهدات می‌گذارد. در [۶۷] یک مدل رگرسیون کلی ارائه شده است که به صورت زیر است:

$$EEG(t) = EEG(t) - \sum_{g=0}^T \beta_g EOG(t-g) \quad (۴-۱)$$

در این رابطه $EOG(t)$ و $EOG(t-g)$ ، اطلاعات EEG و EOG ثبت شده در زمان های t و $t-g$ هستند. β_g تاثیر EOG را بر روی $EOG(t)$ در زمان $t-g$ بیان می کند.

روش دیگر برای حذف مصنوعات EEG، اغلب توسط حذف پنجره های آلوده شده EEG اداره می شود. به طور کلی دو روش برای پنجره کردن سیگنال ارائه شده است. پنجره کردن با طول ثابت و پنجره کردن تطبیقی [۱۷]، [۶۸]. در پنجره کردن با طول ثابت، سیگنال مورد تحلیل به پارتیشن هایی با طول ثابت تقسیم می شود. اما در پنجره کردن تطبیقی، سیگنال مورد آنالیز با توجه به مشخصات آماری آن، از قبیل دامنه یا فرکانس، پنجره می شود که معمولاً این پنجره ها دارای طول های متفاوت با یکدیگر باشند [۱۷]. در پنجره کردن تطبیقی، پنجره هایی که شامل مصنوعات هستند، عموماً به صورت دستی بازبینی و حذف می شوند. اما در سیستم های فیلتر کردن برخط، شناسایی مصنوع به منظور حذف اتوماتیک سیگنال های مصنوع مهم است. در روش پنجره کردن به صورت ایستا خیلی کم اتفاق می افتد که مرزهای ایجاد شده توسط عمل پنجره بندی، در نقاط تغییر مشخصات آماری سیگنال، از قبیل دامنه یا فرکانس، واقع شده باشند به عنوان مثال سیگنال شکل (۴-۷) را در نظر بگیرید، این سیگنال به صورت ایستا به بیست پنجره تقسیم شده است. نقاط عمودی مرزهایی که توسط این پنجره ها ایجاد شده است، را نشان می دهد و فلش ها مرز صحیح پنجره ها را نشان می دهند که در نقاط تغییر مشخصات آماری هستند. همانطور که می بینید تنها مرزهای B4 و B2 که با فلش خط چین در روی شکل مشخص شده اند، توسط پنجره کردن ایستا تصادفاً به درستی تشخیص داده شده اند.




شکل (۴-۷) پنجره کردن ایستا و تطبیقی سیگنال‌های EEG، که مرز آنها به ترتیب با خطوط عمودی و فلش مشخص شده است [۱۷]

پس از پنجره کردن سیگنال، باید پنجره‌های حاوی نویز را شناسایی کرده و آنها را حذف نمائیم. یک روش برای شناختن اجزاء نویز، بر اندازه‌گیری ساختار سیگنال مبتنی است. برای این منظور روش‌های مبتنی بر ابعاد فرکتال و همچنین یک متریک مبتنی بر ضرایب رگرسیون اتوماتیک (AR) به کار رفته اند [۶۹]. از مطالعات دریافت شده است که پلک‌زدن و تپش قلب دارای ابعاد فرکتالی ثابتی بر روی مطالعه داده هستند [۱۷]، [۷۰]. یعنی ممکن است ساختار طیفی برای اجزاء مصنوع خاص (یعنی نویز خطی) متمایز باشد که این حذف اتوماتیک این مصنوعات را ممکن می‌سازد. فیلترکالمن و فیلترهای گسترش‌یافته کالمن نیز برای شناسایی مصنوعات با موفقیتی که بسیار وابسته به نوع آن مصنوع است، به کار رفته‌اند [۷۱]. این روش در شناختن یک پنجره یک ثانیه‌ای شامل مصنوعات حرکتی و ماهیچه موفقیت‌آمیزتر است.


۴-۳- روش پیشنهادی

همانطور که گفتیم یکی از راه‌های حذف مصنوعات این است که ابتدا سیگنال‌ها را پنجره کرده و سپس با حذف پنجره‌های آلوده، قدرت کلاسه‌بند را افزایش دهیم. از طرف دیگر هر یک از پنجره‌های زمانی مربوط به سیگنال EEG قدرت متفاوتی در دسته‌بندی کارها دارند و بعضی از این فریم‌ها نقش مهمی در دسته‌بندی ایفا نمی‌کنند. یک انتخاب مناسب از این پنجره‌ها می‌تواند توانایی کلاسه‌بند را در دسته‌بندی و تعمیم، بهبود داده و کارایی سیستم را بالا ببرد [۱۷]. و علاوه بر این حذف بعضی

پنجره‌های غیرمفید از داده EEG، می‌تواند مقدار داده در دسترس برای تحلیل، در نتیجه حجم محاسبات را به میزان زیادی کاهش دهد. در این مطالعه، از الگوریتم‌های انتخاب ویژگی روبه‌جلو، الگوریتم ژنتیک و الگوریتم بهینه‌سازی ازدحام ذرات، جهت یافتن بهترین و سازگارترین پنجره‌های یک سیگنال که حاوی کمترین آلودگی به مصنوعات باشند، به کار برده شده است. در روش پیشنهادی، ابتدا ویژگی‌های مناسب را از هر یک از پنجره‌ها استخراج کرده و سپس ویژگی‌های مربوط به پنجره‌های انتخاب شده را برای ساختن بردار ویژگی نهائی، در کنار هم قرار می‌دهیم. سپس این بردار ویژگی را به کلاسه‌بند داده، تا با دسته‌بندی سیگنال‌ها، توانائی این ترکیب از پنجره‌ها سنجیده شود. با پنجره‌کردن سیگنال‌ها به ۵۰ پنجره مساوی، قدرت جداسازی هر یک از این پنجره‌ها را در دسته‌بندی کارهای ذهنی، در شکل (۴-۹) می‌بینید.



شکل (۴-۸) نمایش اولین پنجره از سیگنال EEG برای پنج کانال متفاوت، هر کدام با اندازه ۰.۵ ثانیه و داشتن ۱۲۵ نمونه در هر پنجره



شکل (۴-۹) قدرت جداکنندگی هر یک از پنجره‌های یک سیگنال EEG برای دسته‌بندی کارهای ذهنی با در نظر گرفتن ۲۰ پنجره در دسته‌بندی با استفاده از LDA و CSP

اما مسئله اصلی چگونگی شناسایی پنجره‌های آلوده و یا نامرتبط است. در این مطالعه روشی پیشنهاد می‌شود که از طریق الگوریتم‌های بهینه‌سازی از قبیل الگوریتم ژنتیک و بهینه‌سازی ازدحام ذرات و همچنین الگوریتم انتخاب ویژگی روبه‌جلو، سعی در یافتن بهترین و سازگارترین ترکیب پنجره‌ها دارد. در این روش راه‌حل‌های مختلف با حذف تصادفی پنجره‌ها تولید می‌شود و قدرت کلاسه‌بند به ازای هر راه‌حل سنجیده می‌شود تا در نهایت راه‌حلی که بهترین نتیجه را در بر داشته باشد، گزینش شود. به عبارت دیگر این روش با به کارگیری الگوریتم‌های بهینه‌سازی سعی در یافتن و حذف پنجره‌هایی دارد که قدرت کلاسه‌بند را پایین می‌آورند.

همانطوری که گفتیم به دلیل اینکه مرزهای ایجاد شده توسط عمل پنجره‌بندی، ممکن است در نقاط تغییر مشخصات آماری سیگنال، واقع نشده باشند، پنجره‌کردن ایستا در حذف مصنوعات خیلی موفق نیست. زیرا مرزهای جداسازی سیگنال تنها به صورت تصادفی می‌تواند با مرزهای اصلی مطابقت کند. برای از بین بردن این نقص و بالا بردن کارایی الگوریتم، روش پیشنهادی را بر روی سگمنت‌های با

ابعاد مختلف آزمون می‌کنیم. در این صورت ممکن است با اعمال روش پیشنهادی بر روی پارتیشن‌های با ابعاد پائین‌تر، جواب بهتری بگیریم. البته اگر ابعاد پارتیشن‌ها را بیش از حد کوچک در نظر بگیریم، ممکن است خطای کلاسه‌بند افزایش یابد. بنابراین ابعاد پارتیشن هم یکی دیگر از پارامترهایی است که باید از طریق آزمون و خطا بهترین آن را بیابیم. در این پژوهش، الگوریتم پیشنهادی به ازای تعداد پنجره‌های متفاوت ۲۰، ۲۵، ۵۰، ۱۰۰ و ۱۲۵ و هر یک با ابعاد ۰,۴، ۰,۵، ۰,۶، ۰,۸ و ۱، ۰,۱ و ۰,۰۸ ثانیه سنجیده شده است. در ادامه روش پیشنهادی انتخاب سازگارترین و بهترین پنجره‌ها با استفاده از الگوریتم‌های انتخاب ویژگی آورده شده است.

۴-۳-۱- الگوریتم انتخاب ویژگی رو به جلو

انتخاب ویژگی فرایندی است برای انتخاب ویژگی‌های مناسب مربوط به بهترین پنجره‌ها برای ساخت مدلی که بهترین نرخ دسته‌بندی را برای سیستم فراهم نماید. برای به کارگیری الگوریتم‌های انتخاب ویژگی رو به جلو، ابتدا هر یک از سیگنال‌ها را به پنجره‌هایی با ابعاد مساوی تقسیم می‌کنیم. دو الگوریتم متفاوت برای انتخاب ویژگی رو به جلو مطرح می‌شود:

۱. الگوریتم قویا حریصانه که در آن ابتدا باید قدرت هر یک از پنجره‌ها را در جداسازی سیگنال‌ها اندازه بگیریم و سپس با مرتب کردن آنها، ویژگی‌های m تا از بهترین پنجره‌ها را انتخاب کنیم.

۲. الگوریتم حریصانه پس از ارزیابی قدرت تک تک پنجره‌ها در جداسازی، آنها را بر اساس قدرت جداسازی‌شان مرتب می‌کند. این الگوریتم سپس با انتخاب ویژگی‌های قوی‌ترین پنجره شروع کرده و سپس ویژگی‌های بهترین پنجره‌های بعدی را به ترتیب، مرحله به مرحله به ویژگی‌های پنجره‌های انتخاب‌شده قبلی اضافه می‌کند تا زمانی که قدرت کلاسه‌بند به ازای ویژگی‌های پنجره انتخاب شده بعدی کاهش یابد. در این صورت متوقف می‌شویم و به پنجره‌های انتخاب شده اکتفا می‌کنیم. در شکل (۴-۹) قدرت هر یک از پنجره‌ها در کلاسه‌بندی با استفاده از CSP و LDA را مشاهده کردید.

در شکل (۴-۱۰) نرخ موفقیت به صورت مرتب‌شده نشان داده شده‌است. در شکل (۴-۱۱) در سطر اول یک سیگنال EEG نمایش داده‌شده است و سیگنال تغییر یافته که پنجره‌های آن بر اساس نرخ موفقیت به صورت مرتب شده قرار گرفته‌اند، در سطر بعد نمایش داده‌شده است. در الگوریتم روبه‌جلو ویژگی‌های این پنجره‌ها به ترتیب انتخاب می‌شوند.

در مقایسه با الگوریتم فوق حریصانه، این الگوریتم ممکن است در زیر مجموعه‌ای از پنجره‌ها متوقف شود که اندازه آن کمتر از m است، ولی خطای داده تست کمتر از روش قویا حریصانه باشد. بنابراین الگوریتم حریصانه ممکن است با مجموعه ویژگی‌های بهتری نسبت به الگوریتم قویا حریصانه متوقف شود.

۴-۳-۱-۱- الگوریتم روبه‌جلو حریصانه برای یافتن بهترین ترکیب از پنجره‌ها

در روش پیشنهادی استفاده از الگوریتم رو به جلو، مراحل زیر باید انجام شود:

ابتدا مجموعه سیگنال‌های EEG را به P پنجره تقسیم کنید (در این مطالعه، این الگوریتم به ازای P های با مقادیر ۲۰، ۲۵، ۵۰، ۱۰۰ و ۱۲۵ آزمون شده است).

به ازای هر پنجره ویژگی‌های مناسب را استخراج کرده و بردار ویژگی مناسب را تشکیل دهید. هر سیگنال دارای P بردار ویژگی $\{X_1\}, \{X_2\}, \dots, \{X_P\}$ خواهد بود.

به ازای هر یک از پنجره‌ها عمل دسته‌بندی را برای داده‌های تست انجام دهید، و نرخ موفقیت کلاسه‌بند را به عنوان قدرت آن پنجره در جداسازی، ذخیره کنید.

پنجره‌ها را به ازای نرخ موفقیت آنها در جداسازی، به صورت $\{X_{i1}\}, \{X_{i2}\}, \dots, \{X_{ip}\}$ مرتب کنید که در اینجا X_{i1} بیان‌کننده ویژگی‌های قوی‌ترین پنجره مربوط به داده i ام است و بالاترین قدرت جداسازی را دارد و X_{ip} ویژگی‌های ضعیف‌ترین پنجره در جداسازی است.

شروع الگوریتم رو به جلو

ابتدا $\{X_{i1}\}$ را به مجموعه ویژگی‌های انتخاب شده f و اندیس مربوط به پنجره آن را به مجموعه

پنجره‌های انتخاب شده قبلی اضافه کن، یعنی $f \cup \{X_{i1}\}$

برای $j=2, 3, \dots, P$ دستورات زیر را تکرار کن:

ویژگی‌های پنجره $\{X_{ij}\}$ را انتخاب کن و با استفاده از اجتماع ویژگی‌های آن با مجموعه ویژگی


پنجره‌های انتخاب شده قبلی، عمل دسته‌بندی را انجام بده،

اگر نتیجه دسته‌بندی بهبود یافت، آنگاه ویژگی‌های $\{X_{ij}\}$ را به مجموعه ویژگی‌های انتخاب شده f و

اندیس مربوط به پنجره آن را به مجموعه پنجره‌های انتخاب شده قبلی اضافه کن، یعنی


$$f = f \cup \{X_{ij}\}$$

پایان حلقه: اگر f تغییری نکرد بیا بیرون




شکل (۴-۱۰) نرخ دسته‌بندی پنجره‌ها به صورت مرتب‌شده در پنجره‌بندی ۵۰ تایی در کلاسه‌بندی با استفاده از CSP و

LDA



شکل (۴-۱۱) سیگنال اصلی و سیگنال جدید که پنجره‌های آن بر اساس نرخ موفقیت به صورت مرتب شده قرار گرفته‌اند

یکی از معایب الگوریتم روبه‌جلو حریصانه این است که ممکن است پنجره‌ای دارای قدرت جداکنندگی بالایی نباشد و هنگام مرتب کردن پنجره‌ها در رده‌های آخر قرار بگیرد. بنابراین ممکن است قبل از اینکه نوبت به انتخاب آن برسد، الگوریتم متوقف گردد [۷۲]. راه حل پیشنهادی این است که اگر با انتخاب پنجره‌ای قدرت جداکنندگی کاهش یافت، متوقف نشویم. بلکه ویژگی‌های آن پنجره را نادیده بگیریم و پنجره‌های بعدی را نیز آزمون کنیم. بدین‌گونه شانس پنجره‌های با قدرت پایین‌تر را نیز برای انتخاب شدن آزموده‌ایم و نرخ موفقیت کلاسه‌بند افزایش می‌یابد. در شکل (۴-۱۲) بلاک دیاگرام روش پیشنهادی آورده شده است. نتایج انتخاب ویژگی بر روی سیگنال‌ها، وجود ابعاد زائد را نشان می‌دهد و نشان می‌دهد که چگونه ترکیب بهترین پنجره‌ها، به یک دقت بالاتری نسبت به دسته‌بندی با استفاده از همه پنجره‌ها منجر می‌شود.



شکل (۴-۱۲) بلاک‌دیگرام الگوریتم رو به جلو برای انتخاب سازگارترین پنجره‌ها در کلاسه‌بندی

۴-۳-۲- الگوریتم ژنتیک

الگوریتم GA یکی از قدرتمندترین الگوریتم‌های انتخاب ویژگی در هوش مصنوعی است و کاربردهای وسیعی در همه زمینه‌های علوم و فناوری دارد. این الگوریتم برای فضاهای جستجوی بزرگ، که عملاً جستجو در آن غیرممکن است، مناسب می‌باشد. این الگوریتم به صورت تصادفی فضا را جستجو کرده تا بهترین راه‌حل‌ها را تولید نماید. اما جستجوی بهترین راه‌حل می‌تواند خیلی پیچیده باشد، زیرا اینکه

در کجای فضای جستجو، باید به دنبال راه حل مطلوب باشیم و از کجا باید جستجو را آغاز نماییم، الگوریتم‌های ژنتیک را در رده مسائل NP قرار می‌دهد. اگر ارزیابی تمام این راه حل‌ها ممکن باشد، اما زمان بسیار زیادی نیاز دارد. بنابراین در این روش تنها تعداد کمی از این راه حل‌ها به صورت تصادفی توسط کروموزوم‌ها کد می‌شوند تا جمعیت اولیه را شکل دهند. سپس کروموزوم‌های بعدی را به عنوان فرایند ادامه راه حل یافته شده تولید می‌کنیم [۷۳].

۴-۳-۲-۱- روند الگوریتم پیشنهادی GA برای انتخاب سازگارترین پنجره‌ها

در این پژوهش، هدف از به کارگیری الگوریتم ژنتیک (GA) یافتن بهترین و سازگارترین پنجره‌های یک سیگنال است. اما برای انتخاب پنجره‌های یک سیگنال 2^{win} راه حل وجود دارد که بیان کننده کل راه حل‌های ممکن برای مسئله است. در اینجا win تعداد پنجره‌های یک سیگنال را نشان می‌دهد. در GA تنها تعداد کمی از این راه حل‌ها بررسی می‌شود. مثلاً اگر تعداد پنجره‌ها 20 باشد، 2^{20} یعنی 1048576 راه حل وجود دارد. اما در اینجا با در نظر گرفتن ۵۰ دوره آموزشی (epoch=50) و ۶۸ کروموزوم، تنها ۳۴۰۰ راه حل کد می‌شود. اما GA طوری این راه حل‌ها را سازماندهی می‌کند که در نهایت بهترین راه حل‌ها یافت شود. الگوریتم پیشنهاد شده به صورت زیر است:

آغاز: ابتدا جمعیت اولیه متشکل از کروموزوم‌ها که بیان کننده راه حل‌های آغازین مناسب برای مسئله هستند، به صورت تصادفی تولید می‌کنیم. طول هر کروموزوم را برابر با تعداد پنجره‌های سیگنال در نظر می‌گیریم. هر یک از این کروموزوم‌ها بیان کننده این هستند که کدامیک از پنجره‌ها از سیگنال حذف و کدامیک انتخاب شوند. این کروموزوم‌ها را به صورت باینری کد می‌کنیم. ۱ به این معنی است که پنجره متناظر باید انتخاب شود و ۰ به معنی این است که پنجره متناظر از سیگنال حذف شود.

ارزیابی: برای ارزیابی کروموزوم‌ها، ابتدا بردار ویژگی مناسب را از هر یک از پنجره‌های انتخاب شده استخراج می‌کنیم و از کنار هم قرار دادن این ویژگی‌ها بردار ویژگی نهائی را می‌سازیم. سپس

داده‌های تست را توسط کلاسه‌بندهای معرفی شده در فصل قبل دسته‌بندی کرده و نرخ موفقیت آن را به عنوان نرخ ارزیابی آن کروموزوم ذخیره می‌کنیم.

جمعیت جدید: مرحله بعدی تولید یک جمعیت جدید با تکرار گام‌های زیر است تا هنگامی که جمعیت جدید تکمیل گردد:

انتخاب: نیمی از بهترین کروموزوم‌های هر جمعیت را به عنوان کروموزوم‌های پدر انتخاب کن. کروموزوم‌های دارای بهترین مقادیر ارزیابی، دارای بزرگترین شانس برای انتخاب شدن هستند.

تقاطع: پدرها را برای تولیدمثل متقاطع کن تا یک نسل جدید شکل گیرد. اگر هیچ تقاطعی صورت نگیرد، نسل تولیدشده یک کپی از پدران خواهد بود. روشی که در این پژوهش برای تقاطع به کار برده‌ایم، این است که یک رشته مرجع به طول کروموزوم در نظر می‌گیریم، و به صورت تصادفی آن را با مقادیر صفر و یک مقداردهی کنیم. این رشته مرجع مشخص کننده نحوه وراثت فرزندان از والدینشان است. برای مقداردهی به فرزند اول، اگر مقدار متناظر با هر ژن در رشته مرجع ۱ بود، ژن متناظر را از پدر اول به ارث خواهد برد، در غیر این صورت آن را از پدر دوم به ارث می‌برد. برای فرزند دوم عکس این رویه اتفاق می‌افتد.

جهش: در این مرحله یک یا چند کروموزوم از جمعیت جدید تصادفاً تغییر داده می‌شود. این تغییر در یک یا چند ژن این کروموزوم‌ها اتفاق می‌افتد، و مقدار جدید آن ژن از ۰ به ۱ و یا از ۱ به ۰ تغییر داده می‌شود. جهش برای این اتفاق می‌افتد تا دامنه وسیع‌تری از فضای جستجو برای یافتن بهترین راه‌حل کاوش شود. عمل جهش نباید بکرات اتفاق بیفتد، زیرا در این صورت در واقع GA به روش جستجوی تصادفی تغییر خواهد کرد.

پذیرش: قرار دادن نسل جدید در جمعیت جدید

۴. جایگزین کردن: به کار بردن جمعیت تولیدشده جدید برای تکرار الگوریتم


۵. شرط توقف اگر کروموزومی مقدار ارزیابی مطلوب را کسب کرد و یا اگر تعداد تکرارها به یک مقدار از پیش تعیین شده رسید، متوقف شو و بهترین راه حل در جمعیت را به عنوان راه حل پیداشده توسط الگوریتم ژنتیک انتخاب کن.

۶. حلقه برو به گام ۲

یکی از پارامترهای مهم GA اندازه جمعیت است. اگر تعداد کمی کروموزوم در جمعیت وجود داشته باشد، GA امکان کمی برای اجرای تقاطع خواهد داشت و تنها یک بخش کوچک از فضای جستجو کاوش می شود. از طرف دیگر تحقیقات نشان می دهد که پس از محدودیت هایی که وابسته به کد کردن مسئله است، افزایش زیاد در اندازه جمعیت مفید نیست و حل مسئله را سریع تر نمی کند. در این پژوهش به دلیل بزرگ بودن اندازه کروموزوم ها، اندازه جمعیت را ۶۸ در نظر گرفته ایم. به عنوان مثال با پارتیشن کردن یک سیگنال به 50 پنجره، دو تا از بهترین کروموزوم هایی که در طی آموزش GA توانسته اند نرخ موفقیت ۱۰۰٪ را کسب کنند، در جدول (۴-۱) آورده شده اند. در شکل (۴-۱۳) شکل جدید سیگنال های مربوط به تصور ذهنی عمل ضرب، را که بر اساس این دو نوع کروموزوم تولید شده اند، می بینید. همانطور که می بینید طول سیگنال به ۱۵۰۰ تقلیل یافته است. بلاک دیاگرام روش پیشنهادی را در شکل (۴-۱۴) می بینید.

جدول (۴-۱) نمایش بهترین کروموزوم ها به طول ۵۰ و پنجره های انتخاب شده توسط آنها


کروموزوم اول	[۱۰۰۰۰۰۱۱۰۰۱۱۰۱۰۱۱۰۰۰۱۰۱۱۱۱۰۰۰۰۱۰۱۱۱۰۰۱۱۰۱۱۱۱۱۱۱۱]
پنجره های انتخاب شده توسط کروموزوم اول	[1, 7, 8, 11, 12, 14, 16, 17, 21, 23, 24, 25, 26, 27, 32, 34, 35, 36, 39, 40, 42, 43, 44, 46, 47, 48, 49, 50]
کروموزوم دوم	[۱۱۰۰۱۰۰۰۱۱۱۰۱۱۰۰۰۱۰۱۰۱۱۱۱۱۱۰۰۱۱۱۱۰۱۰۱۰۱۱۱۰۱۰۱۱۱۱۰۰۱]
پنجره های انتخاب شده توسط کروموزوم دوم	[1, 2, 5, 9, 10, 11, 13, 14, 18, 20, 22, 23, 24, 25, 26, 27, 30, 31, 32, 33, 35, 37, 39, 40, 41, 43, 45, 46, 47, 50]



شکل (۴-۱۳) سیگنال EEG مربوط تصور ذهنی عمل ضرب، و سیگنال منقبض شده بر طبق کروموزوم اول و

کروموزوم دوم

کروموزوم ها



شکل (۴-۱۴) بلاک دیاگرام انتخاب بهترین پنجره ها با استفاده از الگوریتم ژنتیک

۴-۳-۳- بهینه‌سازی ازدحام ذرات^۱ (PSO)

الگوریتم بهینه‌سازی ازدحام ذرات (PSO) یک الگوریتم جستجوی مبتنی بر جمعیت است که توسط کندی و ابره‌ارت پیشنهاد شده است. این الگوریتم بر اساس رفتار اجتماعی پرندگان همراه یک ازدحام، برای حل مسائل بهینه‌سازی گسسته و پیوسته طراحی شده است. یک ازدحام متشکل از N ذره^۲ است که هر کدام یک راه‌حل خاص را بیان می‌کنند. سپس ذرات در یک فضای بزرگ حرکت می‌کنند که در آن فضا موقعیت هر ذره بر اساس تجربه حرکت او در فضای جستجو و حرکت همسایه‌هایش تغییر می‌کند [۷۴]. یعنی ذرات همراه گروه از یکدیگر یاد می‌گیرند و بر اساس دانش بدست آمده از حرکت سعی می‌کنند تا به بهترین همسایه‌های خود هر چه بیشتر شبیه شوند. شکل (۴-۱۵) اجزاء الگوریتم PSO را برای انتخاب سازگارترین پنجره‌ها نشان می‌دهد. در عمل الگوریتم PSO تنها نیاز به یک سری عملیات ریاضی اولیه دارد، که هم در نیازمندی‌های حافظه و هم سرعت ارزان و معقول است [۷۵].


^۱ Particle Swarm Optimization

^۲ Particle

راه حل ها

[0 1 0 0 0 1 0 1 1 1 0 0 0 ... 0]
[1 1 0 1 0 0 1 1 0 0 1 0 1 ... 1]
...
[1 0 0 1 0 1 0 1 1 1 0 0 1 ... 1]


ازدحام



شکل (۴-۱۵) بلاک دیاگرام اجزاء الگوریتم PSO [۷۶]

۴-۳-۱- روند الگوریتم پیشنهادی PSO برای انتخاب سازگارترین پنجره ها

در این بخش الگوریتم انتخاب بهترین پنجره ها با استفاده از روش PSO همراه با روابط ریاضی آن آورده شده است. هر ذره به عنوان یک راه حل بالقوه برای حل مسئله، فرموله سازی می شود. هر ذره i یک حافظه از بهترین موقعیت قبلی خود را ثبت می کند ($P_i(i)$). موقعیت ذره ای که دارای بیشترین مقدار ارزیابی در کل اجرای الگوریتم تا آن مرحله است، بهترین سراسری نامیده می شود (P_g). در هر تکرار بردار سرعت هر ذره بر اساس بهترین موقعیت پیشین ذره ($P_i(i)$) و بهترین راه حل همسایه های آن (P_g) تنظیم می شود. در ادامه معادلات PSO [۷۷]، برای انتخاب بهترین پنجره های یک سیگنال، توصیف شده است.



شکل (۴-۱۶) تعامل ذرات با بهترین ذره

۱. ابتدا جمعیت اولیه از ذرات را ایجاد می‌کنیم. برای این کار، ابتدا برای هر ذره یک بردار باینری به طول تعداد پنجره‌ها در نظر گرفته و آن را به صورت تصادفی با صفر و یک مقداردهی می‌کنیم. ۱ به این معنی است که پنجره متناظر باید از سیگنال انتخاب شود و ۰ به معنی این است که پنجره متناظر باید از سیگنال حذف شود. سپس ویژگی‌های مورد نیاز را از پنجره‌های انتخاب شده استخراج کرده و بردار ویژگی نهایی را می‌سازیم. این بردار ویژگی را به عنوان موقعیت آن ذره ($X_i(t)$) در نظر می‌گیریم. در اینجا $X_i(t)$ موقعیت ذره i ام را در زمان t نشان می‌دهد.

۲. کارایی هر ذره باید به کمک تابع هدف $F(X_i(t))$ و با به کارگیری موقعیت کنونی ذره یعنی $X_i(t)$ ارزیابی شود. در روش پیشنهادی، برای ارزیابی هر ذره داده‌های تست را کلاسه‌بندی کرده و نرخ موفقیت کلاسه‌بند را به عنوان کارایی آن ذره ثبت می‌کنیم. در تکرار اول الگوریتم این نرخ موفقیت به عنوان بهترین کارایی ذره i ام در P_{il} ذخیره خواهد شد. در تکرارهای بعدی گام ۳ اجرا خواهد شد.

۳. کارایی هر ذره را با بهترین کارایی آن مقایسه کن، اگر موقعیت فعلی ذره از بهترین موقعیت قبلی آن بهتر بود، بهترین موقعیت ذره را به روز رسانی کن، بنابراین اگر $F(X_i(t)) > F(P_{il})$ آنگاه:

$$P_{il} = X_i(t) \quad (۴-۲)$$

۴. کارایی هر ذره را با ذره بهترین سراسری مقایسه کن، اگر از آن بزرگتر بود، بهترین سراسری را با توجه به این ذره جدید به‌روزرسانی کن، یعنی اگر $F(X_i(t)) > F(p_g)$ آنگاه

$$P_g = X_i(t) \quad (3-4)$$

۵. بردار سرعت ذرات را بر اساس رابطه زیر به روزرسانی کن.

$$v_i(t+1) = w v_i(t) + \eta_1 * |R1| * (p_{il}(t) - x_i(t)) + \eta_2 * |R2| * (p_g(t) - x_i(t)) \quad (4-4)$$

در این رابطه w وزن اینرسی است و η_1 و η_2 ثابت‌های مثبت شتاب هستند و $|R1|$ و $|R2|$ اعداد تصادفی مثبت هستند که بر اساس توزیع احتمال گوسین تولید شده‌اند $(N(0, 1))$. V_i بردار سرعت i امین ذره است که فرایند بهینه‌سازی را شبیه‌سازی می‌کند و ردوبدل اطلاعات اجتماعی را منعکس می‌کند [۷۸]، [۷۹]. جمله دوم، یعنی $\eta_1 * |R1| * (p_{il}(t) - x_i(t))$ ، تاثیر اختصاصی ذره i ام بر آن ذره است، و جمله سوم، $\eta_2 * |R2| * (p_g(t) - x_i(t))$ ، تاثیر اجتماعی ذرات را بر هم نشان می‌دهد.


۶. هر ذره را بر اساس بردار سرعت آن، به موقعیت جدیدش تغییر مکان بده:

$$\begin{cases} x_i(t+1) = x_i(t) + v_i(t+1) \\ t = t+1 \end{cases} \quad (5-4)$$

۷. برگرد به گام ۲ و تا زمان همگرایی تکرار کن.

بر اساس این الگوریتم وقتی یک ذره از بهترین سراسری و همچنین از بهترین حالت خود خیلی دور باشد، باید بیشترین تغییر در آن صورت گیرد تا به سمت بهترین راه حل هدایت شود [۲۰]. فرایند بهینه‌سازی تا جایی ادامه می‌یابد که مقدار بهترین سراسری یعنی $F(p_g)$ به یک حد آستانه از پیش تعیین شده برسد و یا تعداد تکرارها به یک مقدار معین برسد. پس از فرایند بهینه‌سازی، می‌توان ذره‌ای را که حول بهترین ناحیه توزیع شده است، به عنوان بهترین راه حل به کار برد [۷۷].

بلاک‌دیگرام شکل (۴-۱۷) روند روش پیشنهادی را بر اساس الگوریتم PSO نشان می‌دهد.



شکل (۴-۱۷) بلاک‌دیگرام انتخاب سازگارترین پنجره‌ها برای یافتن بهینه‌ترین شکل سیگنال بر اساس الگوریتم PSO

فصل پنجم

ارزیابی روش پیشنهادی


۵-۱- مقدمه

در این مطالعه، روش جدیدی برای کلاسه‌بندی سیگنال‌های EEG ارائه شد که از الگوریتم‌های بهینه‌سازی و روش‌های استخراج ویژگی کاهش ابعاد، برای بالا بردن نرخ موفقیت کلاسه‌بند استفاده می‌کند. ایده اصلی این روش استفاده از روش‌های کاهش ابعاد سیگنال، به منظور حذف فریم‌های دارای ویژگی‌های زائد یا مصنوعات است. روش پیشنهادی تا حد زیادی در این رابطه موفق بوده است.

۵-۲- مراحل روش پیشنهادی

در روش پیشنهادی، ابتدا سیگنال اصلی به پنجره‌هایی با ابعاد مساوی تقسیم می‌شود و سپس با استفاده از روش‌های استخراج ویژگی که در فصل سوم عنوان شد، ویژگی‌های مورد نظر از هر پنجره به صورت جداگانه استخراج می‌شود. با کنار هم قرار دادن بردارهای ویژگی هر یک از پنجره‌ها، بردار ویژگی نهایی بدست خواهد آمد. اما همانطور که عنوان شد، تمام پنجره‌ها دارای ویژگی‌های مفید نیستند، حتی ممکن است برخی از پنجره‌ها نویزی باشند و در نتیجه نرخ موفقیت کلاسه‌بند را پائین آورند. بنابراین برای بالا بردن نرخ موفقیت کلاسه‌بند و همچنین کاهش حجم سیگنال، لازم است تا اینگونه پنجره‌ها را یافته و حذف نمائیم. به عبارتی باید ترکیبی از بهترین پنجره‌ها را بیابیم. اما ممکن است به دلیل زیاد بودن تعداد پنجره‌ها، فضای جستجو بسیار بزرگ شود و عملاً یافتن بهترین ترکیب از پنجره‌ها دشوار و یا حتی غیرممکن یا زمان‌بر باشد. بنابراین الگوریتم‌های بهینه‌سازی جستجو از قبیل الگوریتم ژنتیک (GA) و الگوریتم بهینه‌سازی ذرات (PSO)، می‌توانند بسیار کمک‌کننده باشند. یکی دیگر از الگوریتم‌های مفید برای این جستجو، الگوریتم انتخاب ویژگی رو به جلو است، این سه الگوریتم در این مطالعه به کار برده شده‌اند. بلاک‌دیگرام مراحل روش پیشنهاد شده را در شکل (۵-۱)

می‌بینید



شکل (۵-۱) بلاک دیاگرام مراحل روش پیشنهاد شده

۵-۳- پارامترهای مهم در روش پیشنهادی

۱. یکی از پارامترهای مهم مسئله، اندازه پنجره است. به دلیل اینکه در روش پیشنهادی از پنجره کردن ایستا [۱۷] استفاده می‌شود، مرز مصنوعات اضافه شده به درستی تشخیص داده نمی‌شود. در شکل (۴-۷)، مقایسه‌ای بین روش پنجره کردن تطبیقی و پنجره کردن ایستا را دیدید. همانطور که گفتیم در پنجره کردن ایستا، تنها به طور تصادفی مرز پنجره‌ها بر روی تغییر مشخصات آماری می‌افتد. بنابراین برای بالا بردن دقت، روش پیشنهادی را بر روی پنجره‌هایی با ابعاد متفاوت اعمال می‌کنیم تا قدرت کلاسه‌بند را در هر حالت بسنجیم و در نهایت بهترین ابعاد را انتخاب خواهیم کرد. نتایج نشان می‌دهد که این روش می‌تواند بسیار مؤثر باشد.

۲. پارامتر مهم بعدی، نوع ویژگی استخراج شده است. در این مطالعه از روش‌های استخراج ویژگی در حوزه زمان استفاده شده است که در فصل سوم معرفی شدند. اما قدرت هر یک از این روش‌ها برای استخراج ویژگی مناسب، یکی از پارامترهای مهم است و باید در انتخاب بهترین روش دقت شود.

۳. انتخاب بهترین کلاسه‌بند نیز یکی دیگر از چالش‌هایی است که باید بررسی شود. اینکه برای دسته‌بندی سیگنال‌های EEG در حوزه زمان، انتخاب کدام کلاسه‌بند بیشترین نرخ موفقیت را خواهد داشت، یکی از مهمترین پارامترها است.

۴. از دیگر پارامترهای مهم که برای طراحی BCI های برخط باید مورد توجه قرار گیرد، زمان اجرای الگوریتم است. برای دستیابی به این مهم باید طول بردار ویژگی تا حد امکان کم باشد. کلاسه‌بند نیز از دیگر عواملی است که می‌تواند به طور مستقیم بر زمان اجرا تاثیرگذار باشد. بنابراین انتخاب یک کلاسه‌بند به گونه‌ای که علاوه بر دقت دسته‌بندی بالا، دارای زمان اجرای پایینی باشد، باید مورد توجه قرار گیرد.

۵. پارامتر مهم بعدی، مربوط به تعداد بردارهای ویژه انتخاب شده در دو روش PCA و CSP برای استخراج ویژگی است. در این روش‌ها بردارهای ویژه‌ای باید انتخاب شوند که در جهت بیشترین پراکندگی داده‌ها باشند. که با نگاشت داده‌ها در آن جهت، ابعاد داده‌ها به ویژگی‌های مفید کاهش خواهد یافت. بردارهای ویژه‌ای مناسب‌ترند که دارای مقادیر ویژه بالایی باشند. بنابراین بردارهای ویژه متناظر با مقادیر ویژه پایین حذف می‌شوند.

۵-۴- ارزیابی روش پیشنهادی


برای ارزیابی روش پیشنهادی، آن را بر روی یک مجموعه داده پنج کلاسه، شامل ۳۲۵ سیگنال EEG که در دانشگاه کلرادو ثبت شده بود، اعمال کردیم. از ۷۰ درصد این مجموعه داده برای آموزش (۲۳۰ داده) و از ۳۰ درصد دیگر آن (۹۵ داده) برای تست استفاده کردیم. اولین گام، دسته‌بندی است. ابتدا

قدرت و زمان مصرفی کلاسه‌بندهای به‌کار رفته در روش پیشنهادی را با یکدیگر مقایسه می‌کنیم، و در نهایت از بهترین کلاسه‌بند در انتخاب ویژگی استفاده خواهیم کرد. برای ارزیابی هر روش، از معیار TP استفاده می‌کنیم که از رابطه روبرو محاسبه می‌شود:


$$(5-1) \quad TP = \frac{\text{تعداد کل داده‌ها}}{\text{تعداد داده‌های درست کلاسه‌بندی شده}}$$

۵-۴-۱- پارامتر تعداد پنجره‌ها

گفتیم که تعداد پنجره‌ها تاثیر مستقیم در نرخ موفقیت روش پیشنهادی دارند. زیرا در روش پیشنهادی، هدف حذف پنجره‌های حاوی مصنوعات است. اما در پنجره‌بندی به صورت ایستا، نمی‌توان مرز مصنوعات را به درستی تشخیص داد. راه‌حل پیشنهادشده این است که الگوریتم را با پنجره‌های با ابعاد متفاوت، آزمایش کنیم. سیگنال EEG به‌کار رفته در این مطالعه، به طول ۱۰ ثانیه است و حاوی ۲۵۰۰ نمونه زمانی می‌باشد. با در نظر گرفتن ۲۰، ۲۵، ۵۰، ۱۰۰ و ۱۲۵ پنجره، ابعاد هر یک از پنجره‌ها به ترتیب ۵۰۰، ۴۰۰، ۲۰۰، ۱۰۰ و ۸۰ میلی‌ثانیه خواهد بود. در شکل (۵-۲) (الف) نرخ موفقیت هر یک از پنجره‌ها را در روش CSPLDA مشاهده می‌کنید. همانطور که می‌بینید، پنجره ۵۰ تایی، بالاترین نرخ موفقیت را دارا می‌باشد. علاوه بر این، با بالا رفتن تعداد پنجره‌ها، فرایند استخراج ویژگی و انتخاب ویژگی زمان بیشتری مصرف می‌کند و بنابراین زمان اجرای کل الگوریتم نیز افزایش می‌یابد (شکل (۵-۲) (ب)).



(الف)



(ب)


شکل (۲-۵) مقایسه نرخ موفقیت و زمان مصرفی روش پیشنهادی به ازای پنجره‌های ۲۰، ۲۵، ۵۰، ۱۰۰ و ۱۲۵ تایی

۵-۴-۲- مقایسه کلاسه‌بندها


در این بخش مقایسه‌ای بین انواع کلاسه‌بندهای به‌کار رفته در این مطالعه انجام می‌شود و زمان و دقت دسته‌بندی هر یک بررسی خواهد شد.

۵-۴-۱- کلاسه‌بند نزدیک‌ترین همسایه (1-NN)

روش نزدیک‌ترین همسایه (1-NN)، یک روش بانظارت است که در آن برای مشخص کردن کلاس یک داده تست، نزدیک‌ترین همسایه آن را یافته و داده تست را مطابق با کلاس آن دسته‌بندی می‌کنیم. بنابراین لازم است تا فاصله سیگنال تست را تا تمام سیگنال‌های آموزشی محاسبه کنیم. در شکل (۳-۵) قسمت (الف)، نتایج دسته‌بندی به روش نزدیک‌ترین همسایه و با استفاده از چهار معیار شباهت فاصله مربعی، فاصله اقلیدسی، فاصله کسینوسی و چبیشف را ملاحظه می‌کنید. همانطور که در این شکل می‌بینید، فاصله مربعی با اختلاف زیاد، بهترین نتیجه را در دسته‌بندی داده‌ها داشته است. از معایب این کلاسه‌بند دقت پائین دسته‌بندی آن است. یکی دیگر از معایب 1-NN که آن را عملاً در کاربردهای BCI بلااستفاده می‌کند، زمان مصرفی بالای آن است. در نمودار شکل (۳-۵) قسمت (ب) زمان مصرفی این الگوریتم به ازای معیارهای شباهت متفاوت آورده شده است. همانطور که می‌بینید زمان مصرفی فاصله چبیشف از همه پایین‌تر است.



(الف)



(ب)

شکل (۳-۵) مقایسه‌ی بین چهار معیار شباهت به کار رفته در روش 1-NN (الف) مقایسه نرخ موفقیت (ب) مقایسه زمان مصرفی


۵-۴-۲- بررسی کارائی شبکه عصبی MLP

در این پژوهش شبکه عصبی MLP سه لایه استفاده شده است. به دلیل استفاده از یک لایه مخفی و بالا بودن ابعاد داده ورودی، باید تعداد نودهای لایه مخفی را به قدر کافی زیاد در نظر بگیریم، که در اینجا آن را هفت در نظر گرفته‌ایم. تعداد نودهای لایه خروجی نیز سه است تا بتواند پنج کلاس را به صورت باینری کد کند. پس از استخراج ویژگی‌های مناسب و تشکیل بردار ویژگی نهائی، آن را به عنوان ورودی به این شبکه عصبی می‌دهیم. تعداد نودهای لایه ورودی، برابر با طول بردار ویژگی است و چون طول بردار ویژگی، به تعداد پنجره‌های سیگنال EEG بستگی دارد، بنابراین تعداد نودهای لایه ورودی برابر است با:

$$N_{input} = W * F \quad (۲-۵)$$


که W تعداد پنجره‌های انتخاب شده است و F تعداد ویژگی‌های استخراج شده از هر پنجره است. پس از دسته‌بندی سیگنال‌های EEG توسط این شبکه به نتایج خوبی رسیدیم. بیشینه نرخ موفقیت 90% بدست آمد که آن در حالتی رخ داد که تعداد پنجره‌ها ۱۲۵ بود و تعداد الگوهای فضائی CSP برابر با ۲ ($m=2$) بود (شکل (۴-۵)). این در حالی است که از هیچ روش انتخاب ویژگی برای حذف مصنوعات

استفاده نکردیم. در شکل (۵-۵) قسمت (الف)، نرخ موفقیت این کلاسه‌بند را به ازای انتخاب ۲ و ۳ الگوی فضائی مشاهده می‌کنید. همانطور که می‌بینید با انتخاب ۲ الگوی فضائی نتیجه بهتری گرفته‌ایم و همچنین زمان کمتری صرف آموزش این شبکه شده است (شکل (۵-۵) قسمت (ب)).




شکل (۴-۵) خطای شبکه MLP با در نظر گرفتن ۳۰۰ مرحله آموزشی (epoch=300)، در حالت ۱۲۵ پنجره‌ای، با انتخاب ۲ الگوی فضائی در روش CSP ($m=2$)

اما از معایب شبکه عصبی برای دسته‌بندی سیگنال‌های EEG، می‌توان به زمان آموزشی بالای آن اشاره کرد. این عیب زمانی بیشتر آشکار می‌شود که بخواهیم در الگوریتم‌های بهینه‌سازی جستجو از قبیل GA از آن به عنوان تابع ارزیابی استفاده کنیم. در این صورت استفاده از MLP همراه با GA می‌تواند زمان آموزشی را حتی تا چند ساعت بالا ببرد، که این برای کاربردهای BCI برخط مناسب نیست. زمان مصرفی الگوریتم را در شکل (۵-۵) قسمت (ب)، مشاهده می‌کنید. علاوه بر این، از معایب دیگر آن این است که با تغییر تعداد کلاس‌ها باید کل ساختار شبکه را تغییر دهیم، که این دشوار است.



(الف)




(ب)

شکل (۵-۵) مقایسه کلاسه‌بند MLP در روش CSP (الف) مقایسه نرخ موفقیت MLP در تعداد الگوهای $m=2$ و $m=3$ ،
(ب) مقایسه زمان مصرفی الگوریتم در دو حالت


۵-۴-۲-۳- بررسی کارایی LDA

از دیگر کلاسه‌بندهای به کار رفته در این مطالعه LDA است. این کلاسه‌بند داده‌ها را به فضایی می‌برد که فاصله بین کلاسی بیشینه و فاصله درون کلاسی کمینه شود. پس از نگاشت داده‌ها به فضای جدید با توجه به داده‌های آموزشی و با اندازه‌گیری فاصله داده تست تا هر یک از آنها، به دسته‌بندی داده‌ها می‌پردازد. بنابراین انتخاب تابع جداساز می‌تواند در نتیجه آخر بسیار مؤثر باشد. در

این پایان‌نامه از تابع جداساز خطی، تابع قطری خطی و تابع قطری درجه دو استفاده شده است. در شکل (۵-۶) قسمت (الف) مقایسه‌ای بین این توابع جداساز به ازای تعداد متفاوت از پنجره‌ها در روش GACSPLDA با میانگین‌گیری از $m=2$ و $m=3$ آورده شده است. قبلاً هم گفتیم اندازه پنجره یکی از پارامترهای مهم در دسته‌بندی داده‌ها است. همانطور که در این شکل می‌بینید، تابع جداساز خطی دارای بالاترین عملکرد بوده و بعد از آن تابع قطری درجه دو قرار دارد، در این روش تابع قطری خطی در مقام آخر قرار دارد. در قسمت (ب) همین مقایسه در روش GAPCALDA آورده شده است. همانطور که می‌بینید فقط وقتی تعداد پنجره‌ها ۲۵ است، تابع قطری خطی نسبت به تابع خطی برتری دارد. در شکل (۵-۷) نمودار میله‌ای همین مقایسه برای روش‌های متفاوت انتخاب ویژگی یعنی GA، PSO و انتخاب ویژگی رو به جلو آورده شده است. این مقایسه مربوط به روش CSP و با میانگین‌گیری از پنجره‌های ۲۰، ۲۵ و ۵۰ تایی بوده است. همان‌طور که در این نمودار می‌بینید، تابع جداساز خطی در هر سه روش جواب بهتری را داشته است. بنابراین این تابع جداساز بهترین انتخاب برای کلاسه‌بند LDA از لحاظ دقت دسته‌بندی خواهد بود.




(الف)



(ب)


شکل (۵-۶) نرخ موفقیت کلاسه‌بند LDA به ازای توابع جداساز مختلف خطی، تابع قطری خطی و تابع قطری درجه دو به ازای پنجره‌های ۲۰، ۲۵ و ۵۰ تایی (الف) در روش GACSP، (ب) در روش GAPCA



شکل (۵-۷) نمودار میله‌ای نرخ موفقیت کلاسه‌بند LDA به ازای توابع جداساز مختلف خطی، تابع قطری خطی و تابع قطری درجه دو، به ازای سه روش انتخاب ویژگی متفاوت در روش CSP با تعداد الگوهای فضایی $m=3$

در شکل (۵-۸) مقایسه‌ای بین زمان مصرفی این سه تابع جداساز را مشاهده می‌کنید. با اینکه تابع جداساز خطی دارای دقت دسته‌بندی بالاتری است، به همان اندازه نیز زمان بیشتری را صرف آموزش

سیستم می‌کند. اما این تفاوت در حد چند ثانیه است و می‌توان از این چند ثانیه در مقابل نرخ موفقیت بالای آن چشم‌پوشی کرد.



شکل (۵-۸) مقایسه زمان مصرفی سه تابع جداساز خطی، تابع قطری خطی و تابع قطری درجه دو به ازای پنجره‌های


۲۰، ۲۵ و ۵۰ تایی در روش GACSP

۵-۴-۲-۴- مقایسه‌ای بین کلاسه‌بندهای 1-NN و MLP و LDA


در این قسمت مقایسه‌ای بین این سه کلاسه‌بند، از لحاظ دقت دسته‌بندی و زمان مصرفی آورده شده‌است. در مورد دقت دسته‌بندی، نشان داده می‌شود که روش MLP می‌تواند دسته‌بندی مناسب‌تر و با دقت بالاتری نسبت به دو کلاسه‌بند دیگر انجام دهد. با این حال LDA دقت بالایی دارد و تفاوت چندانی با MLP ندارد. مقایسه‌ای بین دقت دسته‌بندی این سه کلاسه‌بند به ازای ویژگی PCA، را می‌توانید در شکل (۵-۹) قسمت (الف) مشاهده کنید.

در حالت کلی، کلاسه‌بندهای 1-NN و MLP، زمان زیادی را برای آموزش صرف می‌کنند. مثلاً وقتی در حالت ۲۰ پنجره‌ای، داده‌ها را توسط 1-NN و با استفاده از GA دسته‌بندی می‌کنیم، حدود ۴۹۰ ثانیه یعنی بیش از ۸ دقیقه زمان صرف اجرای الگوریتم می‌شود و اگر از شبکه عصبی همراه با GA

استفاده کنیم، بیش از چند ساعت به طول می‌انجامد (شکل (۵-۹) قسمت (ب)). در صورتیکه در کلاسه‌بند LDA به طور متوسط حدود ۳۷ ثانیه یا نیم دقیقه مصرف می‌کند. بنابراین MLP و 1-NN به دلیل زمان زیادی که برای آموزش نیاز دارند، عملاً برای BCI‌های برخط مناسب نیستند. اما LDA به دلیل اینکه زمان کمی را برای آموزش و دسته‌بندی نیاز دارد، با داشتن دقت کافی، می‌تواند مناسب‌ترین انتخاب باشد.



(الف)




(ب)

شکل (۵-۹) مقایسه سه روش دسته‌بندی MLP، LDA و 1-NN در الگوریتم GAPCA با میانگین‌گیری از همه معیار شباهت‌ها و میانگین‌گیری از ۲ و ۳ بردار ویژه (PC=2, PC=3)، (الف) نرخ موفقیت (ب) زمان مصرفی

برای تخمین کیفیت هر کلاسه‌بند معیاری به نام Ratio تعریف می‌کنیم که برابر است با:

$$\text{Ratio} = \frac{\text{زمان مصرفی آن}}{\text{نرخ موفقیت کلاسه بند}} \quad (5-3)$$

در شکل (5-10) کیفیت این سه کلاسه‌بند را بر اساس معیار Ratio می‌بینید. در این شکل کاملاً مشخص است که LDA به عنوان دسته‌بند می‌تواند انتخاب مناسبی برای BCI های برخط باشد. زیرا علاوه بر داشتن دقت دسته‌بندی بالا، دارای سرعت مناسبی نیز هست. اما 1-NN با فاصله زیادی در پائین‌ترین سطح قرار دارد. زیرا علاوه بر داشتن کمترین نرخ موفقیت، زمان زیادی نیز برای آموزش نیاز دارد. MLP نیز قدرت بالائی برای دسته‌بندی دارد، اما به دلیل زمان مصرفی بالا دارای نرخ Ratio پائینی است و بدین معناست که برای BCI های برخط مناسب نیست.




شکل (5-10) نمایش کیفیت سه کلاسه‌بند بر اساس معیار Ratio

۵-۴-۳- بررسی روش‌های استخراج ویژگی


PCA و CSP از روش‌هایی هستند که با انتقال داده به فضای دیگر، ابعاد داده را کاهش داده و ناخالصی‌ها را حذف می‌کنند، که در اینجا کارایی این دو روش، همچنین کارایی ویژگی ماکزیمم و میانگین بررسی خواهد شد.

۵-۴-۳-۱- بررسی کارایی روش PCA

همانطور که گفتیم یکی از پارامترهای مهمی که در PCA باید مورد توجه قرار گیرد، تعداد بردارهای ویژه انتخاب شده است. انتخاب یک بردار ویژه وابسته به مقدار ویژه متناظر آن است. اگر مقدار ویژه متناظر به اندازه کافی بزرگ باشد، این بردار ویژه را انتخاب می‌کنیم، و در غیر این صورت آن را حذف می‌کنیم. در شکل (۵-۱۱) مقادیر ویژه که به صورت صعودی مرتب شده‌اند، نمایش داده شده‌اند. همانطور که در این شکل می‌بینید، نمودار مقادیر ویژه به صورت ناگهانی سقوط می‌کند. در این صورت تنها بردارهای ویژه منطبق با مقادیر ویژه قبل از نقطه سقوط را انتخاب کرده و بقیه را حذف می‌نمائیم.



(الف)




(ب)


شکل (۵-۱۱) (الف) نمایش مقادیر ویژه که به صورت صعودی مرتب شده اند، (ب) نمایش پنج مقدار ویژه اول: نزول ناگهانی در نقطه دو نشان دهنده این است که انتخاب دو بردار ویژه اول بهترین انتخاب است

تعداد بردارهای ویژه در نتیجه آخر به صورت مستقیم تاثیر می گذارد. در شکل (۳-۴) توزیع داده ها حول سه بردار ویژه انتخاب شده را مشاهده کردید. همانطور که در این شکل دیدید دو بردار ویژه انتخاب شده، در جهت بیشترین پراکندگی داده ها هستند و بنابراین به خوبی می توانند داده ها را بیان کنند. در شکل (۵-۱۲) تاثیر تعداد بردارهای ویژه انتخاب شده را بر نتیجه دسته بندی مشاهده می کنید. این نتایج به ازای انتخاب ۲ تا ۷ بردار ویژه و به ازای پنجره بندی ۲۰ و ۲۵ تایی بررسی شده است. در این شکل مشخص است که با انتخاب ۳ و ۴ بردار ویژه بهترین دقت دسته بندی به ترتیب برای پنجره بندی ۲۰ تایی و ۲۵ تایی حاصل شده است.


همچنین در شکل (۵-۱۳) داده‌های دسته‌بندی شده توسط LDA در روش PCA و با انتخاب ویژگی توسط GA و PSO را به ازای تعداد متفاوت از پنجره‌ها مشاهده می‌کنید. در این شکل ویژگی‌های هر پنجره توسط PCA استخراج می‌شود و با استفاده از GA یا PSO و به کمک تابع ارزیابی LDA، انتخاب ویژگی صورت می‌گیرد. همانطور که در قسمت (الف) مشاهده می‌کنید، انتخاب دو بردار ویژه، نتیجه بهتری بر کلاسه‌بندی داده‌ها دارد. در قسمت (ب) نیز که انتخاب ویژگی توسط PSO انجام شده است، به صورت مشابه، نشان می‌دهد که انتخاب دو بردار ویژه نتایج بهتری نسبت به انتخاب سه بردار ویژه دارد. این را قبلاً توسط شکل (۵-۱۱) پیش‌بینی کرده بودیم. در آنجا گفتیم که انتخاب بردارهای ویژه قبل از نقطه سقوط بهترین انتخاب خواهد بود.



شکل (۵-۱۲) تاثیر تعداد بردارهای ویژه انتخاب شده بر نرخ موفقیت PCA در پنجره بندی ۲۰ و ۲۵ تایی. نتایج به ازای تعداد بردارهای ویژه از ۲ تا ۷



(الف)




(ب)

شکل (۵-۱۳) ارتباط تعداد بردارهای ویژه انتخاب شده (PC) در PCA (الف) GA، (ب) PSO


۵-۴-۳-۲- بررسی کارایی روش CSP

در این بخش الگوریتم پیشنهادی مشتق شده از CSP دو کلاسه، که برای حل مسئله پنج کلاسه به کار برده‌ایم، را بررسی می‌کنیم. نرخ موفقیت این الگوریتم وابسته به تعداد الگوهای فضائی انتخاب شده است. این الگوریتم به مجموعه داده‌ای از لابراتوری CEBL از دانشگاه کلرادو، اعمال می‌شود تا داده‌ای متشکل از پنج کار ذهنی را دسته بندی نماید. نتایج این دسته‌بندی، کارایی و اعتبار این روش را

نشان می‌دهد. همانطور که از شکل (۵-۱۴) قسمت (الف) می‌بینید نرخ موفقیت به ازای انتخاب سه الگوی فضائی، بیشتر از هنگامی است که دو الگوی فضائی انتخاب شود. با مقایسه زمان مصرفی (قسمت (ب))، مشاهده خواهیم کرد که با انتخاب سه الگوی فضائی، به طور متوسط زمان بیشتری خواهد شد. اما این اختلاف زمان تنها در حد چند ثانیه است، بنابراین می‌توان از آن، در مقابل نرخ موفقیت بالایی که دارد، چشم‌پوشی کرد.



(الف)




(ب)

شکل (۵-۱۴) بررسی تاثیر تعداد الگوهای فضائی انتخاب شده در CSP بر نتیجه نهائی کلاسه‌بند LDA با تابع قطری

خطی، (الف) بررسی نرخ موفقیت کلاسه‌بند، (ب) بررسی زمان مصرفی الگوریتم

۵-۴-۳-۳- بررسی کارائی ویژگی‌های ماکزیمم و میانگین

از دیگر روش‌های استخراج ویژگی که در این مطالعه استفاده شده است، استخراج ویژگی ماکزیمم و میانگین است. همانطور که در فصل سه گفته شد، این روش از هر پنجره یک ویژگی استخراج می‌کند که میانگین یا ماکزیمم داده‌های موجود در آن پنجره است. در شکل (۵-۱۵) مقایسه‌ای بین این ویژگی‌ها با به‌کارگیری روش GALDA خطی آورده شده است. همانطور که در این شکل می‌بینید، در تعداد پنجره‌های زیاد، ویژگی ماکزیمم عملکرد بهتری را نسبت به ویژگی میانگین نشان می‌دهد. همچنین بر خلاف ویژگی میانگین، با افزایش تعداد پنجره‌ها، نرخ موفقیت ویژگی ماکزیمم افزایش می‌یابد. همانطور که می‌بینید حتی با وجود استفاده از روش GA همچنان نرخ موفقیت این دو ویژگی بسیار پائین است. بنابراین نمی‌توان عملاً از این ویژگی‌ها برای BCI‌های برخط استفاده کرد.




شکل (۵-۱۵) بررسی نرخ موفقیت ویژگی ماکزیمم و میانگین در روش GACSP خطی

۵-۴-۳-۴- مقایسه کارائی PCA و CSP و ویژگی‌های ماکزیمم و میانگین

پس از بررسی روش‌های استخراج ویژگی از اجزاء زمانی سیگنال، به این نتیجه می‌رسیم که CSP با اختلاف خیلی زیاد از PCA برتر است. نتیجه این مقایسه را می‌توانید در شکل (۵-۱۶) ببینید. دو

ویژگی دیگر هم نتیجه ضعیفی از خود نشان دادند. بر خلاف آنها، اثبات شده است که CSP در استخراج ویژگی از اجزاء زمانی سیگنال، بسیار موفق بوده است و کاربردهای وسیعی را در BCI دارد.



شکل (۵-۱۶) مقایسه نرخ موفقیت CSP، PCA، ویژگی ماکزیمم و ویژگی میانگین با استفاده از GA و LDA خطی به ازای ۲۰، ۲۵، ۵۰، ۱۰۰ و ۱۲۵ پنجره


۴-۴-۵- بررسی الگوریتم‌های انتخاب ویژگی

در این بخش قدرت الگوریتم‌های انتخاب ویژگی که برای انتخاب بهترین پنجره‌ها به کار برده شده‌اند، ارزیابی می‌شود.


۴-۴-۵-۱- بررسی روش GA

در این مطالعه از GA برای انتخاب بهترین پنجره‌های یک سیگنال که عاری از مصنوعات و نویز باشند، به منظور بالا بردن نرخ موفقیت استفاده شده است. الگوریتم پیشنهادی در فصل چهار کاملاً توضیح داده شد. در پنجره‌بندی ۵۰ تایی GA بهترین عملکرد را از خود نشان داده و نرخ موفقیت ۱۰۰٪ را بدست آورده است، که در شکل (۵-۱۷) روند آموزشی آن را در طی ۵۰ دوره آموزشی (epoch) می‌بینید. قسمت (ب) مربوط به آموزش GA برای حالت ۲۵ پنجره‌ای است که در

آن نرخ موفقیت تا ۹۵ درصد افزایش یافته است. در این شکل میانگین، بیشینه و کمینه نرخ موفقیت کروموزوم‌های جمعیت آورده شده است. همانطور که در قسمت (الف) برای حالت ۵۰ پنجره‌ای می‌بینید، از تکرار هفتم به بعد، حداقل یک کروموزوم در هر جمعیت وجود داشته است که دارای نرخ موفقیت کامل (۱۰۰٪) باشد. در شکل (۵-۱۸) مقایسه‌ای از دسته‌بندی سیگنال‌های EEG با استفاده از GA و بدون استفاده از آن، به ازای تعداد متفاوت از پنجره‌ها آورده شده است. همانطور که می‌توانید مشاهده کنید این الگوریتم تاثیر زیادی بر نرخ موفقیت کلاسه‌بند داشته است و بنابراین می‌تواند برای CSP و LDA در استخراج ویژگی و دسته‌بندی، مکمل خوبی برای انتخاب ویژگی باشد.




(الف)



(ب)


شکل (۵-۱۷) عملکرد کروموزوم‌ها در طی ۵۰ دوره آموزشی (Epoch) در روش GACSPLDA با میانگین‌گیری، ماکزیمم‌گیری، مینیمم‌گیری از نرخ موفقیت کروموزوم‌های هر جمعیت (الف) پنجره‌کردن ۵۰ تایی (ب) پنجره‌کردن ۲۵ تایی




شکل (۵-۱۸) بررسی عملکرد انتخاب ویژگی به روش GA در مقایسه با روش بدون انتخاب ویژگی

۵-۴-۲- بررسی روش PSO

از دیگر روش‌های انتخاب ویژگی به کار رفته در این مطالعه PSO است. همانند GA این الگوریتم سعی می‌کند تا راه‌حل‌های یافت شده را به سوی بهترین راه‌حل‌ها طوری سوق دهد که در نهایت بهترین راه‌حل برای مسئله یافت شود. راه‌حل‌ها یا همان ذرات در این مسئله، طرق مختلف انتخاب پنجره‌های یک سیگنال را بیان می‌کنند. هر ذره تعدادی از پنجره‌ها را انتخاب می‌کند. برای ارزیابی ذره‌ها، بردارهای ویژگی پنجره‌های انتخاب شده از سیگنال را در کنار هم قرار می‌دهیم تا بردار ویژگی نهائی برای آن ذره ساخته شود. پس از دسته‌بندی سیگنال‌ها، نرخ موفقیت کلاسه‌بندی را به عنوان نرخ موفقیت آن ذره در نظر می‌گیریم. در مراحل بعدی بردارهای ویژگی هر ذره بر طبق بهترین حالت آن ذره در طول اجرای الگوریتم و همچنین بر طبق بهترین ذره تغییر داده می‌شوند. بردارهای ویژگی آنقدر تغییر داده می‌شوند که در نهایت به نرخ موفقیت دلخواه برسیم و یا به یک تعداد مراحل مشخص برسیم. در شکل (۵-۱۹) نرخ موفقیت این روش در مقایسه با دسته‌بندی بدون انتخاب ویژگی، در پنجره‌بندی ۲۰، ۲۵، و ۵۰ تایی آورده شده است. همانطور که می‌بینید این روش به خوبی توانسته است نرخ موفقیت را تا بیش از ۹۸٪ بالا ببرد.



(الف)




(ب)

شکل (۵-۱۹) استفاده از PSO برای انتخاب ویژگی در CSPLDA (الف) استفاده از تابع خطی در LDA (ب) استفاده از تابع خطی قطری در LDA


۵-۴-۳- بررسی کارایی الگوریتم انتخاب ویژگی رو به جلو

گفتیم در روش پیشنهادی، با انتخاب ویژگی‌های قوی‌ترین پنجره‌ها شروع می‌کنیم و این روند انتخاب ویژگی را تا جایی ادامه می‌دهیم که نرخ موفقیت به جای افزایش، کاهش یابد. در این صورت به ویژگی‌های پنجره‌های انتخاب شده اکتفا می‌کنیم. در شکل (۵-۲۰) قدرت روش پیشنهادی را در

مقایسه با روش بدون انتخاب ویژگی مشاهده می‌کنید. همانطور که می‌بینید، این روش تنها زمانی موفق‌تر است که تعداد پنجره‌ها زیاد باشد. یعنی وقتی تعداد پنجره‌ها ۵۰، ۱۰۰ و ۱۲۵ بوده است، این روش توانسته است نرخ موفقیت را تا حد زیادی بالا ببرد. با افزایش تعداد پنجره‌ها نرخ موفقیت نیز افزایش می‌یابد. شکل (۵-۲۱) مراحل آموزش الگوریتم روبه‌جلو آورده شده است. در هر مرحله ویژگی‌های آن پنجره به بردار ویژگی نهائی اضافه شده و نرخ موفقیت آن محاسبه می‌شود. بیشترین نرخ موفقیت ۹۸٫۹۵ درصدی هنگامی حاصل شده است که ویژگی‌های ۲۵ امین پنجره انتخاب شده است.




شکل (۵-۲۰) استفاده از الگوریتم رو به جلو برای انتخاب ویژگی در مقایسه با بدون انتخاب ویژگی در الگوریتم CSPLDA در پنجره‌های با ابعاد ۲۰، ۲۵، ۵۰، ۱۰۰ و ۱۲۵




شکل (۵-۲۱) روند انتخاب پنجره در الگوریتم رو به جلو با تعداد ۱۰۰ پنجره در CSPLDA؛ با انتخاب ۲۵ پنجره اول بالاترین نرخ موفقیت یعنی ۹۸٫۹۵٪ بدست آمده است.

۵-۴-۴-۴- مقایسه GA، PSO و روش انتخاب ویژگی روبه جلو

پس از بررسی کارایی تک تک روش‌های انتخاب ویژگی استفاده شده در روش پیشنهادی، می‌خواهیم مقایسه‌ای بین این روش‌ها داشته باشیم. از لحاظ افزایش دقت دسته‌بندی، روش GA مقام اول را دارد و همیشه بهترین نتیجه را در بر داشته است (شکل (۵-۲۲)). اما دو روش دیگر با یکدیگر تعامل دارند، یعنی گاهی روش انتخاب ویژگی روبه جلو و گاهی PSO از لحاظ افزایش دقت دسته‌بندی، عملکرد بهتری را نشان می‌دهند (شکل (۵-۲۲) (ب)). در شکل (۵-۲۳)، مقایسه‌ای بین زمان مصرفی این سه الگوریتم آورده شده است. همانطور که می‌بینید الگوریتم روبه جلو دارای کمترین زمان مصرفی است، و GA بیشترین زمان را صرف آموزش می‌کند. اما با توجه به اینکه GA با اختلاف زیاد دارای قدرت دسته‌بندی بالاتری نسبت به بقیه است، می‌توان از این اختلاف زمان مصرفی، که تنها در حد چند ثانیه است، چشم‌پوشی کرد، و GA را به عنوان بهترین روش انتخاب ویژگی شناخت.




(الف)



(ب)

شکل (۵-۲۲) مقایسه نرخ موفقیت الگوریتم CSPLDA برای الگوریتم‌های PSO, GA و رو به جلو (الف) با استفاده از تابع خطی، (ب) با استفاده از تابع قطری درجه دو



شکل (۵-۲۳) مقایسه زمان مصرفی الگوریتم CSPLDA برای الگوریتم‌های انتخاب ویژگی GA، PSO و رو به جلو

۵-۴-۵- بررسی کارایی الگوریتم‌های پیشنهاد شده




روش‌هایی که در این مطالعه به کار رفته‌اند، وابسته به نوع کلاسه‌بند، روش استخراج ویژگی، روش انتخاب ویژگی، و تعداد پنجره‌ها دارای کارایی متفاوتی هستند. در جدول (۵-۱) نرخ موفقیت تمام الگوریتم‌های پیشنهاد شده را می‌توانید مشاهده کنید. همانطور که قبلاً دیدیم به ازای هر کلاسه‌بند، معیار شباهت‌های متفاوتی وجود داشت، مثلاً LDA دارای سه تابع و 1-NN دارای چهار معیار شباهت متفاوت بود، که در این جدول بیشینه نرخ موفقیت آنها انتخاب شده است و معیار شباهت مزبور که باعث بیشینه‌شدن شده است، برای هر یک آورده شده است. در این جدول M تعداد بردارهای ویژه انتخاب شده را نشان می‌دهد و بنابراین $M=2$ و $M=3$ به ترتیب به معنای انتخاب دو و سه بردار ویژه است. در شکل (۵-۲۴) مقایسه این روش‌ها به صورت نموداری آورده شده است. همانطور که می‌بینید، روش GACSPDLA دارای بالاترین نرخ موفقیت است. سپس PSOCSPDLA و بعد از آن FeedForwardCSPLDA دارای بالاترین نرخ موفقیت هستند. نتیجه می‌شود که برای انتخاب ویژگی استفاده از GA بهترین نتیجه را در بر خواهد داشت. پس از آن به ترتیب PSO و روش انتخاب رو به

جلو می‌توانند برای روش انتخاب ویژگی مؤثر باشند. با نگاه دوباره به این شکل می‌بینیم که WithoutCSPLDA در رتبه چهارم قرار دارد. این روش با به کارگیری CSP و LDA و بدون انتخاب ویژگی به دسته‌بندی داده‌ها می‌پردازد. بنابراین می‌توان نتیجه گرفت که روش CSP برای استخراج ویژگی و روش LDA برای دسته‌بندی بهترین انتخاب هستند. همچنین می‌توانیم متوجه شویم که فرایند انتخاب ویژگی چقدر در بالا بردن نرخ موفقیت کمک خواهد کرد. روش استخراج ویژگی PCA و روش ماکزیمم و میانگین با اختلاف زیاد پس از CSP قرار دارند. همچنین کلاسه‌بند 1-NN هم دارای نرخ دسته‌بندی پائینی است. در کل متوجه می‌شویم که استخراج ویژگی توسط CSP، انتخاب ویژگی توسط GA و دسته‌بندی توسط LDA می‌توانند بهترین نتیجه را در دسته‌بندی به ما بدهند و بنابراین انتخاب مناسبی برای BCI ها خواهند بود.

در مورد تعداد پنجره‌ها، مشاهده می‌شود که از میان ۲۰، ۲۵، ۵۰، ۱۰۰ و ۱۲۵ پنجره، بهترین نتیجه با تعداد پنجره‌های ۵۰ تائی، حاصل شده است. همچنین از مقایسه دو قسمت (الف) و (ب) مشاهده می‌شود که به ازای انتخاب سه بردار ویژه، نسبت به انتخاب دو بردار ویژه نتیجه بهتری حاصل شده است.

جدول (۵-۱) بیشینه نرخ موفقیت هر یک از الگوریتم‌های پیشنهاد شده از طریق معیارهای شباهت متفاوت در پنجره‌بندی با تعداد متفاوت؛ (نمادهای مختصر، L: خطی، DL: قطری خطی، QL: قطری درجه دو، Euc: اقلیدسی، CB: فاصله مربعی، Ch: فاصله چبیشف)

روش پیشنهادی	M=2					M=3				
	۲۰	۲۵	۵۰	۱۰۰	۱۲۵	۲۰	۲۵	۵۰	۱۰۰	۱۲۵
GACSPLDA	۸۴,۲	۹۴,۷	۱۰۰	۸۸,۴	۸۷,۴	۸۶,۳	۹۴,۷	۱۰۰	۱۰۰	۸۷,۴
	L	L	L	DQ	DQ	L	L	L	L	DQ
PSOCSPLDA	۷۹	۸۷,۴	۹۸,۹	۸۴,۲۱	۸۵,۲۶	۸۰	۸۷,۴	۹۸,۹۵	۸۵,۳	۸۶,۳
	L	L	L	DQ	DQ	L	L	L	DQ	DQ
FeedForwardCSPLDA	۸۰	۷۵,۸	۸۹,۵	۸۶,۳	۹۰,۵۳	۷۴,۷	۷۷,۹	۸۳,۱۵	۹۸,۹	۹۵,۸
	L	DQ	L	L	L	L	L	DL	L	L
GAPCALDA	۲۹,۵	۲۷,۴	۳۲,۶۳	۲۶,۳۱	۲۵,۲۶	۳۰,۵۲	۳۲,۶	۳۳,۶۸	۳۱,۶	۲۶,۳
	L	L	DL	L	L	L	DL	L	L	L
GAPCA1-NN	۲۱	۲۱	۳۰	۲۱	۲۱	۲۰	۲۱	۲۰	۱۵,۸	۲۰
	CB	CB	Cos	CB	CB	CB	CB	CB	Ch	Euc
PSOPCALDA	۳۴,۷۳	۳۶,۸	۳۴,۷۳	۳۳,۷	۳۲,۱	۳۱,۶	۳۱,۶	۲۹,۵	۲۳,۴	۲۲,۵
	L	DL	L	L	L	L	L	DL	L	DQ
FeedForwardPCALDA	۲۰	۳۶,۱	۱۹,۲۱	۲۰	۱۹,۱۴	۲۰	۳۶,۲	۲۰	۱۹,۳	۲۰
	L	L	DL	L	L	DQ	DQ	L	L	L
WithoutCSP LDA	۷۴,۷۳	۹۲,۶	۸۳,۱۵	۷۸,۹۴	۷۷,۸۹	۷۶,۸۴	۸۱,۱	۸۴,۱	۸۲,۵	۸۴,۲
	L	L	L	DL	DL	L	L	L	DL	DL
Without CSP MLP	۷۳,۴۵	۷۷,۴	۲۳,۸۴	۳۳,۸	۹۹,۹	۵۹,۵۵	۶۶,۴	۷۷,۱	۷۲,۲	۵۹,۰
	L	L	L	L	L	L	L	L	L	L
Without PCA MLP	۲۷,۸۵	۲۷,۷	۲۸,۱۶	۲۸,۲۶	۲۸,۱۱	۲۷,۱	۲۸,۱	۳۰,۵	۲۸,۱	۲۷,۷
	L	L	L	L	L	L	L	L	L	L
GAMaxLDA	۱۲,۶۳	۱۰,۵	۱۴,۷۳	۲۵,۲۶	۱۸,۹۴	۱۲,۶۳	۱۷,۸	۱۵,۸	۱۳,۷	۱۲,۶
	Max	Max	Max	Max	Max	Avg	Avg	Avg	Avg	Avg






شکل (۵-۲۴) بررسی کارایی روش‌های به کار رفته در دسته‌بندی سیگنال‌ها به ازای پنجره‌بندی‌های با تعداد متفاوت، (الف) انتخاب دو بردار ویژه، (ب) انتخاب سه بردار ویژه

۵-۴-۶- بررسی زمان مصرفی الگوریتم‌های پیشنهاد شده

گفتیم که برای طرحی یک BCI علاوه بر دقت یک الگوریتم، باید زمان مصرفی آن را نیز در نظر بگیریم تا مناسب انواع برخط آن باشد. در شکل (۵-۲۵) مقایسه‌ای بین زمان مصرفی الگوریتم‌های پیشنهاد شده را مشاهده می‌کنید. همانطور که می‌بینید روش GA_PCA1-NN با اختلاف زیاد بیشترین زمان را مصرف می‌کند، زیرا کلاسه‌بند 1-NN بسیار زمان‌بر است که این یکی از معایب اصلی آن است. برای اینکه اختلاف زمانی بقیه الگوریتم‌ها را متوجه شوید، با حذف این روش، شکل قسمت (ب) را ترسیم نمودیم. با نگاه به این شکل متوجه می‌شویم که GA_MAX_LDA زمان زیادی را مصرف می‌کند. زیرا فرایند ماکزیمم‌گیری زمان‌بر است. با حذف این روش به منظور تحلیل آسان‌تر، قسمت (ج) را ترسیم نمودیم. با بررسی این شکل متوجه خواهید شد که ابتدا GA_CSP_LDA و سپس PSO_CSP_LDA بیشترین زمان را مصرف می‌کنند. زیرا همانطور که گفتیم GA سپس PSO زمان نسبتاً بیشتری را نسبت به بقیه مصرف می‌کنند. روش Without_PCA_MLP نیز نسبتاً زمان زیادی مصرف می‌کند که این به دلیل وجود MLP است. در این الگوریتم از هیچ روشی برای انتخاب ویژگی استفاده نشده است، در غیر این صورت آموزش آن ساعت‌ها طول می‌کشد.

همانطور که می‌بینید روش GA_CSP_LDA با داشتن بیشترین دقت کلاسه‌بندی، دارای بیشینه زمان مصرفی ۴۵ ثانیه است که با افزایش تعداد پنجره‌ها این زمان کاهش می‌یابد. اما چون با یک بار آموزش سیستم توسط GA و مشخص شدن پنجره‌های نامربوط، شکل اصلی سیگنال‌ها مشخص می‌شود، پس برای استفاده از سیستم دیگر نیازی به استفاده دوباره از GA نیست، و بنابراین زمان الگوریتم بسیار کاهش می‌یابد. بنابراین GA_CSP_LDA با داشتن بیشترین دقت دسته‌بندی، برای BCI‌های برخط بهترین انتخاب خواهد بود.



شکل (۵-۲۵) (الف) مقایسه زمان مصرفی الگوریتم‌های پیشنهاد شده بر اساس تعداد پنجره‌ها (ب) مقایسه روش‌ها بدون روش GAPCA1NN (ج) مقایسه روش‌ها بدون روش GAMAXLDA و GAPCA1NN

۵-۵- مقایسه روش پیشنهادی با روش‌های دیگر

الگوریتم‌های پیشنهادشده در این مطالعه، بر روی مجموعه داده ثبت شده در دانشگاه کلرادو، اجرا شده‌اند. این مجموعه داده توسط نایت [۶۴] نیز مورد استفاده قرار گرفته است. نایت در مطالعه خود از روشی به نام بیشینه بخش سیگنال^۱ (MSF) استفاده می‌کند که این روش بدون صدمه رسانیدن به اطلاعات اصلی سیگنال تنها از طریق حذف مصنوعات سعی در بالا بردن نرخ سیگنال به نویز را دارد. او همچنین در مطالعه خود از تحلیل مولفه‌های مستقل (ICA) به منظور حذف مصنوعات کمک گرفت. او در پژوهش خود یک دسته‌بندی دو کلاسه را انجام می‌دهد. او داده‌های هر کانال را جداگانه دسته‌بندی نمود. در جدول (۵-۲) قسمت (ب) نتیجه کار او را می‌بینید. در این جدول ماکزیمم و میانگین روش او که بر روی سیگنال آلوده به مصنوع پلک‌زدن و سیگنال بدون آلودگی، اعمال شده است می‌بینید. در جدول (۵-۲) قسمت (الف) مقادیر مرتبط پنج روش برتر این پژوهش را می‌بینید. همانطور که می‌بینید، دو روش پیشنهادی GACSPLDA و PSOCSPDLA با میانگین ۱۰۰ و ۹۸٫۹۴، برتر از دو روش MSF1 و ICA به کار رفته توسط نایت با میانگین‌های ۹۷٫۲ و ۹۸٫۷۴ در سیگنال آلوده به مصنوع و ۹۶٫۸۹ و ۹۷٫۲۱ در سیگنال بدون آلودگی، هستند. همچنین روش پیشنهادی GACSPLDA که از GA برای انتخاب ویژگی و از CSP و LDA برای استخراج ویژگی و دسته‌بندی استفاده می‌کند، با داشتن ماکزیمم ۱۰۰، با ماکزیمم روش‌های MSF1 و ICA برابری می‌کند. این در حالی است که نایت روش خود را به صورت دو کلاسه پیاده‌سازی کرده است، در حالیکه روش پیشنهادی، بر روی مسئله پنج کلاسه پیاده‌سازی شده است، که این برتری روش پیشنهاد شده را می‌رساند.

در [۶۳] نیز از مجموعه داده موجود در این پایان‌نامه استفاده کرده است. او در کار خود ابتدا از PCA جهت کاهش ویژگی و سپس از شبکه‌های عصبی باتل‌نک^۲ جهت کلاسه‌بندی استفاده کرده است. او

¹ Maximum Signal Fraction

² bottleneck

همچنین از کلاسه‌بندهای ماشین بردار پشتیبان (SVM)، LDA، تحلیل جداکننده مربعی¹ (QDA) استفاده کرده‌است. او روش خود را به صورت دوکلاسه اعمال کرده است. بیشینه نرخ موفقیت این روش‌ها را در جدول (۵-۲) قسمت (ج) می‌بینید. همانطور که در این جدول می‌بینید QDA با بیشینه ۱۰۰٪ در مقام اول قرار دارد و بعد از آن NN که همان شبکه عصبی است با ۹۲٪ و سپس SVM با بیشینه ۸۷٪ و LDA با ۴۸٪ در رتبه‌های بعدی قرار دارند. اما روش پیشنهادی GACSPLDA برای کلاسه‌بندی پنج‌کلاسه، نتیجه ۱۰۰٪ را دارد، که این برتری این روش را نسبت به QDA اثبات می‌کند. همچنین روش‌های PSOCSPDLA و FeedForwardCSPLDA به ترتیب با مقادیر 98.94 و 94.73 نسبت به روش‌های LDA و SVM و NN پیشنهاد شده در این مرجع برترند.

جدول (۵-۲) مقایسه نرخ موفقیت روش‌های پیشنهادی با روش‌های پیشنهاد شده در [۶۳] و [۶۴] (الف) نتایج روش پیشنهاد شده در این مطالعه، (ب) نتایج مرجع [64] (ج) نتایج مرجع [۶۳]

روش پیشنهادی	Max(M=2)	Max (M=3)	Mean
GACSPLDA	۱۰۰	۱۰۰	۱۰۰
PSOCSPDLA	۹۸,۹۴	۹۸,۹۵	۹۸,۹۴
FeedForwardCSPLDA	۹۰,۵۲	۹۸,۹۴	۹۴,۷۳
WithoutCSP LDA	۹۲,۶۳	۸۴,۲۱	۸۸,۴۲
Without CSP MLP	۹۹,۹	۷۷,۰۸	۸۴,۰۳

(الف)

	Mean (آلوده به مصنوعات)	Max (آلوده به مصنوعات)	Mean (بدون آلودگی)	Max (بدون آلودگی)
MSF	۹۷,۵۲	۱۰۰	۹۶,۸۹	۹۹,۹۱
ICA	۹۸,۷۴	۱۰۰	۹۷,۲۱	۹۹,۸۳

(ب)

¹ Quadratic Discriminant Analysis

nLags	LDA	QDA	NN	SVM
۱۰	۴۶	۹۳	<u>۹۲</u>	<u>۸۷</u>
۲۰	۴۵	۹۹	۹۲	۸۷
۵۰	۴۶	۹۹	۷۴	۸۶
۱۰۰	<u>۴۸</u>	<u>۱۰۰</u>	۵۸	۷۷

(ج)

فصل ششم

خلاصه مطالب و پیشنهادات ادامه کار

۶-۱- نتیجه‌گیری

در این پژوهش، دسته‌بندی پنج‌کلاسه کارهای ذهنی سیگنال‌های EEG، به منظور کنترل اعضای مصنوعی بدن بررسی شد. زیرا تشخیص تصورات ذهنی یک فرد معلول، به او کمک خواهد کرد تا بدون هیچ واسطه‌ای، مستقیماً توسط مغز خود، فرمان‌های لازم را برای کنترل اعضای مصنوعی خود صادر کند. اما به دلیل اینکه سیگنال‌های EEG از روی مجموعه ثبت می‌شوند، و الکترودهای ثبت سیگنال EEG مستقیماً با مغز تماس ندارند، معمولاً سیگنال‌های EEG آلوده به یک سری مصنوعات هستند. این مصنوعات همزمان با ثبت فعالیت مغزی، از محیط اطراف ثبت می‌شوند. این مصنوعات و همچنین اطلاعات اضافی و زائدی که نقشی در کلاسه‌بندی ایفا نمی‌کنند، می‌توانند نرخ موفقیت کلاسه‌بند را تا حد زیادی پائین بیاورند. علاوه بر دقت کلاسه‌بند، زمان دسته‌بندی هم یکی از معیارهایی است که باید در BCI های برخط مورد توجه قرار گیرد. اطلاعات زمانی سیگنال دارای حجم بسیار بالایی است. بنابراین استفاده از روش‌های کاهش ابعاد ضروری به نظر می‌رسد. بدین منظور روش‌های کاهش ابعاد یعنی PCA و CSP، مورد استفاده قرار گرفتند. این روش‌ها با انتقال داده‌ها به فضای دیگر، جهت اصلی پراکندگی داده‌ها را به کمک بردارها و مقادیر ویژه تشخیص داده و بقیه جهت‌ها را حذف می‌کنند. بدین ترتیب هم اطلاعات زائد دور ریخته می‌شوند و هم ابعاد داده‌ها به طرز قابل توجهی کاهش می‌یابد. اما این داده‌های کاهش یافته هنوز هم حاوی مصنوعات هستند. بنابراین لازم است تا قسمت‌هایی از سیگنال که حاوی مصنوعات هستند را حذف کنیم و از باقیمانده سیگنال جهت استخراج ویژگی استفاده نمائیم. اما تشخیص دقیق قسمت‌های آلوده به مصنوعات، در مؤلفه‌های زمانی سیگنال دشوار است. روشی که در این پژوهش برای حذف مصنوعات پیشنهاد شد این بود که ابتدا سیگنال را به پنجره‌های با ابعاد یکسان تقسیم کنیم و سپس با استفاده از روش‌های انتخاب ویژگی یعنی GA، PSO و انتخاب ویژگی روبه‌جلو، پنجره‌های آلوده را تشخیص داده و حذف نمائیم. برای این کار ابتدا بر روی تک‌تک پنجره‌ها روش‌های استخراج ویژگی از قبیل PCA و CSP را

اعمال کرده و بردارهای ویژگی را از هر پنجره استخراج می‌کنیم. سپس راه‌حل‌های اولیه‌ای را به صورت تصادفی تولید می‌کنیم، که این راه‌حل‌ها بیانگر این هستند که کدام پنجره‌ها انتخاب و کدام‌ها حذف شوند. حال بردارهای ویژگی پنجره‌های انتخاب شده را در کنار هم قرار می‌دهیم تا بردار ویژگی نهائی تشکیل شود. سپس با استفاده از کلاسه‌بندهای MLP، LDA و 1-NN، قدرت هر راه‌حل را در کلاسه‌بندی داده‌ها می‌سنجیم. راه‌حل‌های برتر انتخاب شده و در مرحله بعدی الگوریتم، برای ساخت راه‌حل‌های جدید که احتمالا بهتر از قبلی‌ها هستند، مورد استفاده قرار می‌گیرند. در الگوریتم رو به جلو روند آموزشی متفاوت است. در آنجا، ابتدا با استخراج ویژگی از هر یک از پنجره‌ها، قدرت آنها را به صورت جداگانه در دسته‌بندی سیگنال می‌سنجیم. سپس پنجره‌ها را به ترتیب قدرت جداسازی آنها مرتب می‌کنیم. سپس ابتدا ویژگی‌های قوی‌ترین پنجره را انتخاب کرده و سپس ویژگی‌های دومین پنجره را نیز به آن اضافه می‌کنیم. اگر قدرت دسته‌بندی افزایش یافت، ویژگی‌های استخراج شده از آن را به بردار ویژگی نهائی می‌افزاییم. در غیر این صورت متوقف می‌شویم. این روند را ادامه می‌دهیم تا زمانی که بهترین نتیجه حاصل شود. اما یکی از مهمترین پارامترهایی که باید مورد توجه قرار گیرد، اندازه پنجره است. اندازه بزرگ این عیب را دارد که، ممکن است یک پنجره علاوه بر مصنوعات حاوی اطلاعات مفید نیز باشد، که در این صورت با حذف یک پنجره به صورت کامل، اطلاعات مفید آن نیز از دست خواهند رفت. اندازه بسیار کوچک نیز زمان مصرفی الگوریتم را بالا خواهد برد. برای یافتن بهترین اندازه، از روش آزمون و خطا استفاده می‌کنیم. یعنی الگوریتم پیشنهاد شده را به ازای تعداد متفاوتی از پنجره‌ها آزمایش می‌کنیم تا در نهایت بهترین اندازه را انتخاب نمائیم.

این الگوریتم را بر روی مجموعه داده ثبت شده در دانشگاه کلرادو اعمال نمودیم که حاوی پنج کار ذهنی استراحت، چرخش شکل سه‌بعدی حول یک محور، ضرب ذهنی، نوشتن نامه به یک دوست و همچنین شمارش بصری بود. این سیگنال‌ها با نرخ ۲۵۰ نمونه در ثانیه ثبت شده‌اند و هر کدام به طول ده ثانیه و حاوی ۲۵۰۰ نمونه هستند. این مجموعه داده شامل ۳۲۵ سیگنال بود که از ۷۰ درصد ۷۰ درصد آن برای آموزش و از ۳۰ درصد بقیه برای تست استفاده کردیم. الگوریتم پیشنهادی را در

پنجره‌بندی‌های ۲۰، ۲۵، ۵۰، ۱۰۰ و ۱۲۵ تائی، و هر یک به طول‌های به ترتیب ۵۰۰، ۴۰۰، ۲۰۰، ۱۰۰ و ۸۰ میلی‌ثانیه، اعمال کردیم. نتایج عملی نشان می‌دهد که با اجرای الگوریتم بر روی پنجره‌های با طول ۲۰۰ میلی‌ثانیه (پنجره‌بندی ۵۰ تائی)، بالاترین نرخ موفقیت حاصل می‌شود.

همچنین نتایج نشان می‌داد که استخراج ویژگی به روش CSP نتایج بسیار بهتری را در مقابل PCA تولید می‌کند. همچنین روش انتخاب ویژگی GA در مقایسه با انتخاب ویژگی روبه‌جلو و PSO عملکرد بسیار بهتری را از خود نشان می‌دهد. همچنین از میان کلاسه‌بندی‌های به کار رفته MLP و LDA دو کلاسه بندی هستند که نتایج بسیار بهتری را نسبت به 1-NN از خود به نمایش گذاشتند. البته کلاسه‌بند MLP عملکرد بهتری را نسبت به LDA از خود نشان داد. اما این الگوریتم زمان بسیار بالائی را برای آموزش نیاز دارد که عملاً برای BCI های بر خط مناسب نیست. زیرا اگر بخواهیم این کلاسه‌بند را همزمان با یک روش انتخاب ویژگی خوب مثل GA به کار ببریم، آموزش شبکه ساعت‌ها به طول خواهد کشید. از این گذشته با تغییر تعداد کلاس‌ها ساختار شبکه باید کلاً عوض شود و شبکه برای تنظیم وزن‌های جدید باید دوباره آموزش داده شود. اما LDA زمان کمی را برای آموزش نیاز دارد و اگر با GA تلفیق شود خواهد توانست به دقت بالائی در کلاسه‌بندی دست پیدا کند. علاوه بر این، آموزش این الگوریتم کمتر از یک دقیقه به طول می‌انجامد. بنابراین در میان الگوریتم‌های پیاده‌سازی شده، GACSPLDA با داشتن نرخ موفقیت ۱۰۰ درصد، در رتبه اول قرار دارد. این الگوریتم با انتخاب دو الگوی فضائی، با پنجره‌بندی ۵۰ تائی و با انتخاب سه الگوی فضائی، در پنجره بندی ۵۰ و ۱۰۰ تائی، به نرخ موفقیت ۱۰۰٪ دست یافته است. پس از آن الگوریتم‌های PSOCSPDLA و FeedForwardCSPLDA به ترتیب با نرخ موفقیت 98.95 و 98.94 دارای بالاترین نرخ موفقیت می‌باشند. این نتایج برتری GA را به دو روش دیگر نشان می‌دهد. پس از آن به ترتیب دو روش Without CSP LDA و Without CSP MLP به ترتیب با نرخ موفقیت 92.63 و ۹۰،۹۹ درصد قرار دارند. این دو الگوریتم بدون انتخاب ویژگی، و با استفاده از CSP به استخراج ویژگی می‌پردازند و سپس با استفاده از LDA یا MLP به دسته‌بندی داده‌ها می‌پردازند. این نرخ موفقیت

بالا، اهمیت دو کلاسه‌بند LDA و MLP را نشان می‌دهد. اگر به جای استفاده از CSP از PCA استفاده نمائیم، یعنی مثلاً در روش WithoutPCAMLP بیشینه نرخ موفقیت تنها ۳۰.۵ درصد است که این نشان‌دهنده برتری CSP به PCA می‌باشد. علاوه بر این دو ویژگی، دو ویژگی ماکزیمم و میانگین هر پنجره نیز در این پژوهش به کار رفته است که دارای نرخ موفقیت بسیار پایینی است. از این ویژگی‌ها می‌توان برای فازی کردن سیستم استفاده کرد.

در مورد پارامتر تعداد بردارهای ویژه، همانطور که گفتیم، تنها بردارهای ویژه مطابق با مقادیر ویژه بالا سودمندند. در این مطالعه به ازای انتخاب ۲ تا ۷ بردار ویژه، روش پیشنهادی را آزمایش نمودیم. نتیجه این بود که در PCA انتخاب دو بردار ویژه بهترین است و در CSP انتخاب سه بردار ویژه جواب بهتری داد. البته این بستگی به مسئله دارد و بهترین انتخاب را می‌توان از آزمون و خطا یافت.

در مورد زمان مصرفی مشاهده شد که GA نسبتاً زمان بیشتری را نسبت به PSO و رو به جلو مصرف می‌کند. همچنین MLP دارای زمان آموزشی بسیار بالایی است که اگر با GA، PSO، و یا رو به جلو ترکیب شود، آموزش آن ساعت‌ها به طول می‌انجامد. 1-NN هم زمان اجرائی بالایی دارد و در ترکیب با GA، PSO، و یا رو به جلو، آموزش آن بیشتر از نیم ساعت به طول می‌انجامد. فقط LDA دارای زمان آموزشی پائینی است و می‌تواند برای BCI‌های برخط مناسب باشد. بنابراین از میان الگوریتم‌های گفته شده، الگوریتم‌هایی از نظر زمانی بهترند که از LDA به عنوان کلاسه‌بند استفاده می‌کنند و الگوریتم‌هایی که از CSP برای استخراج ویژگی و از GA برای انتخاب ویژگی استفاده می‌کنند، دارای بالاترین دقت درسته‌بندی خواهند بود.

۶-۲- پیشنهادات ادامه کار

۱. در این پژوهش تکنیک فازی کردن با استفاده از ویژگی ماکزیمم معرفی شد، در ادامه کار این روش با استفاده از Anfis پیاده‌سازی خواهد شد.

۲. پنجره‌بندی سیگنال و انتخاب بهترین پنجره‌ها با استفاده از روش‌های انتخاب ویژگی، روشی بود که در این پژوهش پیاده‌سازی شد و نتایج خوبی حاصل شد. در کارهای آینده این روش در حوزه‌های دیگر مثل حوزه زمان-فرکانس پیاده‌سازی شده و انواع روش‌های استخراج ویژگی از قبیل AR یا تبدیل موجک به جای CSP و PCA به کار خواهند رفت.

منابع

- [1] J. Lehtonen (2002) "EEG-based Brain Computer Interfaces", Master of Science Thesis , HELSINKI UNIVERSITY OF TECHNOLOGY Department of Electrical and Communications Engineering.
- [2] E. Acar (2011) "Classification of Motor Imagery Tasks in EEG Signal and its Application to Brain-Computer Interface for Controlling Assistive Environmental Devices", Thesis, The Graduate School of Natural and Applied Sciences of Middle East Technical University.
- [3] N.J. Hill, T.N. Lal, M. Schr, T. Hinterberger, G. Widman, C.E. Elger, B. Sch, and N. Birbaumer (2006) "Classifying Event-Related Desynchronization in EEG, ECoG and MEG signals", Interface, pp. 404-413.
- [4] F. Lotte and M. Congedo (2007) "A review of classification algorithms for EEGbased brain computer interfaces", Journal of neural engineering, vol. 4.
- [5] N.J. Hill, T.N. Lal, M. Schr, T. Hinterberger, G. Widman, C.E. Elger, B. Sch, and N. Birbaumer, (2006) "Classifying Event-Related Desynchronization in EEG , ECoG and MEG signals", Interface, pp. 404-413.
- [6] E. Niedermeyer and F.H.L.D. Silva (2005) "Electroencephalography: basic principles, clinical applications, and related fields", Lippincott Williams & Wilkins.
- [7] "Electroencephalography" (2012) <http://en.wikipedia.org/wiki/Eeg>, last visited on 15/01/2012.
- [۸] حسینی ش.م، فلاح پ.آ، ک. کاظمزاده طباطبائی (۱۳۸۶) "بررسی الگوهای فعالیت الکتریکی مغز در واکنش به محرک‌های عاطفی با توجه به صفات شخصیتی برون‌گرائی و نورزگرائی" ، فصلنامه علمی-پژوهشی روانشناسی دانشگاه تبریز.
- [9] R. Chai, S.H. Ling, G.P. Hunter, H.T. Nguyen (2012) "Toward Fewer EEG Channels and Better Feature Extractor of Non-Motor Imagery Mental Tasks Classification for a Wheelchair Thought Con", 34th Annual International Conference of the IEEE EMBS San Diego, California USA, PP. 5266-5269.

[10] C.R. Hema (2012) "Four State Brain Machine Interface Design using Functional Link Networks". INTERNATIONAL JOURNAL OF ELECTRICAL AND ELECTRONIC SYSTEMS RESEARCH, VOL.5.

[11] J. Huaping 55. (2012) "Classification for EEG Signals of Different Mental Tasks Based on PNN neural network" International Conference on Education Technology and Computer (ICETC), vol.43.

[12] Ch.W. Anderson, E.A. Stolz, S. Shamsunder "Discriminating Mental Tasks Using EEG Representation by AR Models".

[13] N.Y. LIANG, P. SARATCHANDRAN, G.B. HUANG, N. SUNDARARAJAN (2006) "CLASSIFICATION OF MENTAL TASKS FROM EEG SIGNALS USING EXTREME LEARNING MACHINE". International Journal of Neural Systems. Vol. 16, No. 1, PP 29-38.

[14] M. KOSTILEK (2012.) "EEG signal as biometric characteristic and its long-term temporal stability", POSTER 2012, PRAGUE.

[15] A. Subasi, E. Ercelebi. (2005) "Classification of EEG signals using neural network and logistic regression". Computer Methods and Programs in Biomedicine.78, PP. 87-99.

[16] W. Hsu , Y. Hsu (2013) "WAVELET-COHERENCE FEATURES FOR MOTOR IMAGERY EEG ANALYSIS POSTERIOR TO EOG NOISE ELIMINATION". International Journal of Innovative Computing, Information and Control. Volume 9, Number 2.

[۱۷] س.م. انیشه، پایان نامه ارشد، "ارائه یک روش تطبیقی برای قطعه‌بندی سیگنال"، دانشگاه انوشیروان، بابل.

[18] T. Higuchi (1988) "Approach to an irregular time series on the basis of the fractal theory," Physica D, vol. 31, pp. 277-283.

[19] A. Sarkar, S. Ganguly (2012) "Mathematical Modeling of Motor Imagery Non-invasive Electroencephalogram (EEG) via statistical methods and Probabilistic Neural

⁵⁵ Huaping

Network for Brain-Computer-Interface (BCI)". International Conference on Bioscience, Biochemistry and Bioinformatics, vol.31, PP. 46-52.

[20] G.V. Sridhar, M. Rao (2012) "A Neural Network Approach for EEG Classification in BCI". International Journal of Computer Science and Telecommunications, Volume 3, Issue 10, PP. 44-48.

[21] J.Y. Kim, S.M. Park, K.E.Ko, and K.B. Sim, (2012) "A Binary PSO-Based Optimal EEG Channel Selection Method for a Motor Imagery Based BCI System". Springer-Verlag Berlin Heidelberg ICHIT, CCIS vol. 310, PP. 245-252.

[22] Y. Fang, M. Chen, X. Zheng, R.F. Harrison (2012)) "Extending CSP to Detect Motor Imagery in a Four-class BCI". Journal of Information & Computational Science, PP. 143–151.

[23] J. Jin, E.W. Sellers, X. Wang (2012) " Targeting an efficient target-to-target interval for P300 speller brain–computer interfaces". Springer, Medical & Biological Engineering & Computing, Volume 50, Number 3, PP. 289–296.

[24] J.N. Mak, D.J. McFarland, T.M. Vaughan, L.M. McCane, Ph.Z. Tsui, D.J. Zeitlin, E.W. Sellers, and J.R. Wolpaw (2012)) "EEG correlates of P300-based brain–computer interface (BCI) performance in people with amyotrophic lateral sclerosis". JOURNAL OF NEURAL ENGINEERING, IOP Science, :9, 11 pp.

[25] R. Palaniappan (2005) "Brain Computer Interface Design Using Band Powers Extracted During Mental Tasks". Proceedings of the 2nd International IEEE EMBS Conference on Neural Engineering Arlington, Virginia, PP. 321-324.

[26] S. Makeig, S. Debener, J. Onton, J.A. Delorme (2004) "Mining event-related brain dynamics" Trends Cogn Sci. ,PP.204–210.

[27] B.J. Roach and D.H. Mathalon (2008)" Event-Related EEG Time-Frequency Analysis: An Overview of Measures and An Analysis of Early Gamma Band Phase Locking in Schizophrenia". Journal of Schizophr Bull.v.34(5) , pp. 907–926.

- [28] Molin G.G. Tsoneva T. Nijholt A. (2009) “Emotional Brain-Computer Interfaces” 3rd International Conference on Affective Computing and Intelligent Interaction and Workshops, pp. 1-9.
- [29] Mcfarland D.J. Mccane L.M. David S.V. and Wolpaw J.R. (1997) “Spatial filter selection for EEG-based communication”. *Electroencephalography and clinical Neurophysiology*, vol. 103, pp. 386-394.
- [30] Hassanpour H., Mesbah M. and Boashash B. (2004) “Time-Frequency Feature Extraction of Newborn EEG Seizure Using SVD-Based Techniques”. *EURASIP Journal on Applied Signal Processing*, vol. 16, pp 2544-2554.
- [31] Muller-Gerking J. Pfurtscheller G. and Flyvbjerg H. (1999) “Designing optimal spatial filters for single-trial EEG classification in a movement task” *Clin. Neurophysiol*, 110(5), pp. 787–798.
- [32] X. Yong, R.K. Ward, G.E. Birch (2008) “Robust Common Spatial Patterns for EEG Signal Preprocessing”, 30th Annual International IEEE EMBS Conference Vancouver, British Columbia, Canada, PP. 2087-2090.
- [33] F. Goksu, N.F. Ince, A.H. Tewfik (2011) “SPARSE COMMON SPATIAL PATTERNS IN BRAIN COMPUTER INTERFACE APPLICATIONS”, *IEEE ICASSP*, PP 533-536.
- [34] Ramoser H. Muller-Gerking J. and Pfurtscheller. G. (2000) “Optimal spatial filtering of single trial EEG during imagined hand movement.” *IEEE Trans. Rehabil. Eng.* 8(4), pp. 441–446.
- [35] Dornhege G. Blankertz B. Curio G. and Muller K.R.(2004) “Boosting bit rates in noninvasive EEG single-trial classifications by feature combination and multiclass paradigms.” *IEEE Trans. Biomed. Eng.*; 51(6), pp. 993–1002.
- [36] Yan T. Jingtian T. Andong G. (2008) “Multi-Class EEG Classification for Brain Computer Interface based on CSP”. *International Conference on BioMedical Engineering and Informatics*.
- [37] Pearson K. “On lines and planes of closest fit to systems of points in space”. *Philosophical Magazine*, pp. 559-572.

- [38] Ke L. and Li R. (2009) "Classification of EEG Signals by Multi-Scale Filtering and PCA". IEEE International Conference on Intelligent Computing and Intelligent Systems. pp. 362-366.
- [39] Lee H. and Choi S. "PCA-based linear dynamical systems for multichannel EEG classification" Proceedings of the 9th International Conference on Neural Information Processing, vol. 2, pp. 745-749.
- [40] "principle component analysis", [http:// en.wikipedia.org/wiki/](http://en.wikipedia.org/wiki/), Last Visited on 23/6/2012.
- [41] Lin C. and Hsieh M. (2009) "Classification of mental task from EEG data using neural networks based on particle swarm optimization". Neurocomputing, vol. 72, pp. 1121-1130.
- [42] Macdonald C. (2006) "Long-term EEG monitoring in the Neonatal Intensive Care Unit" IEEE International EMBS conference of the Engineering in Medicine and Biology Society, pp. 2483-2485.
- [43] Kosar K. Lhotska L. and Krajca V. (2004) "Classification of Long-Term EEG Recordings." Book Series in Computer Science, Vol. 3337, pp. 322-332.
- [44] Agarwal R. and Gotman J. (1999) "Adaptive Segmentation of Electroencephalographic Data Using a Nonlinear Energy Operator" Proc. IEEE International Symposium on Circuits and Systems (ISCAS), vol. 4, pp. 199-202.
- [45] Duda S.D.R. Hart P.(2000) "Pattern Classification" Ricoh California Research Center.
- [46] Balakrishnama S. Ganapathiraju A. "Linear Discriminant Analysis- A Brief Tutorial ", Institute For Signal and Information Processing Department of Electrical and Computer Engineering Mississippi State University.
- [47] Kolodziej M. Majkowski A. Rak R.J. (2012) "Linear Discriminant Analysis as EEG Features Reduction Technique for Brain-Computer Interfaces". Electrical Review, ISSN 0033-2097, R. 88 NR 3a.
- [48] Kantardzic M. Wiley J. (2002) " Data Mining: Concepts, Models, Methods, and Algorithms ". IEEE Press.

- [49] Perez J.L.M Cruz A.B (2007) "Linear Discriminant Analysis on Brain Computer Interface". IEEE 1-4244-0830-X/07.
- [50] Axler S. (1995) "Linear Algebra Done Right" Springer-Verlag New York Inc., New York, New York.
- [51] Fukunaga K.(1990) "Introduction to Statistical Pattern Recognition". Academic Press, San Diego, California.
- [52] Friedman J.H.K. (1997) "On bias, variance, 0/1-loss, and the curse-of-dimensionality" Data Mining and Knowledge Discovery, 1(1).
- [53] Blankertz B. ,Curio G. and Muller K. R. (2002) "Classifying single trial eeg: Towards brain computer interfacing" Advances in Neural Information Processing Systems (NIPS 01), pp. 157-164.
- [54] Schlogl A. Lee F. Bischof H. and Pfurtscheller G. (2005) "Characterization of four-class motor imagery eeg data for the bci-competition" Journal of Neural Engineering.
- [55] Boriso J. F. Mason S. G. Bashashati A. and Birch G.E. (2004) "Brain-computer interface design for asynchronous control applications: Improvements to the Ifasd asynchronous brain switch" IEEE Transactions on Biomedical Engineering, 51(6).
- [56] Bhattacharyya S. Khasnobish A. Chatterjee S. Konar A. Tibarewala D.N (2010) "Performance Analysis of LDA, QDA and KNN Algorithms in Left-Right Limb Movement Classification from EEG Data", Proceedings of 2010 International Conference on Systems in Medicine and Biology, liT Kharagpur, India.
- [57] <http://www.gabormelli.com/RKB/Cosine>, last visited on 20/08/2012
- [58] http://inside.mines.edu/~ckarlss/...ing_portfolio/similarity-code.html, last visited on 20/08/2012
- [59] "Chebyshev similarity". <http://en.wikipedia.org/wiki/Chebyshev>, last visited on 20/08/2012.

- [60] Lin C. and Hsieh M. (2009) "Classification of mental task from EEG data using neural networks based on particle swarm optimization" *Neurocomputing*, vol. 72, pp. 1121-1130.
- [61] "City block similarity". http://en.wikipedia.org/wiki/City_block. last visited on 22/08/2012.
- [62] Jain A. and Zongker D. "Feature Selection: Evaluation, Application, and Small Sample Performance" Department of Computer Science Michigan State University East Lansing, Michigan, USA.
- [63] Teli M.N. (2007) "DIMENSIONALITY REDUCTION AND CLASSIFICATION OF TIME EMBEDDED EEG SIGNALS", Master of Science THESIS, Colorado State University, Fort Collins, Colorado.
- [64] Knight J.N. (2003) "SIGNAL FRACTION ANALYSIS AND ARTIFACT REMOVAL IN EEG", Master of Science THESIS, Colorado State University, Fort Collins, Colorado.
- [65] Dhiman R. Saini J.S. Priyanka, Mittal A.P (2010) "ARTIFACT REMOVAL FROM EEG RECORDINGS -AN OVERVIEW", NCCI National Conference on Computational Instrumentation, CSIO Chandigarh, INDIA.
- [66] Jung T.P. Humphries C. Lee T.W. McKeown M.J. Iragui V. Makeig S. Sejnowski T.J. (2000) "Removing electroencephalographic artifacts by blind source separation" *Psychophysiology*, pp 163-178.
- [67] Kenemans J.L. Molenaar P. Verbaten M.N. Slangen J.L. (1991) "Removal of the ocular artifact from the EEG: a comparison of time and frequency domain methods with simulated and real data" *Psychophysiology*, pp 114-121.
- [68] Acharya R. Faust O. Kannathal N. Chua T. Laxminarayan S. (2005) "Non-linear analysis of EEG signals at various sleep stages" *Comput Methods Programs Biomed*, vol. 80, pp. 37-45.
- [69] Cichocki A. Vorobyov S. (2000) "Application of ICA for automatic noise and interference cancellation in multisensory biomedical signals" In *Proceedings of the Second International Workshop on ICA and BSS*, pp 621-626.
- [70] Verobyov S. Cichocki A. (2002) "Blind noise reduction for multisensory signals using ICA and subspace filtering, with application to EEG analysis" *Biological Cybernetics*, 293-303.

- [71] Rahalova M. Sykacek P. Koska M. Dorffner G. (2001) "Detection of the EEG artifacts by the means of the (extended) Kalman filter" *Measurement Science Review*, 59-62.
- [72] Zhang T. "An Adaptive Forward/Backward Greedy Algorithm for Learning Sparse Representations", Statistics Department Rutgers University, NJ.
- [73] "Genetic Algorithm", [HTTP://www.obitko.com/tutorials/genetic-algorithm](http://www.obitko.com/tutorials/genetic-algorithm), last visited on 19/10/2012.
- [74] Kennedy J. and Eberhart R. (1995) "Particle Swarm Optimization" *Proc. IEEE International Conf. on Neural Networks, Perth*, Vol. 4, pp 1942-1948.
- [75] HEMA C.R. PAULRAJ M.P. NAGARAJAN R. YAACOB S. ADOM A.H. (2008) "Application of Particle Swarm Optimization for EEG Signal Classification", *Biomedical Soft Computing and Human Sciences*, Vol.13, No.1, pp 79-84.
- [76] Lin CH.J. Hsieh M.H. (2009) "Classification of mental task from EEG data using neural networks based on Particle Swarm Optimization", *ELSEVIER Neurocomputing*, Volume 72, Issues 4–6, PP 1121–1130.
- [77] You-ping ZH. Xing-hong K. Pei-wei H. (2010) "Improved Algorithm for Distributed Localization in Wireless Sensor Networks", Shanghai Jiaotong University and Springer-Verlag Berlin Heidelberg.
- [78] Hema C.R. Paulraj M.P Yaacob S. Adom A.H. Nagarajan R. (2007) "Motor Imagery Signal Classification for a Four State Brain Machine Interface", *World Academy of Science, Engineering and Technology* 29.
- [79] Shi Y.Y. Eberhart R.C. (1998) "Parameter Selection in Particle Swarm Optimization", *Evolutionary Programming*, Springer Verlag, New York, Vol. 7, pp 591 – 600.

Abstract

In this applicable thesis, we study the classifying of five mental tasks that have been measured by EEG. Time components of EEG signals have high volume, and also they might have some artifacts that haven't been recorded from the brain, such as blinking, or eye movements. So reducing redundancy data and extracting useful data is necessary. In proposed method PCA and CSP have been used for removing redundancy data. But there are some artifacts that don't remove by these methods. For this, first segment EEG signals into several windows, then apply PCA or CSP on each window distinguishably. Then remove features of redundant windows. But the problem is that how recognize windows that have artifacts. It is difficult, because of artifacts aren't clear in EEG signals. But we can probe for solutions related to selecting best windows, by Genetic Algorithm (GA), Particle Swarm Optimization (PSO), and forward feature selection methods. But the problem is that all features of removed windows aren't redundant, but they are removed. Because in static partitioning, the ridge of artifacts isn't clear. So we should use proposed method for different sizes of windows in multi steps, and finally select best dimensions. We applied proposed method on one dataset that contains five mental tasks. We consider 70% of data for training and 30% for testing system, and we acquire 100% success rate, for 50 windows.

Keyword Keys

EEG signals, Brain Computer Interface(BCI), Window, Artifacts Removal, Principle Component Analysis (PCA), common Spatial Pattern (CSP), Genetic Algorithm(GA), Particle Swarm Optimization (PSO), forward feature selection method, Fuzzy Logic



Shahrood University of Technology
Faculty of Computer Engineering & IT

Desired Human Movement Recognition Using EEG Signals

Masoumeh Esmaeili

Supervisor: Dr. Morteza Zahedi

Advisor: Dr. Alireza Ahmadifard

February 2013