استخراج الگوهای فضایی طیفی از سیگنال‌های الکتروانسفالوگرام برای تشخیص اختلال شناختی خفیف

محمدعلی گنجعلی[۱]، دانشجوی کارشناسی ارشد؛ وحید شالچیان[۲]، استادیار

۱- دانشکده مهندسی برق - دانشگاه علم و صنعت ایران - تهران - ایران - m_ganjali@elec.iust.ac.ir
۲- دانشکده مهندسی برق - دانشگاه علم و صنعت ایران - تهران - ایران - shalchyan@iust.ac.ir

چکیده: اختلال شناختی خفیف (MCI) مرحله ابتدایی بیماری آلزایمر(AD) قلمداد می‌شود. تشخیص زودهنگام این عارضه، احتمال درمان و جلوگیری از تبدیل آن به زوال عقلی را افزایش می‌دهد. هدف این مطالعه، تفکیک و طبقه‌بندی دو گروه افراد سالم و بیماران MCI به‌وسیله روش پردازشی پیشرفته با به‌کارگیری فیلترهای فضایی-طیفی در استخراج ویژگی از سیگنال‌های الکتروانسفالوگرام EEG است. روش پیشنهادی بانک فیلتر الگوی فضایی مشترک (FBCSP) است که اخیراً در مطالعات واسط‌های مغز و کامپیوتر برای جداسازی تصورات حرکتی با موفقیت استفاده شده است ولی تاکنون درکاربرد تشخیص MCI بررسی و به‌کارگیری نشده است. تحلیل و بررسی روی داده‌های ۹ فرد بیمار MCI و ۱۲ فرد سالم صورت گرفته و با روش‌های رایج استخراج ویژگی از توان باندهای فرکانسی و الگوی فضایی مشترک (CSP) کلاسیک مقایسه شده است. به‌کارگیری روش FBCSP دقت تفکیک ۱۰۰ درصد را در ارزیابی بایک نمونه خارج شده درپی داشت. یافته‌های این مطالعه، برتری قابل توجه روش FBCSP نسبت به روش توان باندهای فرکانسی و CSP کلاسیک را در دقت تشخیص MCI نشان می‌دهد. نتایج این مطالعه بر نقش استفاده از ترکیب‌های فضایی یادگیری شده در هریک از زیر باندهای فرکانسی برای استخراج ویژگی‌های مؤثر در تفکیک افراد سالم از بیماران MCI تأکید دارد.

واژه‌های کلیدی: اختلال شناختی خفیف، آلزایمر، الکتروانسفالوگرام، بانک فیلتر الگوی فضایی مشترک

Extracting Spatial Spectral Patterns from EEG Signals for Diagnosis of Mild Cognitive Impairment

M. A. Ganjali[1], Msc Student; V. Shalchyan[2], Assistant Professor

1- Faculty of Electrical Engineering, Iran University of Science and Technology, Tehran, Iran, Email: m_ganjali@elec.iust.ac.ir
2- Faculty of Electrical Engineering, Iran University of Science and Technology, Tehran, Iran, Email: shalchyan@iust.ac.ir

Abstract: Mild cognitive impairment (MCI) is an early stage of Alzheimer's disease(AD). Early diagnosis of this disease increases the likelihood of the treatment and prevents its conversion to dementia. The purpose of this study is the discrimination and the classification of two groups of healthy and MCI subjects by an advanced method of extracting spatial spectral features from electroencephalographic (EEG) signals. Filter bank common spatial pattern (FBCSP) has been recently used for classifying motor imagery EEG data in brain-computer interface researches. Here, we propose using FBCSP for classifying EEG data from healthy and MCI subjects. The proposed method was tested and compared to the popular method of frequency band-power and to the classic common spatial pattern (CSP) using a dataset of 9 MCI patients and 12 healthy subjects. A leave-one-out cross validation, using FBCSP resulted in a classification accuracy of 100% and outperformed both the frequency band-power and classic CSP methods. These results reveal the important role of using the learned spatial combinations of EEG signals in different frequency bands as effective features for discrimination of MCI and normal subjects.

Keywords: Mild cognitive impairment (MCI), Alzheimer's disease (AD), Electroencephalogram (EEG), Filter bank common spatial pattern (FBCSP).

تاریخ ارسال مقاله: ۱۳۹۶/۰۵/۳۰
تاریخ اصلاح مقاله: ۱۳۹۶/۰۸/۲۵
تاریخ پذیرش مقاله: ۱۳۹۶/۱۱/۲۱
نام نویسنده مسئول: وحید شالچیان
نشانی نویسنده مسئول: ایران - تهران - نارمک - دانشگاه علم و صنعت ایران - دانشکده مهندسی برق.

۱- مقدمه

زوال عقلی نام عمومی دسته‌ای از بیماری‌هاست که با نقصان عملکرد شناختی، اختلال در حافظه و مهارت‌های فکری و عصبی و تغییرات روان‌شناختی همراه است. عوارض و مشکلات این بیماری با تخریب پیش‌رونده کارکردهای شناختی بروز می‌کند و باعث زوال مغز و از دست رفتن توانایی‌های عصبی می‌شود. تلاش‌های گسترده‌ای در جهت تشخیص و بهبود این دسته بیماری‌ها انجام گرفته است[۱].

بیماری آلزایمر (AD) شناخته‌شده‌ترین بیماری زوال عقل محسوب می‌شود و میزان شیوع این بیماری در افراد مسن گسترده‌تر است. همچنین میزان شیوع بیماری آلزایمر درمجموع از سایر بیماری‌های زوال عقل بیشتر است و بیشترین شیوع در بین اختلالات شناختی را هم داراست[۲]. به لحاظ آماری دلیل ۴۰ تا ۶۰ درصد بیماری‌های زوال عقل، آلزایمر است[۳]. علائم این بیماری فراموشی تدریجی همراه با کاهش سطوح ادراکی است[۵]. بیماری آلزایمر تشخیص و درمان قطعی ندارد، مخصوصاً اگر فرد مبتلا به مراحل پیشرفته بیماری باشد. با این حال تشخیص این بیماری در مراحل ابتدایی و یا تشخیص اختلال شناختی خفیف (MCI) می‌تواند در مسیر بهبود و درمان این بیماران مهم باشد[۲، ۵].

MCI بیماری شناختی است که شدت زیادی ندارد و در اغلب مطالعات، بیماری MCI مرحله قبل از ابتلا به آلزایمر قلمداد می‌شود، این بیماری علائمی خفیف‌تر از بیماری آلزایمر دارد و عوارض آن به‌شدت آلزایمر نیست. MCI موجب تداخلات جدی در اعمال و کارهای روزانه نمی‌شود، اما نرخ رشد و تبدیل آن به آلزایمر حدود ۱۵ تا ۲۰ درصد برآورد می‌شود درحالی‌که برای افراد مسن عادی غیر مبتلا به MCI این نرخ رشد در حدود ۱ تا ۲ درصد است[۶]. همچنین افراد مبتلا به این بیماری سه وضعیت آینده پیش روی خوددارند، تبدیل به بیماری آلزایمر، ثابت ماندن بیماری و بهبود بیماری. این بیماری قابلیت درمان دارد و این مسئله تلاش‌ها برای تشخیص MCI، ثابت نگه‌داشتن و درمان آن را توجیه می‌کند[۷].

مطالعات قبلی اغلب روی تشخیص بیماری آلزایمر و تشخیص مراحل مختلف آن نسبت به افراد سالم صورت گرفته است. از آنجایی که شیوع این بیماری با افزایش سن بیشتر می‌شود، مطالعات بسیاری در جهت تشخیص زودهنگام این بیماری صورت پذیرفته است. که برخی از این مطالعات به‌صورت تست‌های نوروفیزیولوژی انجام گرفته است[۷].

همچنین در مورد MCI، با توجه به اینکه MCI مرحله قبل از آلزایمر است، تشخیص آن برای توقف روند تبدیل به زوال عقلی مهم است. اما به دلیل ماهیت و علائم خفیف آن، تشخیص این بیماری نسبت به آلزایمر به‌مراتب دشوار است و روش‌هایی که اغلب برای تشخیص آن به کار می‌رود شامل تست‌های فیزیولوژیکی و برخی تست‌های اعصاب شناختی می‌شود. همچنین روش‌هایی چون تصویربرداری تشدید مغناطیسی (MRI) هم به تشخیص این بیماری کمک می‌کند[۸].در سال‌های اخیر مطالعات ویژه‌ای برای تشخیص این بیماری با بهره‌گیری از سیگنال الکتروانسفالوگرام EEG و تحلیل آن انجام شده است. ثبت EEG روشی غیرتهاجمی، غیرمستقیم و کم‌هزینه و سریع برای انجام تحلیل‌ها و تشخیص است[۷، ۹، ۱۰].

اغلب مطالعات روی سیگنال EEG بیماران مبتلا به MCI و آلزایمر، سه تغییر مهم را نمایان می‌کنند.

- افزایش توان ریتم‌های دلتا و تتا و کاهش توان در ریتم‌های آلفا و بتا در افراد مبتلا به آلزایمر که پدیده کندشدن ریتم‌های مغزی نام دارد[۱۱، ۱۲] .
- افزایش نظم آماری و کاهش پیچیدگی در سیگنال EEG بیماران مبتلا به آلزایمر[۲، ۱۳] .
- کاهش هماهنگی در باندهای فرکانسی بالا [۱۴] و افزایش هماهنگی در باندهای فرکانسی پایین بین سیگنال‌های EEG از نواحی مختلف مغزی در بیماران آلزایمر[۵، ۱۵، ۱۶].

بررسی‌های طیفی سیگنال EEG از جمله توان باندهای متفاوت، اختلاف بین افراد سالم و مبتلا به MCI و AD را تا حدی نشان می‌دهد. افزایش توان باند گاما در بیماران مبتلا به آلزایمر نسبت به افراد سالم[۱۷] و همچنین افزایش نسبت توان باند تتا به توان باند گاما در بیماران MCI نسبت به افراد سالم گزارش شده است[۱۸].

فعالیت عادی مغز به دلیل وجود محتوای اطلاعاتی باعث ایجاد پیچیدگی و بی‌نظمی سیگنال EEG می‌شود. چون این سیگنال در افراد بیمار اطلاعات کمتر و به‌تبع پیچیدگی کمتری نسبت به افراد سالم دارد، بررسی میزان اطلاعات موجود در سیگنال افراد مبتلا به AD و سنجش میزان قابلیت فشرده‌سازی آن روشی برای تشخیص این بیماری قلمداد می‌شود [۱۹]. برای این منظور از معیارهایی مثل آنتروپی[۲۰، ۲۱] استفاده می‌شود. همچنین از تبدیل ویولت و فشرده‌سازی با استفاده از آن نیز جهت سنجش پیچیدگی استفاده می‌شود[۲۲]. معیار اطلاعات متقابل نیز برگرفته از آنتروپی است و مقدار آن در بیماران مبتلا به آلزایمر نسبت به افراد سالم با افزایش فاصله بین الکترودها کاهش می‌یابد[۲۳، ۲۴]. ویژگی‌هایی چون همدوسی، همبستگی و همدوسی فاز نیز برای بررسی میزان هماهنگی میان الکترودها در سیگنال EEG مورد بررسی قرار می‌گیرد[۲۵]. همدوسی، میزان ارتباطات عملکردی قشر مغز را که نشانه‌ای از هماهنگی در فعالیت ناحیه‌های مغز است، نشان می‌دهد. در بیماران مبتلا به AD، همدوسی باند آلفا کاهش و همدوسی باند دلتا افزایش می‌یابد[۲۶، ۲۷]. سیگنال EEG هنگام تحریک نوری از بیماران ثبت شده‌است و محاسبه همدوسی نشان داده است که ارتباطات عملکردی بین نیمکره‌ای مغز در حالت تحریک و بدون آن دچار اختلال است[۲۸].

به دلیل نزدیک بودن ویژگی‌های جمعیت‌های مبتلا به MCI و جمعیت‌های سالم و اینکه مطالعات کمتری روی بیماری MCI صورت گرفته است، تفکیک بیماران MCI از افراد سالم دشوارتر است. در

مطالعات گذشته اغلب روش‌هایی برای بررسی ویژگی‌های سیگنال EEG در حوزه‌های پردازشی زمانی یا طیفی (فرکانسی) روی کانال‌ها به‌طور مجزا [۳۱-۲۹] و یا در بررسی‌های جدیدتر ویژگی‌های ارتباطی میان جفت کانال‌ها[۳۲، ۳۳] ارائه شده‌است. اما مطالعات محدودی به استفاده از فیلترهای فضایی برای بهبود تشخیص بیماری آلزایمر یا MCI پرداخته‌اند[۱۲، ۳۴، ۳۵]. روش فیلتر فضایی به دنبال یک ترکیب وزن‌دار بهینه از کانال‌های EEG است که در موقعیت‌های فضایی مختلف قرار گرفته‌اند، به‌گونه‌ای که بتوان بهترین ویژگی‌های ناشی از ترکیب فضایی کانال‌ها را برای تشخیص موردنظر به کار گرفت. از آنجایی‌که احتمال برقراری اتصال بین نقاط مختلف مغز به فاصله فضایی آن دو نقطه وابسته و مرتبط است، یافتن رابطه بین تلفات نرونی و این فاصله‌های فضایی می‌تواند به تشخیص بیماری کمک کند[۳۴]. با استفاده از اعمال ICA[۹] روی سیگنال EEG می‌توان تفاوت بین سیگنال افراد سالم و بیمار را بهبود بخشید، و نسبت به تشخیص بیماری اقدام کرد[۳۴]. یکی از فیلترهای فضایی، روش الگوی فضایی مشترک (CSP) است. این روش عمدتاً و به‌طور گسترده‌ای در استخراج ویژگی از کانال‌های EEG برای کاربرد واسط‌های مغز و کامپیوتر مبتنی بر تصور حرکتی استفاده شده است[۳۶]. کاربرد این روش در تشخیص بیماری آلزایمر در سال ۲۰۰۷ توسط مقاله [۱۲] پیشنهاد شد. مطالعه مذکور نتایج رضایت بخشی را در پی استفاده از نوع متداول و کلاسیک CSP برای تفکیک گروه بیماران MCI از افراد سالم نشان داد. اما در CSP کلاسیک از اطلاعات زیرباندهای فرکانسی با وجود اهمیت آن در موضوع تشخیص MCI و آلزایمر استفاده نمی‌شود و پژوهش‌های بیشتری در به‌کارگیری روش‌های پیشرفته‌تری که بتوانند الگوهای فضایی- طیفی را به‌طور هم‌زمان برای طبقه‌بندی بهینه‌سازی کند انجام نشده است. ما در مطالعه حاضر استفاده از روش پیشرفته بانک فیلتر الگوی فضایی مشترک (FBCSP) [۳۷، ۳۸] به همراه روش‌های پیشنهادی برای انتخاب ویژگی‌ها جهت تفکیک ۲ گروه افراد مبتلا MCI و سالم را بررسی می‌کنیم و کارایی این الگوریتم پیشنهادی را با روش‌های رایج قبلی ازجمله روش توان باندهای فرکانسی و CSP کلاسیک مقایسه خواهیم کرد.

۲- روش‌ها

روش‌ها شامل دو بخش جداگانه است. بخش اول که با عنوان روش‌های پیشنهادی طرح می‌شود شامل توصیف داده‌ها، پیش‌پردازش و استفاده از بانک فیلتر الگوی فضایی مشترک (FBCSP) در مرحله استخراج ویژگی و روش‌های انتخاب ویژگی، طبقه‌بندی و ارزیابی است. بخش دوم که با عنوان روش‌های مقایسه‌ای ذکر می‌شود تنها در مرحله استخراج ویژگی از بخش اول متمایز است و از دو رویکرد معرفی شده در تحقیقات قبلی شامل ویژگی‌های توان باندهای فرکانسی و الگوی فضایی مشترک (CSP) به‌منظور مقایسه با روش پیشنهادی استفاده می‌کند و روش‌های پیش‌پردازش، انتخاب ویژگی، طبقه‌بندی و ارزیابی به‌منظور مقایسه منصفانه به‌طور یکسان در دو بخش استفاده شده‌اند.

۲-۱- روش‌های پیشنهادی

این روش شامل مراحل مختلف استخراج ویژگی، انتخاب ویژگی و طبقه‌بندی بین دو گروه افراد سالم و افراد MCI است. ویژگی منحصر به‌فرد این روش استفاده از بانک فیلتر الگوی فضایی مشترک در استخراج ویژگی‌ها است. در شکل ۱ بلوک دیاگرام روش پیشنهادی نشان داده شده است.

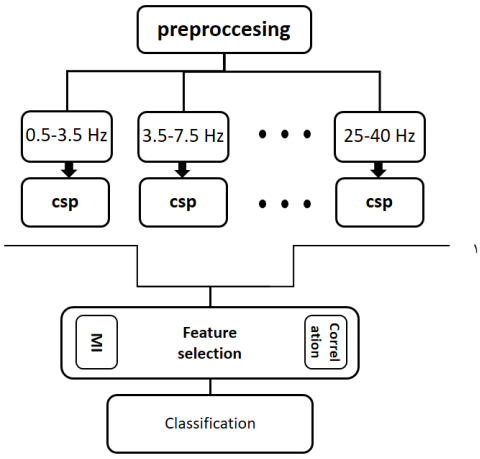

شکل ۱ بلوک دیاگرام مراحل کامل الگوریتم پیشنهادی شامل استخراج ویژگی با روش FBCSP ، انتخاب ویژگی با دو روش و طبقه‌بندی

۲-۱-۱- فرآیند ثبت دادگان

داده‌های سیگنال EEG این مطالعه از دو گروه افراد سالم و بیماران MCI[۱] است که توسط مرکز تحقیقاتی[۱] پردازش تصویر و سیگنال پزشکی دانشگاه علوم پزشکی اصفهان ثبت و در اختیار قرار گرفته است[۳۹]. داده‌های استفاده شده در این مطالعه مجموعاً از ۲۱ نفر شامل ۱۲ فرد سالم و ۹ فرد بیمار MCI در رده سنی ۶۰ تا ۷۷ سال با تحصیلات ابتدایی یا بالاتر و سابقه آنژیوگرافی در ساله‌ای اخیر است. همه سیگنال‌ها در روز و زمانی که فرد در حال استراحت با چشم بسته اما هوشیار در اتاقی ساکت حضور داشت ثبت شده است. فعالیت EEG به‌صورت پیوسته و از ۱۹ الکترود که مطابق با سیستم استاندارد ثبت ۱۰-۲۰روی جمجمه افراد قرار داشته اخذ شده است. ثبت از هر فرد به مدت ۳۰ دقیقه با نرخ نمونه برداری ۲۵۶ هرتز توسط سیستم (Galileo NT, EBneuro, Italy) و با امپدانس کمتر از ۵ کیلو اهم بین الکترودها و پوست سر انجام شده است. فیلتر شکافی برای حذف نویز فرکانس ۵۰ هرتز ناشی از تداخل برق شهری روی داده اعمال شده است. آرتیفکت‌های ناشی از لغزش‌های الکترود روی پوست توسط بازبینی چشمی‌و رسیدن به سیگنال تمیز حذف شده است. شماره و

نـوع کانال‌هـا و مکـان الکترودهـا روی جمجمـه در شـکل ۲ آمـده است[۳۹].

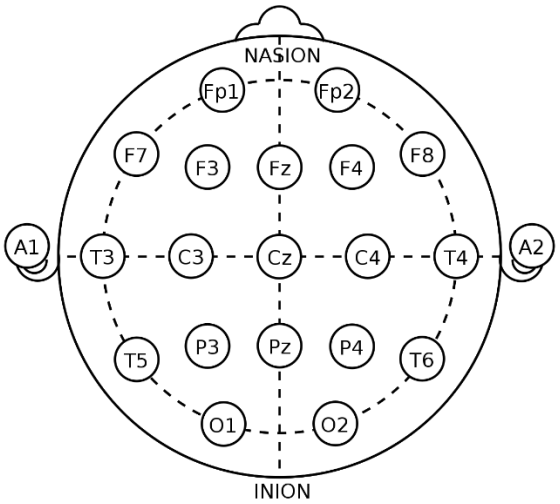

شکل ۲ موقعیت استقرار الکترودها روی جمجمه و نام الکترودها

۲-۱-۲- پیش‌پردازش

پیش‌پردازش روی داده‌های هر فرد که شامل ۱۹ کانال سـیگنال EEG با طول زمانی ۳۰ دقیقه و نرخ نمونـه‌برداری۲۵۶ هرتـز اسـت صـورت می‌گیرد. ابتدا سیگنال‌ها توسط یک فیلتر باترورث میان‌گذر درجه ۶ در بازه فرکانسی ۰/۵ تا ۴۰ هرتـز، فیلتـر می‌شـوند. پـس از ایـن مرحلـه، داده‌ها باید نرمالیزه گردند. برای این کار، نمونه‌های موجود در هر کانال بر مقدار انحراف معیار آن کانال تقسیم شد. با توجه به این‌که محتـوای فرکانسی سیگنال پس از فیلترینگ اولیه تا فرکانس ۴۰ هرتز می‌باشـد به‌منظور کاهش حجم سـیگنال و محاسـبات، نـرخ نمونـه بـرداری بـه یک‌سوم نرخ اولیه کاهش یافت.

۳-۱-۲- استخراج ویژگی

برای طبقه‌بندی و تفکیک دو گروه سالم و MCI از یکدیگر ویژگی‌هایی باید استخراج شوند که تا حد ممکـن تمـایز لازم را بـین دو گـروه در مقادیر به وجود آورند تا در مرحله بعد تفکیک دو گروه توسط طبقه‌بند با راحتی صورت پذیرد.

۱-۳-۱-۲-ویژگی‌های بانک فیلتر الگوی فضایی مشترک

الف) الگوی فضایی مشترک (CSP)

هر فیلتر CSP دریک فرایند بهینه‌سازی روی داده‌های آموزشـی، یـک ترکیب خطی (جمع وزن‌دار) فضایی از کانال‌های اولیه ویژگی می‌سازد. فرآیند بهینه‌سازی در فیلتر CSP به معنای یافتن وزن‌های بهینه فیلتر فضایی برای ترکیب کانال‌ها است تا ترکیب وزن‌دار کانال‌های مختلـف در داده افراد دو گروه به‌گونه‌ای باشـد کـه خروجـی فیلتـر CSP بـرای داده‌های یک گروه بیشترین واریانس و به‌طور هم‌زمان بـرای داده‌هـای گروه دیگر کمترین واریـانس را ایجـاد کنـد. بـرای ایـن منظـور، تـابع هزینه‌ای به‌صورت نسبت کوواریانس داده‌های فیلترشده یـک گـروه بـه کوواریانس داده‌هـای فیلتـر شـده گـروه دوم تعریـف می‌شـود و بـرای بهینه‌سازیCSP این تابع هزینه بایستی ماکزیمم شود[۳۶].

استفاده از این فضای ویژگی امکان تفکیک بهتر بین مشـاهدات دو کلاس را در مرحله طبقه‌بندی داده‌های تست فراهم می‌کند. این عمـل بـا قطری‌سـازی هم‌زمـان دو مـاتریس کوواریـانس روی مشـاهدات داده‌های آموزشی صورت می‌گیرد و محاسبه آن در ذیل توصـیف شـده است.

اگر E یـک سـطر از مـاتریس $N\times T$ سـیگنال باشـد کـه N تعـداد کانال‌ها و T تعداد مشاهدات در هرکانال است، کوواریـانس نرمال‌شـده فضایی EEG به‌صورت زیر است.

$$C=\frac{E.E'}{trace\left(E.E'\right)} \qquad (۱)$$

که ' عملگر ترانهاده و $trace$ مجموع عناصر قطری یک مـاتریس اسـت. ماتریس کوواریانس‌های $\overline{Cp}$ و $\overline{Cn}$ به ترتیب میـانگین کوواریانس‌هـای افراد متعلق به گـروه بیمـار و سـالم می‌باشـند و مـاتریس کوواریـانس ترکیبی مشاهدات به‌صورت زیر است.

$$C_c=\overline{C_n}+\overline{C_p} \qquad (۲)$$

در رابطـه بـالا C_c می‌توانـد به‌صـورت $C_c=U_c\lambda_c U_c'$ باشـد کـه U_c ماتریس بردارهای ویژه و λ_c ماتریس قطری مقادیر ویژه اسـت. مقـادیر ویژه به‌صورت نزولی مرتب می‌شـوند. تبـدیل $P=\sqrt{\lambda_c^{-1}U_c}$ برابـر بـا واریانس در محدوده فضایی است، به‌گونـه‌ای کـه مقـادیر ویـژه PC_cP' برابر یک است به شرط زیر:

$$S_p=P\overline{C_p}P' \qquad (۳)$$

$$S_n=P\overline{C_n}P' \qquad (۴)$$

بنـابراین S_p و S_n دارای بردارهـای ویـژه مشـترک مثـل B هسـتند به‌گونه‌ای که اگر $S_n=B\lambda_nB'$ آنگـاه $S_p=B\lambda_pB'$ و $\lambda_p+\lambda_n=I$ که در آن I ماتریس یکه است. از آنجایی‌که مجموع مقادیر ویـژه برابـر یک است، بردار ویژه‌ای مثل B اگر بزرگ‌ترین مقدار ویژه مربوط به $\overline{S_n}$ را تولیـد کنـد هم‌زمـان کوچـک‌ترین مقـدار ویـژه را بـرای $\overline{S_p}$ دارد و بالعکس. این ویژگی بردار ویـژه B را بـرای طبقه‌بنـدی دو گـروه مـؤثر می‌کند. کل بردارهای ویژه در کنار هم یک مـاتریس مربعـی بـا انـدازه تعداد کانال‌هاست و شامل وزن‌های مربوط به هر کانال است. درواقع m سطر اول این ماتریس(فیلتر CSP) واریانس کلاس سالم را حـداکثر و واریانس کلاس بیمار را حداقل می‌کند و m سـطر آخـر ایـن مـاتریس واریانس کلاس بیمار را حـداکثر و واریـانس کـلاس بیمـار را حـداکثر می‌کند. اعمـال ایـن $۲m$ سـطر بیشـترین اخـتلاف واریـانس را ایجـاد می‌کند. ضرب سیگنال EEG تبدیل شده در تعداد m بردار ویـژه اول و m بردار ویژه آخر، سیگنال (ویژگی) فیلتر شده با فیلتـر فضـایی فیلتـر فضایی بهینه CSP جهت تفکیک دو گروه را در اختیار می‌گذارد.

$$W=\left(B'P\right)' \qquad (۵)$$

$$Z=WE \qquad (۶)$$

هر ستون از W' یک CSP است و ویژگی‌های استخراج شونده واریانس‌های نتیجه اعمال $2m$ فیلتر CSP به سیگنال اصلی می‌باشد. در این مطالعه برای $2m$ مقادیر {۲، ۴، ۶ و ۸} درنظر گرفته شده است.

ب) محاسبه ویژگی‌های بانک فیلتر الگوی فضایی مشترک

FBCSP روش پیشرفته‌تر و جدیدتری نسبت به CSP کلاسیک می‌باشد که در ساله‌ای اخیر برای کاربردهای واسط مغز و کامپیوتر توسعه یافته است[۳۷، ۳۸]. تا جایی‌که اطلاع داریم تاکنون توانایی این روش در موضوع تشخیص MCI یا آلزایمر بررسی نشده است. جذابیت این روش در مقابل CSP کلاسیک در استفاده از اطلاعات زیربانده‌های فرکانسی EEG و امکان به دست آوردن ترکیب وزن‌دار بهینه کانال‌های فیلتر شده در ذیل هریک از زیربانده‌ها مثل باندهای آلفا، بتا، گاما و... است.

روش استخراج ویژگی توسط FBCSP مشابه[۳۸] و به‌صورتی است که در ادامه مختصراً توضیح داده می‌شود. ابتدا هر کانال سیگنال اصلی توسط بانک فیلتر (۷ فیلتر) باتروث میان‌گذر از درجه۶ به زیربانده‌های دلتا (۰/۵ تا ۳/۵ هرتز)، تتا (۳/۵ تا ۷/۵ هرتز)، آلفا۱ (۷/۵ تا ۹/۵ هرتز) ، آلفا۲ (۹/۵ تا ۱۲/۵ هرتز)، بتا۱ (۱۲/۵ تا ۱۷/۵ هرتز)، بتا۲ (۱۷/۵ تا ۲۵ هرتز) و گاما (۲۵ تا ۴۰ هرتز) تجزیه شد. برای هر یک از زیربانده‌های فوق، فیلتر CSP طبق آنچه در بخش قبل توضیح داده شد محاسبه می‌گردد. هر فیلتر CSP روی کانال‌های سیگنال در زیربانده خود اعمال می‌شود و به ازای هر زیرباند m سطر اول و m سطر آخر هر ماتریس CSP جدا می‌شوند. در هر زیرباند، ویژگی‌های استخراج شده واریانس‌های نتیجه اعمال $2m$ فیلتر CSP به سیگنال فیلتر شده هر زیرباند می‌باشد. به ازای مقادیر مختلف m از ۱ تا ۴ برای هر باند بین ۲ تا ۸ ویژگی و در مجموع با در نظر گرفتن ۷ زیرباند بین ۱۴ تا ۵۶ ویژگی اولیه استخراج گردید.

۴-۱-۲- روش‌های انتخاب ویژگی

به دلیل تعداد زیاد ویژگی‌ها و اینکه تمام ویژگی‌های به‌دست‌آمده لزوماً برای طبقه‌بندی دو گروه ممکن است مؤثر نباشند و حتی در مواردی وجود ویژگی‌های نامرتبط می‌توانند باعث افت دقت طبقه‌بندی شوند، عمل انتخاب ویژگی قبل از مرحله طبقه‌بندی ضروری به نظر می‌رسد. در این مرحله و برای ارزیابی بهتر از دو روش انتخاب ویژگی استفاده شد.

۱-۴-۱-۲- انتخاب برمبنای حداکثر اطلاعات متقابل[۱۳]

بر اساس تئوری اطلاعات، اطلاعات متقابل بین دو سیگنال، کمیتی است که وابستگی دو سیگنال را به لحاظ میزان اطلاعات متقابل اندازه‌گیری می‌کند. اگر x, y دو متغیر تصادفی به ترتیب دارای احتمال وقوع $p(x_i)$ ، $p(y_i)$ باشند. آنتروپی $H(y), H(x)$ به‌صورت زیر تعریف می‌شود. آنتروپی معیاری برای تشخیص میزان تصادفی بودن و عدم قطعیت یک یا چند متغیر است [۴۰].

$$H(x)=\sum_{i=1}^{n}p(x_i)log_b(p(x_i)) \quad (۷)$$

$$H(y)=\sum_{i=1}^{n}p(y_i)log_b(p(y_i)) \quad (۸)$$

براین اساس، اطلاعات متقابل دومتغیر $MI(x,y)$ به‌صورت زیر تعریف می‌گردد.

$$MI(x.y)=H(x)+H(y)-H(x.y)=H(y)-H(y|x) \quad (۹)$$

که در آن آنتروپی شرطی $H(y|x)$ و آنتروپی توأم بین متغیرهای تصادفی $H(x.y)$ در زیر تعریف می‌شود.

$$H(y|x)=-Ex\left[Ey\left[log_b\left(p(y|x)\right)\right]\right] \quad (۱۰)$$

$$H(x.y)=-Ex\left[Ey\left[log_b\left(p(x.y)\right)\right]\right] \quad (۱۱)$$

به‌این‌ترتیب اطلاعات متقابل هر ویژگی در همه داده‌های آموزش با برچسب طبقه آن داده‌ها محاسبه می‌شود. زمانی که این معیار برای همه ویژگی‌ها به دست آمد ویژگی‌ها به ترتیب از حداکثر تا حداقل معیار اطلاعات متقابل مرتب می‌شوند و متناسب با تعداد ویژگی موردنیاز برای طبقه‌بندی از n ویژگی اول استفاده می‌شود.

۲-۴-۱-۲- انتخاب برمبنای حداکثر ضریب همبستگی[۱۴]

معیار ضریب همبستگی P_{xy}، میزان همبستگی را بین دو سیگنال x, y در حوزه زمان می‌سنجد،

$$P_{xy}=Corr(x.y)=\frac{\sigma_{xy}}{\sigma_x\sigma_y} \quad (۱۲)$$

که در آن σ_{xy} کوواریانس دو متغیر تصادفی و $\sigma_y.\sigma_x$ به ترتیب انحراف معیارهای متغیرهای $y.x$ می‌باشند. مقدار این ضریب بین ۱- و ۱+ تغییر می‌کند، مقدار ۱+ همبستگی کامل مثبت، مقدار صفر عدم همبستگی و مقدار ۱- همبستگی کامل منفی را نشان می‌دهد[۴۱]. البته ما در این مطالعه از قدرمطلق ضریب همبستگی $|P_{xy}|$ به‌عنوان معیار انتخاب ویژگی استفاده می‌کنیم. بر این اساس قدرمطلق همبستگی بین ویژگی‌های داده‌های آموزش و برچسب طبقه آن داده‌ها محاسبه شد، این کار برای همه ویژگی‌ها صورت پذیرفت و ویژگی‌ها به ترتیب از حداکثر تا حداقل معیار قدرمطلق همبستگی مرتب می‌شوند و متناسب با تعداد ویژگی موردنیاز برای طبقه‌بندی از n ویژگی اول استفاده می‌شود.

۵-۱-۲- طبقه‌بندی

پس از مراحل استخراج و انتخاب ویژگی مرحله طبقه‌بندی انجام می‌شود. برای این کار از طبقه‌بند ماشین بردار پشتیبان SVM دوکلاسی استفاده شده است. مبنای کار این ابزار، طبقه‌بندی خطی داده‌ها است و درتقسیم داده‌ها در فضای ویژگی چندبعدی ابرصفحه‌ای

را انتخاب می‌کند که در هر بعد ویژگی برای داده‌های دو گروه حاشیه اطمینان بیشتری را برای تفکیک ایجاد کند[۴۲].

شکل ۲ بلوک دیاگرام مراحل کامل الگوریتم پیشنهادی شامل استخراج ویژگی با روش FBCSP ، انتخاب ویژگی از دو روش پیشنهادی و طبقه‌بندی دو گروه بیمار و سالم را نشان می‌دهد.

۶-۱-۲- ارزیابی

برای ارزیابی و مقایسه کارایی روش‌ها در طبقه‌بندی، از معیار دقت طبقه‌بندی [۱] برای داده‌های آزمون استفاده می‌شود که نسبت (درصد) تعداد داده‌های درست طبقه‌بندی شده به تعداد کل داده‌های آزمون تعریف می‌گردد.

برای ارزیابی، تقسیم‌بندی داده‌ها به داده‌های آموزش و داده‌های آزمون از روش ارزیابی متقابل با زیرمجموعه تصادفی استفاده می‌شود. برای این کار داده‌های ۹ فرد سالم و ۹ فرد بیمار به‌عنوان بانک داده اصلی انتخاب می‌شوند و از هر گروه هر بار یک زیرمجموعه K نمونه‌ای به‌عنوان داده آموزش و زیرمجموعه نمونه‌های باقیمانده به‌عنوان داده تست در نظر گرفته می‌شود. البته برای حالت K=۸ داده آموزش، روش ارزیابی متقابل با یک نمونه خارج شده محسوب می‌شود.

کلیه مراحل بهینه‌سازی CSP وFBCSP و سایر روش‌های انتخاب ویژگی و همچنین آموزش مدل طبقه بند SVM صرفاً بر روی داده‌های آموزش انجام شده و نتایج به‌دست‌آمده عیناً روی داده‌های تست پیاده‌سازی شده‌اند. این کار به ازای مقادیر مختلف K از ۵ تا ۸ هرکدام ۱۰ بار تکرار شده و مقادیر میانگین و انحراف معیار نتایج دقت طبقه‌بندی روی تکرارها محاسبه شده است.

یکی از عوامل مؤثر در افزایش دقت طبقه‌بندی انتخاب دقیق تعداد ویژگی‌هایی است که در مرحله انتخاب ویژگی و پس از رتبه‌بندی ویژگی‌ها برای اعمال به ورودی طبقه بند استفاده می‌شود. در این مطالعه برای آنکه از بایاس و تأثیر انتخاب این پارامتر روی مقایسه روش‌ها جلوگیری شود به روشی که در ادامه اشاره خواهد شد برای هر الگوریتم تعداد ویژگی‌های بهینه محاسبه می‌گردد تا مقایسه نهایی میان حداکثر کارایی هر الگوریتم براساس انتخاب بهینه تعداد ویژگی‌ها صورت گیرد. روال کار به این صورت است که ابتدا دقت طبقه‌بندی داده‌های آزمون (با درنظرگرفتن تکرارها) با استفاده از اولین ویژگی که بالاترین رتبه را دارد محاسبه گردیده و سپس در هر پله با اضافه نمودن یک ویژگی با رتبه بعدی مراحل محاسبه دقت طبقه‌بندی تکرار می‌گردد. در نهایت n_{opt} ویژگی اول که بیشترین میانگین دقت را روی داده‌های تست (با تکرارهای لازم) به دست می‌دهند به‌عنوان n_{opt} ویژگی بهینه برای الگوریتم مورد نظر استفاده می‌گردند.

۲-۲- روش‌های مقایسه‌ای:

برای مقایسه عملکرد روش پیشنهادی از دو روش پردازشی دیگر که در مطالعات قبل [۷، ۱۲ و ۳۹] معرفی شده‌اند استفاده شده‌است. در این دو روش، استخراج ویژگی توسط رویکردهای توان باندهای فرکانسی و الگوی فضایی مشترک (CSP) صورت می‌گیرد. در این روش‌ها پس از انجام پیش‌پردازش مشابه روش پیشنهادی در بخش ۲-۱-۲، استخراج ویژگی توسط هر یک از دو روش توان باندهای فرکانسی و استفاده از الگوی فضایی مشترک انجام می‌شود و سپس مراحل انتخاب ویژگی و طبقه‌بندی نیز مانند روش پیشنهادی در بخش‌های ۲-۱-۴ و ۲-۱-۵ صورت می‌گیرد.

۱-۲-۲- ویژگی‌های توان باندهای فرکانسی:

از جمله مهم‌ترین ویژگی‌های پایه در تشخیص MCI از افراد سالم ویژگی‌های توان باندهای فرکانسی می‌باشد که در بسیاری از مطالعات قبلی با موفقیت به کار گرفته شده است[۷، ۳۹]. در این مطالعه از ویژگی‌های توان باندهای فرکانسی به‌عنوان یک روش پایه برای مقایسه با روش‌های پیشنهادی [۷] استفاده نموده‌ایم. برای این منظور [۱] از ۷ زیرباند فرکانسی استفاده شده است که به‌صورت زیر باندهای فرکانسی دلتا δ (۰/۵ تا۳/۵ هرتز)، تتا θ (۳/۵ تا ۷/۵ هرتز)، آلفا۱ α1 (۷/۵ تا ۹/۵هرتز)، آلفا۲ α2 (۹/۵ تا ۱۲/۵ هرتز)، بتا۱ β1 (۱۲/۵ تا ۱۷/۵ هرتز)، بتا۲ β2 (۱۷/۵ تا ۲۵ هرتز) و گاما γ (۲۵ تا ۴۰ هرتز) تعریف می‌شود. ویژگی‌های [۸] مرتبط با توان باندهای فرکانسی [۱] در نظرگرفته شده مشابه[۷] شامل توان کل باند (۰/۵ تا ۴۰ هرتز)، توان هریک از زیرباندها و توان نسبی هر یک از زیرباندها به توان کل باند فرکانسی و سه ویژگی توان‌های نسبی R_1, R_2 , R_3 که به‌صورت زیر تعریف می‌شود و همچنین ویژگی فرکانس پیک آلفا که فرکانسی در طیف توان EEG در محدوده باند آلفا است که در آن فرکانس حداکثر توان مشاهده می‌شود.

$$R_1 = \frac{p_\theta}{p_{\alpha1} + p_{\alpha2} + p_{\beta1}} \quad (۱۳)$$

$$R_2 = \frac{p_\theta + p_\delta}{p_{\alpha1} + p_{\alpha2} + p_{\beta1} + p_{\beta2}} \quad (۱۴)$$

$$R_3 = \frac{p_\theta}{p_{\alpha1} + p_{\alpha2}} \quad (۱۵)$$

هر یک از ۱۹ ویژگی ذکر شده برای هریک از ۱۹ کانال داده‌های EEG هر فرد محاسبه می‌شود، در نهایت تعداد ویژگی‌های مربوط به هر فرد ۳۶۱ ویژگی خواهد بود. محاسبه توان باندهای فرکانسی توضیح داده شده در فوق از روش مشابه [۷] صورت می‌گیرد. سیگنال با طول ۳۰ دقیقه توسط پنجره‌گذاری هنینگ به قطعه‌هایی با طول ۲ ثانیه با همپوشانی ۵۰ درصد تقسیم می‌شود و سپس چگالی طیف توان هر قطعه به روش پریودوگرام اصلاح‌شده Welch محاسبه شده و با میانگین‌گیری از پریودوگرام همه قطعات، چگالی طیف توان کل سیگنال و از روی آن ویژگی‌های مرتبط با توان باند محاسبه می‌گردد.

۲-۲-۲- ویژگی‌های الگوی فضایی مشترک (CSP)

برای استخراج فیلترهای فضایی CSP باید ترکیب‌های وزن‌دار بهینه‌ای از کانال‌های EEG را پیدا نمود که بتوانند بیشترین تفکیک بین دو

مجموعه از داده‌های EEG یعنی افراد سالم و MCI را ایجاد کند. نحوه استفاده از این روش در بخش قبل توضیح داده شد. در این روش با استفاده از سیگنال تمام باند داده‌های آموزش دو گروه، فیلتر فضایی به‌دست آمد و با اعمال ۲m فیلتر بر داده‌های دو گروه ویژگی‌های مدنظر استخراج شد. در این مرحله هم مقدار m از ۱ تا ۴ تغییر می‌کند.

۳- نتایج

نتایج طبقه‌بندی داده‌های تست توسط طبقه‌بند SVM برای الگوریتم‌های مختلف در جدول شماره ۱ آمده است. ستون اول سمت چپ جدول نشان دهنده روش‌های مختلف در استخراج ویژگی شامل ویژگی‌های توان باندهای فرکانسی، ویژگی‌های CSP با ۸ مؤلفه و ویژگی‌های FBCSP با ۲ تا ۸ مؤلفه در هر زیر باند می‌باشد. ستون دوم سمت چپ جدول روش‌های انتخاب ویژگی استفاده شده شامل انتخاب برمبنای حداکثر اطلاعات متقابل یا حداکثر همبستگی می‌باشد. برای تعداد K مختلف داده آموزش نسبت به کل داده‌ها (۹ داده درهرگروه)، بهترین نتایج دقت طبقه‌بندی به ازای تعداد بهینه ویژگی‌ها به‌صورت درصد میانگین ± انحراف معیار گزارش شده است. تعداد ویژگی انتخاب شده در هر روش و زمان اجرای هر یک از روش‌ها به ازای تعداد داده‌های مختلف آموزش در ستون جداگانه گزارش شده است. زمان اجرای الگوریتم‌ها در یک کامپیوتر شخصی با پردازنده اینتل Core i7 و ۱۶ گیگابایت رم اندازه‌گیری شده و شامل یک‌بار اجرای کامل تمام مراحل الگوریتم پیش‌پردازش، استخراج ویژگی، انتخاب ویژگی و آموزش مدل طبقه‌بندی کننده روی تعداد K داده یادگیری و تعداد $9-K$ داده آزمون برحسب ثانیه است.

برای روش CSP کلاسیک به ازای تعداد مولفه‌ها از ۲ تا ۸ دقت طبقه‌بندی محاسبه شده و چون بهترین عملکرد برای ۸ مؤلفه بوده است برای رعایت اختصار در جدول۱ فقط همین نتیجه نمایش داده شده است.

همان‌طور که از نتایج مشاهده می‌شود؛ در تمام حالات‌ها روش FBCSP از روش‌های دیگر انتخاب ویژگی شامل توان باندهای فرکانسی و همچنین CSP کلاسیک دقت طبقه‌بندی بالاتری دارد. در

جدول ۱ دقت طبقه بندی (درصد میانگین± انحراف معیار)، تعداد ویژگی‌های انتخاب شده و زمان اجرا (برحسب ثانیه)به ازای روش‌های متفاوت استخراج و انتخاب ویژگی و تعداد K داده آموزش و تعداد $9-K$ داده آزمون

روش استخراج ویژگی	معیار انتخاب ویژگی‌ها	K=۵			K=۶			K=۷			K=۸		
		دقت	n_{opt}	زمان اجرا	دقت	n_{opt}	زمان اجرا	دقت	n_{opt}	زمان اجرا	دقت	n_{opt}	زمان اجرا
توان باندهای فرکانسی	اطلاعات متقابل	۵۳/۷٪ ±۱۷/۷	۱	۳۵	٪۵۰ ±۱۵/۷	۲۹۱	۵۶	۵۷/۵٪ ±۲۰/۶	۱	۳۵	٪۵۰ ±۳۵/۳	۱	۳۹
	همبستگی	٪۴۰ ±۹/۸	۶۴	۳۹	٪۳۵ ±۱۲/۳	۱	۳۵	٪۳۵ ±۱۷/۵	۱	۳۵	۳۸/۹٪ ±۳۳/۳	۵	۳۹
CSP با ۸ مؤلفه	اطلاعات متقابل	۴۳/۷٪ ۱۰±/۹	۱	۱	٪۳۳ ±۱۹/۲	۱	۱	٪۴۰ ±۱۷/۴	۱	۱	۴۴/۴٪ ±۳۹	۵	۲
	همبستگی	۴۲/۵٪ ±۱۰/۵	۱	۱	٪۳۳ ±۱۵/۷	۱	۱	۳۲/۵٪ ±۱۶/۸	۱	۱	۴۴/۴٪ ±۳۹	۵	۲
FBCSP با ۲ مؤلفه	اطلاعات متقابل	۷۶/۲٪ ±۷/۱	۶	۸	۸۱/۶٪ ±۱۶/۵	۴	۹	۸۲/۵٪ ±۲۰/۵	۴	۹	۸۸/۹٪ ±۲۲	۲	۹
	همبستگی	۷۲/۵٪ ±۱۳/۲	۲	۳	٪۷۵ ±۱۵/۳	۶	۱۰	۷۷/۵٪ ±۱۷/۴	۱۳	۱۴	۸۸/۹٪ ±۲۲	۵	۱۰
FBCSP با ۴ مؤلفه	اطلاعات متقابل	۸۲/۵٪ ±۶/۴	۹	۱۴	۸۳/۳٪ ±۱۷/۵	۹	۱۵	٪۹۰ ±۱۲/۹	۱۴	۲۱	۸۸/۹٪ ±۲۲	۲	۱۰
	همبستگی	۷۶/۲٪ ±۱۲	۱۴	۲۰	٪۷۵ ±۱۵/۸	۸	۱۵	۷۷/۵٪ ±۱۰/۵	۸	۱۵	۹۴/۴٪ ±۱۶/۶	۷	۱۴
FBCSP با ۶ مؤلفه	اطلاعات متقابل	۸۱/۲٪ ±۱۰/۶	۶	۱۴	٪۹۰ ±۱۱/۶	۱۳	۲۵	٪۹۰ ±۱۲/۹	۲۵	۴۴	۹۴/۴٪ ±۱۶/۶	۱۲	۱۱
	همبستگی	۷۷/۵٪ ±۱۲	۹	۱۹	۷۸/۳٪ ±۱۱/۱	۱۱	۲۲	٪۸۰ ±۱۲/۹	۳۷	۶۰	٪۱۰۰ ±۰	۵	۱۵
FBCSP با ۸ مؤلفه	اطلاعات متقابل	۸۲/۵٪ ±۶/۴	۱۳	۳۲	۸۶/۶٪ ±۱۵/۳	۱۴	۳۵	۸۷/۵٪ ±۱۳/۱	۳۱	۶۹	۹۴/۴٪ ±۱۶/۶	۲	۱۱
	همبستگی	٪۸۰ ±۸/۷	۲۰	۴۶	۷۸/۳٪ ±۱۸/۳	۲۸	۶۴	۸۲/۵٪ ±۱۷/۴	۵۵	۱۱۸	٪۱۰۰ ±۰	۶	۲۰

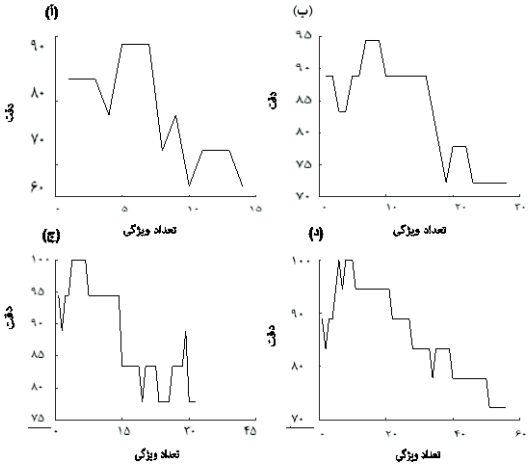

شکل ۳ نمودارهای میانگین دقت برحسب تعداد ویژگی انتخابی با معیار همبستگی از مجموعه ویژگی‌های FBCSP در روش ارزیابی متقابل با یک نمونه خارج شده. (آ) بانک فیلتر با ۲ مؤلفه، (ب) بانک فیلتربا ۴ مؤلفه، (ج) بانک فیلتربا ۶ مؤلفه، (د)بانک فیلتربا ۸ مؤلفه

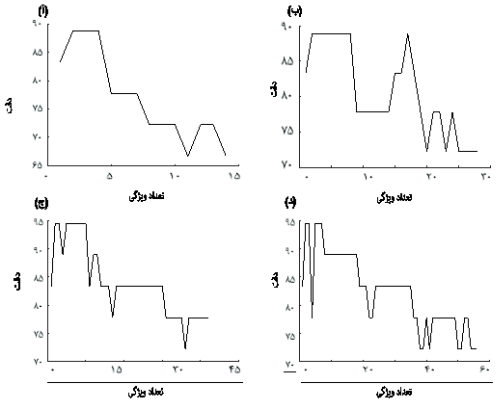

شکل ۴ نمودارهای میانگین دقت برحسب تعداد ویژگی انتخابی با معیار اطلاعات متقابل از مجموعه ویژگی‌های FBCSP در روش ارزیابی متقابل با یک نمونه خارج شده. (آ) بانک فیلتر با ۲ مؤلفه، (ب) بانک فیلتر با ۴ مؤلفه، (ج) بانک فیلتربا ۶ مؤلفه، (د)بانک فیلتربا ۸ مؤلفه

مورد زمان اجرا، همان‌طور که در جدول ۱ مشاهده می‌شود، زمان اجرای الگوریتم CSP کلاسیک از همه روش‌ها کمتر است اگرچه دقت قابل قبولی ندارد. زمان اجرای الگوریتم FBCSP نیز در بسیاری از موارد از روش استخراج ویژگی‌های توان باندهای فرکانسی کمتر و در برخی موارد از این روش بیشتر است اما در تمام موارد دقت الگوریتم FBCSP از روش استخراج ویژگی‌های توان باندهای فرکانسی بالاتر است.

روش FBCSP با استفاده از ۶ مؤلفه نتایجی مشابه و نزدیک به ۸ مؤلفه دارد که نشان می‌دهد استفاده از ۶ مؤلفه برای استخراج ویژگی کافی است. در روش ارزیابی زیرمجموعه تصادفی که روی تعداد داده آموزش ۵، ۶و ۷ صورت می‌گیرد، روش اطلاعات متقابل بازده بیشتری از روش همبستگی دارد. مثلاً برای ۷ داده آموزش در هرگروه با روش انتخاب ویژگی اطلاعات متقابل حداکثر، میانگین دقت برابر ۹۰ درصد و با روش همبستگی حداکثر، میانگین دقت برابر ۸۷،۵ درصد است.

شکل ۳ (آ-د) نمودارهای دقت طبقه‌بندی روش پیشنهادی FBCSP برحسب تعداد ویژگی‌های انتخابی با معیار همبستگی از مجموعه ویژگی‌های FBCSP (با ۲ تا ۸ مؤلفه) در روش ارزیابی متقابل با یک نمونه خارج شده را نشان می‌دهد. همان‌طورکه در شکل دیده می‌شود بالاترین دقت طبقه‌بندی در حالت‌های ۲، ۴، ۶ و ۸ مؤلفه به ازای n_{opt} برابر با تعداد ۵، ۷، ۵ و۶ ویژگی اول مرتب شده با معیار همبستگی، به ترتیب به میانگین دقت ٪۸۸/۹، ٪۹۴/۴، ٪۱۰۰ و ٪۱۰۰ می‌انجامد.

شکل ۴ (آ-د) نمودارهای دقت طبقه‌بندی روش پیشنهادی FBCSP برحسب تعداد ویژگی‌های انتخابی با معیار اطلاعات متقابل از مجموعه ویژگی‌های FBCSP (با ۲ تا ۸ مؤلفه) در روش ارزیابی متقابل با یک نمونه خارج شده را نشان می‌دهد. همان‌طورکه در شکل دیده می‌شود بالاترین دقت طبقه‌بندی در تمام حالت‌های ۲، ۴، ۶ و ۸ مؤلفه، همواره به ازای n_{opt} برابر ۲ ویژگی اول مرتب شده با معیار اطلاعات متقابل بوده و به ترتیب به میانگین دقت ٪۸۸/۹، ٪۸۸/۹، ٪۹۴/۴ و ٪۹۴/۴ می‌انجامد.

در مقایسه دو روش مختلف انتخاب ویژگی در FBCSP با ۸ مؤلفه، زمانی که از ۸ داده به‌عنوان داده آموزش استفاده می‌شود، ویژگی‌های انتخاب شده توسط معیار همبستگی شامل واریانس خروجی‌های دو فیلتر CSP از باند α1، یک فیلتر CSP از باند θ و سه فیلتر CSP از باند β2 می‌باشد. با استفاده از معیار اطلاعات متقابل، دو ویژگی اول منتخب در این حالت واریانس خروجی‌های یک فیلتر CSP از باند α1 و یک فیلتر CSP از باند β2 می‌باشد.

با توجه به این نتایج، استفاده از فیلترهای CSP از دو زیرباند فرکانسی α1 و β2 در هردو روش انتخاب ویژگی مشترک بوده و استفاده از آن موجب افزایش یافتن و بهبود عملکرد تفکیک دو گروه می‌شود.

شکل۵ نقشه توپوگرافیکی وزن‌های بهینه ۶ ویژگی اول انتخاب شده با معیار همبستگی از مجموعهFBCSP با ۸ مؤلفه درهرباند فرکانسی را نشان می‌دهد. همان‌طور که قبلاً نشان داده شده در ارزیابی متقابل با یک نمونه خارج شده اعمال این فیلترها منجر به تشکیل ۶ ویژگی بهینه و میانگین دقت ٪۱۰۰ در طبقه‌بندی می‌شود.

در نام‌گذاری این نقشه‌ها در بالای هر نقشه، ابتدا نام زیرباندی که ویژگی مربوطه از به آن زیرباند تعلق دارد ذکر شده است و سپس شماره مؤلفه انتخابی از میان ۸ مؤلفه CSP آن باند آمده است. به‌این‌ترتیب شش ویژگی برتر انتخابی در حالت فوق به ترتیب مؤلفه‌های پنجم و هشتم باند α1، مؤلفه پنجم باند θ و مؤلفه‌های ششم، هفتم و پنجم باند β2 می‌باشند.

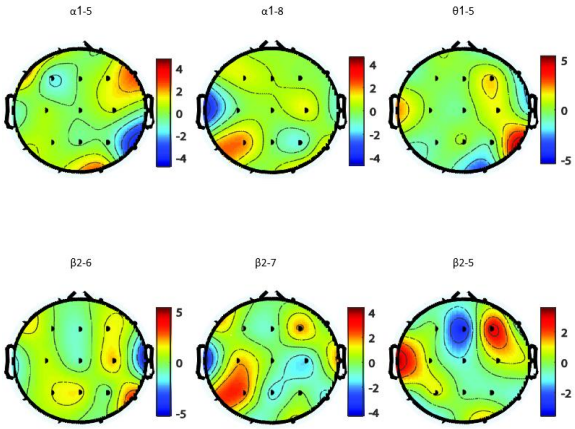

شکل ۵ نقشه‌های توپوگرافیکی از بالا سمت چپ به راست و پایین به ترتیب وزن‌های بهینه کانال‌ها در شش ویژگی اول انتخابی توسط معیار همبستگی روی FBCSP با ۸ مؤلفه درهرباند.

از آنجایی‌که مؤلفه‌های پنجم تا هشتم هر CSP در هر زیرباند مربوط به m مؤلفه پایینی CSP می‌باشد، این مولفه‌ها به فیلترهایی اشاره دارند که کمترین واریانس را در کلاس افراد سالم و بیشترین واریانس را در کلاس بیماران MCI ایجاد می‌کنند.

به‌این‌ترتیب نتایج به‌دست‌آمده نشان داد که شش ویژگی برتر انتخاب شده درحالت فوق ازمولفه‌های پنجم تا هشتم می‌باشند و با ایجاد کمترین واریانس در کلاس افراد سالم و بیشترین واریانس در کلاس بیماران MCI بهترین نتیجه طبقه‌بندی در ارزیابی متقابل با یک نمونه خارج شده را به وجود می‌آورند.

همچنین ازلحاظ تعداد ویژگی‌های انتخاب شده از باندهای فرکانسی مختلف در میان شش ویژگی، باند β2 با سه ویژگی انتخابی، باند α1 با دو ویژگی و باند تتا با یک ویژگی، به‌عنوان مؤثرترین زیرباندها با استفاده از معیار همبستگی در طبقه‌بندی افراد سالم و MCI در ارزیابی متقابل با یک نمونه خارج شده می‌باشد. از ضرایب وزنی فیلترهای فضایی بهینه در شکل ۵ مشاهده می‌شود که درباند α1 که ویژگی‌ها بالاترین رتبه با استفاده از معیار همبستگی برای تفکیک افراد سالم از MCI را دارند، فیلتر فضایی از تفاضل کانال‌های ناحیه پیشانی-گیجگاهی از آهیانه- گیجگاهی نیمکره راست و تفاضل ناحیه آهیانه-گیجگاهی از گیجگاهی نیمکره چپ حاصل شده است. ویژگی انتخاب شده از باند θ که موجب بهبود عملکرد می‌شود، از تفاضل نواحی گیجگاهی از ناحیه پس سری بهترین فیلتر فضایی حاصل شده است و در باندβ2 نیز از تفاضل نواحی آهیانه-گیجگاهی از گیجگاهی هر یک از دو نیمکره راست و چپ و همچنین ترکیب نواحی پیشانی راست و گیجگاهی چپ و تفاضل آن از ناحیه پیشانی مرکزی بهترین فیلتر فضایی را جهت ایجاد بیشترین تمایز میان دو کلاس ساخته است.

در نمودار (د) شکل۳ نیز تأثیر افزودن ویژگی‌های چهارم تا ششم که واریانس خروجی فیلترهای CSP مربوط به باند β۲ هستند در افزایش دقت طبقه‌بندی و تشخیص به‌خوبی نشان داده شده است. استفاده از ویژگی‌های حاصل از باند β۲ امکان تشخیص بهتر را فراهم می‌کند. پیش از این نیز در مقدمه ذکر شد که اختلاف در باندهای فرکانس بالا بین بیماران و افراد سالم دیده می‌شود.

۴- بحث

در این مطالعه روشی مطمئن و قوی برای تشخیص و جداسازی بیماران دچار MCI در برابر افراد سالم ارائه شد، این روش بر پایه استفاده از FBCSP بنا شده است، همچنان که در نتایج (جدول ۱) مشاهده شد، روش FBCSP درتمام حالت‌ها نتایجی به‌وضوح بهتر است سایر روش‌های بررسی شده در این مقاله به دست می‌دهد، به‌گونه‌ای که با استفاده از هر دو روش انتخاب ویژگی و تعداد نسبتاً کم ویژگی‌ها در ارزیابی یک نمونه خارج شده، دقت این روش به ۱۰۰ درصد می‌رسد.

درمقایسه با روش پیشنهادی FBCSP، استفاده از ویژگی‌های توان باندهای فرکانسی که در مقاله [۷] پیشنهاد شده است دقت طبقه‌بندی مناسبی را برای تفکیک دو گروه افراد MCI و سالم به‌وجود نیاورده است. همچنین، استفاده از توان باندهای فرکانسی نسبت به اغلب حالات استفاده از FBCSP مخصوصاً حالت استفاده از ۸ داده به‌عنوان داده آموزش میزان حجم و پیچیدگی محاسبات و در نتیجه زمان اجرای بیشتری دارد (جدول ۱). روش دیگر مورد استفاده استخراج ویژگی از فیلترفضایی CSP کلاسیک است. در یک مطالعه قبلی[۱۲] این روش به‌عنوان نوعی پیش‌پردازش مورد استفاده قرار گرفته است. در مطالعه مذکور از ترکیب فیلترفضایی CSP و ویژگی‌هایی مثل توان، توان نسبی باند تتا، توان پنجره‌گذاری شده و آنتروپی نمونه سیگنال تفکیک قابل قبولی گزارش شده است[۱۲]. اما در مطالعه حاضر با توجه به تفاوت نوع ویژگی‌ها، نتایج به‌دست‌آمده در جدول۱، فیلتر CSP کلاسیک نیز نتایجی بهتر از ویژگی‌های توان باندهای فرکانسی به دست نمی‌دهد. حجم محاسبات و زمان اجرای فرآیند در روش فیلتر CSP کلاسیک نسبت به ویژگی‌های توان باندهای فرکانسی و استفاده از FBCSP بسیار کمتر است. در مطالعه حاضر هدف اصلی تفکیک صحیح گروه بیمار از سالم است، که استفاده از دو روش توان باندهای فرکانسی و فیلتر CSP این هدف را برآورده نمی‌کند.

از مقایسه نتایج حاصل از FBCSP و CSP کلاسیک می‌توان نتیجه گرفت که عملکرد نامطلوب CSP کلاسیک به دلیل محدودکردن ترکیب فیلترهای فضایی صرفاً به اطلاعات کانال‌ها روی کل باند فرکانسی سیگنال است درحالی‌که FBCSP امکان به دست آوردن ترکیب‌های بهینه فضایی را روی هر یک از ۷ باند فرکانسی به‌طور جداگانه فراهم می‌کند.

برای اینکه بتوان از این روش به نتایج مطمئن‌تر و قابل‌اتکاتر رسید، محدودیت این مطالعه که تعداد کم داده‌های در اختیار است، باید رفع شود. در مطالعات تکمیلی برای سنجش کارایی روش

FBCSP، استفاده از داده‌های به‌دست‌آمده از سایر پارادایم‌های رایج ثبت داده‌ها برای تشخیص MCI مثل داده‌های ثبت شده با چشم باز در حالت استراحت یا داده‌های ثبت شده با چشم باز در اعمال شناختی تعریف شده را نیز می‌توان بررسی نمود[۳، ۲۰، ۴۳].

۵- نتیجه‌گیری

تشخیص بیماری آلزایمر و اختلال شناختی خفیف از اهمیت بالایی برخوردار است. به دلیل ارزان و غیرتهاجمی‌بودن، استفاده از EEG برای تشخیص MCI توجه بیشتری قرار دارد. در مطالعه حاضر کاربرد فیلترهای فضایی طیفی بهینه‌سازی شده در استخراج ویژگی‌های مؤثر از سیگنال‌های EEG با روش FBCSP مورد بررسی قرار گرفت. نتایج این مطالعه، برتری کامل روش پیشنهادی در مقایسه با فیلتر فضایی CSP کلاسیک و همچنین ویژگی‌های توان باند فرکانسی سیگنال بدون استفاده از فیلترهای فضایی را نشان داد. به‌عنوان نتیجه‌گیری، این مطالعه بر نقش مهم استفاده از ترکیب‌های فضایی یادگیری شده در هریک از زیرباندهای فرکانسی برای استخراج ویژگی‌های مؤثر در تفکیک افراد سالم از بیماران MCI تأکید دارد.

سپاس‌گزاری

این تحقیق با حمایت مالی معاونت پژوهش و فناوری دانشگاه علم و صنعت ایران، پژوهشکده‌ی مهندسی و فناوری عصبی ایران (طرح کلان ملی «طراحی و ساخت پروتز عصبی حرکتی زیر جلدی برای بازیابی حرکت در افراد ضایعه نخاعی» به شماره ۱۱۱۱۹۴/م/۴۸) انجام شده است.

مراجع

[1] J. B. Orange and E. B. Ryan "Alzheimer's disease and other dementias." *Clinics in geriatric medicine*, vol. 16, pp. 153-173, 2000.

[2] E. Gallego-Jutglàa, J. Solé-Casalsa, F. B. Vialatteb, J. Dauwelsc, and A. Cichocki, "A theta-band EEG based index for early diagnosis of Alzheimer's disease Running title: EEG based index to improve AD diagnosis." *Journal of Alzheimer's Disease*, vol. 43, pp. 1175-1184, 2015

[3] B. Czigler, D. Csikós, Z. Hidasi, Z. A. Gaál, É. Csibri, É. Kiss, P. Salacz, and M. Molnár, "Quantitative EEG in early Alzheimer's disease patients—power spectrum and complexity features." *International Journal of Psychophysiology*, vol. 68, pp. 75-80, 2008.

[4] Y. M. Park, H. J. Che, C. H. Im, H. T. Jung, S. M. Bae, and S.H. Lee, "Decreased EEG synchronization and its correlation with symptom severity in Alzheimer's disease." *Neuroscience research*, vol. 62, pp. 112-117, 2008.

[5] J. Dauwels, F. Vialatte, T. Musha, and A. Cichocki, "A comparative study of synchrony measures for the early diagnosis of Alzheimer's disease based on EEG." *NeuroImage*, vol. 49, pp. 668-693, 2010.

[6] M. R. Daliri, "Kernel earth mover's distance for eeg classification." *Clinical EEG and neuroscience*, vol. 44, pp. 182-187, 2013.

[7] J. C. McBride, X. Zhao, N. B. Munro, C. D. Smith, G. A. Jicha, L. Hively, L. S. Broster, F. A. Schmitt, R. J. Kryscio, and Y. Jiang, "Spectral and complexity analysis of scalp EEG characteristics for mild cognitive impairment and early Alzheimer's disease." *Computer methods and programs in biomedicine*. vol. 114, pp. 153-163, 2014.

[8] M. R. Daliri, "Automated diagnosis of Alzheimer disease using the scale-invariant feature transforms in magnetic resonance images." *Journal of medical systems*, vol. 36, vol. 995-1000, 2012.

[9] مرتضی به نام و حسین پورقاسم، «شناسایی صرع بر اساس بهینه‌سازی ویژگی‌های ادغامی‌تبدیل‌هارتلی با مدل ترکیبی MLP و GA همراه با استراتژی یادگیری ممتیک»، مجله مهندسی برق تبریز، جلد ۴۵، شماره ۴، صفحه ۵۱-۶۷، ۱۳۹۴.

[10] مرتضی جهان‌تیغ و مصطفی چرمی، «افزایش صحت طبقه‌بندی سیگنال‌های EEG تصور حرکتی با ترکیب منطقی طبقه‌بندها و با به‌کارگیری الگوریتم ژنتیک و درختان تصمیم کوچک»، مجله مهندسی برق تبریز، جلد ۴۷، شماره ۳، صفحه ۹۳۱-۹۳۸، ۱۳۹۶.

[11] C. S. Herrmann and T. Demiralp. "Human EEG gamma oscillations in neuropsychiatric disorders." *Clinical neurophysiology*, vol. 116, pp. 2719-2733, 2005.

[12] C. F. Latchoumane, F. Vialatte, A. Cichocki, and J. Jeong, "Multiway analysis of Alzheimer's disease: classification based on space-frequency characteristics of EEG time series." In *Proceedings of the World Congress on Engineering*, vol. 2, pp. 2-4. 2008.

[13] W. Woon, A. Cichocki, F. Vialatte, and T. Musha. "Techniques for early detection of Alzheimer's disease using spontaneous EEG recordings." *Physiological Measurement*. vol. 28, pp 335-347, 2007.

[14] J. Jaeseung, "EEG dynamics in patients with Alzheimer's disease." *Clinical neurophysiology*. vol. 115, pp. 1490-1505, 2004.

[15] T. König, L. Prichep, T. Dierks, D. Hubl, L. O. Wahlund, E. R. John, and V. Jelic. "Decreased EEG synchronization in Alzheimer's disease and mild cognitive impairment." *Neurobiology of aging*, vol.26, pp. 165-171, 2005.

[16] J. Dauwels, F. Vialatte, C. Latchoumane, J. Jeong, and A. Cichocki. "Loss of EEG synchrony in early-stage AD patients: a study with multiple synchrony measures and multiple EEG data sets." In *Proceedings of the 31st annual international conference of the IEEE engineering in medicine and biology society*. vol. 2009, pp.2224-2227, 2009.

[17] J. A. Deursen, E. F. Vuurman, F. R. Verhey, V. H. van Kranen-Mastenbroek, and W. J. Riedel, "Increased EEG gamma band activity in Alzheimer's disease and mild cognitive impairment." *Journal of neural transmission*, vol. 115, pp. 1301-1311, 2008.

[18] D. V. Moretti, C. Fracassi, M. Pievani, C. Geroldi, G. Binetti, O. Zanetti, K. Sosta, P. M. Rossini, and G. B. Frisoni. "Increase of theta/gamma ratio is associated with memory impairment." *Clinical Neurophysiology*, vol. 120, pp. 295-303, 2009.

[19] P. Zhao, P. Van-Eetvelt, C. Goh, N. Hudson, S. Wimalaratna, and E. Ifeachor. "Characterization of EEGs

[31] R. P. Brenner, R. F. Ulrich, D. G. Spiker, R. J. Sclabassi, C. F. Reynolds, R. S. Marin, and F. Boller. "Computerized EEG spectral analysis in elderly normal, demented and depressed subjects." *Electroencephalography and clinical neurophysiology*. vol. 64, pp. 483-492, 1986.

[32] K. J. Blinowska, F. Rakowski, M. Kaminski, F. De Vico Fallani, C. Del Percio, R. Lizio, and C. Babiloni. "Functional and effective brain connectivity for discrimination between Alzheimer's patients and healthy individuals: A study on resting state EEG rhythms." *Clinical Neurophysiology*, vol. 128, pp. 667-680, 2017.

[33] J. McBride, X. Zhao, N. Munro, C. Smith, G. Jicha, and Y. Jiang, "Resting EEG discrimination of early stage Alzheimer's disease from normal aging using inter-channel coherence network graphs." *Annals of biomedical engineering*, vol. 41, pp. 1233-1242, 2013.

[34] F. B. Vialatte, J. Solé-Casals, M. Maurice, C. Latchoumane, N. Hudson, S. Wimalaratna, J. Jeong, and A. Cichocki. "Improving the quality of EEG data in patients with Alzheimer's disease using ICA." In *International Conference on Neural Information Processing*, vol. 2008, pp. 979-986, 2008.

[35] C. F. Latchoumane, F. B. Vialatte, J. Solé-Casals, M. Maurice, S. R. Wimalaratna, N. Hudson, J. Jeong, and A. Cichocki. "Multiway array decomposition analysis of EEGs in Alzheimer's disease." *Journal of neuroscience methods*, vol. 207, pp 41-50, 2012.

[36] H. Ramoser, J. Muller-Gerking, and G. Pfurtscheller. "Optimal spatial filtering of single trial EEG during imagined hand movement." *IEEE transactions on rehabilitation engineering*, vol. 8, pp. 441-446, 2000.

[37] B. Blankertz, R. Tomioka, S. Lemm, M. Kawanabe, and K. R. Muller. "Optimizing spatial filters for robust EEG single-trial analysis." *IEEE Signal processing magazine*, vol. 25, pp. 41-56, 2008.

[38] K. K. Ang, Z. Y. Chin, C. Wang, C. Guan, and H. Zhang. "Filter bank common spatial pattern algorithm on BCI competition IV datasets 2a and 2b." *Frontiers in neuroscience*, vol. 6, 2012.

[39] M. Kashefpoor, H. Rabbani, and M. Barekatain. "Automatic diagnosis of mild cognitive impairment using electroencephalogram spectral features." *Journal of medical signals and sensors*, vol. 6, pp. 25-32, 2016.

[40] H. Liu, J. Sun, L. Liu, and H. Zhang. "Feature selection with dynamic mutual information." *Pattern Recognition*, vol. 42, pp. 1330-1339, 2009.

[41] S. M. Stigler, "Francis Galton's account of the invention of correlation." *Statistical Science*. vol. 4, pp. 73-79, 1989.

[42] M. A. Hearst, S. T. Dumais, E. Osuna, J. Platt, and B. Scholkopf. "Support vector machines." *IEEE Intelligent Systems and their applications*, vol. 13, pp. 18-28, 1998.

[43] P. Ghorbanian, D. M. Devilbiss, A. J. Simon, A. Bernstein, T. Hess, and H. Ashrafiuon. "Discrete wavelet transform EEG features of Alzheimer's disease in activated states." In *Engineering in Medicine and Biology Society (EMBC), 2012 Annual International Conference of the IEEE*, pp. 2937-2940, 2012.

in Alzheimer's disease using information theoretic methods." In *Engineering in Medicine and Biology Society, 2007. EMBS 2007. 29th Annual International Conference of the IEEE*, vol. 2007 pp. 5127-5131, 2007.

[20] D. Labate, F. L. Foresta, G. Morabito, I. Palamara, and F. C. Morabito, "Entropic measures of EEG complexity in Alzheimer's disease through a multivariate multiscale approach." *IEEE Sensors Journal*, vol. 13, pp. 3284-3292, 2013.

[21] D. Abásolo, J. Escudero, R. Hornero, C. Gómez, and P. Espino, "Approximate entropy and auto mutual information analysis of the electroencephalogram in Alzheimer's disease patients." *Medical & biological engineering & computing*, vol. 46, pp. 1019-1028, 2008.

[22] F. C. Morabito, D. Labate, A. Bramanti, F. L. Foresta, G. Morabito, I. Palamara, and H. H. Szu. "Enhanced compressibility of eeg signal in alzheimer's disease patients." *IEEE Sensors Journal*, vol. 13, pp. 3255-3262, 2013.

[23] J. Jeong, J. C. Gore, and B. S. Peterson. "Mutual information analysis of the EEG in patients with Alzheimer's disease." *Clinical neurophysiology*, vol. 112, pp. 827-835, 2001.

[24] R. Hornero, D. Abásolo, J. Escudero, and C. Gómez. "Nonlinear analysis of electroencephalogram and magnetoencephalogram recordings in patients with Alzheimer's disease." *Philosophical Transactions of the Royal Society of London A: Mathematical, Physical and Engineering Sciences*, vol. 367, pp. 317-336, 2009.

[25] M. J. Hogan, G. R. Swanwick, J. Kaiser, M. Rowan, and B. Lawlor. "Memory-related EEG power and coherence reductions in mild Alzheimer's disease." *International Journal of Psychophysiology*, vol. 49, pp. 147-163, 2003.

[26] J. Dauwels, F. Vialatte, and A. Cichocki, "A comparative study of synchrony measures for the early detection of Alzheimer's disease based on EEG." In *International Conference on Neural Information Processing*, vol. 2007, pp. 112-125. 2007.

[27] T. Locatelli, M. Cursi, D. Liberati, M. Franceschi, and G. Comi, "EEG coherence in Alzheimer's disease"*Electroencephalography and clinical neurophysiology*, vol. 106, pp. 229-237, 1998.

[28] Y. Wada, Y. Nanbu, Y. Koshino, N. Yamaguchi, and T. Hashimoto, "Reduced interhemispheric EEG coherence in Alzheimer disease: analysis during rest and photic stimulation." *Alzheimer Disease & Associated Disorders*, vol. 12, pp. 175-181, 1998.

[29] D. V. Moretti, Davide V., C. Babiloni, G. Binetti, E. Cassetta, G. D. Forno, F. Ferreric, R. Ferri, B. Lanuzza, C. Miniussi, F. Nobili, G. Rodriguez, S. Salinari and P. M. Rossini, "Individual analysis of EEG frequency and band power in mild Alzheimer's disease." *Clinical Neurophysiology*, vol. 115, pp. 299-308, 2004.

[30] C. Babiloni, F. Vecchio, R. Lizio, R. Ferri, G. Rodriguez, N. Marzano, G. B. Frisoni, and P. M. Rossini. "Resting state cortical rhythms in mild cognitive impairment and Alzheimer's disease: electroencephalographic evidence." *Journal of Alzheimer's Disease*, vol. 26 pp. 201-214, 2011.

زیرنویس‌ها

[1] Dementia
[2] Alzheimer disease
[3] Mild Cognitive Impairment
[4] Electroencephalogram
[5] Slowing
[6] Complexity
[7] Synchrony
[8] Spatial Pattern
[9] Independent Components Analysis

[1] Common Spatial Pattern

[1] Filter Bank Common Spatial Pattern
[1] Covariance
[1] Mutual Information
[1] Correlation
[1] Support Vector Machine
[1] Classification accuracy
[1] Random Sub-Sampling
[1] Leave-one-out