

Evaluating the Integration of EEG Brain Connectivity with Local Graph Structures in the Diagnosis of Multiple Psychiatric and Cognitive Disorders

Moshiryan, Sara ^۱ / Sanati Fahandari, Arezoo ^۲ / Goshvarpour, Ateke ^{**۳}

- Master's student, Department of Biomedical Engineering, Imam Reza International University, Mashhad, Iran ^۱

- Assistant Professor, Department of Biomedical Engineering, Imam Reza International University, Mashhad, Iran ^۲

ARTICLE INFO

DOI: 10.22041/ijbme.2025.2060041.1981

Received: 7/5/2025

Revised: 30/6/2025


Accepted: 18/7/2025

KEY WORDS

Cognitive and Mental Disorders
Brain Connectivity
Electroencephalogram Classification
Nonlinear Features

ABSTRACT

With recent advancements in the processing of brain signals, the classification of psychological disorders has gained increasing importance. While previous studies were mostly limited to the classification of one or two disorders, this study addresses the classification of five distinct conditions, including a healthy control group and four types of psychological disorders (depression, schizophrenia, mild cognitive impairment, and Alzheimer's disease) using the analysis of electroencephalogram signals. This research presents various combinations of functional connectivity measures including Pearson correlation coefficient, phase locking value, and mutual information to generate connectivity matrices without redundant data. The features were extracted from the matrices using local graph structures and through Shannon entropy, logarithmic energy entropy, and singular value decomposition. For final classification, machine learning algorithms including K-nearest neighbors and Naïve Bayes were used. Moreover, the capability of different electroencephalogram frequency bands in classifying psychological states was investigated. This study achieved an accuracy of 90.29% in diagnosing mild cognitive impairment by combining Pearson correlation and mutual information in the beta frequency band using the largest singular value feature and the K-nearest neighbors' classifier. Additionally, by combining phase locking value and mutual information in the gamma frequency band using the largest singular value and the Naïve Bayes algorithm, an accuracy of 89.53% was achieved. Furthermore, by combining three features (Shannon entropy, logarithmic energy entropy, and singular value decomposition) in the combination of Pearson correlation and phase locking value in the beta frequency band using the K-nearest neighbors' algorithm, an accuracy of 90.63% was obtained. In the diagnosis of depression, by combining Pearson correlation and phase locking value in the gamma frequency band using the Naïve Bayes algorithm, an accuracy of 88.52% was achieved.



ارزیابی ترکیب اتصالات مغزی EEG با ساختارهای گراف محلی در تشخیص چند اختلال روانی و شناختی

مشیریان، سارا^۱ / صنعتی فهندری، آرزو^۲ گشوارپور، عاتکه^۳*

^۱ - دانشجوی کارشناسی ارشد، گروه مهندسی پزشکی، دانشگاه بین المللی امام رضا (ع)، مشهد، ایران

^۲ - استادیار، گروه مهندسی پزشکی، دانشگاه بین المللی امام رضا (ع)، مشهد، ایران

مشخصات مقاله

شناسه‌ی دیجیتال: 10.22041/ijbme.2025.2060041.1981

پذیرش: ۱۴۰۴/۴/۲۷

بازنگری: ۱۴۰۴/۴/۹

ثبت در سامانه: ۱۴۰۴/۲/۱۷

چکیده

واژه‌های کلیدی

با پیشرفت‌های اخیر در پردازش سیگنال‌های مغزی، طبقه‌بندی اختلالات روان‌شناختی اهمیت فزاینده‌ای یافته است. در حالی که مطالعات پیشین عمدتاً به طبقه‌بندی یک یا دو اختلال محدود بودند، این مطالعه به طبقه‌بندی پنج وضعیت متمایز شامل یک گروه کنترل سالم و چهار نوع اختلال روان‌شناختی (افسردگی، اسکیزوفرنی، اختلال شناختی خفیف و آلزایمر) با استفاده از تحلیل سیگنال‌های الکتروانسفالوگرام می‌پردازد. این پژوهش، ترکیب‌های مختلف اتصالات عملکردی شامل ضریب همبستگی پیرسون، مقدار قفل شدگی فاز و اطلاعات متقابل جهت تولید ماتریس‌های اتصال‌پذیری بدون داده‌های حشو را ارائه می‌دهد. ویژگی‌های استخراج‌شده از این ماتریس‌ها با بهره‌گیری از ساختارهای گراف محلی و با آنتروپی شانون و آنتروپی لگاریتم انرژی و تجزیه مقدار منفرد حاصل شده و به منظور طبقه‌بندی نهایی، از الگوریتم‌های یادگیری ماشین شامل K -نزدیک‌ترین همسایه و بیز ساده استفاده شده است. همچنین، قابلیت باندهای مختلف فرکانسی الکتروانسفالوگرام در طبقه‌بندی حالات روان‌شناختی مورد بررسی قرار گرفت. این پژوهش در تشخیص اختلال شناختی خفیف با ترکیب اتصالات عملکردی ضریب همبستگی پیرسون و اطلاعات متقابل در باند فرکانسی بتا با استفاده از ویژگی بزرگترین مقدار منفرد در طبقه‌بند K -نزدیک‌ترین همسایه به صحت 90.29% دست یافت. همچنین با ترکیب مقدار قفل شدگی فاز و اطلاعات متقابل در باند فرکانسی گاما با استفاده از ویژگی بزرگترین مقدار منفرد و الگوریتم بیز ساده به صحت 89.53% رسید. علاوه بر این، با ترکیب ۳ ویژگی (آنتروپی شانون، آنتروپی لگاریتم انرژی، تجزیه مقدار منفرد) در ترکیب ضریب همبستگی پیرسون و مقدار قفل شدگی فاز در باند فرکانسی بتا با استفاده از الگوریتم K -نزدیک‌ترین همسایه به صحت 90.63% را نشان داد. در تشخیص افسردگی نیز با ترکیب ضریب همبستگی پیرسون و مقدار قفل شدگی فاز در باند فرکانسی گاما با استفاده از الگوریتم بیز ساده به صحت 88.52% را نشان داد.

اختلالات شناختی و روانی
اتصالات مغزی
ساختار گراف‌های محلی
الکتروانسفالوگرام
طبقه‌بندی
ویژگی‌های غیرخطی

۱- مقدمه

مرحله بیماری آلزایمر را از هم تشخیص دادند. آن‌ها این اندازه‌گیری‌ها را برای بررسی الگوهای ریتمیک مغز انجام دادند و نشان دادند که این ویژگی‌ها می‌توانند مراحل اولیه بیماری را با صحت خوبی تشخیص دهند. این پژوهش نشان می‌دهد که بررسی الگوهای غیرخطی ارتباطات مغزی می‌تواند در تشخیص مراحل مختلف آلزایمر کمک‌کننده باشد. فودور و همکاران [۳] نیز الگوهای ارتباطی و همبستگی‌های عملکردی در EEG را بررسی کردند و دریافتند که کاهش ارتباط عملکردی در باند آلفا می‌تواند نشانگر مهمی برای تشخیص اختلالات شناختی، به ویژه آلزایمر و MCI باشد. این مطالعه بر اهمیت تغییرات در الگوهای ارتباطات مغزی برای تشخیص اختلالات تأکید دارد. خار و همکاران [۴] ارتباطات عملکردی در افراد مبتلا به مشکلات حرکتی و شناختی را بررسی کردند و نشان دادند که تغییرات در ارتباط بین بخش‌های مغز در باندهای آلفا و بتا می‌تواند نشان‌دهنده مشکلات شناختی در این افراد باشد. این پژوهش نشان می‌دهد که بررسی ارتباطات مغزی می‌تواند در تشخیص مشکلات شناختی مرتبط با بیماری‌های دیگر نیز مفید باشد. در راستای بررسی روش‌های تشخیص سایر اختلالات، سیپریان و همکاران [۵] از STE^۵ و الگوریتم Relief برای انتخاب ویژگی‌های مرتبط در تشخیص اسکیزوفرنی در مقابل افراد سالم استفاده کردند و به صحت ۹۶/۹۲٪ با الگوریتم KNN^۶ دست یافتند. گادفری و سینگ [۶] نیز از تحلیل آماری، تحلیل طیفی، تحلیل موجک و ارزیابی اتصال عملکردی برای تشخیص افسردگی در مقابل افراد سالم استفاده کردند و به صحت ۹۹٪ با الگوریتم RBFSVM^۷ رسیدند.

در زمینه تشخیص اسکیزوفرنی، روئیز د میراس و همکاران [۷] با بررسی معیارهای خطی و غیرخطی سیگنال EEG و استفاده از طبقه‌بندهای مختلف، به صحت ۸۷٪ با KNN رسیدند. شن و همکاران [۸] نیز با تمرکز بر فرکانس باند آلفا و استفاده از مدل MVAR^۸ برای استخراج ویژگی‌های حوزه فرکانس و شبکه‌های عصبی CNNs برای طبقه‌بندی، به صحت ۹۸/۴۷٪ در تشخیص اسکیزوفرنی دست یافتند. در تحقیقی دیگر [۹] با محاسبه شاخص اتصال وزنی و استفاده از الگوریتم MST^۹ برای استخراج ویژگی‌های توپولوژیکی شبکه‌های مغزی، کاهش توان در باندهای آلفا و بتا را در گروه MCI نشان داد. در همین راستا، پژوهش اکبری موحد و همکاران [۱۰] نشان داد که ترکیب ویژگی‌های طیفی، اتصال کارکردی و ویژگی‌های غیرخطی مبتنی بر EEG با استفاده از الگوریتم BSFS^{۱۰} و طبقه‌بند KNN می‌تواند صحت بالایی (۹۸/۸۰٪) در تشخیص MCI به دست دهد.

پژوهش‌های مذکور روش‌های مختلفی را برای تشخیص اختلالات شناختی و روانی با استفاده از EEG به کار برده‌اند. با این حال، مشکل

امروزه همه‌گیری اختلالات روانی و شناختی، به‌ویژه افسردگی، اسکیزوفرنی، اختلال شناختی خفیف (MCI)^۱ و آلزایمر، تهدیدی جدی برای سلامت جامعه به شمار می‌رود. رویکردهای سنتی تشخیص این بیماری‌ها، مانند ارزیابی‌های بالینی که بر مشاهدات فردی تکیه دارند، یا روش‌های تصویربرداری پیشرفته و پرهزینه همچون MRI^۲ و PET^۳، اغلب محدودیت‌هایی دارند. این محدودیت‌ها شامل وابستگی به بروز علائم رفتاری واضح، عدم توانایی در تشخیص تغییرات اولیه در سطح شبکه‌های عصبی، و رزولوشن زمانی ناکافی است. در این میان، روش‌های مبتنی بر الکتروانسفالوگرام (EEG)^۴ به عنوان یک جایگزین غیرتهاجمی، ارزان‌تر و با دقت زمانی بسیار بالا، نسبت به سایر روش‌ها برتری قابل توجهی نشان می‌دهند. EEG با ثبت لحظه‌ای فعالیت‌های الکتریکی مغز، امکان تحلیل دقیق و سریع تغییرات آنی در الگوهای فعالیت مغزی و ارتباطات عملکردی را فراهم می‌سازد. این ویژگی، به ویژه در اختلالاتی مانند MCI و آلزایمر که با اختلالات تدریجی در شبکه‌های عصبی همراه هستند، ابزاری حیاتی برای تشخیص زودهنگام، پیگیری دقیق روند بیماری و طراحی درمان‌های متناسب با هر فرد به شمار می‌رود. افزون بر این، برخلاف روش‌های تصویربرداری ثابت یا گران‌قیمت، EEG در محیط‌های درمانی گوناگون و حتی در شرایط پویای بیمار قابل استفاده است و از این رو، به ارتقای کیفیت درمان و کاهش هزینه‌های نظام سلامت کمک می‌کند.

تحلیل اتصالات مغزی با استفاده از EEG، از طریق بررسی هم‌زمانی فعالیت نواحی گوناگون مغز، امکان شناسایی الگوهای مرتبط با اختلالات روانشناختی را فراهم می‌آورد. این رویکرد، در مقایسه با روش‌های سنتی که بر بررسی نواحی خاص مغز تمرکز دارند، درک عمیق‌تری از تعاملات پویای شبکه‌های عصبی ارائه داده و امکان تشخیص زودهنگام اختلالات شناختی-روانی را از طریق شناسایی تغییرات ظریف در اتصالات عملکردی میسر می‌سازد. پژوهش‌ها حاکی از آن هستند که این تحلیل‌ها، به ویژه در باندهای فرکانسی معین، اثر قابل توجهی در تشخیص اختلالات از خود نشان می‌دهند. هاتا و همکاران [۱۱] ارتباط عملکردی مغز در بیماران آلزایمری را با روش همگام‌سازی فازی تأخیری بررسی کردند. آن‌ها دریافتند که این ارتباط در باند دلتا در بیماران آلزایمری کمتر است و این روش به دلیل مقاومت در برابر نویز، می‌تواند برای تشخیص زودهنگام آلزایمر مفید باشد. این پژوهش نشان می‌دهد که بررسی ارتباطات مغزی در تشخیص زودرس آلزایمر مهم است. همچنین، رودریگز و همکاران [۲] با اندازه‌گیری فواصل خاص در سیگنال EEG، سه

^۶ K-Nearest Neighbors^۷ Radial Basis Function Support Vector Machine^۸ Multivariate Autoregressive Model^۹ Minimum Spanning Tree^{۱۰} Backward Sequential Feature Selection^۱ Mild Cognitive Impairment^۲ Magnetic Resonance Imaging^۳ Positron Emission Tomography^۴ Electroencephalography^۵ Symbolic Transfer Entropy

گرنجر، استخراج ساختارهای گراف محلی (LGS) از آن ماتریس، و سپس محاسبه ویژگی‌های آماری شامل تجزیه مقدار منفرد، آنتروپی انرژی لگاریتمی و آنتروپی شانون از LGS عمل می‌کند. نتایج نهایی با طبقه‌بندی‌کننده‌های یادگیری ماشین نظیر SVM و KNN به دست آمد. مطالعه حاضر با حفظ هدف اصلی مطالعه قبل (تشخیص همزمان اختلالات)، با معرفی بهبودهای ساختاری، چارچوب مذکور را به‌سوی یک سیستم تشخیصی جامع‌تر و تطبیق‌پذیرتر سوق می‌دهد. مقاله قبل منحصراً از علیت گرنجر به‌عنوان معیار اتصال استفاده می‌کند، درحالی‌که پژوهش حاضر ترکیب سه معیار مکمل همبستگی خطی (ضریب همبستگی پیرسون، PCC)، هماهنگی فازی (مقدار قفل‌شدگی فاز، PLV) و ارتباطات غیرخطی (اطلاعات متقابل، MI) را بکار می‌گیرد و از حشو در محاسبات جلوگیری می‌نماید. از این رو، می‌توان تغییرات و بهبودهای مطالعه جاری را نسبت به مطالعه پیشین بصورت زیر برشمرد:

۱. رویکرد تک معیاری گرنجر با ترکیب معیارهای مکمل جایگزین می‌شود تا همزمان اطلاعات خطی (PCC)، فازی (PLV) و غیرخطی (MI) را پوشش دهد.
 ۲. برای هر اختلال (مثلاً آلزایمر یا اسکیزوفرنی)، ترکیب طلایی (معیارهای ترکیبی + باند فرکانسی) از طریق تحلیل صحت تشخیص تعیین می‌شود که بیانگر بهینه‌سازی اختصاصی اختلال-باند است.
 ۳. عملکرد ترکیبات مختلف معیارها (PCC و PLV، MI و PCC)، در باندهای گوناگون مقایسه می‌شود تا روابط پنهان الگوهای اتصال مغزی آشکار گردد.
 ۴. با حذف محدودیت‌های روش‌های تک‌معیاری و استفاده از اطلاعات چندبُعدی، افزایش صحت تشخیص (خصوصاً در تمایز اختلالات با نشانه‌های همپوشان) مورد انتظار است.
- بطور کلی، این پژوهش با تبدیل چارچوب مقاله پیشین از یک سیستم "مبتنی بر گرنجر" به یک مدل ترکیبی، پوشش کامل‌تر مکانیزم‌های اتصالات مغزی از طریق تلفیق معیارهای مکمل و تشخیص اختلالات با کشف الگوهای فرکانسی-اتصال منحصربه‌فرد هر بیماری را فراهم می‌نماید.

۲- روش

بلوک دیاگرام روش پیشنهادی در شکل (۱) قابل مشاهده است:

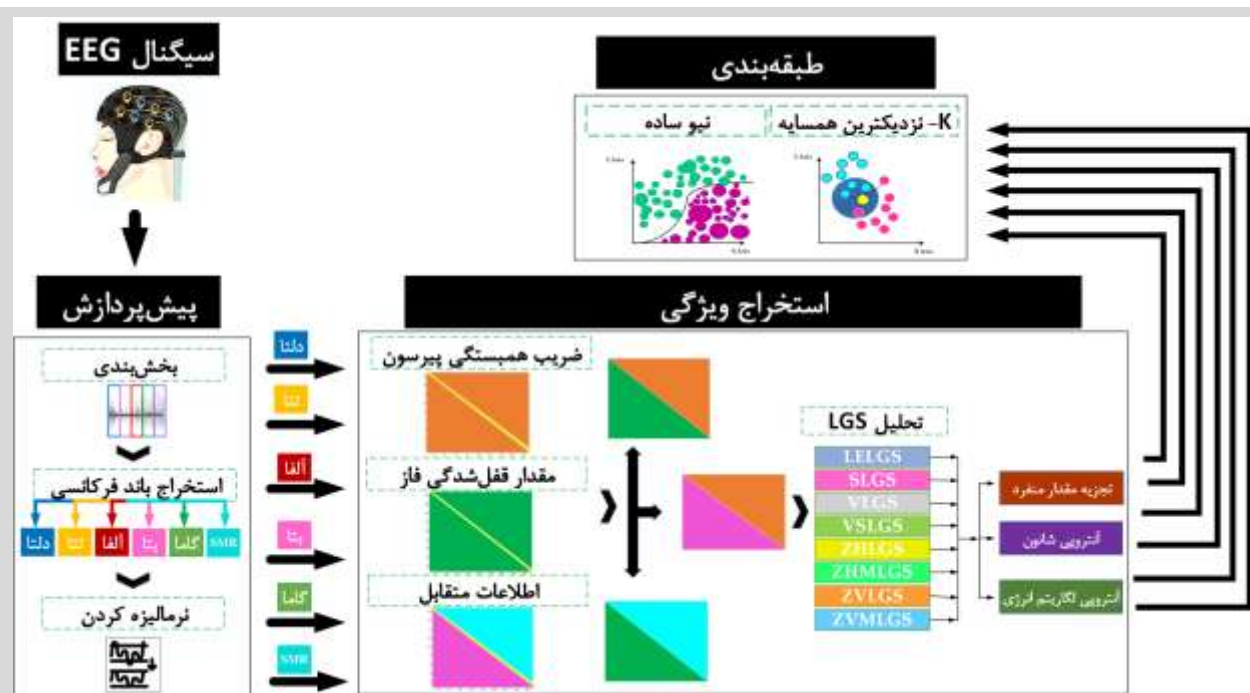
اصلی بسیاری از این مطالعات این است که فقط یک یا دو نوع اختلال، در یک یا چند سطح را بررسی کرده‌اند. در حالیکه پژوهش فوق به تشخیص چند اختلال می‌پردازد. همچنین، هنوز به اندازه کافی به ترکیب همزمان انواع مختلف ارتباطات مغزی و بررسی نقش آن‌ها در تشخیص چندگانه اختلالات مختلف توجه نشده است. به همین دلیل، انگیزه اصلی این پژوهش، ارائه یک روش جامع‌تر برای تشخیص دقیق‌تر اختلالات شناختی و روانی است. ما در این پژوهش تلاش می‌کنیم با بررسی همزمان و منظم ترکیبات مختلفی از ارتباطات مغزی (PCC^۱ و PLV^۲ و MI^۳) در باندهای فرکانسی مختلف EEG و ارزیابی اینکه هر کدام از این ترکیبات چگونه می‌توانند به تشخیص چند نوع اختلال کمک کنند، به درک بهتری از الگوهای پیچیده ارتباطات مغزی مرتبط با این اختلالات برسیم و راه را برای روش‌های تشخیص دقیق‌تر و کارآمدتر باز کنیم. پژوهش حاضر، نخستین مطالعه‌ای است که به بررسی ترکیب همزمان اتصالات عملکردی شامل ضریب همبستگی پیرسون، مقدار قفل‌شدگی فاز و اطلاعات متقابل در قالب یک چارچوب یکپارچه برای تشخیص اختلالات روانی و شناختی می‌پردازد. این تحقیق ارائه یک مدل ترکیبی مبتنی بر تحلیل سیگنال‌های الکتروانسفالوگرام است که با ادغام شاخص‌های چندگانه اتصالات مغزی مذکور و تحلیل آن‌ها در ساختارهای گراف محلی، امکان تشخیص چندکلاسه اختلالات (افسردگی، اسکیزوفرنی، اختلال شناختی خفیف و آلزایمر) را فراهم می‌سازد. از آنجا که PCC و PLV اتصالات بدون جهت را مدل‌سازی می‌کنند و MI قادر به شبیه‌سازی ارتباطات غیرخطی و پیچیده‌تر است، این ترکیب به ما امکان می‌دهد تا ارتباطات میان نواحی مغزی را به صورت جامع‌تری تحلیل کنیم. علاوه بر این، این پژوهش برای نخستین بار به انجام یک مقایسه سیستماتیک بین ترکیبات مختلف این اتصالات (PCC و MI، PCC و PLV، PLV و MI) باندهای فرکانسی گوناگون (دلتا، تتا، آلفا، SMR، بتا، گاما) پرداخته و نقش هر یک از این ترکیبات در بهبود صحت تشخیص انواع اختلالات عصبی را ارزیابی می‌کند. بررسی عملکرد این ترکیبات در باندهای فرکانسی مختلف برای تشخیص دقیق‌تر هر اختلال، از اهداف کلیدی این پژوهش است.

در مطالعه پیشین [۱۱]، چارچوبی نوین جهت تشخیص همزمان پنج اختلال شناختی-روانی (سالم، اسکیزوفرنی، MCI، آلزایمر و افسردگی) ارائه دادیم که با محاسبه ماتریس اتصال مبتنی بر علیت

^۱ Mutual Information

^۲ Pearson Correlation Coefficient

^۳ Phase Locking Value



شکل ۱- بلوک دیاگرام روش پیشنهادی

(LGS: Local Graph Structure، LELGS: Logically extended local graph structure، SLGS: Symmetric Local graph structure، VLGS: Vertical local graph structure، VSLGS: Vertical symmetric local graph structure، ZHLGS: Zigzag horizontal local graph structure، ZHMLGS: Zigzag horizontal middle local graph structure، ZVLGS: Zigzag vertical local graph structure، ZVMLGS: Zigzag vertical middle local graph structure)

ثبت‌های مربوط به EEG خواب به منظور کاهش اثرات مداخله‌ای حذف گردیده‌اند.

۲-۲ پیش پردازش داده‌ها

پیش پردازش صحیح سیگنال‌های EEG برای تضمین کیفیت استخراج ویژگی‌های بعدی و کاهش تأثیر نویز، امری حیاتی است. در این پژوهش از سه گام اصلی بخش‌بندی، نرمالیزه کردن و استخراج باندهای فرکانسی استفاده شده است.

۲-۲-۱ بخش بندی

سیگنال خام EEG شامل ۱۶۶,۰۰۰ نمونه به پنجره‌های غیرهمپوشان با اندازه ۳۰,۰۰۰ نمونه تقسیم می‌شود؛ با نرخ نمونه برداری ۵۰۰ هرتز، هر پنجره معادل ۶۰ ثانیه از سیگنال است. این تقسیم‌بندی به دو دلیل اساسی انجام می‌شود. اول آنکه امکان بررسی دقیق تغییرات دینامیکی و فرکانسی در بازه‌های زمانی کوتاه را فراهم می‌سازد. دوم، موجب کاهش حجم داده‌های پردازش شده در هر مرحله می‌شود که سرعت اجرای الگوریتم‌های بعدی را بهبود می‌بخشد.

۲-۲-۲ استخراج باندهای فرکانسی

برای تجزیه سیگنال به باندهای فرکانسی، یک فیلتر باتروث (Butterworth) مرتبه دوم بر روی هر قطعه از داده‌های EEG اعمال شد تا شش باند فرکانسی مجزا (دلتا ۴-۰/۵ هرتز)، تتا (۴-۸ هرتز)، آلفا (۸-۱۳ هرتز)، بتا (۱۳-۳۰ هرتز)، گاما (۳۰-۱۰۰ هرتز)، ریتم حسی-حرکتی (SMR) (۱۲-۱۵ هرتز) استخراج شود [۶].

۲-۱ پایگاه داده

مطالعه حاضر بر روی پایگاه داده EEG با مشخصات زیر انجام شده است [۱۲]. نمونه‌های مورد استفاده شامل ۲۳۰ شرکت‌کننده با میانگین سنی ۵۸ سال (دامنه سنی: ۹۱-۱۸ سال؛ ۵۶/۱٪ زن) می‌باشد. به تفکیک گروه‌ها، در گروه افسردگی، ۲۸ فرد با تشخیص افسردگی اساسی (میانگین سنی: ۶۹/۷ سال؛ دامنه سنی: ۹۱-۳۳ سال؛ ۷۱/۴٪ زن) حضور دارند که در طول دوره بررسی بستری بوده و حداقل یک دوره افسردگی تکراری قبل از سن ۳۰ سالگی را تجربه کرده‌اند. در گروه اسکیزوفرنی، ۴۲ فرد (میانگین سنی: ۴۱/۴ سال؛ دامنه سنی: ۷۶-۱۸ سال؛ ۳۵/۷٪ زن) که بر اساس معیارهای ICD-10 تشخیص داده شده‌اند و در طول دوره بستری بوده‌اند، مشارکت داشته‌اند. در گروه اختلال شناختی/الزایمر، ۶۵ فرد (میانگین سنی: ۷۲/۹ سال؛ دامنه سنی: ۸۷-۶۰ سال؛ ۴۷/۷٪ زن) وجود دارند که از این میان ۲۵ نفر به عنوان مبتلای MCI (میانگین سنی: ۷۳/۵ سال؛ دامنه سنی: ۸۵-۶۲ سال؛ ۴۴٪ زن) و ۴۰ نفر به عنوان مبتلا به آلزایمر تشخیص داده شده‌اند. در گروه کنترل، ۹۵ فرد بدون بیماری‌های نورولوژیک یا روانپزشکی (میانگین سنی: ۵۲/۲ سال؛ دامنه سنی: ۸۰-۱۹ سال؛ ۶۶/۳٪ زن) قرار دارند.

ثبت‌های EEG بین ساعت ۸ صبح تا ۱ بعدازظهر با استفاده از دستگاه Nihon Kohden، شامل ۱۹ الکتروود طبق سیستم بین‌المللی ۲۰-۱۰ و با نرخ نمونه برداری ۵۰۰ هرتز انجام شده‌اند. شرکت‌کنندگان در حالت استراحت (با چشمان باز و بسته) قرار داشته‌اند؛ همچنین

به عبارت دیگر، اگر دو سیگنال به‌طور خطی تغییر کنند، ضریب همبستگی پیرسون بالاتر می‌رود و اگر تغییرات آن‌ها مخالف یکدیگر باشد، ضریب همبستگی منفی می‌شود.

رابطه (۱) نحوه محاسبه PCC را نمایش می‌دهد:

$$PCC_{m,n} = \frac{\sum_{t=1}^T (X_{m,t} - \bar{X}_m)(X_{n,t} - \bar{X}_n)}{\sqrt{\sum_{t=1}^T (X_{m,t} - \bar{X}_m)^2 (X_{n,t} - \bar{X}_n)^2}} \quad (1)$$

که در آن $X_{m,t}$ و $X_{n,t}$ مقادیر سیگنال‌های EEG در زمان t \bar{X}_m و \bar{X}_n میانگین سیگنال‌های EEG در کانال‌های m و n هستند.

- مقدار قفل شدگی فاز (PLV): این معیار به‌طور خاص برای اندازه‌گیری اختلاف فاز بین دو سیگنال در بازه‌های زمانی مختلف طراحی شده است. در این روش، ابتدا اختلاف فاز بین دو سیگنال در زمان‌های مختلف محاسبه می‌شود و سپس میانگین این اختلاف فاز به‌عنوان شاخص PLV در نظر گرفته می‌شود. PLV به‌طور خاص برای شبیه‌سازی ارتباطات فازی و زمانی میان سیگنال‌ها استفاده می‌شود. این معیار می‌تواند اتصالات و هم‌زمانی‌هایی را که به‌طور مستقیم در دامنه زمانی مشهود نیستند، شبیه‌سازی کرده و به‌ویژه در سیگنال‌هایی که تغییرات فازی مهمی دارند، کاربرد فراوانی دارد.

رابطه (۲) نحوه محاسبه PLV را نمایش می‌دهد:

$$PLV_{m,n} = \left| \frac{1}{T} \sum_{t=1}^T e^{j(\varphi_{m,t} - \varphi_{n,t})} \right| \quad (2)$$

که در آن $\varphi_{m,t}$ و $\varphi_{n,t}$ به ترتیب زوایای فاز سیگنال‌های $X_{m,t}$ و $X_{n,t}$ را نمایش می‌دهد.

- اطلاعات متقابل (MI): این معیار غیرخطی برای سنجش میزان اطلاعات مشترک بین دو سیگنال استفاده می‌شود. اطلاعات متقابل، وابستگی متقابل دو سیگنال را به‌طور جامع منعکس می‌کند، به‌طوری‌که قادر است ارتباطات پیچیده‌ای را شناسایی کند که ممکن است به‌صورت خطی قابل شبیه‌سازی نباشند. به‌طور خاص، اطلاعات متقابل نشان‌دهنده میزان اطلاعاتی است که می‌توان از یک سیگنال برای پیش‌بینی سیگنال دیگر استفاده کرد. این معیار به‌ویژه زمانی مفید است که ارتباطات بین سیگنال‌ها غیرخطی یا پیچیده باشند، زیرا قادر است وابستگی‌های پنهان و غیرخطی را که سایر معیارها قادر به شبیه‌سازی آن‌ها نیستند، شناسایی کند.

رابطه (۳) نحوه محاسبه معیار MI را نشان می‌دهد:

$$MI_{m,n} = \sum_{x_m, x_n} P_{X_m, X_n}(x_m, x_n) \log_2 \frac{P_{X_m, X_n}(x_m, x_n)}{P_{X_m}(x_m) P_{X_n}(x_n)} \quad (3)$$

در طراحی فیلترها، پهنای باند انتقالی^۱ در فیلترهای پایه‌ی مرتبه‌اول ممکن است به‌طور نامطلوبی طولانی و گسترده باشد. برای حل این چالش و دستیابی به جداسازی فرکانسی دقیق‌تر، نیاز به استفاده از فیلترهای فعال با مرتبه بالاتر از یک بود. بر این اساس، در مطالعه حاضر از فیلتر باترورث مرتبه دوم جهت استخراج بهینه باند‌های فرکانسی استفاده گردید [۱۳].

فیلترهای باترورث دارای بهترین پاسخ فلات ممکن در باند عبور هستند. این ویژگی تضمین می‌کند که دامنه مولفه‌های فرکانسی درون باند مورد نظر (مثلاً آلفا یا بتا) بدون اعوجاج غیرخطی عبور می‌کنند. برای مطالعات کمی EEG، حفظ یکخواختی دامنه در باند عبور ضروری است تا داده‌ها تغییر نکنند. اگرچه فیلترهای باترورث فاز کاملاً خطی ندارند (برخلاف فیلترهای Bessel یا FIR)، ولی در مرتبه پایین‌تر (مرتبه ۲) اعوجاج فاز به‌مراتب کمتر از مرتبه‌های بالاتر (مثلاً ۴ یا ۶) است. این ویژگی برای کاهش تغییرات زمانی ناخواسته در سیگنال‌های EEG (مانند پیک‌های امواج) اهمیت دارد. از طرفی، فیلترهای مرتبه بالا اگرچه شیب قطع تندتری دارند، اما نیاز به محاسبات پیچیده‌تر دارند و اعوجاج فاز را افزایش می‌دهند. بنابراین، این انتخاب متناسب با نیازهای تحلیل طیفی سیگنال‌های نوروفیزیولوژیک (نه تحلیل‌های حساس به فاز مانند ERP) انجام شده است.

۲-۲-۳ نرمالیزه کردن

برای نرمال‌سازی، از نمره استاندارد^۲ استفاده شده است. این روش نرمال‌سازی بر پایه میانگین و انحراف معیار سیگنال عمل می‌کند، به این ترتیب که میانگین داده‌ها صفر و انحراف معیار آن‌ها یک می‌شود. در مقایسه با سایر روش‌های نرمال‌سازی مانند نرمال‌سازی مبتنی بر محدوده^۳ که داده‌ها را بین یک بازه مشخص (مثلاً ۰ تا ۱) نگه می‌دارد، نمره استاندارد بهتر با داده‌های EEG سازگار است زیرا این داده‌ها اغلب دارای نوسانات بزرگی هستند که ممکن است با روش نرمال‌سازی مبتنی بر محدوده به‌درستی تنظیم نشوند.

۲-۳ استخراج ویژگی‌ها

استخراج ویژگی‌ها در این پژوهش در سه مرحله صورت می‌گیرد:

۱-۳-۲ ارتباطات مغزی

برای سنجش تعاملات و همبستگی بین کانال‌های EEG سه شاخص بررسی شده است:

- ضریب همبستگی پیرسون (PCC): این شاخص برای اندازه‌گیری قدرت و جهت ارتباط بین دو سیگنال استفاده می‌شود. در این روش، با حذف تأثیر سایر سیگنال‌ها یا نویزها، ضریب همبستگی پیرسون به‌طور مستقیم رابطه خطی بین دو سیگنال را محاسبه می‌کند. این معیار مقداری بین ۱- تا ۱ دارد که ۱ نشان‌دهنده ارتباط مثبت کامل، ۱- نشان‌دهنده ارتباط منفی کامل، ۰ نشان‌دهنده عدم وجود ارتباط خطی بین سیگنال‌ها است.

^۲ Min-Max Normalization

^۱ Transition Band

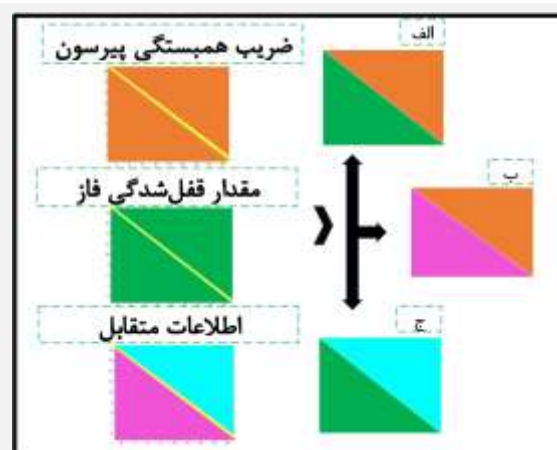
^۳ z-score

مقدار هر سلول با سلول‌های همسایه خود مقایسه می‌شود و اختلاف‌ها به صورت دودویی کدگذاری می‌شوند. به این معنی که اگر اختلاف مثبت باشد، مقدار ۱ در نظر گرفته می‌شود و در غیر این صورت مقدار ۰ انتخاب می‌شود. سپس این ارقام دودویی به صورت یک رشته باینری ترکیب شده و به یک مقدار عددی تبدیل می‌شود.

۳. انواع استخراج ویژگی مبتنی بر LGS^1 : در این پژوهش از چندین روش مختلف برای تحلیل و استخراج ویژگی‌های ساختاری سیگنال‌ها استفاده شده است. در ادامه شرح دقیقی از چگونگی ترکیب و ادغام ویژگی‌ها در انواع ساختارها آمده است.

LGS یک روش محاسباتی کارآمد برای استخراج ویژگی‌های موضعی از ماتریس است. در این پژوهش، به جای اعمال مستقیم روش مذکور به تمام سلول‌های ماتریس، از این رویکرد برای تحلیل ماتریس 19×19 حاصل از ترکیب اتصالات مغزی به شکلی مشابه استفاده شد. ابتدا، ماتریس I با ابعاد $m \times n$ به نواحی کوچکتر ($m' \times n'$ بسیار کوچکتر از ابعاد اصلی) تقسیم می‌شود. سپس، عملگر LGS روی هر یک از این نواحی اعمال شده و یک مقدار تبدیل‌شده را بر اساس ساختار گراف محلی جهت‌داری که از سلول‌های همسایه تشکیل شده، محاسبه می‌کند. در این روش، سلول‌های همسایه نسبت به سلول مبدأ و بر اساس جهت گراف ارزیابی می‌شوند. برای برچسب‌گذاری لبه‌های گراف محلی مربوط به یک سلول، مقدار آن سلول مبدأ با مقادیر سلول‌های همسایه‌اش مقایسه شده و اختلاف‌ها محاسبه می‌گردد. اگر این اختلاف بزرگتر یا مساوی صفر باشد، به لبه‌ی مربوطه مقدار ۱ و در غیر این صورت (اگر اختلاف کمتر از صفر باشد)، مقدار ۰ اختصاص داده می‌شود. در ادامه، مقادیر باینری (۰ و ۱) حاصل از لبه‌های این گراف محلی جهت‌دار، طبق جهت گراف به یکدیگر متصل شده و یک عدد باینری ۸ بیتی را تشکیل می‌دهند. این عدد باینری سپس به معادل دسیمال خود تبدیل شده و آن مقدار دسیمال به سلول هدف مورد نظر نسبت داده می‌شود. به این ترتیب، هر سلول در ماتریس با یک عدد دسیمال منحصر به فرد که از طریق اعمال LGS جهت‌دار و با در نظر گرفتن عدد باینری مرتبط به دست آمده، مشخص می‌گردد (شکل (۳)).

که PX_m, X_n به معنای توزیع احتمال مشترک X_m و X_n و $PX_m(x_m)PX_n(x_n)$ به معنای توزیع احتمال X_m و X_n می‌باشد. از آنجا که دو معیار PCC و PLV ، جز اتصالات بدون جهت هستند و در نتیجه ماتریس‌ها نسبت به قطر اصلی متقارن بوده و اطلاعات حشو وجود دارد، بخش بالا مثلثی یا پایین مثلثی این اتصالات را با بخش پایین مثلثی یا بالا مثلثی معیار MI که به صورت دو جهت عمل میکند، ترکیب نموده تا ضمن جلوگیری از تکرار محاسبات، به اطلاعات بهتری دست یابیم و از حشو محاسباتی جلوگیری کنیم. این فرایند در شکل (۲) نمایش داده شده است.




شکل ۲- الف) ترکیب بالا مثلثی PCC و پایین مثلثی PLV (ب) ترکیب بالا مثلثی PCC و پایین مثلثی MI (ج) ترکیب بالا مثلثی MI و پایین مثلثی PLV

۲-۳-۲ استخراج ویژگی‌های مبتنی بر ساختار گراف محلی پس از محاسبه ماتریس‌های ارتباطات (ترکیب شاخص‌های PCC ، PLV و MI) از تکنیک‌های مبتنی بر ساختار گراف محلی برای استخراج ویژگی‌های توصیفی استفاده می‌شود. مراحل این رویکرد به شرح زیر است:

۱. تقسیم ماتریس: ماتریس ارتباطی با ابعاد بزرگ به زیرمجموعه‌های کوچکتر تقسیم می‌شود به گونه‌ای که ابعاد هر زیرمجموعه کوچک‌تر از ابعاد اصلی ماتریس باشد.
۲. اعمال عملگر ساختار گراف محلی: برای هر زیرمجموعه، عملگر ساختار گراف محلی اعمال می‌شود. در این فرایند،

¹ Local Graph Structure




شکل ۳- ساختار نمودار محلی مراحل محاسبه اعشاری

$$(01011100)_2 = (0 \times 2^7) + (1 \times 2^6) + (0 \times 2^5) + (1 \times 2^4) + (1 \times 2^3) + (1 \times 2^2) + (0 \times 2^1) + (0 \times 2^0)$$

همسایه متکی است، SLGS هفت پیکسل همسایه را به همراه سلول هدف به عنوان یک مقدار مرجع در نظر می‌گیرد. این روش امکان استخراج یکسان تر اطلاعات بافت را از سمت چپ و راست پیکسل هدف فراهم می‌کند. در فرآیند SLGS، ماتریس علیت گرنجر به بلوک‌های 3×5 سلولی تقسیم می‌شود. لبه‌های گراف در SLGS از پیکسل هدف شروع شده و در جهت پادساعتگرد به ناحیه چپ پیش می‌روند و یک کد باینری ۴ بیتی ایجاد می‌کنند. سپس، برچسب‌گذاری از پیکسل هدف در جهت ساعتگرد به ناحیه راست ادامه یافته و یک کد باینری ۴ بیتی دیگر تولید می‌کند. ترکیب این دو کد، یک الگوی باینری ۸ بیتی مربوط به پیکسل هدف را به دست می‌دهد (شکل (۴)).

در این مطالعه، هشت نوع مختلف از [۱۴] LGS به کار گرفته شد که عبارتند از: ساختار گراف محلی منطقی توسعه‌یافته (LELGS^۱)، ساختار گراف محلی متقارن (SLGS^۲)، ساختار گراف محلی عمودی (VLGS^۳)، ساختار گراف محلی متقارن عمودی (VSLGS^۴)، ساختار گراف محلی افقی زیگزاگی (ZHLGS^۵)، ساختار گراف محلی افقی میانه زیگزاگی (ZHMLGS^۶)، ساختار گراف محلی عمودی زیگزاگی (ZVLGS^۷) و ساختار گراف محلی عمودی میانه زیگزاگی (ZVMLGS^۸).

ساختار گراف محلی متقارن (SLGS): این ساختار برای بهبود کیفیت بافت ماتریس از طریق استخراج متوازن اطلاعات بافتی از پیکسل‌های همسایه طراحی شده است. برخلاف LGS که تنها به چهار پیکسل



شکل ۴- ساختار نمودار محلی متقارن مراحل محاسبه اعشاری

$$(10100110)_2 = (1 \times 2^7) + (0 \times 2^6) + (1 \times 2^5) + (0 \times 2^4) + (0 \times 2^3) + (1 \times 2^2) + (1 \times 2^1) + (0 \times 2^0)$$

ویژگی‌ها وابسته است. با ترکیب تابع علامت و عملگر OR بیتی، LELGS به طور مؤثر الگوها و روابط پیچیده درون داده‌ها را ثبت می‌کند. استفاده از گراف‌های عمودی و افقی نیز به بهبود فرآیند استخراج ویژگی‌ها کمک کرده و منجر به تولید ویژگی‌های باینری ۸ بیتی می‌شود که حاوی اطلاعات مهم هستند (شکل (۵)).

ساختار گراف محلی منطقی توسعه‌یافته (LELGS): این روش که توسط راکشید و همکاران [۱۴] معرفی شده، از یک بلوک همپوشانی 4×4 ، یک تابع علامت (signum function) و یک عملگر OR بیتی برای استخراج ویژگی‌های باینری ۸ بیتی استفاده می‌کند. عملکرد این روش به شدت به بلوک همپوشانی 4×4 برای استخراج جامع

^۱ Zigzag horizontal local graph structure

^۲ Zigzag horizontal middle local graph structure

^۳ Zigzag vertical local graph structure

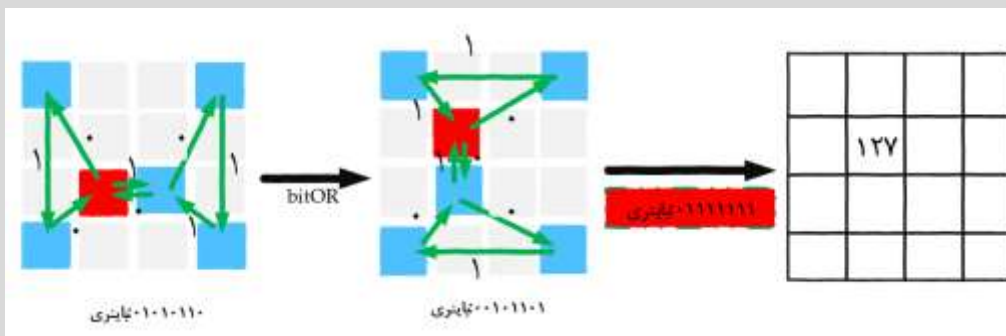
^۴ Zigzag vertical middle local graph structure

^۱ Logically extended local graph structure

^۲ Symmetric Local graph structure

^۳ Vertical local graph structure

^۴ Vertical symmetric local graph structure




شکل ۵- ساختار نمودار محلی توسعه یافته منطقی مراحل محاسبه اعشاری

$$(0111111)_2 = (0 \times 2^7) + (1 \times 2^6) + (1 \times 2^5) + (1 \times 2^4) + (1 \times 2^3) + (1 \times 2^2) + (1 \times 2^1) + (1 \times 2^0)$$

سراسری داده‌ها است. استفاده از بلوک همپوشانی 3×4 به طور قابل توجهی مقاومت این توصیف‌گر را در برابر تغییرات مقیاس و جهت‌گیری افزایش می‌دهد. راکشید و همکاران [۱۴] کارایی VLGS را در زمینه‌های مختلف بینایی کامپیوتر نشان داده و دقت و کارایی برتر آن را در مقایسه با توصیف‌گرهای سنتی تأیید کرده‌اند (شکل ۶).

ساختار گراف محلی عمودی (VLGS): این ساختار که یک نسخه پیشرفته از LGS است و توسط راکشید و همکاران [۱۴] معرفی شده، از یک پیکربندی بلوک همپوشانی 3×4 استفاده می‌کند. ویژگی اصلی این توصیف‌گر، استفاده از یک گراف عمودی است که دلیل نام‌گذاری آن به VLGS نیز می‌باشد (شکل ۶). بهره‌گیری از ساختار گراف عمودی، قادر به ثبت اطلاعات محلی و




شکل ۶- ساختار گراف محلی عمودی مراحل محاسبه اعشاری

$$(01101011)_2 = (0 \times 2^7) + (1 \times 2^6) + (1 \times 2^5) + (0 \times 2^4) + (1 \times 2^3) + (0 \times 2^2) + (1 \times 2^1) + (1 \times 2^0)$$

ادغام ویژگی‌های متقارن است. استفاده از بلوک‌های همپوشانی 5×3 در کنار تابع علامت، رویکرد جامع‌تری برای استخراج ویژگی‌ها فراهم کرده و در نتیجه، دقت بالاتری را در کاربردهای مختلف به دست می‌دهد (شکل ۷).

ساختار گراف محلی متقارن عمودی (VSLGS): این ساختار که مدل متقارن VLGS محسوب می‌شود، توسط راکشید و همکاران [۱۴] معرفی گردیده است. VSLGS از بلوک‌های همپوشانی با اندازه 3×5 به همراه تابع علامت برای استخراج ویژگی‌ها استفاده می‌کند (شکل ۷). هدف اصلی این مدل، بهبود عملکرد VLGS از طریق




شکل ۷- ساختار گراف محلی متقارن عمودی مراحل محاسبه اعشاری

$$(10110100)_2 = (1 \times 2^7) + (0 \times 2^6) + (1 \times 2^5) + (1 \times 2^4) + (0 \times 2^3) + (1 \times 2^2) + (0 \times 2^1) + (0 \times 2^0)$$

و همکاران [۱۴] معرفی شده است. یک نمونه تصویری از ZHLGS در شکل (۸) ارائه شده است.

ساختار گراف محلی افقی زیگزاگی (ZHLGS): این ساختار از یک بلوک همسایگی افقی با ابعاد 3×3 استفاده می‌کند و توسط راکشید




شکل ۸- ساختار گراف محلی افقی زیگزاگ مراحل محاسبه اعشاری

$$(00101001)_2 = (0 \times 2^7) + (0 \times 2^6) + (1 \times 2^5) + (0 \times 2^4) + (1 \times 2^3) + (0 \times 2^2) + (0 \times 2^1) + (1 \times 2^0)$$

برای ثبت اطلاعات فضایی درون هر بلوک ماتریس طراحی شده است. با استفاده از گراف افقی میانی زیگزاگی، امکان استخراج ویژگی‌های متمایز فراهم می‌شود که می‌توانند در تحلیل‌ها و طبقه‌بندی‌های بعدی مورد استفاده قرار گیرند.

ساختار گراف محلی افقی میانی زیگزاگی (ZHMLGS): در این ساختار، ماتریس به بلوک‌های 3×3 تقسیم شده و یک الگوی خاص به همراه تابع علامت برای استخراج ویژگی‌ها به کار می‌رود. الگوی مورد استفاده، یک گراف افقی میانی زیگزاگی است که نمایش گرافیکی آن در شکل (۹) نشان داده شده است [۱۴]. این الگو به دقت




شکل ۹- ساختار گراف محلی افقی زیگزاگ وسط مراحل محاسبه اعشاری

$$(01100000)_2 = (0 \times 2^7) + (1 \times 2^6) + (1 \times 2^5) + (0 \times 2^4) + (0 \times 2^3) + (0 \times 2^2) + (0 \times 2^1) + (0 \times 2^0)$$

زیگزاگی است [۱۴]. این فرآیند با استفاده از بلوک‌های همپوشانی 3×3 انجام می‌شود (شکل (۱۰)).

ساختار گراف محلی عمودی زیگزاگی (ZVLGS): هدف این ساختار، استخراج ویژگی‌های عمودی از ماتریس از طریق اعمال یک الگوی




شکل ۱۰- ساختار گراف محلی عمودی زیگزاگ مراحل محاسبه اعشاری

$$(01010010)_2 = (0 \times 2^7) + (1 \times 2^6) + (0 \times 2^5) + (1 \times 2^4) + (0 \times 2^3) + (0 \times 2^2) + (1 \times 2^1) + (0 \times 2^0)$$

می‌شود و از یک گراف عمودی میانی زیگزاگی برای استخراج ویژگی‌ها استفاده می‌گردد (شکل (۱۱)).

ساختار گراف محلی عمودی میانی زیگزاگی (ZVMLGS): این ساختار یک اقتباس از روش ZVLGS است [۱۴]. در ZVMLGS، سلول مرکزی درون بلوک به عنوان نقطه مرجع اولیه در نظر گرفته



شکل ۱۱- ساختار گراف محلی عمودی زیگزاگ وسط مراحل محاسبه‌ی اعشاری

$$(\cdot 111 \cdot 110)_2 = (\cdot \times 2^7) + (1 \times 2^6) + (1 \times 2^5) + (1 \times 2^4) + (\cdot \times 2^3) + (1 \times 2^2) + (1 \times 2^1) + (\cdot \times 2^0)$$

طبقه‌بندی دارد. انتخاب مقدار مناسب K برای دستیابی به نتایج بهینه با الگوریتم نزدیک‌ترین همسایگان ضروری است. مقدار کوچک K ممکن است نویز را وارد فرآیند طبقه‌بندی کند، در حالی که مقدار بزرگ می‌تواند باعث هموار شدن بیش از حد شود. بنابراین، پس از ارزیابی مقادیر مختلف K ، ما مقدار بهینه ۵ را تعیین کردیم که بهترین نتایج طبقه‌بندی را به همراه داشت.

الگوریتم Naïve Bayes یک روش طبقه‌بندی احتمالاتی است که از قضیه بیز استفاده می‌کند و تحت فرض استقلال ویژگی‌ها عمل می‌کند. این الگوریتم نمونه‌های جدید را با محاسبه احتمال شرطی هر ویژگی در هر کلاس طبقه‌بندی می‌کند. فرض استقلال ویژگی‌ها محاسبات مربوط به این الگوریتم را به‌طور قابل توجهی ساده می‌کند و آن را هم راحت و هم کارآمد می‌سازد. علیرغم سادگی آن، Naïve Bayes عملکرد قوی‌ای از خود نشان می‌دهد و برای سرعت بالای آموزش و نیاز محاسباتی کم شناخته شده است.

برای ارزیابی عملکرد الگوریتم‌ها، از معیارهای زیر استفاده شده است: در این مطالعه، عملکرد طبقه‌بندها با استفاده از چهار معیار اصلی ارزیابی شامل صحت (Accuracy)، دقت (Precision)، حساسیت (Sensitivity) و امتیاز F_1 بررسی شده است. این ارزیابی‌ها از طریق روش اعتبارسنجی متقاطع ده‌برابری (10-fold cross-validation) و روش دسته‌بندی یک‌به‌همه (OVA^2) انجام شده‌اند.

برای هر کلاس، یک طبقه‌بند باینری ساخته می‌شود که تشخیص می‌دهد آیا نمونه به آن کلاس تعلق دارد یا خیر. این روش به‌ویژه زمانی که تعداد کلاس‌ها زیاد است، می‌تواند مفید باشد، زیرا هر کلاس به‌صورت جداگانه آموزش داده می‌شود و نتایج برای هر کلاس به‌طور مستقل محاسبه می‌شود.

در نهایت، مقادیر متوسط این معیارها (صحت، حساسیت، دقت و امتیاز F_1) پس از ۱۰ بار اجرای اعتبارسنجی متقاطع محاسبه و به‌عنوان ارزیابی نهایی از عملکرد طبقه‌بندها ارائه گردید. این روش‌ها امکان ارزیابی دقیق‌تر و متعادل‌تر از عملکرد مدل‌ها را فراهم می‌آورد.

۳- بیان و تحلیل نتایج

۳-۲ کمی سازی

برای کاهش ابعاد داده‌های استخراج‌شده افزایش قدرت تفکیک‌کنندگی و کمی سازی از روش‌های زیر استفاده شد:

- تجزیه مقدار منفرد (SVD^1)
- این فرآیند شامل تقسیم یک ماتریس به سه ماتریس مستطیلی کوچکتر است:
- کاهش ابعاد ماتریس مقادیر منفرد قطری، می‌تواند اطلاعات ضروری از ماتریس اصلی را به‌طور مؤثر حفظ کرده و ابعاد آن را بهینه‌سازی کرد. آنتروپی شانون به دلیل توانایی آن در اندازه‌گیری عدم قطعیت یا پیش‌بینی‌ناپذیری اطلاعات به شیوه‌ای داده‌محور انتخاب شده است، که این امکان را می‌دهد تا از فرضیات و مدل‌های از پیش تعیین‌شده صرف‌نظر شود [۱۵].
- آنتروپی لگاریتم انرژی و شانون

آنتروپی مرتبط با لگاریتم انرژی یک مفهوم بنیادی در فیزیک و نظریه اطلاعات است که امکان اندازه‌گیری پیچیدگی یک سیستم را فراهم می‌کند. پس از محاسبه SVD ، آنتروپی انرژی لگاریتمی و آنتروپی شانون برای هر ویژگی LGS از طبقه‌بند استفاده می‌شود. این طبقه‌بند بر روی ویژگی‌های استخراج‌شده آموزش داده می‌شود و سپس برای پیش‌بینی نقاط داده جدید به کار می‌رود.

۳-۴ طبقه‌بندی

این مطالعه از دو الگوریتم طبقه‌بندی معتبر K -نزدیکترین همسایه (KNN) و نیو ساده (Naïve Bayes) برای طبقه‌بندی پنج وضعیت متمایز، شامل یک گروه کنترل و چهار دسته از اختلالات روانشناختی (افسردگی، اسکیزوفرنی، اختلال شناختی خفیف و آلزایمر) استفاده شده است. الگوریتم KNN با شناسایی نزدیک‌ترین همسایگان یک نمونه داده در فضای ویژگی عمل می‌کند که سپس برای طبقه‌بندی استفاده می‌شود. در ابتدا، الگوریتم نزدیک‌ترین K نمونه به نمونه جدید در فضای ویژگی را پیدا می‌کند. سپس، کلاس اکثریتی بین این K همسایگان برای تخصیص کلاس به نمونه جدید استفاده می‌شود. پارامتر K یک مؤلفه حیاتی در این الگوریتم است و باید توسط کاربر مشخص شود. مقدار آن تأثیر قابل توجهی بر عملکرد

² One-VS-All

¹ Singular Value Decomposition

PCC، PLV و MI ارزیابی شده است. ردیف‌های جدول بیانگر کمی‌سازهای پیشنهادی هستند که به پنج زیر بخش تقسیم می‌شوند و با پنج کلاس طبقه‌بندی مطابقت دارند. این کلاس‌ها شامل اسکیزوفرنی (کلاس ۱)، اختلال شناختی خفیف (کلاس ۲)، افسردگی (کلاس ۳)، گروه کنترل (افراد سالم) (کلاس ۴) و بیماری آلزایمر (کلاس ۵) هستند. ستون‌های جدول، مقادیر میانگین و انحراف معیار را برای معیارهای ارزیابی طبقه‌بندی شامل صحت، حساسیت، امتیاز F1 و دقت را نمایش می‌دهند.

این بخش شامل ارائه نتایج در دو حالت بررسی ویژگی‌ها به صورت جداگانه و ترکیب آنها شامل می‌باشد. تمام نتایج به دست آمده در فایل پیوست الف، قرار داده شده و به علت محدودیت تعداد صفحات، بهترین نتایج در ادامه آورده شده است.

جدول ۱ تا ۴ نمای کلی از بهترین نتایج به دست آمده توسط مدل طبقه‌بندی KNN و Naïve Bayes را نشان می‌دهد که بر اساس ویژگی‌های مختلف از جمله آنتروپی شانون، آنتروپی لگاریتم انرژی و تجزیه مقادیر منفرد و همچنین در ترکیب ویژگی‌ها، با استفاده از داده‌های باندهای فرکانسی مختلف EEG برای حالات ترکیب

جدول ۱. بهترین نرخ‌های طبقه‌بندی KNN بر اساس ویژگی‌های مختلف باندهای فرکانسی EEG

ویژگی	شماره کلاس	صحت (%)	حساسیت (%)	امتیاز F1 (%)	دقت (%)
سیگنال EEG باند بتا (PCC و MI)					
آنتروپی شانون	۲	۹۰/۲۱±۱/۰	۹۰/۸۵±۱/۵	۹۴/۷۱±۱/۳	۹۹/۷۱±۱/۰
آنتروپی لگاریتم انرژی	۳	۸۸/۵۶±۱/۱	۸۹/۲۱±۱/۵	۹۳/۸۸±۱/۳	۹۹/۹۰±۰/۹
SVD	۲	۹۰/۲۹±۱/۰	۹۱/۰۲±۱/۴	۹۴/۷۵±۱/۲	۹۹/۷۱±۰/۹
سیگنال EEG باند تتا (PCC و PLV)					
آنتروپی شانون	۲	۸۹/۸۵±۰/۷۷	۹۰/۹۹±۰/۴۰	۸۲/۵۴±۱۸/۹۶	۹۴/۴۹±۰/۴۳
آنتروپی لگاریتم انرژی	۳	۸۹/۶۴±۰/۵۴	۹۰/۱۱±۰/۶۸	۸۴/۸۳±۱۶/۸۲	۹۴/۴۱±۰/۴۶
SVD	۲	۸۹/۸۵±۰/۷۷	۹۰/۹۹±۰/۴۰	۸۲/۵۴±۱۸/۹۶	۹۴/۴۹±۰/۴۳
سیگنال EEG باند SMR (MI و PLV)					
آنتروپی شانون	۳	۸۸/۷۰±۱/۰	۸۹/۴۳±۱/۵	۹۳/۹۴±۱/۳	۱۰۰±۱/۰
آنتروپی لگاریتم انرژی	۲	۸۹/۱۲±۱/۰	۸۹/۷۸±۱/۶	۹۴/۱۶±۱/۴	۸۹/۱۲±۱/۸
SVD	۲	۹۰/۰۲±۱/۰	۹۰/۱۸±۱/۶	۹۴/۶۳±۱/۴	۱۰۰±۰/۸
توجه: کلاس ۱: اسکیزوفرنی. کلاس ۲: اختلال شناختی خفیف (MCI). کلاس ۳: افسردگی. کلاس ۴: کنترل‌ها (افراد سالم). و کلاس ۵: بیماری آلزایمر					

در تشخیص اختلال شناختی خفیف با ویژگی SVD، با درصد صحت ۹۰/۲۹ به دست آمده است.

طبق نتایج ارائه شده در جدول ۱ برای طبقه‌بند KNN، در باند فرکانسی بتا و در حالت ترکیب داده‌های PCC و MI، صحت بالایی

جدول ۲. بهترین نرخ‌های طبقه‌بندی Naïve Bayes بر اساس ویژگی‌های مختلف باندهای فرکانسی EEG

ویژگی	شماره کلاس	صحت (%)	حساسیت (%)	امتیاز F1 (%)	دقت (%)
سیگنال EEG باند گاما (MI و PCC)					
آنتروپی شانون	۲	۸۸/۲۴±۰/۰۰	۸۸/۲۴±۰/۰۰	۵۰/۵۴±۰/۰۰	۹۳/۷۵±۰/۰۰
آنتروپی لگاریتم انرژی	۳	۸۹/۲۳±۰/۳۳	۸۹/۳۰±۰/۳۵	۱۰۰±۰/۰۰	۹۴/۲۴±۰/۱۶
SVD	۳	۸۹/۵۲±۰/۴۰	۸۹/۳۸±۰/۳۷	۱۰۰±۰/۰۰	۹۴/۳۹±۰/۲۰
سیگنال EEG باند گاما (PLV و PCC)					
آنتروپی شانون	۳	۸۹/۳۸±۰/۶۹	۸۹/۷۰±۰/۳۵	۸۸/۳۳±۱۹/۳۲	۹۴/۳۰±۰/۳۷
آنتروپی لگاریتم انرژی	۳	۸۸/۸۸±۰/۳۴	۸۸/۹۲±۰/۰۸	۸۸/۳۳±۲۴/۹۰	۹۴/۰۷±۰/۱۷
SVD	۳	۸۸/۶۶±۰/۴۴	۸۹/۳۹±۰/۳۰	۶۸/۳۳±۰/۲۴	۹۳/۹۱±۰/۲۴
سیگنال EEG باند گاما (MI و PLV)					
آنتروپی شانون	۲	۸۸/۳۱±۰/۲۷	۸۸/۵۶±۰/۲۹	۲۸/۶۰±۳۰/۵۴	۹۳/۷۸±۰/۱۳
آنتروپی لگاریتم انرژی	۳	۸۹/۲۲±۰/۳۶	۸۹/۵۵±۰/۲۲	۹۶/۶۶±۱۰/۵۴	۹۴/۲۳±۰/۱۹
SVD	۳	۸۸/۵۳±۱/۳۰	۹۰/۱۳±۰/۴۷	۵۴/۸۳±۱۹/۰۵	۹۳/۷۹±۰/۷۱
توجه: کلاس ۱: اسکیزوفرنی. کلاس ۲: اختلال شناختی خفیف (MCI). کلاس ۳: افسردگی. کلاس ۴: کنترل‌ها (افراد سالم). و کلاس ۵: بیماری آلزایمر					

نتایج جدول ۲ نشان می‌دهد، مدل طبقه‌بندی بیز ساده در باند فرکانسی گاما و در حالات ترکیبی PCC و MI، برای ویژگی SVD، عملکرد مطلوبی در تشخیص اختلال افسردگی با درصد صحت ۸۹/۵۲٪ داشته است. با این حال، امتیاز F1 در ترکیبات مختلف، به‌ویژه برای ویژگی آنتروپی شانون و SVD، تنوع قابل توجهی را نشان می‌دهد که ممکن است منعکس‌کننده تعادل متفاوتی بین صحت و حساسیت باشد. ویژگی آنتروپی لگاریتم انرژی در ترکیبات، به‌ویژه PCC و MI و همچنین PLV و MI، امتیاز F1 بسیار بالایی را نشان می‌دهد.

نتایج جدول ۳ نشان می‌دهند که مدل طبقه‌بندی KNN در باند فرکانسی بتا و در ترکیب PLV و PCC صحت ۹۰/۶۳٪ در تشخیص اختلال شناختی خفیف داشته است. امتیاز F1 نیز در تمامی این

جدول ۳. بهترین نرخ‌های طبقه‌بندی KNN بر اساس ویژگی‌های مختلف باندهای فرکانسی EEG

شماره کلاس	صحت (%)	حساسیت (%)	امتیاز F1 (%)	دقت (%)
سیگنال EEG باند بتا (MI و PCC)				
۲	۹۰/۳۵±۰/۸۲	۹۱/۱۱±۰/۷۱	۹۱/۶۶±۱۳/۶۰	۹۴/۷۸±۰/۴۲
سیگنال EEG باند بتا (PLV و PCC)				
۲	۹۰/۶۳±۱/۱۰	۹۱/۴۵±۰/۹۶	۸۹/۴۰±۱۲/۳۵	۹۴/۹۲±۰/۵۶
سیگنال EEG باند بتا (MI و PLV)				
۳	۸۹/۸۱±۰/۷۴	۹۰/۱۰±۰/۷۷	۹۱/۳۰±۱۴/۱۳	۹۴/۵۲±۰/۳۷
توجه: کلاس ۱: اسکیزوفرنی. کلاس ۲: اختلال شناختی خفیف (MCI). کلاس ۳: افسردگی. کلاس ۴: کنترل‌ها (افراد سالم). و کلاس ۵: بیماری آلزایمر				

نتایج جدول ۳ نشان می‌دهند که مدل طبقه‌بندی KNN در باند فرکانسی بتا و در ترکیب PLV و PCC صحت ۹۰/۶۳٪ در تشخیص اختلال شناختی خفیف داشته است. امتیاز F1 نیز در تمامی این

نتایج جدول ۳ نشان می‌دهند که مدل طبقه‌بندی KNN در باند فرکانسی بتا و در ترکیب PLV و PCC صحت ۹۰/۶۳٪ در تشخیص اختلال شناختی خفیف داشته است. امتیاز F1 نیز در تمامی این

جدول ۴. بهترین نرخ‌های طبقه‌بندی Naïve Bayes بر اساس ویژگی‌های مختلف باندهای فرکانسی EEG

شماره کلاس	صحت (%)	حساسیت (%)	امتیاز F1 (%)	دقت (%)
سیگنال EEG باند دلتا (MI و PCC)				
۳	۸۸/۱۹ ± ۰/۵۶	۸۹/۱۶ ± ۰/۴۳	۵۷/۶۱ ± ۲۲/۹۶	۹۳/۶۶ ± ۰/۳۲
سیگنال EEG باند گاما (PLV و PCC)				
۳	۸۸/۵۲ ± ۱/۷۴	۸۹/۹۴ ± ۰/۷۰	۶۰/۶۰ ± ۲۶/۷۱	۹۳/۷۸ ± ۰/۹۵
سیگنال EEG باند بتا (MI و PLV)				
۲	۸۶/۵۸ ± ۱/۷۲	۹۰/۷۴ ± ۰/۷۵	۴۰/۱۱ ± ۱۰/۲۰	۹۲/۵۸ ± ۰/۹۸
توجه: کلاس ۱: اسکیزوفرنی. کلاس ۲: اختلال شناختی خفیف (MCI). کلاس ۳: افسردگی. کلاس ۴: کنترل‌ها (افراد سالم). و کلاس ۵: بیماری‌های آلزایمر				

گسترده‌ای از باندهای فرکانسی برای تشخیص چندکلاسه اختلالات نهفته است. بسیاری از مطالعات قبلی، با تمرکز بر تشخیص دودویی یا بررسی یک نوع اختلال خاص، نتایج قابل توجهی را گزارش کرده‌اند. برای مثال، سپریان و همکاران [۵] در تشخیص اسکیزوفرنی در مقابل افراد سالم از آنتروپی انتقال نمادین و الگوریتم Relief برای انتخاب ویژگی‌های مرتبط استفاده کردند و به صحت ۹۲/۹۶٪ با الگوریتم KNN دست یافتند. گادفری و سینگ [۶] نیز در تشخیص افسردگی در مقابل افراد سالم از تحلیل آماری، تحلیل طیفی، تحلیل موجک و ارزیابی اتصال عملکردی استفاده کردند و به صحت ۹۹٪ با الگوریتم RBFSVM رسیدند. در زمینه اسکیزوفرنی، رونیز د میراس و همکاران [۷] با بررسی معیارهای خطی و غیرخطی و استفاده از طبقه‌بندهای مختلف، صحت ۸۷٪ را با KNN گزارش کردند و شن و همکاران [۸] با استفاده از مدل خودرگرسیو چند متغیره برای استخراج ویژگی در حوزه فرکانس باند آلفا و شبکه‌های عصبی کانولوشن سه بعدی به صحت ۹۸/۴۷٪ دست یافتند. تحقیقی دیگر [۹] با محاسبه شاخص اتصال وزنی و استفاده از الگوریتم درخت پوشای کمینه برای استخراج ویژگی، کاهش توان در باندهای آلفا و بتا را در گروه MCI نشان داد. استخراج ویژگی‌های باند های فرکانسی تفاوت‌های معنی‌داری بین گروه‌های MCI و آلزایمر و افراد سالم را نشان می‌دهد، در همین راستا، پژوهش اکبری موحد و همکاران [۱۰] نشان داد که ترکیب ویژگی‌های طیفی، اتصال عملکردی و ویژگی‌های غیرخطی مبتنی بر EEG با استفاده از الگوریتم انتخاب ویژگی بازگشتی رو به عقب و طبقه‌بند KNN می‌تواند صحت بالایی (۹۸/۸۰٪) در تشخیص MCI به دست دهد. محدودیت این پژوهش می‌تواند شامل استفاده از داده‌های غیربومی و بررسی تک متغیره EEG فقط در حالت استراحت می‌باشد. برای پژوهش‌های آتی، پیشنهاد می‌شود از الگوریتم‌های یادگیری عمیق و شبکه‌های عصبی برای استخراج خودکار ویژگی‌های پیچیده‌تر و ارتقاء صحت طبقه‌بندی استفاده شود. همانطور که در مرور آخاند و همکاران [۱۶] نیز اشاره شد، بهره‌گیری از مدل‌های یادگیری عمیق نتایج دقیقی در شناسایی الگوهای عملکردی مغز فراهم کرده است.

نتایج جدول ۴ نشان می‌دهند که مدل طبقه‌بندی بیز ساده در باند فرکانسی دلتا و در حالت ترکیب PCC و MI در تشخیص اختلال افسردگی با درصد صحت ۸۸/۱۹٪، نتیجه مطلوبی داشته است. با این حال، امتیاز F1 در تمامی این ترکیبات در مقایسه با مدل KNN پایین‌تر است، که نشان‌دهنده عملکرد ضعیف‌تر در ایجاد تعادل بین صحت و حساسیت در این مدل می‌باشد. این امر به‌ویژه در باند بتا با ترکیب PLV و MI مشهود است که امتیاز F1 به‌طور قابل توجهی پایین‌تر است (۹۲/۵۸٪).

۴- نتیجه‌گیری و پیشنهادات

پژوهش حاضر با هدف ارائه یک مدل طبقه‌بندی چندگانه برای تشخیص اختلالات روانشناختی و شناختی، شامل افسردگی، اسکیزوفرنی، اختلال شناختی خفیف و آلزایمر بر اساس تحلیل سیگنال‌های الکتروانسفالوگرام انجام شد. در این راستا، ارتباطات عملکردی مغز با استفاده از ساختارهای گراف محلی مدل‌سازی شده و الگوهای ارتباطی از طریق معیارهای ضریب همبستگی پیرسون، ارزش قفل‌سازی فاز و اطلاعات متقابل ارزیابی گردیدند. اعمال الگوریتم‌های طبقه‌بندی Naïve Bayes و KNN بر روی ویژگی‌های استخراج شده شامل بزرگترین مقدار منفرد، آنتروپی شانون و آنتروپی لگاریتم انرژی در باندهای فرکانسی مختلف (دلتا، تتا، آلفا، SMR، بتا، گاما) نشان داد که ترکیبات خاصی از این معیارها در باندهای بتا و گاما، صحت قابل قبولی در تشخیص اختلالات ارائه می‌دهند. به‌طور خاص، در باند فرکانسی بتا و در حالت ترکیب داده‌های PCC و MI، صحت بالایی در تشخیص اختلال شناختی خفیف با ویژگی SVD، با درصد صحت ۹۰/۲۹٪ به دست آمد. همچنین، مدل طبقه‌بندی KNN در باند فرکانسی بتا و در ترکیب PLV و PCC صحت بسیار بالایی در تشخیص MCI (با درصد صحت ۹۰/۶۳٪) نشان داد. در تشخیص اختلال افسردگی، مدل طبقه‌بندی بیز ساده در باند فرکانسی گاما و در حالات ترکیبی PCC و MI، برای ویژگی SVD، عملکرد مطلوبی با درصد صحت ۸۹/۵۲٪ داشته است. در مقایسه با تحقیقات پیشین، نوآوری اصلی پژوهش حاضر در بررسی همزمان و سیستماتیک ترکیبات متنوعی از اتصالات عملکردی در طیف

است. این انتخاب ناشی از عدم توازن شدید نمونه‌ها بین گروه‌ها (مثلاً کنترل: ۹۵ نمونه، افسردگی: ۲۸ نمونه) و در نتیجه، تضعیف عملکرد مدل چندکلاسه اتخاذ شد. اگرچه این رویکرد امکان ارزیابی اولیه تمایز هر اختلال را فراهم می‌کند، اما قادر به تشخیص همزمان و مستقیم بین تمامی پنج گروه نیست و ریسک خطاهای متقاطع (مانند تشخیص نادرست یک نمونه در چند مدل مجزا) را افزایش می‌دهد. در نتیجه، صحت گزارش شده تنها بازتاب عملکرد هر مدل باینری جداگانه است و لزوماً بیانگر توانمندی سیستم در تمایز جامع اختلالات نیست. برای حل این چالش در آینده، افزایش حجم نمونه‌های گروه‌های اقلیت (یا متوازن‌سازی نمونه‌ها) و توسعه الگوریتم‌های طبقه‌بندی پیشرفته‌تر و مقاوم به عدم تعادل داده‌ها (مانند تکنیک‌های نمونه‌گیری مجدد^۱ یا معماری‌های یادگیری عمیق مبتنی بر توجه^۲) ضروری است. در نهایت، توسعه مدل‌هایی برای تشخیص زودهنگام‌تر و دقیق‌تر اختلالات در مراحل اولیه تمایز بین اختلالات با نشانگان مشابه مانند MCI و مراحل اولیه آلزایمر، و ارزیابی عملکرد مدل‌ها در محیط‌های بالینی واقعی از اولویت‌های تحقیقات آینده خواهد بود. ترکیب طبقه‌بندی و استفاده از الگوریتم‌های کاهش داده نیز می‌تواند در بهبود کارایی و صحت مدل‌های تشخیصی مبتنی بر EEG مؤثر واقع شود.

۵- مراجع

- Hata, M., Kazui, H., Tanaka, T., Ishii, R., Canuet, L., Pascual-Marqui, R. D., Aoki, Y., Ikeda, S., Kanemoto, H., Yoshiyama, K., Iwase, M., & Takeda, M. (2016). Functional connectivity assessed by resting state EEG correlates with cognitive decline of Alzheimer's disease – An eLORETA study. *Clinical Neurophysiology*, 127(9), 1269–1278. <http://dx.doi.org/10.1016/j.clinph.2015.10.030>
- Rodrigues, P. M., Bispo, B. C., Garrett, C., Alves, D., Teixeira, J. P., & Freitas, D. (2021). Lacsogram: A New EEG Tool to Diagnose Alzheimer's Disease. *IEEE Journal of Biomedical and Health Informatics*, 25(9), Article ID 2014001. <https://ieeexplore.ieee.org/document/9390181>
- Fodor, Z., Horváth, A., Hidasi, Z., Gouw, A. A., Stam, C. J., & Csukly, G. (2021). EEG Alpha and Beta Band Functional Connectivity and Network Structure Mark Hub Overload in Mild Cognitive Impairment During Memory Maintenance. *Journal Title*, October 2021. <https://doi.org/10.1155/2022/2014001>
- Khare, S. K., & Acharya, U. R. (2023). EEG-Derived Functional Connectivity Patterns Associated with Mild Cognitive Impairment in Parkinson's Disease.

ترکیب داده‌های EEG با سایر روش‌های تصویربرداری مغزی و نشانگرهای زیستی می‌تواند منجر به توسعه مدل‌های تشخیصی جامع‌تری گردد. علاوه بر این، افزایش حجم و تنوع مجموعه‌داده‌های مورد استفاده و بررسی سایر شاخص‌های اتصال عملکردی و مؤثر مغزی، همانند آنچه در مطالعه گوناواردا و همکاران [۱۷] با معرفی مدل Isomap-GPLVM برای بررسی اتصالات عملکردی EEG مطرح شد، می‌تواند به افزایش قابلیت تعمیم و پایایی مدل‌ها کمک کند. در زمینه پردازش سیگنال EEG، توجه به حذف نویزها و آثار مصنوعی از اهمیت بالایی برخوردار است. آرتیفکت‌های عضلانی می‌توانند به طور قابل توجهی بر سیگنال EEG تأثیر بگذارند، به ویژه در محدوده‌های فرکانسی مرتبط با فعالیت عضلانی (معمولاً بین ۲۰ هرتز و ۱۰۰ هرتز) و همپوشانی بالقوه با فرکانس‌های خاص امواج مغزی (نظیر بتا و گاما). از این رو، اگرچه رویکرد پیشنهادی شامل رویه‌های خاص حذف آرتیفکت نبود، که به طور بالقوه پیچیدگی پردازش داده‌ها را کاهش می‌دهد، اما ممکن است توانایی آن را در افزایش صحت طبقه‌بندی نیز محدود کند. عدم حذف آرتیفکت در واقع محدودیتی برای مطالعه حاضر است، زیرا گنجاندن چنین مراحل پیش‌پردازشی می‌تواند استحکام یافته‌های را بهبود بخشد. با توجه به این محدودیت، پژوهش‌های آینده می‌توانند از روش‌های پیشرفته‌تری برای کاهش نویز، مانند فیلترهای تطبیقی و الگوریتم‌های مبتنی بر یادگیری ماشین، بهره ببرند. اگرچه طول پنجره‌های ۶۰ ثانیه‌ای در این پژوهش بر اساس شواهد مطالعات پیشین [۱۸] مبنی بر بهینه‌بودن برای تحلیل شبکه‌های عملکردی مغز انتخاب شد، اما این انتخاب به‌طور تجربی عمدتاً برای یک اختلال خاص (بیماری آلزایمر) اعتبارسنجی شده است. بنابراین، لزوماً تضمینی برای بهینه‌بودن آن برای تمام اختلالات مورد بررسی حاضر (شامل اسکیزوفرنی، افسردگی و اختلال شناختی خفیف (MCI)) وجود ندارد. این تعمیم طول پنجره ثابت به همه موارد می‌تواند یک محدودیت محسوب شود، چرا که الگوهای دینامیکی اتصالات مغزی ممکن است بین اختلالات مختلف تفاوت چشمگیری داشته باشند. به منظور رفع این محدودیت، پیشنهاد می‌شود مطالعات آینده با هدف بررسی سیستماتیک تعیین طول بهینه پنجره به‌ازای هر اختلال خاص انجام گردد. یکی از محدودیت اصلی این پژوهش، تفاوت معنادار توزیع سنی بین گروه‌های مورد مطالعه است (میانگین سنی گروه افسردگی: ۶۹/۷ سال، اسکیزوفرنی: ۴۱/۴ سال، آلزایمر: ۷۲/۹ سال، کنترل: ۵۲/۲ سال). از آنجا که داده‌های EEG از پایگاه‌های عمومی استخراج شده‌اند، ما نقشی در طراحی پروتکل ثبت یا همسان‌سازی گروه‌ها نداشته‌ایم. این موضوع می‌تواند منجر به اختلاط اثرات پیری طبیعی با نشانگرهای پاتولوژیک شود. برای حل این چالش در پژوهش‌های آتی، پیشنهاد می‌شود از پایگاه‌های داده‌ای با گروه‌های همسان سنی استفاده شود. یکی از محدودیت مهم این مطالعه، اتخاذ رویکرد طبقه‌بندی "یکی در مقابل همه" به‌جای مدل چندکلاسه یکپارچه

^۱ Attention-based Deep Learning

^۲ Resampling



- S.W., Ed.; Newnes: Amsterdam, The Netherlands; Boston, MA, USA, 2003; pp. 333–342. ISBN 9780750674447. <https://doi.org/10.1016/B978-0-7506-7444-7/50057-1>
14. Rakshit, R. D., Nath, S. C., & Kisku, D. R. (2018). Face identification using some novel local descriptors under the influence of facial complexities. *Expert Systems with Applications*, 93, 105–119. <https://doi.org/10.1016/j.eswa.2017.09.038>
 15. Kumar, A., & Singh, B. (2017). Face identification using some novel local descriptors under the influence of facial complexities. *International Journal of Computer Applications*, 165(9), 1–7. <https://www.researchgate.net/publication/319701264>
 16. Akhand, M. A. H., Akter Maria, M., Kamal, M. A. S., & Murase, K. (2023). Improved EEG-based emotion recognition through information enhancement in connectivity feature map. *Scientific Reports*, 13, Article 13804. <https://doi.org/10.1016/j.nbd.2023.106380>
 17. Gunawardena, R., Sarrigiannis, P. G., Blackburn, D. J., & He, F. (2023). Kernel-based nonlinear manifold learning for EEG-based functional connectivity analysis and channel selection with application to Alzheimer's disease. *Neuroscience*, 523, 140–156. <https://doi.org/10.1016/j.neuroscience.2023.05.033>
 18. Guo, H., Liu, L., Chen, J., Xu, Y., & Jie, X. (2017). Alzheimer classification using a minimum spanning tree of high-order functional network on fMRI dataset. *Frontiers in Neuroscience*, 11, Article 639. <https://doi.org/10.3389/fnins.2017.00639>
 - Knowledge-Based Systems*, 278, Article 110858. <https://doi.org/10.1016/j.knosys.2023.110858>
 5. Ciprian, C., Masychev, K., Ravan, M., Manimaran, A., & Deshmukh, A. (2021). Diagnosing schizophrenia using effective connectivity of resting-state EEG data. *Algorithms*, 14(5), Article 139. <https://doi.org/10.3390/a14050139>
 6. Godfrey, M., & Singh, K. D. (2021). Measuring robust functional connectivity from resting-state MEG using amplitude and entropy correlation across frequency bands and temporal scales. *NeuroImage*, 226, Article 117551. <https://doi.org/10.1016/j.neuroimage.2020.117551>
 7. Ruiz de Miras, J., Ibañez-Molina, A. J., Soriano, M. F., & Iglesias-Parro, S. (2023). Schizophrenia classification using machine learning on resting state EEG signal. *Biomedical Signal Processing and Control*, 79, Article 104233. <https://doi.org/10.1016/j.bspc.2022.104233>
 8. Shen, M., Wen, P., Song, B., & Li, Y. (2024). 3D convolutional neural network for schizophrenia detection using EEG-based functional brain network. *Biomedical Signal Processing and Control*, 89, Article 105815. <https://doi.org/10.1016/j.bspc.2023.105815>
 9. Das, S., & Puthankattil, S. D. (2020). Complex network analysis of MCI-AD EEG signals under cognitive and resting state. *Brain Research*, 1735, Article 146743. <https://doi.org/10.1016/j.brainres.2020.146743>
 10. Akbari Movahed, R., & Rezaeian, M. (2022). Automatic diagnosis of mild cognitive impairment based on spectral, functional connectivity, and nonlinear EEG-based features. *Computational and Mathematical Methods in Medicine*, Article 2014001. <https://doi.org/10.1155/2022/2014001>
 11. Sanati Fahandari, A., Moshiryan, S., & Goshvarpour, A. (2025). Diagnosis of cognitive and mental disorders: A new approach based on spectral–spatiotemporal analysis and local graph structures of electroencephalogram signals. *Brain Sciences*, 15, Article 68. <https://doi.org/10.3390/brainsci15010068>
 12. Benninger, F., Shor, O., Glik, A., Yaniv-Rosenfeld, A., Valevski, A., Weizman, A., & Khrennikov, A. (n.d.). EEG p-adic quantum potential accurately identifies depression, schizophrenia and cognitive decline [Data set]. Dryad. <https://doi.org/10.5061/dryad.8gth76pw>
 13. Smith, S.W. CHAPTER 20—Chebyshev Filters. In *Digital Signal Processing*; Smith,