

Classification of Alzheimer's and Schizophrenia Diseases Based on Statistical and Nonlinear Features of EEG Signals: A Focus on Fuzzy Entropy

Tofighi Milani, Mahdiyeh¹ / Shamekhi, Sina^{2*} / Zarei, Asghar³

¹ - M.Sc student, Faculty of Biomedical Engineering, Sahand University of Technology, Sahand New City, Tabriz, Iran

² - Associate Professor, Faculty of Biomedical Engineering, Sahand University of Technology, Sahand New City, Tabriz, Iran

³ - Assistant Professor, Faculty of Biomedical Engineering, Sahand University of Technology, Sahand New City, Tabriz, Iran

ARTICLE INFO

DOI: 10.22041/ijbme.2025.2052292.1955

Received: 1/2/2025

Revised: 7/6/2025


Accepted: 12/7/2025

KEYWORDS

Alzheimer's Disease
Schizophrenia
Electroencephalogram
Machine Learning
Fuzzy Entropy

ABSTRACT

Alzheimer's disease and schizophrenia are among the most common and complex neuropsychiatric disorders, and their differential diagnosis, particularly in the early stages, poses significant challenges. Although current diagnostic methods provide valuable information, they are often costly and, in some cases, invasive. In this study, a non-invasive and cost-effective approach based on EEG signals and machine learning algorithms is proposed to differentiate between these two disorders. In the proposed method, EEG signals are first decomposed into various frequency sub-bands using the Fast Fourier Transform (FFT), and a set of statistical and nonlinear features, including kurtosis, skewness, Shannon entropy, fuzzy entropy, mobility, and complexity, are extracted. Feature selection is performed using the ReliefF algorithm, and the selected features are subsequently fed into classifiers such as k-nearest neighbors, linear support vector machine, random forest, and others. The performance of the proposed method was initially evaluated on the first dataset, which consists of two distinct parts containing data from patients with Alzheimer's disease and schizophrenia, where the random forest (RF) classifier achieved the best performance with an average accuracy of 98.61%. Furthermore, evaluation on the second dataset showed that the proposed method, using the same classifier, achieved an average accuracy of 88.11%, confirming the strong capability of the model in distinguishing between patients with Alzheimer's disease and schizophrenia. It is worth noting that fuzzy entropy consistently outperformed other features across both datasets and was identified as a key indicator in the differentiation of these two disorders.



طبقه‌بندی بیماری‌های آلزایمر و اسکیزوفرنی با تحلیل ویژگی‌های آماری و غیرخطی سیگنال‌های EEG: تمرکز بر آنتروپی فازی

توفیقی میلانی^۱، مهدیه^۱ / شامخی، سینا^{۲*} / زارعی، اصغر^۳

^۱ - دانشجوی کارشناسی ارشد، دانشکده مهندسی پزشکی، دانشگاه صنعتی سهند، شهر جدید سهند، تبریز، ایران

^۲ - دانشیار، دانشکده مهندسی پزشکی، دانشگاه صنعتی سهند، شهر جدید سهند، تبریز، ایران

^۳ - استادیار، دانشکده مهندسی پزشکی، دانشگاه صنعتی سهند، شهر جدید سهند، تبریز، ایران

مشخصات مقاله

شناسه‌ی دیجیتال: 10.22041/ijbme.2025.2052292.1955

پذیرش: ۱۴۰۴/۴/۲۱

بازنگری: ۱۴۰۴/۳/۱۷

ثبت در سامانه: ۱۴۰۳/۱۱/۱۳

چکیده

واژه‌های کلیدی

بیماری‌های آلزایمر و اسکیزوفرنی از جمله اختلالات شایع و پیچیده عصبی-روانشناختی هستند که تشخیص افتراقی آن‌ها، به‌ویژه در مراحل اولیه، با چالش‌های قابل توجهی همراه است. روش‌های تشخیصی موجود، با وجود ارائه اطلاعات ارزشمند، اغلب پرهزینه و در برخی موارد تهاجمی هستند. در این پژوهش، یک روش غیرتهاجمی و مقرون‌به‌صرفه مبتنی بر سیگنال‌های EEG و الگوریتم‌های یادگیری ماشین برای تفکیک این دو بیماری ارائه شده است. در روش پیشنهادی، سیگنال‌های EEG ابتدا با استفاده از تبدیل فوریه سریع (FFT) به زیرباندهای فرکانسی مختلف تجزیه شده و سپس مجموعه‌ای از ویژگی‌های آماری و غیرخطی شامل کشیدگی، چولگی، آنتروپی شانون، آنتروپی فازی، تحرک و پیچیدگی با استفاده از الگوریتم ReliefF انتخاب و به ورودی طبقه‌بندهایی نظیر k نزدیک‌ترین همسایگی، ماشین بردار پشتیبان با هسته خطی، جنگل تصادفی و غیره اعمال شده‌اند. ارزیابی عملکرد روش پیشنهادی بر روی پایگاه داده اول، متشکل از دو بخش متفاوت شامل داده‌های بیماران مبتلا به آلزایمر و اسکیزوفرنی، نشان داد که طبقه‌بند جنگل تصادفی (RF) با دستیابی به میانگین صحت ۹۸/۶۱ درصد بهترین عملکرد را ارائه داده است. علاوه بر این، ارزیابی بر روی پایگاه داده دوم نیز انجام شد و روش پیشنهادی با استفاده از همان طبقه‌بند، به میانگین صحت ۸۸/۱۱ درصد دست یافت که کارایی بالای مدل را در افتراق بیماران مبتلا به آلزایمر و اسکیزوفرنی تایید می‌کند. لازم به ذکر است که ویژگی آنتروپی فازی در هر دو پایگاه داده به‌طور معناداری نسبت به سایر ویژگی‌ها عملکرد برتری داشته و به‌عنوان یک شاخص کلیدی در تفکیک این دو بیماری عمل کرده است.

بیماری آلزایمر
اسکیزوفرنی
الکتروانسفالوگرام
یادگیری ماشین
آنتروپی فازی

۱- مقدمه

بیماری‌های عصبی-روانشناختی، از جمله آلزایمر^۱ (AD) و اسکیزوفرنی^۲ (SZ)، از نگرانی‌های اصلی در دستور کار بهداشت جهانی هستند. تاکنون حدود ۲۴ میلیون نفر در سراسر جهان تحت تأثیر بیماری SZ قرار گرفته‌اند. افراد مبتلا به این بیماری دو تا سه برابر بیشتر از جمعیت عمومی در معرض خطر مرگ زودرس قرار دارند. این بیماری به طور قابل توجهی با ناتوانی‌های شناختی، اجتماعی و عملکردی همراه بوده، و باعث بروز علائم روان‌پریشی می‌شود [۱].

بیماری AD نیز، به‌عنوان شایع‌ترین نوع زوال عقل شناخته می‌شود. بر اساس آمارهای جهانی، بیش از ۵۵ میلیون نفر در حال حاضر با اختلالات مرتبط با زوال عقل زندگی می‌کنند. علاوه بر این، هر ساله حدود ۱۰ میلیون نفر دیگر به این بیماری‌ها مبتلا می‌شوند، که بیماری آلزایمر سهمی معادل ۶۰ تا ۷۰ درصد از این موارد را به خود اختصاص می‌دهد. انتظار می‌رود که این رقم در سال ۲۰۳۰ به ۷۸ میلیون و در سال ۲۰۵۰ به ۱۳۹ میلیون افزایش یابد [۲].

بیماری‌های AD و SZ پیامدهای گسترده‌ای را در تمام زمینه‌های زندگی، از جمله اجتماعی، خانوادگی، تحصیلی، شغلی و روانشناختی ایجاد می‌کنند که نه‌تنها زندگی افراد مبتلا را تحت تأثیر قرار می‌دهد، بلکه مراقبان، خانواده‌ها و جامعه را نیز درگیر چالش‌های متعددی می‌سازد [۳، ۴]. بنابراین تشخیص دقیق و به موقع این بیماری‌ها به‌منظور جلوگیری از آسیب‌های غیرقابل برگشت بسیار مهم است.

بیماری‌های AD و SZ دارای شباهت‌های قابل توجهی در سطوح ژنتیکی، نوروفیزیولوژیکی و بالینی هستند که تشخیص افتراقی میان این دو بیماری را، به‌ویژه در مراحل اولیه دشوار می‌سازد. به عنوان مثال، اختلالات

شناختی (مانند نقص در حافظه و توجه)، تغییرات شخصیتی و رفتاری (مانند افسردگی و انزوا)، کاهش حجم مغزی (به‌ویژه در لوب‌های پیشانی و گیجگاهی) و بروز علائم روان‌پریشی (مانند هذیان و توهم) در هر دو بیماری گزارش شده‌اند [۵، ۶]. در راستای بررسی این همپوشانی‌ها، اوهی و همکاران در سال ۲۰۲۴، به بررسی جامع شباهت‌های ژنتیکی، نوروفیزیولوژیکی و بالینی میان AD و SZ پرداختند. نتایج مطالعه مذکور نشان داد که بیماران مبتلا به SZ، به‌ویژه در مواردی با شروع دیر هنگام یا در سنین بالاتر، در معرض خطر بالاتری برای ابتلا به آلزایمر قرار دارند. از سوی دیگر، تقریباً ۳۰٪ از بیماران مبتلا به AD نیز، علائم روان‌پریشی نظیر هذیان و توهم را تجربه می‌کنند، علائمی که به‌طور کلاسیک با SZ مرتبط هستند [۷].

در تایید این همپوشانی‌های ساختاری، کوچونوف و همکاران در سال ۲۰۲۱، با استفاده از شاخص آسیب‌پذیری منطقه‌ای^۳ در تصویربرداری ماده سفید، نشان دادند که بیماران مبتلا به اسکیزوفرنی، به‌ویژه در سنین بالا، الگوهای از آسیب ماده سفید مشابه با بیماران آلزایمری از خود نشان می‌دهند. این آسیب‌ها عمدتاً در نواحی کلیدی مانند قشر پیش‌پیشانی، جسم پینه‌ای^۴ و فورنیکس مشاهده شده و با کاهش عملکردهای شناختی در هر دو بیماری مرتبط هستند [۸]. این همپوشانی در علائم، فرآیند تشخیص را پیچیده کرده و نیازمند به‌کارگیری روش‌های دقیق و قابل‌اعتماد برای افتراق میان آن‌ها است. اگرچه روش‌های مختلف تصویربرداری عصبی مانند تصویربرداری تشدید مغناطیسی^۵ (MRI)، برش‌نگاری گسیل پوزیترون^۶ (PET)، برش‌نگاری کامپیوتری^۷ (CT) و تصویربرداری تشدید مغناطیسی کارکردی^۸ (fMRI) اطلاعات مفیدی ارائه می‌دهند، اما به دلیل

^۵ Magnetic Resonance Imaging^۶ Positron Emission Tomography^۷ Computed Tomography^۸ functional Magnetic Resonance Imaging^۱ Alzheimer's^۲ Schizophrenia^۳ Regional Vulnerability Index^۴ Corpus Callosum

۹۹٪/۱ در طبقه‌بندی افراد FTD و HC دقت ۹۸٪، و در طبقه‌بندی افراد FTD و AD دقت ۹۷٪ حاصل گردید [۱۰]. در سال ۲۰۲۳، خاویر و همکاران با استفاده از تبدیل فوریه گسسته گراف^۶ (GDFT) به بررسی کاربرد تکنیک‌های پردازش سیگنال گراف^۷ (GSP) در تحلیل سیگنال‌های EEG پرداختند. در مطالعه مذکور، سیگنال‌های ۸۸ شرکت‌کننده پس از تجزیه و تحلیل، به سه گروه (افراد مبتلا به آلزایمر، دمانس فرونتوتمپورال و افراد سالم) دسته‌بندی شدند. عملکرد مدل بر روی مجموعه تست برای طبقه‌بندی دودویی بین زوال عقل و افراد سالم با استفاده از طبقه‌بند ماشین بردار پشتیبان^۸ (SVM) به دقت بالای ۸۵٪ دست یافت. همچنین، عملکرد مدل بر روی همان مجموعه در طبقه‌بندی چندکلاسه با استفاده از طبقه‌بند بیز ساده^۹ (NB) به دقت بالای ۴۴٪ دست یافت [۱۱]. در سال ۲۰۲۳، یائو و همکاران یک روش جدید برای تفکیک افراد مبتلا به AD، FTD و HC معرفی کردند. در مطالعه مذکور، ویژگی‌های طیفی توان از سیگنال‌های EEG خام استخراج و به ورودی طبقه‌بندهای RF و شبکه‌های عصبی مصنوعی^{۱۰} (ANN) به منظور تفکیک بیماران AD، FTD و HC اعمال شد. محققان گزارش کردند که با استفاده از ANN می‌توان به میانگین دقت ۹۶٪ در طبقه‌بندی افراد AD و HC، ۹۲٪ در طبقه‌بندی افراد AD و FTD و ۹۵٪ در طبقه‌بندی افراد HC و FTD دست یافت. همچنین، محققان به دقت ۹۰٪/۴ در طبقه‌بندی چندکلاسه دست یافتند [۱۲]. در سال ۲۰۲۴، اوتکارش و همکاران به ارزیابی جامع روش‌های مختلف استخراج ویژگی برای تجزیه و تحلیل سیگنال‌های EEG پرداختند. روش‌های استفاده شده برای استخراج

هزینه بالا و تهاجمی بودن، استفاده از آن‌ها در بسیاری از موارد محدود می‌شود. در مقابل، سیگنال‌های الکتروانسفالوگرام^۱ (EEG) به دلیل ویژگی‌های منحصر به فرد خود از جمله قابل حمل بودن، غیرتهاجمی بودن، کم هزینه بودن و رزولوشن زمانی بالا، به عنوان روشی مناسب برای تشخیص افتراقی این دو بیماری مورد توجه قرار گرفته است. این ویژگی‌ها، سیگنال‌های EEG را به گزینه‌ای مؤثر و مقرون به صرفه برای کاربردهای کلینیکی تبدیل کرده است [۹].

با توجه به شباهت‌های قابل توجه میان بیماری‌های آلزایمر و اسکیزوفرنی که موجب دشواری در تشخیص افتراقی آن‌ها می‌شود، توسعه روشی نوین مبتنی بر تحلیل سیگنال‌های EEG به منظور تفکیک مؤثر این دو بیماری از یکدیگر، به عنوان هدف اصلی این پژوهش تعیین گردیده است. با این وجود، به دلیل محدودیت در تعداد مطالعاتی که به طور همزمان به بررسی این دو گروه پرداخته‌اند، تمرکز این بخش از مقاله حاضر بیشتر بر مقالاتی است که به صورت جداگانه ویژگی‌ها و روش‌های تشخیصی مرتبط با هر یک از این بیماری‌ها را تحلیل کرده‌اند.

در سال ۲۰۲۱، میلیادوس و همکاران از ۶ روش یادگیری ماشین نظارت شده برای دسته‌بندی سیگنال‌های EEG بیماران مبتلا به آلزایمر، دمانس فرونتوتمپورال^۲ (FTD) و افراد کنترل سالم^۳ (HC) استفاده کردند. در مطالعه مذکور، از ویژگی‌های حوزه فرکانس مانند انرژی باند فرکانسی و همچنین ویژگی‌های حوزه زمان مانند میانگین، واریانس و دامنه میان چارکی^۴ (IQR) استفاده شد. روش پیشنهادی، از طریق اعتبارسنجی متقابل ۱۰ لایه و طبقه‌بند جنگل تصادفی^۵ (RF) به دقت‌های بالایی دست یافت، به طوری که در طبقه‌بندی افراد AD و HC دقت

^۶ Graph Discrete Fourier Transform^۷ Graph Signal Processing^۸ Support Vector Machine^۹ Naive Bayes^{۱۰} Artificial Neural Network^۱ Electroencephalogram^۲ Frontotemporal Dementia^۳ Healthy Control^۴ Interquartile Range^۵ Random Forest

SVM و KNN و یک شبکه عصبی کانولوشنی^{۱۱} (CNN) آموزش داده شدند و عملکرد آن‌ها مقایسه شد. نتایج نشان داد که مدل CNN با دقت ۹۵٪ بر روی داده‌های اعتبارسنجی عملکرد بهتری نسبت به سه مدل دیگر دارد [۱۵]. در سال ۲۰۲۴، تامیلاراسی و همکاران مطالعه‌ای با هدف بهبود دقت تشخیص اسکیزوفرنی با استفاده از سیگنال‌های EEG و الگوریتم‌های یادگیری ماشین انجام دادند. در مطالعه مذکور ویژگی‌ها با استفاده از روش PSD از سیگنال‌های EEG استخراج گردید. در نهایت، الگوریتم‌های مختلف یادگیری ماشین بر روی ویژگی‌های استخراج شده اعمال شد. نتایج نشان داد که الگوریتم درخت تصمیم‌گیری^{۱۲} (DT) به دقت ۸۹٪/۱۲ در تفکیک بیماران مبتلا به اسکیزوفرنی از افراد سالم دست یافت [۱۶]. در سال ۲۰۲۴، الفارسی و المتوالی یک مطالعه مقایسه‌ای جامع از سه مدل یادگیری ماشین شامل LR، SVM و RF برای طبقه‌بندی سیگنال‌های EEG مرتبط با اسکیزوفرنی انجام دادند. مجموعه‌ای از ویژگی‌های آماری برای ثبت اطلاعات مرتبط از سیگنال‌های EEG استخراج شد. نتایج مطالعه مذکور نشان داد که طبقه‌بند RF بالاترین میزان دقت برابر با ۹۶٪ را به دست آورد [۱۷].

در سال ۲۰۲۳، گوکر و توسون یک راهکار مبتنی بر EEG برای طبقه‌بندی بیماری‌های آلزایمر و اسکیزوفرنی با استفاده از تبدیل سریع والش-هادامارد^{۱۳} (FWHT) و رویکرد یادگیری عمیق پیشنهاد دادند. در مطالعه مذکور، گروه‌های AD و SZ به طور خودکار طبقه‌بندی شدند. عملکرد الگوریتم‌های یادگیری ماشین شامل SVM، DT،

ویژگی‌ها شامل بُعد فرکتال هیگوجی^۱ (HFD)، آنتروپی تجزیه مقادیر منفرد^۲ (SVDE)، نرخ عبور از صفر، تحلیل نوسانات حذف‌شده^۳ (DFA) و پارامترهای یورث^۴ بودند. نتایج این مطالعه نشان داد، تکنیک استخراج ویژگی SVDE با استفاده از طبقه‌بند k نزدیک‌ترین همسایگی^۵ (KNN) همراه با ۹۰٪ همپوشانی در پنجره‌گذاری لغزان^۶ بهترین عملکرد را دارد. این مدل، به میانگین دقت ۹۱٪ در طبقه‌بندی افراد AD و HC، ۹۳٪ در طبقه‌بندی افراد FTD و HC و ۹۱٪ در طبقه‌بندی افراد AD و FTD دست یافت [۱۳].

در سال ۲۰۲۳، ناتودورای مطالعه‌ای با هدف ارزیابی عملکرد مدل‌های یادگیری ماشین و یادگیری عمیق در تحلیل تفاوت‌های موجود در زیر باندهای فرکانسی کانال‌های EEG به منظور شناسایی افراد مبتلا به اسکیزوفرنی انجام داد. در مطالعه مذکور، چگالی طیفی توان^۷ (PSD) سیگنال برای پیش‌بینی بیماران مبتلا به اسکیزوفرنی استخراج شد. الگوریتم‌های مختلف یادگیری ماشین بر روی ویژگی‌های استخراج شده اعمال گردید. نتایج این مطالعه نشان داد که الگوریتم تحلیل تمایزگر خطی^۸ (LDA) با فراهم کردن دقتی معادل با ۷۰٪ به عنوان کارآمدترین الگوریتم یادگیری ماشین عمل کرده است [۱۴]. در سال ۲۰۲۳، قیوم و همکاران اثربخشی مدل‌های مختلف یادگیری ماشین را برای تشخیص SZ با استفاده از سیگنال‌های EEG بررسی کردند. آن‌ها از مجموعه داده‌ای شامل ۱۴ بیمار اسکیزوفرنی و ۱۴ فرد سالم استفاده کردند. ۱۲ ویژگی پس از اعمال تجزیه و تحلیل مؤلفه‌های مستقل^۹ (ICA) از داده‌ها استخراج گردید. سه مدل سنتی یادگیری ماشین شامل رگرسیون لجستیک^{۱۰} (LR)،

^۱ Linear Discriminant Analysis^۲ Independent Component Analysis^۳ Logistic Regression^۴ Convolutional Neural Network^۵ Decision Tree^۶ Fast Walsh-Hadamard Transform^۱ Higuchi's Fractal Dimension^۲ Singular Value Decomposition Entropy^۳ Detrended Fluctuation Analysis^۴ Hjorth^۵ K-Nearest Neighbors^۶ Sliding Window^۷ Power Spectral Density

کاهش پیچیدگی مدل شده، بلکه در مقایسه با سایر ویژگی‌های غیرخطی عملکرد بهتری از خود نشان داده است. این یافته‌ها، بر اهمیت انتخاب ویژگی هدفمند در تشخیص افتراقی آلزایمر و اسکیزوفرنی تاکید داشته و گامی نوآورانه در بهینه‌سازی روش‌های طبقه‌بندی در حوزه‌ی تحلیل سیگنال‌های EEG محسوب می‌شود.

این مقاله در ۴ بخش تنظیم شده است، که در بخش دوم روش پیشنهادی تحقیق توضیح داده می‌شود. در بخش سوم نتایج تحقیق ارائه شده و مورد بحث و بررسی قرار می‌گیرد. در بخش چهارم نتیجه‌گیری حاصل از این پژوهش و کارهای آینده اشاره می‌شود.

۲- مواد و روش‌ها

در این بخش، ضمن معرفی پایگاه‌های داده، هر یک از مراحل روش پیشنهادی اعم از پیش‌پردازش، استخراج ویژگی، انتخاب ویژگی و طبقه‌بندی توضیح داده می‌شود.

در این مقاله، از دو پایگاه داده اصلی تحت عناوین پایگاه داده اول و پایگاه داده دوم که شامل سیگنال‌های EEG می‌باشند، برای ارزیابی عملکرد روش‌های ارائه شده استفاده شده است. در ادامه، جزئیات مربوط به هر دو پایگاه داده شرح داده می‌شود.

۲-۱- پایگاه داده اول

پایگاه داده اول شامل دو بخش متفاوت است. بخش اول این پایگاه داده به مجموعه داده‌ی بیماران مبتلا به اسکیزوفرنی اختصاص دارد که از پایگاه داده IBIB PAN که به صورت رایگان قابل دسترس است، انتخاب شده است [۲۱]. در این پایگاه داده، سیگنال‌های EEG از ۲۸ فرد ثبت شده است که ۱۴ نفر از آن‌ها بیماران مبتلا به اسکیزوفرنی پارانوئید و ۱۴ نفر از آن‌ها افراد سالم به عنوان گروه کنترل در نظر گرفته شده‌اند. تشخیص بیماران بر اساس معیارهای طبقه‌بندی بین‌المللی بیماری‌ها (ICD-10) برای اسکیزوفرنی

KNN و حافظه بلند-کوتاه مدت دوطرفه^۱ (BiLSTM) مقایسه شد. در نهایت، الگوریتم BiLSTM با فراهم کردن صحت کلی ۹۸/۳۸٪ بهترین عملکرد را ارائه داد [۱۸].

رایج‌ترین تغییرات گزارش شده در سیگنال EEG حالت استراحت بیماران آلزایمری، کند شدن کلی فعالیت EEG است. در بیماران آلزایمری، این کندی معمولاً به صورت کاهش قدرت باندهای آلفا و بتا و افزایش هم‌زمان قدرت باندهای دلتا و تتا در مقایسه با سالمندان سالم مشاهده می‌شود [۱۹]. برخلاف بیماری آلزایمر، تغییرات گزارش شده در سیگنال‌های EEG بیماران اسکیزوفرنی، در باندهای فرکانسی بالا (بتا و گاما) و به‌ویژه در اثر انجام وظیفه بیشتر از تغییرات حالت استراحت گزارش شده است. با این حال، گزارش‌هایی از تغییرات در نوسانات باند گاما، در بیماران اسکیزوفرنی، چه در حالت استراحت و چه پیش از یک وظیفه خاص وجود دارد [۲۰].

در حالی که مطالعات قبلی عمدتاً بر تشخیص یکی از این دو بیماری از افراد سالم پرداخته‌اند، تعداد مطالعات متمرکز بر روی تفکیک این دو بیماری از یکدیگر محدود می‌باشد. از این‌رو، در این مقاله با هدف پر کردن خلأ تحقیقاتی موجود، یک روش جدید بر پایه ویژگی‌های استخراج شده از زیرباندهای فرکانسی سیگنال EEG برای تمایز بین این دو بیماری ارائه شده است. در روش پیشنهادی این پژوهش، پس از استخراج مجموعه‌ای از ویژگی‌های متنوع، از الگوریتم انتخاب ویژگی ReliefF برای شناسایی مؤثرترین ویژگی‌ها استفاده شده است. نتایج این مرحله نشان داد که ویژگی آن‌تروپی فازی، که برای نخستین بار در این مطالعه به‌منظور تفکیک بیماران مبتلا به آلزایمر و اسکیزوفرنی مورد استفاده قرار گرفته، به‌عنوان یک شاخص افتراقی کلیدی شناسایی شده است. استفاده از این ویژگی نه تنها موجب افزایش دقت طبقه‌بندی و

^۱ Bidirectional Long-Short-Term Memory

AD، ۱۲ دقیقه برای گروه FTD و ۱۳/۸ دقیقه برای گروه HC بوده است. در مجموع، ۴۸۵/۵ دقیقه برای گروه AD، ۲۷۶/۵ دقیقه برای گروه FTD و ۴۰۲ دقیقه برای گروه HC، ثبت انجام گرفته و در فرمت set ذخیره شده است. داده‌های EEG مطابق با سیستم استاندارد بین‌المللی ۲۰-۱۰ و با استفاده از ۱۹ الکتروود سطحی به همراه ۲ الکتروود مرجع ثبت شده‌اند. این داده‌ها با نرخ نمونه‌برداری ۵۰۰ هرتز و وضوح ۱۰ میکروولت بر میلی‌متر ذخیره شده‌اند.

در پژوهش حاضر، از پایگاه داده اول، داده‌های مربوط به ۱۴ بیمار مبتلا به اسکیزوفرنی از بخش اول و داده‌های مربوط به ۱۴ بیمار مبتلا به آلزایمر از بخش دوم، به صورت تصادفی انتخاب و مورد استفاده قرار گرفته است. همچنین، به منظور افزایش قابلیت اطمینان یافته‌ها و کاهش احتمال سوگیری ناشی از انتخاب تصادفی بیماران مبتلا به آلزایمر، فرآیند انتخاب تصادفی افراد ۱۰ بار تکرار شده است. در هر تکرار، ۱۴ نفر به طور تصادفی انتخاب شده و نتایج این ۱۰ بار تکرار، به صورت میانگین \pm انحراف معیار گزارش شده است.

با توجه به اینکه پایگاه داده اول از دو بخش متفاوت تشکیل شده است، نرخ نمونه‌برداری سیگنال‌های EEG در این دو بخش با یکدیگر متفاوت می‌باشد. از این رو، به منظور یکسان‌سازی نرخ نمونه‌برداری میان دو بخش پایگاه داده، یک عمل بازنمونه‌برداری بر روی داده‌های مربوط به پایگاه داده آلزایمر انجام گرفت و نرخ نمونه‌برداری آن‌ها به ۲۵۰ هرتز کاهش داده شد. هر دو پایگاه داده شامل ۱۹ کانال با ترتیب و نام‌های مشابه می‌باشند.

علاوه بر تفاوت در نرخ نمونه‌برداری، استفاده از دو پایگاه داده متفاوت ممکن است موجب بروز تفاوت‌هایی در شرایط ثبت سیگنال، مانند نوع دستگاه، شرایط محیطی (نور، نویز و صدا) و پروتکل‌های اجرایی گردد که این عوامل می‌توانند بر نتایج تحلیل‌ها

پارانوئید انجام شده است. معیارهای ورود به مطالعه شامل حداقل سن ۱۸ سال، تشخیص اسکیزوفرنی پارانوئید طبق ICD-10 و حداقل ۷ روز دوره پاک‌سازی دارویی بوده است. در مقابل، معیارهای خروج شامل بارداری، بیماری‌های مغزی ارگانیک، بیماری‌های شدید عصبی (مانند صرع، آلزایمر یا پارکینسون)، وجود بیماری‌های جسمی عمومی و مرحله بسیار اولیه اسکیزوفرنی (مانند اولین حمله اسکیزوفرنی) بوده است. در این مطالعه، داده‌های EEG از تمام افراد به مدت ۱۵ دقیقه در حالت استراحت با چشمان بسته ثبت و در فرمت edf ذخیره شده است. این داده‌ها با نرخ نمونه‌برداری ۲۵۰ هرتز و با استفاده از سیستم استاندارد ۲۰-۱۰ در ۱۹ کانال EEG ثبت شده‌اند. بخش دوم این پایگاه داده نیز، به مجموعه داده‌ی بیماران مبتلا به آلزایمر اختصاص دارد که از پایگاه داده OpenNEURO که به صورت رایگان قابل دسترس است، انتخاب شده است [۲۲]. این پایگاه داده، شامل سیگنال‌های EEG ثبت شده از ۸۸ فرد بوده که ۳۶ نفر از آن‌ها بیماران مبتلا به آلزایمر، ۲۳ نفر از آن‌ها بیماران مبتلا به دمانس فرونتوتامپورال و ۲۹ نفر از آن‌ها افراد سالم به عنوان گروه کنترل هستند. معیارهای انتخاب شرکت‌کنندگان بر اساس راهنمای تشخیصی و آماری اختلالات روانی (DSM-IV، ICD-10) و معیارهای مؤسسه ملی اختلالات عصبی و انجمن بیماری آلزایمر (NINCDS-) (ADRDA) تعیین شده است. علاوه بر این، برای بیماران گروه آلزایمر، هیچ بیماری همراه مرتبط با زوال عقل گزارش نشده است. میانگین نمره آزمون وضعیت شناختی (MMSE) برای گروه آلزایمر ۱۷/۷۵ با انحراف معیار ۴/۵، برای گروه دمانس فرونتوتامپورال ۲۲/۱۷ با انحراف معیار ۸/۲۲ و برای گروه کنترل سالم ۳۰ بوده است. در این مطالعه، مدت زمان ثبت سیگنال‌های EEG در حالت استراحت با چشمان بسته برای هر گروه به‌طور متوسط، ۱۳/۵ دقیقه برای گروه

تعیین شده به گروه‌های افسردگی، اسکیزوفرنی، اختلالات شناختی (MCI یا AD) و کنترل تقسیم شدند. سیگنال‌های EEG مطابق با سیستم استاندارد بین‌المللی ۲۰-۱۰ با استفاده از ۱۹ الکتروود و با نرخ نمونه‌برداری ۵۰۰ هرتز ثبت شدند. شرکت‌کنندگان در شرایط استراحت با چشمان باز و بسته قرار داشتند. در پژوهش حاضر، از پایگاه داده دوم، داده‌های مربوط به ۴۲ بیمار مبتلا به اسکیزوفرنی و داده‌های مربوط به ۴۰ بیمار مبتلا به آلزایمر مورد استفاده قرار گرفته است.

۲-۳- روش پیشنهادی

بلوک دیاگرام روش پیشنهادی در شکل ۱ نشان داده شده است. همان‌طور که مشاهده می‌شود، در این تحقیق ابتدا سیگنال‌های EEG پیش‌پردازش می‌شوند و سپس ویژگی‌های موردنظر از آن‌ها استخراج می‌گردد. در ادامه، ویژگی‌های مؤثر به کمک الگوریتم ReliefF انتخاب می‌شوند. در انتها با استفاده از بردار ویژگی انتخاب شده، طبقه‌بندی داده‌ها صورت می‌گیرد. جزئیات هر یک از مراحل روش پیشنهادی در ادامه توضیح داده می‌شود.

۲-۳-۱- پیش‌پردازش

در این مقاله، پیش‌پردازش داده‌ها متشکل از ۲ مرحله‌ی پنجره‌بندی و فیلترکردن است. جزئیات هر کدام از این مراحل در ادامه آورده شده است. پنجره‌بندی: سیگنال‌های EEG به دلیل ماهیت نایستای خود نیاز به تقسیم به بخش‌های کوتاه‌تری دارند. از این‌رو، در این پژوهش به‌منظور اعمال پنجره‌بندی و غلبه بر مشکل نایستایی، هر سیگنال به پنجره‌هایی با طول ۲ ثانیه (معادل ۵۰۰ نمونه در نرخ نمونه‌برداری ۲۵۰ هرتز) تقسیم می‌شود. همچنین، به‌منظور بررسی تأثیر طول پنجره بر عملکرد مدل، پنجره‌هایی با طول‌های ۴، ۵ و ۱۰ ثانیه نیز مورد آزمایش قرار گرفتند. نتایج حاصل نشان داد که

تأثیرگذار باشند. برای کاهش اثرات این تفاوت‌های احتمالی، ابتدا فرایند نرمال‌سازی بر روی داده‌ها اعمال شد تا تفاوت‌های احتمالی میان دو پایگاه داده به حداقل برسد. علاوه بر این، به‌منظور اطمینان بیشتر از عدم دخالت عوامل غیر بیماری‌شناختی در عملکرد روش پیشنهادی، کلیه آنالیزها مجدداً بر روی یک پایگاه داده جدید انجام گرفت. در این پایگاه داده، سیگنال‌های EEG تمامی شرکت‌کنندگان تحت شرایط مشابه، با یک دستگاه ثبت EEG یکسان و در محیطی کنترل‌شده جمع‌آوری شده‌اند. استفاده از این پایگاه داده، احتمال بروز سوگیری ناشی از تفاوت در شرایط ثبت را به‌طور کامل حذف کرده و تضمین می‌کند که تفاوت‌های مشاهده شده، صرفاً ناشی از تفاوت‌های واقعی میان گروه‌های مورد بررسی هستند. در ادامه، توضیحات مربوط به پایگاه داده دوم شرح داده می‌شود.

۲-۲- پایگاه داده دوم

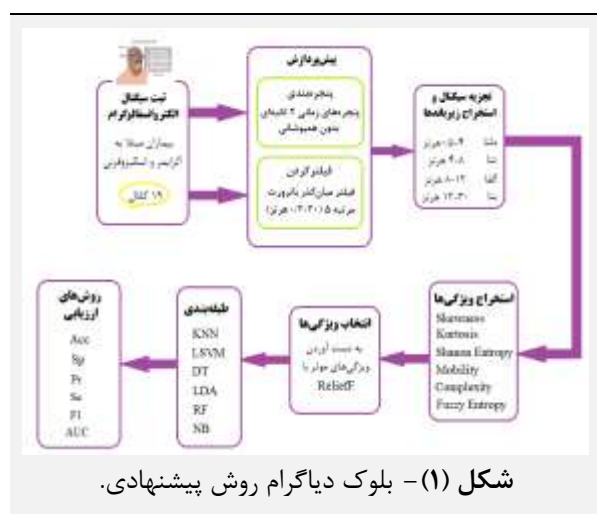
مجموعه داده‌های مربوط به بیماران مبتلا به آلزایمر و اسکیزوفرنی هر دو از پایگاه داده DRYAD که به صورت رایگان قابل دسترس است، انتخاب شده‌اند [۲۳]. این پایگاه داده، شامل سیگنال‌های EEG ثبت شده از ۲۳۰ فرد بوده که ۲۸ نفر از آن‌ها بیماران مبتلا به اختلال افسردگی اساسی^۱ (MDD)، ۴۲ نفر از آن‌ها بیماران مبتلا به SZ، ۶۵ نفر از آن‌ها بیماران دارای اختلالات شناختی که از این میان، ۲۵ نفر از آن‌ها بیماران مبتلا به اختلال شناختی خفیف^۲ (MCI) و ۴۰ نفر از آن‌ها بیماران مبتلا به AD بودند. علاوه بر این، ۹۵ نفر از آن‌ها افراد سالم به عنوان گروه کنترل هستند. ثبت سیگنال‌های EEG در یک محیط بالینی استاندارد و توسط یک تکنسین باتجربه انجام شد. تمامی شرکت‌کنندگانی که در این مطالعه گنجانده شدند، بین ساعت ۸ صبح تا ۱ بعدازظهر تحت ثبت EEG قرار گرفته و بر اساس معیارهای تشخیصی

^۲ Mild Cognitive Impairment

^۱ Major Depressive Disorder

نیز، روش ICA به کار گرفته شده است. همچنین، از ابزار ICLabel در نرم‌افزار EEGLAB برای پردازش داده‌ها و کنترل کیفی کانال‌ها استفاده شده است. در بخش دیگر این پایگاه داده که مربوط به بیماران مبتلا به اسکیزوفرنی است، تحلیل سیگنال‌های EEG بر روی بازه‌های ۳۰ ثانیه‌ای بدون آرتیفکت (از جمله حرکات چشم، فعالیت قلبی و انقباضات عضلانی) انجام شده است. سپس، سیگنال‌های هر کانال با استفاده از یک فیلتر باترورث در باندهای فرکانسی فیزیولوژیکی مورد پردازش قرار گرفته‌اند. علاوه بر این، داده‌ها از نظر نویزی بودن تک‌کانال‌ها بررسی شده و به منظور کاهش نویز ناشی از مرجع‌گیری نامناسب، روش مرجع‌گذاری مجدد به شیوه میانگین‌گیری اعمال شده است. این روش باعث کاهش تأثیر نویز و بهبود کیفیت سیگنال می‌شود.

در پایگاه داده دوم، مجموعه داده‌های مربوط به بیماران مبتلا به آلزایمر و اسکیزوفرنی از نظر نویزی بودن تک‌کانال‌ها، پیش‌تر توسط ارائه‌دهندگان پایگاه داده نیز مورد بررسی قرار گرفته است. برای این منظور، ابتدا یک فیلتر شکافی برای حذف نویز برق شهر استفاده شده است. سپس یک فیلتر بالاگذر ۱ هرتز بر روی داده‌ها اعمال شده تا دریفت‌های آهسته^۲ در سیگنال EEG را حذف کند و بر روی اجزای فرکانس مربوطه برای تجزیه و تحلیل تمرکز کند.



پنجره‌ی ۲ ثانیه‌ای تعادل مناسبی میان دقت تشخیص و کارایی محاسباتی برقرار می‌کند. از این‌رو، این مقدار به‌عنوان طول پنجره‌ی بهینه انتخاب شده و در ادامه مورد استفاده قرار گرفته است. همان‌طور که گفته شد به دلیل متفاوت بودن نرخ نمونه‌برداری سیگنال‌های دو پایگاه داده، یک عمل بازنمونه‌برداری انجام گرفت و نرخ نمونه‌برداری سیگنال‌های پایگاه داده آلزایمر به ۲۵۰ هرتز کاهش یافت، تا با نرخ نمونه‌برداری سیگنال‌های پایگاه داده اسکیزوفرنی یکسان شود. همچنین، برچسب‌زنی داده‌های آلزایمر و اسکیزوفرنی، در این بخش انجام گردید. به طوری که برچسب ۱ برای آلزایمر و برچسب صفر برای اسکیزوفرنی، اختصاص داده شد.

فیلترکردن: پس از پنجره‌بندی، سیگنال‌های EEG از یک فیلتر میان‌گذر باترورث با مرتبه ۵ و فرکانس‌های قطع اول و دوم ۰/۳ تا ۳۰ هرتز، عبور داده شدند.

لازم به توضیح است که داده‌های EEG مورد استفاده در این پژوهش علاوه بر پیش‌پردازش‌های انجام شده در چارچوب مطالعه حاضر، پیش‌تر نیز توسط ارائه‌دهندگان اصلی پایگاه‌های داده، تحت فرایند پیش‌پردازش اولیه قرار گرفته‌اند. این پیش‌پردازش‌ها شامل حذف نویزهای تک‌کاناله، حذف آرتیفکت‌های مرتبط با حرکات چشم و فعالیت‌های عضلانی و بهبود کلی کیفیت سیگنال بوده‌اند. جزئیات این مراحل برای پایگاه داده‌های اول و دوم در ادامه توضیح داده شده است.

در پایگاه داده اول، مجموعه داده‌ی مربوط به بیماران مبتلا به آلزایمر توسط ارائه‌دهندگان پایگاه داده مورد پیش‌پردازش قرار گرفته و نویزهای تک‌کانال‌ها بررسی و حذف شده‌اند. در این راستا، از یک فیلتر میان‌گذر باترورث برای حذف نویزهای محیطی و از یک فیلتر شکافی^۱ برای حذف نویز برق شهر استفاده شده است. برای حذف آرتیفکت‌های ناشی از حرکات چشم و فک

¹ Notch Filter

^۲ Slow Drifts

یک فرآیند گوسی نادیده گرفته شوند، کمک کنند [۲۵]. ویژگی‌های غیرخطی مانند آنتروپی شنون و آنتروپی فازی برای بررسی و تحلیل عملکرد نایستای مغز می‌توانند نتایج ارزشمندی به همراه داشته باشند [۲۶]. ویژگی آنتروپی معیاری از عدم قطعیت یا بی‌نظمی سیگنال بوده و یکی از قوی‌ترین ابزارهای ارزیابی مولفه‌های پویا در سری‌های زمانی است. ویژگی‌های تحرک و پیچیدگی، ابعاد دیگری از رفتار غیرخطی و پویای مغز را به تصویر می‌کشند و در تحلیل سیگنال‌های EEG برای بررسی عملکردهای پیچیده مغزی کاربرد دارند [۲۷]. روابط مربوط به هر کدام از ویژگی‌های مطرح شده، در جدول ۱ بیان شده است. در نهایت می‌توان گفت، هر کانال EEG به ۴ زیرباند مختلف تجزیه شده، سپس از هر یک از زیرباندها ۶ ویژگی استخراج می‌شود. بنابراین، برای هر کانال ۲۴ ویژگی (۶ ویژگی × ۴ زیرباند) و برای هر دو پایگاه داده که شامل ۱۹ کانال می‌باشد، در مجموع (۴۵۶ = ۶ × ۴ × ۱۹) ویژگی از سیگنال‌های EEG استخراج می‌گردد.

۲-۳-۲- تجزیه سیگنال و استخراج زیرباندهای فرکانسی سیگنال EEG
در این بخش، سیگنال‌های EEG که پیش‌تر مطابق با بخش ۲-۳-۱ پیش‌پردازش شده‌اند، به کمک تبدیل فوریه سریع^۱ (FFT) به حوزه فرکانس منتقل شده و طیف فرکانسی آن‌ها محاسبه می‌گردد. در ادامه، زیرباندهای فرکانسی دلتا، تتا، آلفا و بتا از طیف سیگنال استخراج می‌شوند. این زیرباندها به منظور تحلیل دقیق الگوهای فعالیت مغزی بیماران مورد بررسی قرار گرفته و ویژگی‌های مرتبط از آن‌ها استخراج می‌شود. در این مطالعه، طول FFT برابر با تعداد نمونه‌های پنجره ورودی در نظر گرفته شده است، که با نرخ نمونه‌برداری ۲۵۰ هرتز و پنجره‌های ۲ ثانیه‌ای، معادل ۵۰۰ نمونه در هر پنجره محاسبه می‌شود.

۲-۳-۳- استخراج ویژگی‌ها

مرحله استخراج ویژگی با هدف استخراج ویژگی‌های مطلوب از سیگنال EEG خام انجام می‌شود. تحقیقات نشان داده است که ویژگی‌های استخراج شده در حوزه زمان یکی از بهترین روش‌ها برای شناسایی فعالیت‌های ذهنی با استفاده از سیگنال‌های EEG هستند [۲۴].

مجموعه گسترده‌ای از ویژگی‌های آماری و غیرخطی بررسی شدند. در نهایت، ۶ ویژگی شامل چولگی^۲، کشیدگی^۳، آنتروپی شنون^۴، آنتروپی فازی^۵، تحرک^۶ و پیچیدگی^۷ به دلیل عملکرد مناسب و توانایی در تفکیک کلاس‌ها، که در ادامه مورد تحلیل و بررسی قرار گرفته‌اند، از زیرباندهای فرکانسی سیگنال محاسبه و در قالب بردار ویژگی برای ایجاد ماتریس ویژگی استفاده شده است. ویژگی‌های آماری مرتبه بالا مانند چولگی و کشیدگی می‌توانند به شناسایی جزئیاتی از سیگنال که ممکن است هنگام مدل‌سازی آن به‌عنوان

جدول (۱) - روابط ویژگی‌های استخراج شده.

ویژگی‌ها	روابط
چولگی	$SKEW = \frac{1/N \sum_{i=1}^N X_i^3}{\sigma^3}$
کشیدگی	$KURT = \frac{1/N \sum_{i=1}^N X_i^4}{\sigma^4}$
آنتروپی شنون	$H_{Shannon}(x) = - \sum_{x \in X} p(x) \log p(x)$
آنتروپی فازی	$H_{Fuzzy}(m, n, r) = \ln(\Phi^m(n, r)) - \ln(\Phi^{m+1}(n, r))$
تحرک	$Mobility = \sqrt{\frac{var(\dot{x})}{var(x)}}$
پیچیدگی	$Complexity = \frac{Mobility(\dot{x})}{Mobility(x)}$

^۱ Fuzzy Entropy

^۲ Mobility

^۳ Complexity

^۱ Fast Fourier Transform

^۲ Skewness

^۳ Kurtosis

^۴ Shannon Entropy

همچنین، عبارات $\Phi^m(n, r)$ و $\Phi^{m+1}(n, r)$ به صورت زیر قابل محاسبه‌اند:

$$\Phi^m(n, r) = \frac{1}{N-m} \sum_{i=1}^{N-m} \left(\frac{1}{N-m-1} \sum_{j=1, j \neq i}^{N-m} D_{ij}^m \right) \quad (5)$$

$$\Phi^{m+1}(n, r) = \frac{1}{N-m} \sum_{i=1}^{N-m} \left(\frac{1}{N-m-1} \sum_{j=1, j \neq i}^{N-m} D_{ij}^{m+1} \right) \quad (6)$$

۲-۳-۴- انتخاب ویژگی با استفاده از الگوریتم ReliefF تعداد نسبتاً بالای ویژگی‌ها می‌تواند باعث افزایش هزینه‌های محاسباتی و زمان پردازش گردد. بنابراین، برای حفظ و بهبود معیارهای ارزیابی و کاهش زمان انجام محاسبات طبقه‌بندی، باید بهترین ویژگی‌ها انتخاب شوند. الگوریتم ReliefF، برای رتبه‌بندی و امتیازدهی به ویژگی‌ها در مرحله انتخاب ویژگی‌ها اعمال می‌شود. این الگوریتم امتیاز هر ویژگی را بر اساس توانایی آن در تمایز میان نمونه‌های مشابه و نمونه‌های مختلف محاسبه می‌کند. هرچه تفاوت ویژگی‌ها در میان نمونه‌های مشابه کمتر باشد، امتیاز آن ویژگی کاهش می‌یابد، و هرچه تفاوت آن در میان نمونه‌های مختلف بیشتر باشد، امتیاز ویژگی افزایش می‌یابد [۳۰]. در این پژوهش، الگوریتم ReliefF به منظور انتخاب ۲۰ ویژگی برتر به کار گرفته شد، که به طور مؤثری تفاوت‌های موجود میان نمونه‌های مربوط به کلاس‌های آرایمر و اسکیزوفرنی را برجسته ساخت. تحلیل نتایج نشان داد که به کارگیری الگوریتم ReliefF، برای انتخاب ویژگی‌ها، زمانی که ۲۰ ویژگی برتر در فرایند طبقه‌بندی مورد استفاده قرار می‌گیرد، بهترین عملکرد را به عنوان روش پیشنهادی ارائه می‌دهد.

۲-۳-۵- طبقه‌بندی

آخرین مرحله از روش پیشنهادی، طبقه‌بندی داده‌ها است. در این تحقیق، برای طبقه‌بندی و مقایسه عملکرد، از ۶ روش یادگیری ماشین که شامل KNN،

در روابط جدول ۱، x سیگنال فرکانسی، σ انحراف معیار، $p(x)$ احتمال وقوع هر حالت x و \dot{x} مشتق اول سیگنال فرکانسی می‌باشد. همچنین در رابطه آنتروپی فازی، درجه عضویت با استفاده از یک تابع نمایی $(\exp((-d_{ij}^m)^n / r))$ محاسبه می‌شود. برای این کار ابتدا، X_i^m به صورت زیر محاسبه می‌شود [۲۸]:

$$X_i^m = \{u(i), u(i+1), \dots, u(i+m-1)\} - u_0(i) \quad (1)$$

که در آن $\{u(i): 1 \leq i \leq N\}$ نشان‌دهنده سری زمانی سیگنال مورد نظر است، N بیانگر تعداد نمونه‌های سیگنال مورد نظر و $u_0(i)$ به صورت $u_0(i) = \frac{1}{m} \sum_{j=0}^{m-1} u(i+j)$ قابل محاسبه است. همچنین فاصله d_{ij}^m بین X_i^m و X_j^m به صورت زیر

$$d_{ij}^m = d[X_i^m, X_j^m] = \max_{k \in (0, m-1)} |u(i+k) - u_0(i) - (u(j+k) - u_0(j))| \quad (2)$$

محاسبه می‌شود:

D_{ij}^m (درجه شباهت) برای یک n و r مشخص به صورت زیر نوشته می‌شود:

$$D_{ij}^m(n, r) = \varphi(d_{ij}^m, n, r) = \exp(-(d_{ij}^m)^n / r) \quad (3)$$

که در آن $\varphi(d_{ij}^m, n, r)$ تابع فازی است.

در نهایت، ویژگی آنتروپی فازی می‌تواند با استفاده از تفاوت لگاریتم طبیعی $\Phi^m(n, r)$ و $\Phi^{m+1}(n, r)$

$$H_{Fuzzy}(m, n, r) = \ln(\Phi^m(n, r)) - \ln(\Phi^{m+1}(n, r)) \quad (4)$$

محاسبه شود:

که در آن، تعیین مقادیر پارامترهای $m = 2$ و $r = \times$ $std(signal) \cdot 0.2$ به صورت تجربی و بر اساس مطالعات پیشین صورت گرفته است [۲۹].

تمرکز بر باندهای فرکانسی، کانال‌های EEG و ارزیابی آن‌ها از نظر معیار AUC ارائه شده است. هر باند فرکانسی می‌تواند نشان‌دهنده نوع خاصی از فعالیت‌های مغزی باشد. به‌عنوان مثال، باند آلفا که بیشترین سهم را در میان ویژگی‌های انتخاب شده دارد، بیانگر اهمیت ویژه این باند در بررسی عملکرد مغزی بیماران آلزایمری و اسکیزوفرنی است. نتایج مطالعات قبلی نشان می‌دهد که در بیماران آلزایمری، کاهش قدرت باند آلفا اغلب با کاهش حافظه، توجه و توانایی پردازش اطلاعات همراه است [۳۱]. در مقابل، در بیماران اسکیزوفرنی، کاهش انسجام و توان باند آلفا اغلب با نقص در توانایی تنظیم شناختی و عملکردهای اجرایی مرتبط می‌باشد [۳۲]. یافته‌های پژوهش حاضر نیز، با استناد به تحلیل‌های ارائه شده در جدول ۳، این نتایج را تایید کرده و بر همسویی آن‌ها صحنه می‌گذارد. در میان کانال‌های EEG، کانال‌های T3، Fp1، C4، Pz و P4 (به ترتیب واقع در نواحی پیش‌پیشانی، گیجگاهی، مرکزی و آهیانه‌ای مغز) هر کدام با حضور در ۲ ویژگی انتخاب شده نقش برجسته‌ای در تفکیک داده‌ها دارند. این کانال‌ها، به دلیل ارتباط آن‌ها با عملکردهای شناختی و مکانیزم‌های آسیب‌شناختی هر بیماری، اطلاعات ارزشمندی برای تمایز بین دو گروه آلزایمر و اسکیزوفرنی ارائه می‌دهند [۳۳، ۳۴]. در نهایت، الگوریتم Relief، با توجه به توانایی خود در ارزیابی اهمیت ویژگی‌ها بر اساس تأثیر آن‌ها بر تفکیک‌پذیری کلاس‌ها توانسته است ویژگی آنترپی فازی را به‌عنوان یک ویژگی مهم در تحلیل سیگنال‌های EEG انتخاب کند. لازم به ذکر است که این ویژگی در پایگاه داده دوم نیز، به‌عنوان یکی از عوامل مؤثر در تمایز میان گروه‌های مورد بررسی شناسایی شده است.

ماشین بردار پشتیبان با هسته خطی^۱ (L-SVM)، LDA، DT، RF و NB می‌باشد، استفاده شده است. نتایج حاصل از هر یک از روش‌های فوق در بخش نتایج ارائه شده است.

۲-۳-۶- معیارهای ارزیابی

معیارهای کمی که در این تحقیق برای مقایسه و ارزیابی عملکرد روش طبقه‌بندی استفاده شده است، به صورت زیر هستند:

$$Accuracy = \frac{TP + TN}{TP + FN + FP + TN} \quad (7)$$

$$Specificity = \frac{TN}{TN + FP} \quad (8)$$

$$Precision = \frac{TP}{TP + FP} \quad (9)$$

$$Sensitivity = \frac{TP}{TP + FN} \quad (10)$$

$$F1Score = 2 \times \frac{Sensitivity \times Precision}{Sensitivity + Precision} \quad (11)$$

در روابط ۷ تا ۱۱، TP به نمونه‌هایی اشاره دارد که واقعا آلزایمر بوده‌اند و مدل به درستی آن‌ها را به‌عنوان آلزایمر پیش‌بینی کرده است، FP به نمونه‌هایی اشاره دارد که واقعا اسکیزوفرنی بوده‌اند ولی مدل به اشتباه آن‌ها را به‌عنوان آلزایمر پیش‌بینی کرده است، TN به نمونه‌هایی اشاره دارد که واقعا اسکیزوفرنی بوده‌اند و مدل به درستی آن‌ها را به‌عنوان اسکیزوفرنی پیش‌بینی کرده است و FN به نمونه‌هایی اشاره دارد که واقعا آلزایمر بوده‌اند ولی مدل به اشتباه آن‌ها را به‌عنوان اسکیزوفرنی پیش‌بینی کرده است.

۳- یافته‌ها و بحث

در این بخش، به بررسی نتایج حاصل از روش پیشنهادی پرداخته می‌شود. در جدول ۲، نتایج مربوط به اجرای یکی از تکرارهای انتخاب تصادفی افراد از پایگاه داده اول، گزارش شده است. در این جدول، ویژگی‌های انتخاب شده توسط الگوریتم Relief با

^۱ Linear Support Vector Machine

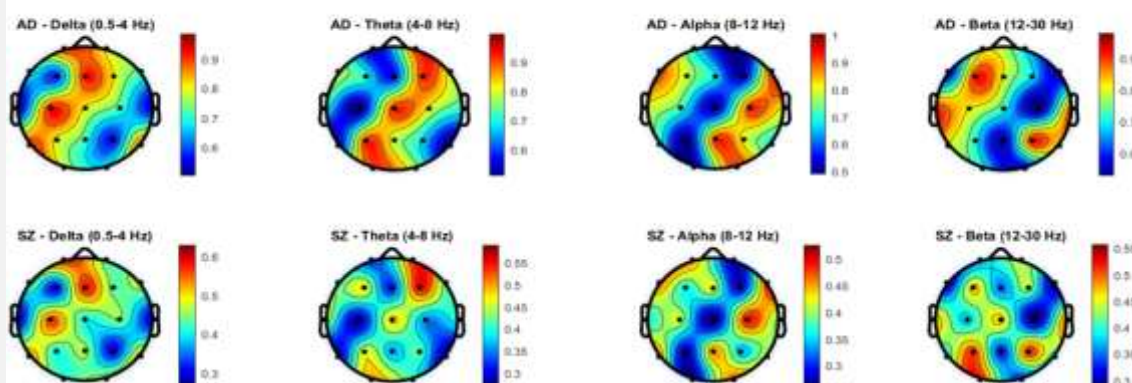
به کمک نرم افزار EEGLAB ترسیم و در شکل ۲ نمایش داده شده است. در این شکل، هر تصویر یک توپوگرافی مغزی را نمایش می‌دهد که مقادیر آنتروپی فازی نرمال‌سازی شده را به‌عنوان میانگین مقادیر مربوط به افراد مختلف، برای دو گروه بیماری در ۱۹ کانال و ۴ زیرباند فرکانسی دلتا، تتا، آلفا و بتا به‌منظور مقایسه الگوهای فعالیت مغزی بیماران مبتلا به آلزایمر و اسکیزوفرنی برجسته می‌کند. این توپوگرافی‌ها، تفاوت‌های قابل‌توجهی را به‌طور بصری در نواحی مختلف مغزی بین دو گروه بیماری نمایان می‌سازند. تحلیل سیگنال‌های EEG با ارائه اطلاعات دقیق از تغییرات فعالیت مغزی در زیرباندهای فرکانسی مختلف، امکان شناسایی الگوهای خاص مرتبط با بیماری‌های آلزایمر و اسکیزوفرنی را فراهم می‌کند. این یافته‌ها با تفاوت‌های اساسی در تصاویر توپوگرافی مغزی بیماران که در این پژوهش بررسی شده‌اند، همخوانی دارد.

در بیماران آلزایمری، افزایش آنتروپی در زیرباندهای فرکانسی پایین (دلتا و تتا) به‌ویژه در نواحی پیشانی و مرکزی قابل مشاهده است. همچنین، کاهش قابل توجهی در زیرباندهای فرکانسی بالا (آلفا و بتا) به‌ویژه

جدول (۲) - ویژگی‌های انتخابی توسط الگوریتم ReliefF حاصل از پایگاه داده اول، با تمرکز بر باندهای فرکانسی، کانال‌های EEG و ارزیابی آن‌ها از نظر معیار AUC.

AUC	نوع ویژگی	کانال	باند	ویژگی
۰/۸۶	آنتروپی فازی	F3	بتا	۱
۰/۸۶	آنتروپی فازی	Fz	بتا	۲
۰/۸۶	آنتروپی فازی	Pz	آلفا	۳
۰/۸۵	آنتروپی فازی	T3	آلفا	۴
۰/۸۵	آنتروپی فازی	O2	آلفا	۵
۰/۸۵	آنتروپی فازی	F8	آلفا	۶
۰/۸۵	آنتروپی فازی	P4	آلفا	۷
۰/۸۵	آنتروپی فازی	P3	تتا	۸
۰/۸۴	آنتروپی فازی	Cz	تتا	۹
۰/۸۴	آنتروپی فازی	F7	آلفا	۱۰
۰/۸۴	آنتروپی فازی	C4	تتا	۱۱
۰/۸۳	آنتروپی فازی	T3	بتا	۱۲
۰/۸۲	آنتروپی فازی	Fp1	تتا	۱۳
۰/۸۲	آنتروپی فازی	C3	بتا	۱۴
۰/۸۱	آنتروپی فازی	T5	تتا	۱۵
۰/۸۱	آنتروپی فازی	Fp1	بتا	۱۶
۰/۸۱	آنتروپی فازی	C4	آلفا	۱۷
۰/۸۱	آنتروپی فازی	Fp2	آلفا	۱۸
۰/۷۳	آنتروپی فازی	Pz	تتا	۱۹
۰/۷۲	آنتروپی فازی	P4	بتا	۲۰

Topographic Maps for Frequency Bands in AD and SZ Groups.



شکل (۲) - توپوگرافی‌های مغزی حاصل از پایگاه داده اول بر اساس ویژگی آنتروپی فازی، به دست آمده از میانگین مقادیر مربوط به افراد مختلف، در زیرباندهای فرکانسی مختلف، برای بیماران مبتلا به AD (ردیف بالا) و SZ (ردیف پایین).

در نواحی پیشانی، مرکزی و آهیانه‌ای مشاهده می‌شود. به‌طور مشابه، در بیماران اسکیزوفرنی، افزایش آنتروپی

در ادامه، توپوگرافی‌های مغزی مربوط به اجرای یکی از تکرارهای انتخاب تصادفی افراد از پایگاه داده اول،

بازاری مؤثر برای درک بهتر مکانیسم‌های زیربنایی این بیماری‌ها و همچنین توسعه شاخص‌های تشخیصی جدید مطرح شود. یافته‌های پژوهش حاضر، نتایج مطالعات پیشین را تایید کرده و نشان‌دهنده هم‌راستایی آن‌ها با یافته‌های گزارش شده در مطالعات [۳۱، ۳۲، ۳۵-۴۰] است.

کلید نتایج ارائه شده در این پژوهش، با استفاده از اعتبارسنجی متقابل ۱۰ لایه در قالب میانگین و

در زیرباندهای فرکانسی پایین به‌ویژه در نواحی پیشانی بارز است. همچنین، کاهش قابل توجهی در زیرباندهای فرکانسی بالا به‌ویژه در نواحی پیشانی و مرکزی مشاهده می‌شود. یافته‌های پژوهش حاضر، ضمن تایید نتایج مطالعات بالینی پیشین [۱۹، ۲۰]، با ارائه جزئیات دقیق‌تر از الگوهای فعالیت مغزی، درک بهتری از تغییرات عملکردی مرتبط با بیماری‌های آلزایمر و اسکیزوفرنی فراهم می‌آورند.

یافته‌های جدول ۳، نشان می‌دهد که تحلیل آنتروپی فازی در زیرباندهای فرکانسی مختلف می‌تواند به‌عنوان

جدول (۳) - تحلیل تغییرات آنتروپی فازی حاصل از پایگاه داده اول، در هر یک از زیرباندهای فرکانسی بین دو گروه بیماری.

بیماران مبتلا به SZ		زیرباند	بیماران مبتلا به AD	
یافته‌های پیشین	یافته‌های پژوهش حاضر		یافته‌های پیشین	یافته‌های پژوهش حاضر
افزایش آنتروپی در این باند، می‌تواند ناشی از اختلال در ارتباطات شبکه‌های عصبی مغز باشد که منجر به بی‌نظمی عملکردی در این نواحی می‌شود [۳۶].	توزیع آنتروپی در این باند به‌طور غیر یکنواخت است. مقادیر آنتروپی فازی در نواحی پیشانی افزایش یافته است.	دلتا	افزایش و تمرکز انرژی در نواحی پیشانی می‌تواند نشان‌دهنده کاهش کنترل عصبی و کندی پردازش اطلاعات باشد که در بیماران آلزایمری رایج است [۳۵].	آنتروپی فازی در نواحی پیشانی، مرکزی و گیجگاهی افزایش یافته است.
افزایش آنتروپی در این باند، می‌تواند نشان‌دهنده اختلال در عملکردهای اجرایی و بی‌نظمی فعالیت قشر پیشانی باشد که مشخصه‌ی بارز این بیماری است [۳۸].	توزیع آنتروپی در این باند، یکنواخت‌تر است. بیشترین افزایش آنتروپی فازی، در نواحی پیشانی دیده می‌شود.	تتا	باند تتا با فعالیت‌های شناختی و حافظه مرتبط است. افزایش آنتروپی در این باند، می‌تواند ناشی از اختلال در حافظه و کاهش عملکردهای شناختی در این بیماران باشد [۳۷].	آنتروپی فازی در نواحی پیشانی، مرکزی و آهیانه‌ای افزایش یافته است.
کاهش آنتروپی در این باند، با نقص در پردازش اطلاعات حسی-حرکتی و اختلالات شناختی ارتباط دارد، که یکی از علائم شایع این بیماری می‌باشد [۳۲].	آنتروپی فازی در نواحی پیشانی، مرکزی و آهیانه‌ای کاهش یافته است.	آلفا	باند آلفا با آرامش و پردازش اطلاعات مرتبط است. کاهش آنتروپی در این زیرباند، معمولاً با اختلالات شناختی و کاهش حافظه در این بیماران مرتبط است [۳۱].	آنتروپی فازی در نواحی پیشانی، مرکزی و آهیانه‌ای کاهش یافته است.
کاهش آنتروپی در این باند، می‌تواند نشان‌دهنده کاهش پیچیدگی و اختلال در هماهنگی شبکه‌های عصبی باشد که در این بیماران بارز است [۴۰].	آنتروپی فازی در نواحی پیشانی و مرکزی کاهش یافته است.	بتا	باند بتا با فرایندهای شناختی سطح بالا مرتبط است. کاهش آنتروپی در این باند، بیانگر ضعف در پردازش شناختی و نقص در توجه در این بیماران می‌باشد [۳۹].	آنتروپی فازی در نواحی پیشانی، مرکزی و آهیانه‌ای کاهش یافته است.

تکرار فرآیند انتخاب تصادفی افراد به مدت ۱۰ بار مورد ارزیابی قرار گرفت و نتایج این بخش در جدول ۴ گزارش گردید. در ادامه، به منظور بررسی پایداری و تعمیم‌پذیری نتایج، از کل مجموعه داده‌ی آرزایمر شامل ۳۶ نفر استفاده شده و نتایج حاصل در جدول ۵ ارائه گردیده است. بر اساس این نتایج، طبقه‌بند RF با دستیابی به میانگین صحت ۹۶/۸٪ و میانگین نمره F1 برابر با ۹۵/۵۶٪، همچنان بهترین عملکرد را در مقایسه با سایر روش‌ها ارائه داده است. در مقابل، طبقه‌بند NB ضعیف‌ترین عملکرد را در میان روش‌های بررسی شده نشان داده است.

نتایج به دست آمده از طبقه‌بندهای مختلف بر روی پایگاه داده دوم، که شامل داده‌های EEG مربوط به ۴۲ بیمار مبتلا به اسکیزوفرنی و ۴۰ بیمار مبتلا به

انحراف معیار برای معیارهای مرحله تست به دست آمده است. جدول ۴ نتایج طبقه‌بندهای مختلف را در پایگاه داده اول نشان می‌دهد، که در آن فرآیند انتخاب تصادفی افراد ۱۰ بار با انتخاب تصادفی ۱۴ نفر از بیماران مبتلا به آرزایمر تکرار شده است. مشاهده می‌شود که طبقه‌بند RF با میانگین صحت ۹۸/۶۱٪ و میانگین نمره F1 برابر با ۹۸/۸۱٪ بهترین عملکرد را در مقایسه با سایر روش‌های مقایسه‌ای ارائه نموده است. از این رو، استفاده از این طبقه‌بند برای تفکیک بیماران مبتلا به آرزایمر و اسکیزوفرنی پیشنهاد می‌گردد. در مقابل طبقه‌بند NB ضعیف‌ترین عملکرد را در بین روش‌های مورد بررسی نشان داده است.

عملکرد طبقه‌بندهای مختلف در پایگاه داده اول، ابتدا با انتخاب تصادفی ۱۴ نفر از بیماران مبتلا به آرزایمر و

جدول (۴) - نتایج عملکرد طبقه‌بندهای مختلف حاصل از پایگاه داده اول، با انتخاب ۲۰ ویژگی برتر توسط الگوریتم ReliefF، در حالت استراحت با چشمان بسته و نرمال‌سازی کل ویژگی‌ها. فرآیند انتخاب تصادفی افراد ۱۰ بار با انتخاب تصادفی ۱۴ نفر از بیماران مبتلا به آرزایمر تکرار شده و نتایج به صورت میانگین \pm انحراف معیار گزارش شده است.

طبقه‌بند	صحت (%)	اختصاصیت (%)	دقت (%)	حساسیت (%)	نمره F1 (%)	AUC
KNN	۹۸/۳۳ \pm ۰/۳	۹۹/۳۵ \pm ۰/۳۳	۹۹/۵۲ \pm ۰/۲۴	۹۷/۶ \pm ۰/۴۷	۹۸/۵۵ \pm ۰/۲۶	۰/۹۹۴ \pm ۰/۰۰۲
L-SVM	۹۶/۴۴ \pm ۰/۴۴	۹۴/۹۸ \pm ۰/۸۷	۹۶/۳۱ \pm ۰/۶	۹۷/۶۵ \pm ۰/۵۲	۹۶/۹۷ \pm ۰/۳۷	۰/۹۹۱ \pm ۰/۰۰۲
DT	۹۵/۸۴ \pm ۰/۵۱	۹۴/۲۹ \pm ۱/۱۴	۹۵/۹۶ \pm ۰/۸۳	۹۶/۹۵ \pm ۰/۶۵	۹۶/۴۵ \pm ۰/۴۵	۰/۹۸ \pm ۰/۰۰۵
LDA	۹۷/۲۱ \pm ۰/۴۳	۹۴/۱۲ \pm ۰/۹۷	۹۵/۹۵ \pm ۰/۷۲	۹۹/۴۴ \pm ۰/۲۶	۹۷/۶۵ \pm ۰/۳۷	۰/۹۹۶ \pm ۰/۰۰۲
RF	۹۸/۶۱ \pm ۰/۳	۹۸/۰۵ \pm ۰/۶	۹۸/۶۱ \pm ۰/۴۴	۹۹ \pm ۰/۳۵	۹۸/۸۱ \pm ۰/۲۷	۰/۹۹۸ \pm ۰/۰۰۰۶
NB	۸۷/۸۴ \pm ۰/۸۷	۹۳/۰۵ \pm ۰/۹۷	۹۴/۳ \pm ۰/۷۵	۸۴/۱۱ \pm ۱/۳۸	۸۸/۸۵ \pm ۰/۸۲	۰/۹۷ \pm ۰/۰۰۴

جدول (۵) - نتایج عملکرد طبقه‌بندهای مختلف حاصل از پایگاه داده اول، با انتخاب ۲۰ ویژگی برتر توسط الگوریتم ReliefF، در حالت استراحت با چشمان بسته و نرمال‌سازی کل ویژگی‌ها. این نتایج با استفاده از کل مجموعه داده‌ی آرزایمر شامل ۳۶ نفر، به دست آمده است.

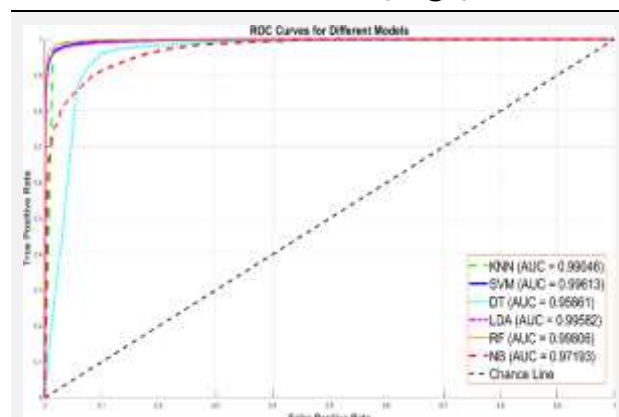
طبقه‌بند	صحت (%)	اختصاصیت (%)	دقت (%)	حساسیت (%)	نمره F1 (%)	AUC
KNN	۹۴/۱۸ \pm ۰/۴۱	۹۹/۶۹ \pm ۰/۱۲	۹۹/۳۲ \pm ۰/۲۷	۸۴/۰۴ \pm ۱/۰۷	۹۱/۰۴ \pm ۰/۶۳	۰/۹۶ \pm ۰/۰۰۴
L-SVM	۹۱/۶۳ \pm ۰/۵۲	۹۴/۴۷ \pm ۰/۵۲	۸۹/۴۸ \pm ۰/۸۲	۸۶/۴ \pm ۱/۳۵	۸۷/۹ \pm ۰/۷۴	۰/۹۸ \pm ۰/۰۰۳
DT	۹۳/۰۳ \pm ۰/۵۳	۹۴/۳۸ \pm ۱/۰۵	۸۹/۷۸ \pm ۱/۷۸	۹۰/۵۵ \pm ۲/۱۵	۹۰/۱۳ \pm ۰/۷۶	۰/۹۷ \pm ۰/۰۰۴
LDA	۹۴/۶۱ \pm ۰/۷۴	۹۲/۲۱ \pm ۱/۰۲	۸۷/۳۶ \pm ۱/۵۴	۹۹/۰۱ \pm ۰/۳۵	۹۲/۸۲ \pm ۰/۹۸	۰/۹۹۳ \pm ۰/۰۰۱
RF	۹۶/۸ \pm ۰/۳۳	۹۶/۳ \pm ۰/۵۱	۹۳/۵ \pm ۰/۸۲	۹۷/۷۱ \pm ۰/۳۷	۹۵/۵۶ \pm ۰/۴۴	۰/۹۹۶ \pm ۰/۰۰۰۶
NB	۸۹/۶ \pm ۰/۶۴	۹۳/۵۱ \pm ۰/۶۵	۸۷/۳۲ \pm ۱/۳۸	۸۲/۴ \pm ۱/۵۴	۸۴/۷۸ \pm ۱/۱۲	۰/۹۷ \pm ۰/۰۰۳

طبقه‌بند مختلف، بر اساس ۲۰ ویژگی انتخاب شده توسط الگوریتم ReliefF رسم شده است. محور افقی نرخ مثبت کاذب (FPR) و محور عمودی نرخ مثبت صحیح (TPR) یا حساسیت را نشان می‌دهد. مشاهده می‌شود که طبقه‌بند RF، با میانگین AUC برابر با ۰/۹۹۸، بهترین عملکرد را در مقایسه با سایر الگوریتم‌ها نشان داده است. در مجموع، تمامی الگوریتم‌ها، میانگین AUC بالای ۰/۹۵ دارند که نشان‌دهنده عملکرد مناسب تمامی مدل‌ها در طبقه‌بندی داده‌ها است، اما اختلاف بین DT و دیگر الگوریتم‌ها بیشتر به چشم می‌خورد.

۳-۱- مقایسه روش پیشنهادی با نتایج تحقیقات پیشین

گوکر و توسون در سال ۲۰۲۳، با استفاده از سیگنال‌های EEG و ترکیب FWHT با رویکرد یادگیری عمیق مبتنی بر الگوریتم BiLSTM به صحت کلی ۹۸/۳۸٪ در طبقه‌بندی بیماری‌های آلزایمر و اسکیزوفرنی دست یافتند [۱۸]. روش پیشنهادی پژوهش حاضر، با وجود بهره‌گیری از یک الگوریتم ساده‌تر، عملکردی رقابتی ارائه داده است. این روش توانسته الگوریتم‌های پیچیده‌ای همچون BiLSTM را به چالش بکشد و نتایج قابل مقایسه با نشان‌دهنده کارآمدی و قابلیت روش پیشنهادی در طبقه‌بندی بیماری‌های آلزایمر و اسکیزوفرنی است.

آلزایمر است، در جدول ۶ ارائه شده است. همان‌گونه که در جدول مشاهده می‌شود، طبقه‌بند RF با دستیابی به میانگین صحت ۸۸٪/۱۱ و میانگین نمره F1 برابر با ۸۵٪/۸۴، بهترین عملکرد را در مقایسه با سایر روش‌های مورد بررسی نشان داده است. این نتایج بیانگر توانمندی بالای این طبقه‌بند در افتراق مؤثر بین بیماران مبتلا به آلزایمر و اسکیزوفرنی می‌باشد. در مقابل، طبقه‌بند NB ضعیف‌ترین عملکرد را با میانگین صحت ۶۰٪/۶۷ و میانگین نمره F1 برابر با ۴۱٪/۹۶ ارائه کرده است. نتایج به دست آمده از پایگاه داده دوم، نشان می‌دهد که مدل پیشنهادی از صحت قابل قبول، پایداری مناسب و قابلیت تعمیم‌پذیری بالا برای تفکیک این دو اختلال عصبی-روانشناختی برخوردار است، که می‌تواند در کاربردهای تشخیصی مبتنی بر EEG مفید واقع شود.



شکل (۳) - نمودار ROC برای طبقه‌بندهای KNN، SVM، DT، LDA، RF و NB

نمودار شکل ۳، منحنی ROC مربوط به اجرای یکی از تکرارهای انتخاب تصادفی افراد از پایگاه داده اول را نشان می‌دهد. این نمودار، برای ارزیابی عملکرد ۶ مدل

جدول (۶) - نتایج عملکرد طبقه‌بندهای مختلف حاصل از پایگاه داده دوم، با انتخاب ۲۰ ویژگی برتر توسط الگوریتم ReliefF، در حالت استراحت با چشمان بسته و باز و نرمال‌سازی کل ویژگی‌ها.

طبقه‌بند	صحت (%)	اختصاصیت (%)	دقت (%)	حساسیت (%)	نمره F1 (%)	AUC
KNN	۸۷/۳۱ ± ۰/۵۶	۸۸/۸۷ ± ۰/۵۱	۸۴/۶۸ ± ۰/۷۳	۸۵/۲۱ ± ۰/۸۵	۸۴/۹۴ ± ۰/۶۸	۰/۹۲ ± ۰/۰۰۵
L-SVM	۶۹/۵۵ ± ۰/۵۸	۸۴/۳۷ ± ۰/۹۷	۶۹/۳ ± ۱/۸۷	۴۹/۵ ± ۰/۸۷	۵۷/۷۲ ± ۱/۰۵	۰/۷۲ ± ۰/۰۰۹
DT	۶۹/۲۴ ± ۰/۷۹	۶۷/۱۵ ± ۳	۶۱/۸۷ ± ۱/۴۲	۷۲/۱ ± ۳/۴۲	۶۶/۵۲ ± ۱/۰۶	۰/۷۳ ± ۰/۰۰۹
LDA	۷۵/۰۹ ± ۰/۷۸	۷۷/۵۱ ± ۱/۶۲	۷۰/۰۴ ± ۱/۶	۷۱/۸۱ ± ۰/۸۶	۷۰/۹ ± ۰/۸۶	۰/۸۱ ± ۰/۰۰۵
RF	۸۸/۱۱ ± ۰/۴۹	۸۹/۷۶ ± ۰/۸۱	۸۵/۸ ± ۱	۸۵/۸۹ ± ۱/۱۲	۸۵/۸۴ ± ۰/۶۲	۰/۹۴ ± ۰/۰۰۳
NB	۶۰/۶۷ ± ۰/۶۷	۴۱/۹۶ ± ۰/۹۶	۴۱/۹۶ ± ۰/۹۶	۴۱/۹۶ ± ۰/۹۶	۴۱/۹۶ ± ۰/۹۶	۰/۴۱ ± ۰/۰۰۳

استفاده قرار گیرد. این یافته‌ها بیانگر کارایی بالای روش پیشنهادی در ارائه ابزاری دقیق، غیرتهاجمی و مقرون‌به‌صرفه برای کمک به فرآیند تشخیص در محیط‌های بالینی هستند و می‌توانند مبنایی برای توسعه سامانه‌های هوشمند تشخیص در آینده فراهم سازند. همچنین، با انتخاب تصادفی ۱۴ نفر از بیماران مبتلا به آلزایمر از پایگاه داده اول و تکرار فرآیند انتخاب تصادفی افراد به مدت ۱۰ بار، مشخص شد که طبقه‌بند RF با دستیابی به میانگین صحت 98.61% و میانگین نمره F1 برابر با 98.81% ، بهترین عملکرد را در بین سایر طبقه‌بندهای مورد استفاده ارائه داده است. علاوه بر این، ارزیابی بر روی پایگاه داده دوم نیز انجام شد که در آن طبقه‌بند RF با دستیابی به میانگین صحت 88.11% و میانگین نمره F1 برابر با 85.84% توانست کارایی قابل قبولی در تفکیک بیماران مبتلا به آلزایمر و اسکیزوفرنی نشان دهد. در این پژوهش، نتایج صرفاً مبتنی بر داده‌های ثبت شده از افراد در حالت استراحت با چشمان بسته در پایگاه داده اول نیست، بلکه تحلیل‌ها بر روی پایگاه داده دوم نیز انجام شده است که در آن، سیگنال‌های EEG افراد در هر دو وضعیت استراحت با چشمان باز و بسته ثبت گردیده‌اند. در این راستا، داده‌های مربوط به ۲۸ نفر (۱۴ فرد مبتلا به آلزایمر و ۱۴ فرد مبتلا به اسکیزوفرنی) از پایگاه داده اول، و داده‌های مربوط به ۸۲ نفر (۴۰ فرد مبتلا به آلزایمر و ۴۲ فرد مبتلا به اسکیزوفرنی) از پایگاه داده دوم، به‌منظور تکمیل ارزیابی و بهبود عملکرد مدل پیشنهادی استفاده شده است. با این حال، در مطالعات بعدی می‌توان نتایج به دست آمده از روش پیشنهادی را به سایر بیماری‌های عصبی-روانشناختی مانند استرس، اضطراب، افسردگی و غیره تعمیم داد.

۵- مراجع

- [۱] Wróblewski H, Chojeła D, Zimna A, Zygmunt E, Wróblewska K. Is schizophrenia just a mental illness? - The correlation between

جدول (۷) - مقایسه عملکرد روش پیشنهادی با تحقیقات پیشین با استفاده از معیار صحت.

صحت (%)	ویژگی	روش	سال	محققان
۹۸/۳۸	FWHT	یادگیری عمیق BiLSTM	۲۰۲۳	گوکر و توسون
پایگاه داده ۱ = ۹۸/۶۱ پایگاه داده ۲ = ۸۸/۱۱	FFT	یادگیری ماشین RF	۲۰۲۵	روش پیشنهادی

۴- جمع‌بندی

در این تحقیق، روشی کارآمد و نوآورانه برای طبقه‌بندی بیماری‌های آلزایمر و اسکیزوفرنی مبتنی بر تحلیل سیگنال‌های EEG و بهره‌گیری از الگوریتم‌های یادگیری ماشین ارائه شده است. نوآوری اصلی پژوهش حاضر، در تمرکز بر تشخیص افتراقی میان بیماری‌های آلزایمر و اسکیزوفرنی با وجود همپوشانی در الگوهای سیگنال EEG و شباهت‌های نوروفیزیولوژیکی قابل توجه نهفته است، به‌گونه‌ای که با بهره‌گیری همزمان از ویژگی‌های غیرخطی و تحلیل‌های حوزه فرکانس، رویکردی جامع و یکپارچه برای تمایز دقیق و مؤثر میان این دو بیماری ارائه شده است. برخلاف بسیاری از مطالعات پیشین که عمدتاً بر تشخیص یک بیماری از گروه کنترل سالم تمرکز داشته‌اند، این تحقیق به‌طور مشخص بر تفکیک‌پذیری مستقیم میان این دو اختلال عصبی-روانشناختی متمرکز بوده است، مسأله‌ای که از نظر بالینی و مفهومی دارای اهمیت ویژه‌ای است. همچنین، نتایج این تحقیق نشان داد که ویژگی آنروپی فازی به‌طور معناداری عملکرد برتری نسبت به سایر ویژگی‌ها داشته و می‌تواند به‌عنوان یک شاخص کلیدی در تشخیص بیماری‌های آلزایمر و اسکیزوفرنی مورد



- 2023;2011-23.
- [۱۲] Yao A, Goldsztein G, Renaud A. Diagnosing Alzheimer's Disease and Frontotemporal Dementia Using Machine Learning and EEG. *J Student Res.* 2023;12(4).
- [۱۳] Lal U, Chikkankod AV, Longo L. A Comparative Study on Feature Extraction Techniques for the Discrimination of Frontotemporal Dementia and Alzheimer's Disease with Electroencephalography in Resting-State Adults. *Brain Sci.* 2024;14(4):335.
- [۱۴] Nattudurai N. Classifying Schizophrenia Disorder through EEG Signal Analysis and Machine Learning. *IEEE MIT Undergrad Res Technol Conf URTC 2023 - Proc.* 2023;1-4.
- [۱۵] Qayyum T, Trabelsi Z, Tariq A, Belkacem AN, Serhani MA. Diagnosis of Schizophrenia from EEG signals Using ML Algorithms. In: 2023 IEEE International Conference on Bioinformatics and Biomedicine (BIBM). IEEE; 2023. p. 2564-70.
- [۱۶] T. K, P. S, Kumar A. Detecting Schizophrenia from Healthy control using Machine Learning and EEG Signals. In: 2024 International Conference on Expert Clouds and Applications (ICOECA). 2024. p. 434-42.
- [۱۷] Elfarsy A, El-Metwally S. Leveraging EEG Signals and Machine Learning for Schizophrenia Classification. In: 2024 6th International Conference on Computing and Informatics (ICCI). IEEE; 2024. p. 23-7.
- [۱۸] Göker H, Tosun M. Fast Walsh-Hadamard transform and deep learning approach for diagnosing psychiatric diseases from electroencephalography (EEG) signals. *Neural Comput Appl [Internet].* 2023;35(32):23617-30. Available from: <https://doi.org/10.1007/s00521-023-08971-6>
- [۱۹] Bhattacharya B Sen, Coyle D, Maguire LP. Alpha and Theta Rhythm Abnormality in Alzheimer's Disease: A Study Using a Computational Model BT - From Brains to Systems. In: Hernández C, Sanz R, Gómez-Ramirez J, Smith LS, Hussain A, Chella A, et al., editors. New York, NY: Springer New York; 2011. p. 57-73.
- [۲۰] Danjou P, Viardot G, Maurice D, Garcés P, Wams EJ, Phillips KG, et al. Electrophysiological assessment methodology of sensory processing dysfunction in schizophrenia and dementia of the Alzheimer type. *Neurosci Biobehav Rev [Internet].* 2019;97:70-84. Available from: <https://www.sciencedirect.com/science/article/pii/S0149763417308643>
- [۲۱] Olejarczyk E, Jernajczyk W. Graph-based analysis of brain connectivity in schizophrenia. *PLoS One.* 2017;12(11):1-28.
- schizophrenia and cancer. *J Educ Heal Sport.* 2022;12(5):184-92.
- [۲] Gauthier S, Rosa-Neto P, Morais JA, Webster C. World Alzheimer Report 2021: Journey through the diagnosis of dementia. *Alzheimer's Dis Int.* 2021;2022:30.
- [۳] Sołtys A, Tyburski E. Predictors of mental health problems in formal and informal caregivers of patients with Alzheimer's disease. *BMC Psychiatry [Internet].* 2020;20(1):435. Available from: <https://doi.org/10.1186/s12888-020-02822-7>
- [۴] Grover S, Avasthi A. Clinical Practice Guidelines for the Management of Schizophrenia in Children and Adolescents. *Indian J Psychiatry [Internet].* 2019;61(Suppl 2). Available from: https://journals.lww.com/indianjpsychiatry/fulltext/2019/61002/clinical_practice_guidelines_for_the_management_of.15.aspx
- [۵] McCormick L, Bodla AP, Rubin RT. Very early onset dementias: Importance of differentiating from schizophrenia spectrum disorders. *PLOS Ment Heal [Internet].* 2024;1(3):e0000107. Available from: <http://dx.doi.org/10.1371/journal.pmen.0000107>
- [۶] White KE, Cummings JL. Schizophrenia and Alzheimer's disease: Clinical and pathophysiologic analogies. *Compr Psychiatry.* 1996;37(3):188-95.
- [۷] Ohi K, Fujikane D, Shioiri T. Genetic overlap between schizophrenia spectrum disorders and Alzheimer's disease: Current evidence and future directions - An integrative review. *Neurosci Biobehav Rev [Internet].* 2024;167:105900. Available from: <https://www.sciencedirect.com/science/article/pii/S0149763424003695>
- [۸] Kochunov P, Zavaliangos-Petropulu A, Jahanshad N, Thompson PM, Ryan MC, Chiappelli J, et al. A White Matter Connection of Schizophrenia and Alzheimer's Disease. *Schizophr Bull.* 2021;47(1):197-206.
- [۹] Göker H. Automatic detection of migraine disease from EEG signals using bidirectional long-short term memory deep learning model. *Signal, Image Video Process [Internet].* 2023;17(4):1255-63. Available from: <https://doi.org/10.1007/s11760-022-02333-w>
- [۱۰] Miltiadous A, Tzimourta KD, Giannakeas N, Tsiouras MG, Afrantou T, Ioannidis P, et al. Alzheimer's disease and frontotemporal dementia: A robust classification method of eeg signals and a comparison of validation methods. *Diagnostics.* 2021;11(8).
- [۱۱] Mootoo XS, Fours A, Dinesh C, Ashkani M, Kiss A, Faltyn M. Detecting Alzheimer Disease in EEG Data with Machine Learning and the Graph Discrete Fourier Transform. *medRxiv.*



- [Internet]. 2011;70(12):1134–42. Available from: <http://dx.doi.org/10.1016/j.biopsych.2011.06.029>
- [۳۳] Lin G, Wu Z, Chen B, Zhang M, Wang Q, Liu M, et al. Altered Microstate Dynamics and Spatial Complexity in Late-Life Schizophrenia. *Front Psychiatry*. 2022;13(June):1–9.
- [۳۴] Movahed RA, Rezaeian M. Automatic diagnosis of mild cognitive impairment based on spectral, functional connectivity, and nonlinear EEG-Based features. *Comput Math Methods Med*. 2022;2022(1):2014001.
- [۳۵] Sankari Z, Adeli H, Adeli A. Intrahemispheric, interhemispheric, and distal EEG coherence in Alzheimer's disease. *Clin Neurophysiol*. 2011;122(5):897–906.
- [۳۶] Spironelli C, Angrilli A, Calogero A, Stegagno L. Delta EEG Band as a Marker of Left Hypofrontality for Language in Schizophrenia Patients. *Schizophr Bull* [Internet]. 2011 Jul 1;37(4):757–67. Available from: <https://doi.org/10.1093/schbul/sbp145>
- [۳۷] Yan Y, Zhao A, Ying W, Qiu Y, Ding Y, Wang Y, et al. Functional connectivity alterations based on the weighted phase lag index: An exploratory electroencephalography study on Alzheimer's Disease. *Curr Alzheimer Res*. 2021;18(6):513–22.
- [۳۸] Iglesias-Tejedor M, Díez Á, Llorca-Bofi V, Núñez P, Castaño-Díaz C, Bote B, et al. Relation between EEG resting-state power and modulation of P300 task-related activity in theta band in schizophrenia. *Prog Neuro-Psychopharmacology Biol Psychiatry* [Internet]. 2022;116:110541. Available from: <https://www.sciencedirect.com/science/article/pii/S0278584622000331>
- [۳۹] König T, Prichep L, Dierks T, Hubl D, Wahlund LO, John ER, et al. Decreased EEG synchronization in Alzheimer's disease and mild cognitive impairment. *Neurobiol Aging*. 2005;26(2):165–71.
- [۴۰] Yeragani VK, Cashmere D, Miewald J, Tancer M, Keshavan MS. Decreased coherence in higher frequency ranges (beta and gamma) between central and frontal EEG in patients with schizophrenia: A preliminary report. *Psychiatry Res* [Internet]. 2006;141(1):53–60. Available from: <https://www.sciencedirect.com/science/article/pii/S0165178105002222>
- [۲۲] Miltiadous A, Tzimourta KD, Afrantou T, Ioannidis P, Grigoriadis N, Tsalikakis DG, et al. A Dataset of Scalp EEG Recordings of Alzheimer's Disease, Frontotemporal Dementia and Healthy Subjects from Routine EEG. *Data*. 2023;8(6):1–10.
- [۲۳] Shor O, Glik A, Yaniv-Rosenfeld A, Valevski A, Weizman A, Khrennikov A, et al. EEG p-adic quantum potential accurately identifies depression, schizophrenia and cognitive decline. *PLoS One* [Internet]. 2021;16(8 August):1–19. Available from: <http://dx.doi.org/10.1371/journal.pone.0255529>
- [۲۴] Nanthini K, Sivabalaselvamani D, Kumar MCM, Kaviya R. Comprehensive EEG Signal Feature Extraction for Neurological Disorder Diagnosis: Focus on Alzheimer's, Parkinson's, and Seizure Disorders. *Int Res J Multidiscip Technovation*. 2024;6(5):80–93.
- [۲۵] Khomami SA, Shamekhi S. Persian sign language recognition using IMU and surface EMG sensors. *Measurement*. 2021;168:108471.
- [۲۶] Rezaeezadeh M, Shamekhi S, Shamsi M. Attention Deficit Hyperactivity Disorder Diagnosis using non-linear univariate and multivariate EEG measurements: a preliminary study. *Phys Eng Sci Med*. 2020;43(2):577–92.
- [۲۷] Hamida ST Ben, Ahmed B, Penzel T. A novel insomnia identification method based on Hjorth parameters. 2015 IEEE Int Symp Signal Process Inf Technol ISSPIT 2015. 2016;(November):548–52.
- [۲۸] Zarei A, Asl BM. Automatic detection of obstructive sleep apnea using wavelet transform and entropy-based features from single-lead ECG signal. *IEEE J Biomed Heal informatics*. 2018;23(3):1011–21.
- [۲۹] Xiang J, Tian C, Niu Y, Yan T, Li D, Cao R, et al. Abnormal Entropy Modulation of the EEG Signal in Patients With Schizophrenia During the Auditory Paired-Stimulus Paradigm. 2019;13(February):1–11.
- [۳۰] Kononenko I, Simec E, Robnik, Sikonja M. Overcoming the Myopia of Inductive Learning Algorithms with {RELIEFF}. *Appl Intell*. 1995;10:39–55.
- [۳۱] Han Y, Wang K, Jia J, Wu W. Changes of EEG spectra and functional connectivity during an object-location memory task in Alzheimer's disease. *Front Behav Neurosci*. 2017;11(May):1–12.
- [۳۲] Hinkley LBN, Vinogradov S, Guggisberg AG, Fisher M, Findlay AM, Nagarajan SS. Clinical symptoms and alpha band resting-state functional connectivity imaging in patients with schizophrenia: Implications for novel approaches to treatment. *Biol Psychiatry*