

Diagnostic Techniques and Artificial Intelligence for Multiple Sclerosis Identification

Asma Raisi¹ , Mahsa Nasiri¹ , Hajar Danesh^{1*} 

¹ Dept of Electrical and Biomedical Engineering, Faculty of Engineering and Technology, Shahid Ashrafi Esfahani University, Isfahan, Iran

Article Info

Article type:
Review article

Article History:

Received: Jan. 19, 2025
Received in revised form:
Mar. 09, 2025
Accepted: Oct. 26, 2025
Published Online: Apr. 29, 2025

*** Correspondence to:**

Hajar Danesh
Dept of Electrical and
Biomedical Engineering,
Faculty of Engineering and
Technology, Shahid Ashrafi
Esfahani University, Isfahan,
Iran

Email:
hajardanesh@yahoo.com

ABSTRACT

Introduction: Multiple sclerosis is a chronic autoimmune disorder causing the degeneration of the myelin sheath, affecting nerve signal transmission. Symptoms include muscle weakness, visual disturbances, balance impairments, and incoordination. Early diagnosis is crucial for effective disease management and preventing irreversible neurological damage. This research was designed to explore diagnostic methods and introduces machine learning for automated data analysis and faster diagnosis.

Materials & Methods: This study reviewed diagnostic methods for multiple sclerosis (MS), including electroencephalography (EEG), electromyography (EMG), clinical data, cerebrospinal fluid analysis, magnetic resonance imaging (MRI), and optical coherence tomography (OCT). Artificial intelligence (AI)-based approaches were also introduced to enable automated data analysis and expedite disease diagnosis. A novel platform-based method was proposed as an exclusive approach for automated detection through the integration of established diagnostic techniques.

Results: Findings indicated that magnetic resonance imaging (MRI) demonstrates high accuracy in the diagnosis of multiple sclerosis. Based on the average performance of artificial intelligence-based methods across the primary diagnostic modalities, accuracies of 90%, 75%, 80%, 90%, and 95% were achieved for MRI, optical coherence tomography (OCT), electroencephalography (EEG), electromyography (EMG), and cerebrospinal fluid analysis, respectively. The proposed platform integrates these modalities to enhance both the speed and accuracy of disease detection.

Conclusion: The utilization of advanced diagnostic techniques, coupled with the integration of multiple methodologies, markedly improves the early detection and therapeutic intervention of multiple sclerosis, thereby reducing the associated complications of the disease.

Keywords: Multiple sclerosis, MRI, OCT, EEG, Artificial intelligence

Cite this paper: Raisi A, Nasiri M, Danesh H. Diagnostic Techniques and Artificial Intelligence for Multiple Sclerosis Identification. *Journal of Ilam University of Medical Sciences*. 2025;33(3):113-148.

Introduction

Multiple sclerosis (MS) is a chronic, inflammatory, and neurodegenerative disease characterized by demyelination and axonal damage in the central nervous system (CNS), ultimately leading to progressive neurological disabilities (1). Common clinical manifestations include fatigue, muscle weakness, spasticity, visual disturbances, dizziness, and sensory impairments (1). MS affects approximately 2.3 million individuals globally, with the typical onset occurring between the ages of 20 and 40 (2). Historically, the diagnosis of MS was based

on clinical evaluations and computed tomography (CT) imaging, both of which had significant limitations in sensitivity and specificity (3). Since the 1980s, magnetic resonance imaging (MRI) has become the gold standard for detecting CNS lesions and improving diagnostic accuracy (3). Current diagnostic protocols integrate clinical assessment with advanced tools such as MRI, electroencephalography (EEG), and cerebrospinal fluid (CSF) analysis, the latter of which can provide evidence of CNS inflammation (4). Despite advancements, previous studies have encountered challenges



including limited diagnostic accuracy and inadequate integration of diverse data sources (4). In recent years, artificial intelligence (AI) and machine learning (ML) technologies have shown promise in overcoming these obstacles by enhancing data analysis precision, supporting early detection, and enabling automation in the diagnostic process (5). This research was designed to explore diagnostic methods and introduces machine learning for automated data analysis and faster diagnosis.

Methods

This study explores various methods for diagnosing multiple sclerosis (MS) using artificial intelligence (AI) and deep learning algorithms. The methods include MRI imaging for brain and spinal lesions, optical coherence tomography (OCT) for analyzing the optic nerve, and cerebrospinal fluid (CSF) testing to identify oligoclonal bands as markers of inflammation in the central nervous system (CNS). Electroencephalography (EEG) is used to evaluate brain electrical activity, while electromyography (EMG) assesses neuromuscular function. Machine learning and deep learning subfields are investigated for processing extracted data. An integrated platform combining traditional diagnostic tools with advanced AI and machine learning techniques is proposed. MRI-based diagnosis is recognized as a key tool for identifying and monitoring MS by detecting lesions in the brain and spinal cord. AI enhances the accuracy and speed of MRI analysis through algorithms such as gradient boosting, support vector machines (SVM), and convolutional neural networks (CNNs). CSF testing is another critical method for MS diagnosis and monitoring, enabling the detection of specific biomarkers like oligoclonal bands and neurofilament light chain (NFL). McDonald criteria, particularly serum cNfL, have proven effective in identifying patients at high risk. EEG signal analysis reveals significant differences between MS patients and healthy individuals, with abnormalities detected in 20-60% of patients. AI-based techniques, such as CATBoost and multifractal analysis, aid in identifying abnormal patterns and enhancing prediction accuracy. The proposed platform supports real-time data collection and processing from multiple sources and serves as a clinical decision-support infrastructure. Leveraging the Internet of Things (IoT), the patient's condition is continuously monitored,

enabling early detection of anomalies. This multidimensional approach supports healthcare professionals in complex decision-making and contributes to a more promising outlook for patients.

Results

The methods reviewed for MS diagnosis demonstrate significant advancements across various techniques. The average accuracy of the approaches studied is as follows: MRI: highest accuracy at 95%, capable of detecting brain and spinal lesions and tracking disease progression. CSF testing: 90% accuracy in identifying CNS inflammation markers. OCT: 90% accuracy with the use of AI models and CNNs. EEG: 80% accuracy, improved by multifractal analysis. EMG: lowest accuracy at 75%, used for evaluating neuromuscular function. MRI remains the most accurate and reliable method. Furthermore, integrating advanced MRI techniques with AI algorithms and biological markers can improve diagnostic precision and enhance patient experience. However, challenges such as high costs, the need for large training datasets, and the lack of standardized data collection protocols persist. These issues may hinder the development and implementation of these methods and require effective solutions.

Conclusion

This study has explored high-accuracy diagnostic approaches for MS using a range of techniques, including machine learning, deep learning, and AI. Results indicate that MRI-based methods are the most effective, and their integration with techniques such as EEG and CSF testing provides clinicians with a comprehensive understanding of the disease. The application of AI algorithms, particularly CNNs, significantly improves diagnostic accuracy. Nevertheless, challenges remain, including the need for high-quality data, privacy concerns, and the necessity for powerful hardware. It is hoped that through the integration and personalization of methods, patients' quality of life will improve and disease-related damage will be reduced. The concurrent use of multiple methods and AI algorithms can shorten diagnostic time and increase precision. This comprehensive approach may enhance clinical workflows and improve healthcare services for MS patients.

Authors' Contribution

Conceptualization, Methodology: Validation, Formal Analysis, Investigation, Resources, Software, Data Curation, Writing—Original Draft Preparation, Writing—Review & Editing, Visualization, Supervision, Project Administration: AR, MN, HD.

Ethical Statement

Due to the lack of animal testing, there was no need to obtain an ethics code. The authors avoided data fabrication, falsification, plagiarism, and misconduct.

Conflicts of Interest

The authors declare no conflict of interest.

Funding

Authors declare that no funds, grants, or other support were received during the preparation of this manuscript.

Acknowledgment

The authors thank the all of participants and persons who help in this project.

مروری بر فنون تشخیصی و هوش مصنوعی برای شناسایی مالتیپل اسکلروزیس

اسماء رئیسی^۱, مهسا نصیری^{۱*}, هاجر دانش^۱

^۱ گروه برق و مهندسی پزشکی، دانشکده فنی و مهندسی، دانشگاه شهید اشرفی اصفهانی، اصفهان، ایران

اطلاعات مقاله

چکیده

نوع مقاله: مروری

مقدمه: مالتیپل اسکلروزیس (MS) اختلالی خودایمنی است که در آن دستگاه اینمنی به غلاف میلین اعصاب حمله می‌کند و باعث آسیب و اختلال در انتقال سیگنال‌های عصبی می‌شود. این بیماری می‌تواند به ضعف عضلاتی، مشکلات بینایی، نداشتن تعادل و ناهمانگی منجر گردد. تشخیص سریع و دقیق آن برای مدیریت و کنترل بیماری ضروری است؛ زیرا می‌تواند روند پیشرفت را کند نماید و از آسیب‌های دائمی جلوگیری کند.

تاریخ دریافت: ۱۴۰۳/۱۰/۳۰

تاریخ ویرایش: ۱۴۰۳/۱۲/۱۹

تاریخ پذیرش: ۱۴۰۴/۰۲/۰۹

تاریخ انتشار: ۱۴۰۴/۰۵/۰۵

مواد و روش‌ها: در این پژوهش، روش‌های تشخیصی MS شامل الکتروانسفالوگرافی، الکترومیوگرافی، داده‌های بالینی، آنالیز مایع مغزی نخاعی، تصویربرداری رزونانس مغناطیسی و توموگرافی انسجام نوری بررسی شد؛ همچنین روش‌های مبتنی بر هوش مصنوعی برای تحلیل خودکار داده‌ها و تشخیص سریع تر بیماری معروفی گردیدند. به عنوان روش انحصاری، پلتفرم مبتنی بر تشخیص خودکار از طریق ادغام روش‌های موجود ارائه شد.

نویسنده مسئول:

هاجر دانش

یافته‌های پژوهش: بررسی‌ها نشان داد که تصویربرداری رزونانس مغناطیسی دقت بالایی در تشخیص دارد. با توجه به میانگین دقت روش‌های مبتنی بر هوش مصنوعی در هر کدام از روش‌های اصلی برای تصویربرداری رزونانس مغناطیسی، توموگرافی انسجام نوری، الکتروانسفالوگرافی، الکترومیوگرافی و آزمایش‌های مایع مغزی نخاعی به ترتیب به دقت‌های ۹۰، ۹۰، ۹۰، ۹۰ و ۹۵ درصدی دست می‌یابند. پلتفرم پیشنهادی ترکیب این روش‌ها را برای افزایش سرعت و دقت تشخیص ارائه می‌دهد.

اصفهان، ایران

بحث و نتیجه‌گیری: استفاده از فنون پیشرفته در تشخیص MS و ترکیب روش‌های مختلف می‌تواند به تشخیص زودهنگام، بهبود روند درمان و کاهش عوارض بیماری کمک کند.

Email:
hajardanesh@yahoo.com

واژه‌های کلیدی: مولتیپل اسکلروزیس، هوش مصنوعی، EEG، OCT، MRI

استناد: رئیسی اسماء، نصیری مهسا، دانش هاجر. مروری بر فنون تشخیصی و هوش مصنوعی برای شناسایی مالتیپل اسکلروزیس. مجله دانشگاه علوم پزشکی ایلام، مرداد ۱۴۰۴؛ ۱۱۳-۱۴۸: ۳۳(۳).

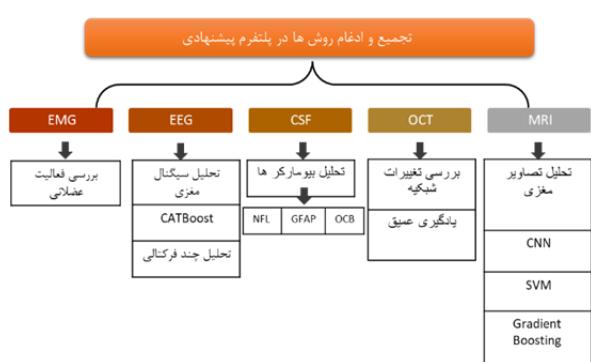


داشت که شامل مواردی چون معاینه بالینی، تصویربرداری مغزی با MRI، آزمایش مایع مغزی نخاعی، آزمون‌های الکتروفیزیولوژیک، بررسی تاریخچه پزشکی و آزمایش‌های خون می‌شد که نتایج آزمایش‌ها و تصاویر بدون بهره گیری از هوش مصنوعی و زیرشاخه‌های آن صورت می‌گرفت. امروزه فنون گوناگونی برای تشخیص اماس ارائه شده است. این روش‌ها شامل تصویربرداری ام آر آی، تجزیه و تحلیل داده‌های بالینی، الکتروآنفالوسوگرافی، الکترومايوگرافی، تصویربرداری توموگرافی انسجام نوری (OCT) نیز می‌شود (۸). آزمایش مایع مغزی نخاعی (CSF) یکی دیگر از روش‌های آزمایشگاهی برای تشخیص اماس است که با تحلیل پروتئین‌ها و شناسایی باندهای اولیگوکاللونال IgG در CSF، التهاب دستگاه عصبی مرکزی را نشان می‌دهد (۹). علاوه بر این، در روش پتانسیل‌های برانگیخته، پاسخ‌های عصبی به محرك‌های بصری، شناوی یا حرکتی ثبت می‌گردد تا عملکرد دستگاه عصبی مرکزی بررسی شود. تحقیقات پیشین در زمینه تشخیص مالتیپل اسکلروزیس با محدودیت‌های چشمگیری روپرو بوده‌اند. این محدودیت‌ها شامل واپستگی به روش‌های سنتی با دقت پایین، یکپارچه نبودن داده‌های چندمنبعی و ناتوانی در پیش‌بینی دقیق سیر بیماری هستند؛ برای مثال، تصویربرداری CT که در گذشته به عنوان یکی از روش‌های اولیه تشخیص MS استفاده می‌شد، قادر به شناسایی ضایعات کوچک مغزی نبود و محدودیت‌هایی در دقت تشخیص داشت. با ظهور MRI به عنوان جایگزین CT، مشکلاتی مانند خطأپذیری تفسیر انسانی و امکان نداشتن ترکیب داده‌های چندمدلی همچنان وجود داشت. علاوه بر این، روش‌های تشخیصی موجود عموماً به صورت مجزا عمل کرده‌اند؛ به عنوان مثال، داده‌های تصویری مانند MRI یا OCT و آزمایش‌های آزمایشگاهی مانند CSF به طور جداگانه تحلیل شده‌اند که این موضوع به کاهش دقت تشخیص و پیش‌بینی پیشرفت بیماری منجر گردیده است. هوش مصنوعی و روش‌های یادگیری ماشین نقش مهمی در پر کردن این شکاف‌ها ایفا می‌کند. شبکه‌های عصبی کانولوشنی و مدل‌های یادگیری عمیق دقت تحلیل

مقدمه

مالتیپل اسکلروزیس (MS) یک بیماری مزمن التهابی و عصبی است که با دمیلیتاسیون و دژنراسیون آکسون‌ها در دستگاه عصبی مرکزی (CNS) مشخص می‌شود. این فرایندها به از دست رفتن تدریجی بافت و تشدید ناتوانی‌های عصبی در طول زمان منجر می‌گردند (۱). علائمی مانند خستگی، ضعف عضلاتی، اسپاستیسیتی، تغییرات بینایی، سرگیجه، تغییرات ذهنی، تغییرات عاطفی و افسردگی و اختلال در تعادل و مشکلات حسی از شایع ترین علائم در بیماران اماس است (۲، ۳). اماس ممکن است تحت تأثیر عواملی مانند جغرافیا، کمبود ویتامین D، چاقی و سیگار کشیدن قرار گیرد. این بیماری حدود ۲/۳ میلیون نفر را در سراسر جهان تحت تأثیر قرار می‌دهد و میزان بروز آن در حال افزایش است (۴) و عمده‌تاً در دو سوم بیماران، در سنین ۲۰ تا ۴۰ سالگی آغاز می‌شود (۵). بسیاری از علائم بالقوه در بیماران مبتلا به مالتیپل اسکلروزیس (PwMS) به صورت قابل توجهی متغیر است؛ زیرا این بیماری بر هر فرد به شکل متفاوتی تأثیر می‌گذارد؛ به همین علت، در حال حاضر هیچ رویکرد قابل اعتمادی برای پیش‌بینی چگونگی پیشرفت بیماری در یک PwMS خاص وجود ندارد؛ همچنین برخی از MS ممکن است سال‌ها پس از تشخیص، سالم به نظر بیایند، در حالی که دیگران ممکن است با سرعت بیشتری به سوی پیشرفت بیماری حرکت کنند. این تنوع در شدت و روند بیماری، چالش‌های بسیاری را در تشخیص و درمان ایجاد می‌کند (۶). روش‌های قدیمی برای تشخیص بیماری اماس شامل ترکیبی از ارزیابی بالینی، آزمایش‌های تصویربرداری و آزمایش‌های آزمایشگاهی بوده است. یکی از روش‌های اولیه تشخیص اماس استفاده از تصاویر سی‌تی اسکن (CT) است. با این حال، CT قادر به شناسایی ضایعات اماس به طور دقیق نبود و محدودیت‌های فراوانی داشت؛ زیرا نمی‌توانست ضایعات کوچک‌تر مغزی را تشخیص دهد که معمولاً در اماس یافت می‌شود (۶). از دهه ۱۹۸۰ به بعد، ام آر آی (MRI) به عنوان یک روش دقیق‌تر برای تشخیص اماس معرفی شد و جایگزین CT گردید (۷). در گذشته، تشخیص اماس روندی طولانی‌تر و مستعد خطا

دقت مدل‌ها و نوآوری در روش‌های به کار رفته بود. کیفیت مقالات به طور ویژه با توجه به روش‌شناسی دقیق و نتایج قابل اعتماد آن‌ها سنجیده شد؛ همچنین مقالاتی که عملکرد مدل‌های هوش مصنوعی خود را با معیارهای نظری دقت، حساسیت، ویژگی و ضریب تشابه دایس گزارش کرده بودند، در اولویت قرار گرفتند. نوآوری نیز یکی دیگر از معیارهای کلیدی بود، به طوری که مقالاتی انتخاب گردیدند که از روش‌های نوین یا ترکیبی برای تشخیص MS استفاده کرده بودند. پس از ارزیابی اولیه، ۶۰ مقاله انتخاب شدند که از نظر روش‌ها، دقت و نتایج مرتبط‌تر و با کیفیت‌تر بودند. این مقالات شامل مطالعاتی بودند که از روش‌های متنوعی مانند شبکه‌های عصبی کانولوشنی، ماشین بردار پشتیبان، Gradient Boosting و الگوریتم‌های ترکیبی برای تشخیص MS استفاده کرده بودند. مدل‌های یادگیری ماشین بردار پشتیمان و جنگل تصادفی به علت توانایی بالای خود در طبقه‌بندی داده‌های پیچیده و نویزی و همچنین الگوریتم XGBoost با دقت عالی در شیوه‌سازی روابط غیرخطی، به عنوان گزینه‌های مؤثر شناخته می‌شوند. در کنار آن، مدل‌های یادگیری عمیق مانند شبکه‌های عصبی کانولوشنی و مدل‌های یادگیری عمیق مانند شبکه‌های عصبی کانولوشنی و ResNet152 نیز توانایی شناسایی الگوهای پیچیده در تصاویر OCT و OCT MRI را دارند. روند بررسی‌های صورت گرفته در شکل شماره ۱ قابل مشاهده است.



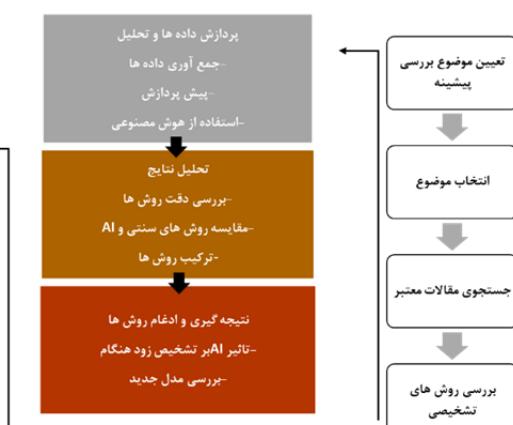
شکل شماره ۱. نمودار جریان کاری روند بررسی‌های انجام شده

استفاده از تصویربرداری ام آر آی برای شناسایی ضایعات مغزی و نخاعی، تحلیل عصب بینایی با روش OCT و آزمایش

تصاویر MRI را به میزان ۹۸ درصد افزایش داده‌اند. روش‌هایی مانند ماشین بردار پشتیمان و Gradient Boosting نیز امکان پردازش خودکار داده‌ها را فراهم کرده‌اند. به طور خاص، هوش مصنوعی با خودکارسازی تحلیل داده‌های چندمنبعی، افزایش دقت تشخیص، کاهش وابستگی به تفسیر انسانی و بهبود پیش‌بینی‌های بالینی تحول مهمی در مدیریت MS ایجاد کرده است. این مقاله به بررسی روش‌های تشخیص این بیماری و همچنین معرفی روش‌های نوین یادگیری ماشین و یادگیری عمیق برای تحلیل خودکار داده‌های این روش‌ها و تشخیص سریع تر می‌پردازد. در بخش دوم به شرح روش‌های پرداخته می‌شود و در قسمت سوم مقاله به بررسی نتایج کلی و جمع‌بندی و معرفی بهترین روش و در بخش چهارم به ارائه پیشنهادهایی برای آینده می‌پردازد.

مواد و روش‌ها

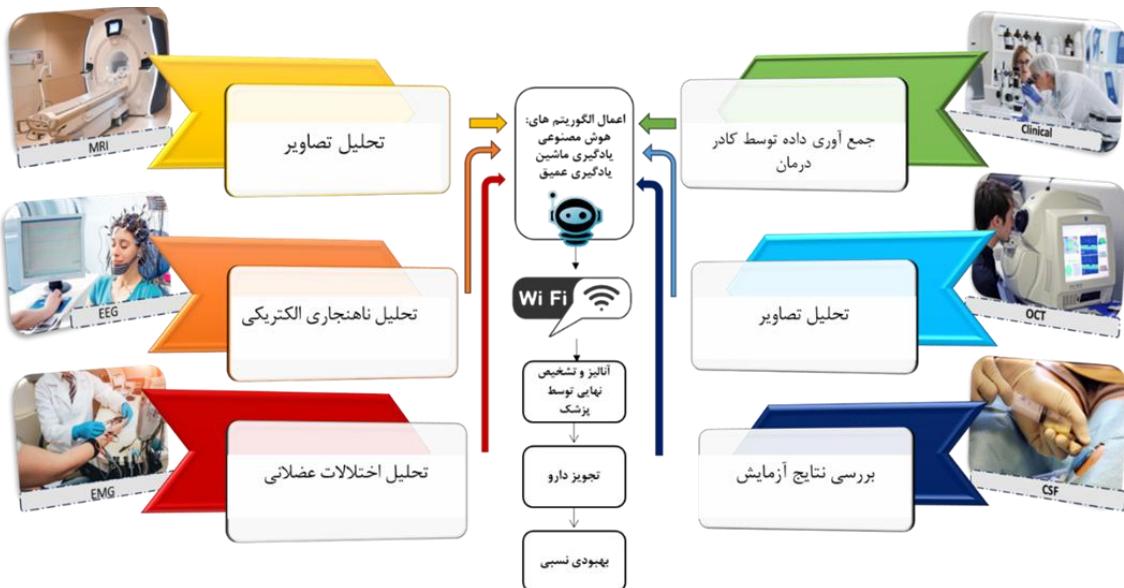
در این تحقیق، جستجو در پایگاه‌های معتبر علمی شامل گوگل اسکولار، الزیور، اسکوپوس و IEEE با استفاده از واژه‌های کلیدی نظیر مولتیپل اسکلروزیس، یادگیری عمیق، تشخیص پیشگیرانه، یادگیری ماشینی، هوش مصنوعی و شبکه عصبی کانولوشنال انجام شد. در فرایند انتخاب مقالات برای بررسی تشخیص بیماری مولتیپل اسکلروزیس، معیارهای خاصی مدنظر قرار گرفت که شامل کیفیت مقاله،



در ادامه، با تمرکز بر روش‌های مبتنی بر هوش مصنوعی، روش‌های مختلف تشخیص بیماری ام اس شامل

تشخیصی، زیرشاخه‌های یادگیری ماشین و یادگیری عمیق به همراه الگوریتم‌های متنوع هر زیرشاخه به منظور تحلیل داده‌های استخراج شده در هریک از روش‌ها مطالعه گردیدند. شکل شماره ۲ جزئیات روش‌های یادشده و تحلیل داده‌ها و روند تشخیص ییماری را نشان می‌دهد.

مایع مغزی نخاعی برای تشخیص باندهای اولیگو کلانوال به عنوان نشانه‌ای از التهاب در دستگاه عصبی مرکزی، نقش الکتروانسفالوگرافی در ارزیابی فعالیت‌های الکتریکی مغز و سیگال الکترومیوگرافی برای بررسی عملکرد عصبی-عضلاتی تحلیل شده است. برای هریک از روش‌های



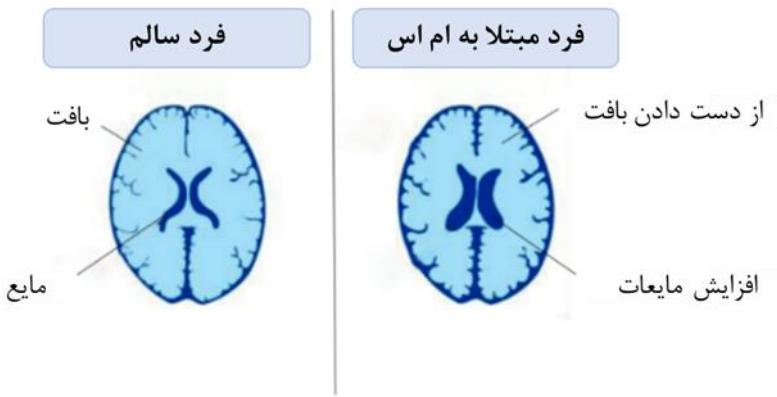
شکل شماره ۲. روش‌های تشخیص اماس

فرایند سیگال‌هایی تولید می‌کند که به تصاویر تبدیل می‌شوند. از فنون مختلف ام آر آی مانند T1-weighted و T2-weighted برای شناسایی ضایعات در ماده سفید و خاکستری مغز استفاده می‌گردد که در تصاویر شناسایی ساختارهای مغزی مشخص و ضایعات قدیمی شناسایی می‌شوند، در حالی که تصاویر T2-weighted حساس‌تر به تغییرات حاد و التهابی هستند و ضایعات جدید و فعل را بویژه در ماده سفید مغز نشان می‌دهد؛ همچنین فنون پیشرفته‌تری مانند تصویربرداری وزنی حساسیت برای شناسایی التهاب مزمن به کار می‌روند. گاهی اوقات از ماده کنترast گادولینیوم به منظور شناسایی نواحی با التهاب حاد در تصویربرداری ام آر آی استفاده می‌گردد. در تصاویر ام آر آی با کنتراست گادولینیوم، ضایعات فعل به علت افزایش نفوذپذیری سد خونی-مغزی روشن‌تر دیده می‌شوند. پراکنده‌گی این ضایعات در نواحی مختلف مغز، بویژه اطراف بطن‌ها، ساقه مغز، مخچه و نخاع، از دیگر نشانه‌های بارز این بیماری است. تصاویر ام آر آی در بیماران مبتلا به اماس

تشخیص اماس با استفاده از تصاویر ام آر آی
ام آر آی به عنوان ابزاری کلیدی در تشخیص و پایش بیماری اماس شناخته شده است. اهمیت تصویربرداری ام آر آی در تشخیص اماس به گنجاندن معیارهای ام آر آی در معیارهای پانل بین‌المللی تشخیص (معیارهای مکدونالد) در سال ۲۰۰۱ منجر شده است (۱۰). این تکنیک تصویربرداری به پزشکان این امکان را می‌دهد که آسیب‌های مغزی و نخاعی ناشی از این بیماری را شناسایی کنند، بهویژه با توجه به وجود ضایعات سفید مغز که نشان‌دهنده التهاب و آسیب در دستگاه عصبی مرکزی هستند. هنگامی که شواهد بالینی برای اثبات عود ناکافی باشد، اسکن ام آر آی می‌تواند به عنوان روشی مکمل برای تأیید تشخیص استفاده شود (۱۱). در این روش، میدان مغناطیسی قوی مولکول‌های هیدروژنی موجود در آب بدن را تحت تأثیر قرار می‌دهد و آن‌ها را همسو با میدان مغناطیسی تنظیم می‌کند؛ پس از آن، امواج رادیویی به این مولکول‌ها فرستاده می‌شود که موج جذب انرژی می‌گردد و پس از قطع امواج، به حالت اولیه بازمی‌گردند. این

نشان داده می شود. در افراد مبتلا به ام اس، ضایعاتی در ماده سفید مغز مشاهده می شود که به صورت نواحی با سیگنال غیرطبیعی در تصاویر ام آر آی ظاهر می گردد. این ضایعات نشان دهنده التهاب، دمیلینه شدن و اسکار هستند. در مقابل، در مغز افراد سالم چنین ضایعاتی وجود ندارد و ماده سفید به طور یکنواخت و بدون نواحی غیرطبیعی دیده می شود؛ همچنین در افراد مبتلا به این بیماری ممکن است کاهش حجم مغز و تغییرات در ماده خاکستری نیز مشاهده گردد که در افراد سالم دیده نمی شود (۱۴). تحقیقات جدید (۱۵) نشان داده اند که تغییرات رنگ در ضایعات قابل شناسایی هستند و در طول ۱۰ سال ثابت باقی مانده اند؛ همچنین تحلیل های کمی نشان می دهند که رنگ می تواند ارتباط میان میزان آسیب مغزی و شدت ضایعات را مشخص کند. به کمک پیشرفتهای هوش مصنوعی و اطلاعات رنگی می توان در کم بهتری از بیولوژی ام اس به دست آورد.

نشانه های منحصر به فردی دارند. از این نشانه ها می تواند به وجود نواحی غیرطبیعی به صورت لکه های سفید یا روشن در ماده سفید مغز و نخاع اشاره کرد که به علت التهاب یا تخریب میلین ایجاد می شوند. این ضایعات معمولاً در تصاویر T2-weighted FLAIR با شدت سیگنال بالا نمایان می گردد (۱۶). مطالعه دوانیان و همکاران (۱۷) به بررسی بخش بندی و مکان یابی ضایعات مغزی در بیماران مبتلا به MS با استفاده از هوش مصنوعی پرداخته است؛ همچنین در یک رقابت تخصصی، گروه ها با بهره گیری از مدل های یادگیری عمیق، از جمله U-Net تلاش کرده اند تا ضایعات را در تصاویر FLAIR MRI از ۸۱ بیمار با دقیق برش بالا شناسایی کنند. برخلاف روش های سنتی و دستی که وابسته به تجربه رادیولوژیست ها و زمان برد هستند، هوش مصنوعی با سرعت و دقت بالاتر، امکان بخش بندی خود کار و دقیق ضایعات را فراهم می کند. در شکل شماره ۳ تفاوت میان ام آر آی در فرد سالم و بیمار



شکل شماره ۳. ام آر آی سالم و بیمار ام اس

ام آر آی را تحلیل کنند و پیش بینی هایی درباره پیشرفت بیماری ارائه دهند. الگوریتم های هوش مصنوعی استفاده شده در تشخیص و مدیریت بیماری ام اس شامل مدل های یادگیری ماشین مبتنی بر مدل های یادگیری نظرات شده است که این مدل ها از داده های دارای برچسب برای یادگیری و پیش بینی استفاده می کنند و مدل های یادگیری بدون نظارت که این مدل ها برای استخراج الگوهای از داده ها بدون نیاز به برچسب استفاده می شوند و همچنین شبکه های عصبی شامل شبکه های عصبی کانولوشنی نیز برای تحلیل تصاویر ام آر آی استفاده می گردد و می توانند ویژگی های مهم تصاویر را

هوش مصنوعی در تجزیه و تحلیل داده های ام آر آی
تحلیل و بررسی تصاویر ام آر آی تو سط کادر درمان برای شناسایی ضایعات و تغییرات مغزی، به علت پیچیدگی و حجم بالای داده ها، بسیار دشوار و زمان برد است و معمولاً امکان انجام آن با دقت بالا وجود ندارد. هوش مصنوعی قادر است علائم جدید و مرتبط با بیماری ها را که در گذشته نادیده گرفته شده اند، شناسایی کند. با از استفاده از روش هایی مانند Gradient Boosting، ماشین بردار پشتیبان و شبکه های عصبی کانولوشنالی، امکان تجزیه و تحلیل دقیق تر و سریع تر تصاویر ام آر آی فراهم می شود. این روش ها قادرند ویژگی های تصاویر

این فرایند باعث کاهش خطأ و بهبود دقت پیش‌بینی‌ها می‌گردد. قابلیت تنظیم و رگولاریزیشن یکی از ویژگی‌های مهم این الگوریتم است که از پیش‌برازش جلوگیری می‌کند و مدل‌ها را قادر می‌سازد تا ویژگی‌های مهم‌تر را شناسایی کنند. نتایج این تحلیل‌ها برای شناسایی بیمارانی با شبیه‌تغییرات سریع‌تر، پایش روند بیماری، ارزیابی اثربخشی درمان‌ها و ارائه پیش‌بینی‌های بلندمدت از وضعیت بیمار استفاده می‌شود. در مقاله کمپانیونی و همکاران (۱۷)، از نسخه بهینه‌شده‌ای از گرادیان بوستینگ به نام XGBoost برای تحلیل ویژگی‌های تصویربرداری اولیه ام آر آی در بیماران اماس استفاده شده است. در این مطالعه، از ابزار SHAP برای تفسیر نتایج مدل و شفاف‌سازی تأثیر هر ویژگی بر پیش‌بینی‌ها استفاده شده است. SHAP روش مؤثری برای تفسیر مدل‌های یادگیری ماشین است که به‌ویژه در تشخیص بیماری‌هایی مانند اماس کاربرد دارد. این ابزار با استفاده از نظریه بازی‌ها، اهمیت هر ویژگی ورودی را به‌طور عادلانه محاسبه می‌کند و تأثیر ویژگی‌ها را در تصمیم‌گیری مدل تحلیل می‌نماید. SHAP با تجسم داده‌ها از طریق نمودارهای مختلف، نقش ویژگی‌ها را به‌وضوح نمایش می‌دهد. در زمینه تشخیص اماس، SHAP به تحلیل ویژگی‌های تصویربرداری ام آر آی و داده‌های بالینی مانند سن و جنسیت می‌پردازد و شفافیت و قابلیت اعتماد مدل‌ها را افزایش می‌دهد. مدل‌های GradientBoosting به‌ویژه در پیش‌بینی تغییرات در مقیاس ناتوانی و تشخیص میان انواع مختلف اماس مؤثر هستند (۱۸). با به‌کارگیری این روش می‌توان مسیر بیماری را با دقت بالا پیش‌بینی کرد، به‌ویژه استفاده از ابزارهایی مانند SHAP باعث بهبود شفافیت و تفسیر مدل‌ها می‌شود. این ابزار به‌وضوح تأثیر ویژگی‌های مختلف بر پیش‌بینی‌ها را مشخص می‌کند و به پژوهشکاران این امکان را می‌دهد تا تصمیمات بهتری در مدیریت بیماران اتخاذ کنند.

ماشین بردار پشتیبان

ماشین بردار پشتیبان یکی از الگوریتم‌های قدرتمند یادگیری ماشین است که برای مسائل طبقه‌بندی و رگرسیون استفاده می‌شود. این الگوریتم با یافتن مرز hyperplane

به‌طور خودکار استخراج نمایند (۱۶). در فرایند تحلیل داده‌های ام آر آی، با جمع‌آوری داده‌ها، پیش‌بردازش و مدل‌سازی آن‌ها، ویژگی‌های کلیدی از تصاویر ام آر آی استخراج می‌شوند. این ویژگی‌ها شامل اندازه، موقعیت و نوع ضایعات هستند؛ سپس مدل‌های یادگیری ماشین با بهره‌گیری از داده‌های آموزشی که شامل تصاویر ام آر آی و اطلاعات بالینی است، آموزش داده می‌شوند. ارزیابی مدل و درنهایت، تحلیل نتایج انجام می‌گردد. این پیش‌بینی‌ها می‌توانند در اتخاذ تصمیمات بالینی یاری‌رسان باشند. در ادامه، روش‌های مبتنی بر هوش مصنوعی مانند درخت تصمیم‌گیری، جنگل تصادفی، ماشین بردار پشتیبان (SVM)، شبکه عصبی کانولوشنی (CNN) برای تشخیص تصاویر ام آر آی دارای اماس و طبیعی معرفی می‌گردد. مدل‌های استفاده شده شامل درخت تصمیم‌گیری برای شناسایی و تفسیر ویژگی‌های کلیدی، جنگل تصادفی برای افزایش دقت پیش‌بینی با ترکیب چندین درخت و SVM برای طبقه‌بندی دقیق داده‌ها هستند؛ همچنین CNN به‌طور خاص برای شناسایی الگوهای پیچیده در تصاویر طراحی شده‌اند و گرادیان بوستینگ با شناسایی تعاملات پیچیده میان ویژگی‌ها و کاهش خطأ، عملکردی بهینه ارائه می‌دهد. این روش‌ها نه تنها دقت بالایی در تشخیص بیماری و پیش‌بینی مسیر پیشرفت آن دارند، بلکه می‌توانند به اتخاذ تصمیمات بالینی بهتر و شخصی‌سازی شده کمک کنند.

الگوریتم Gradient Boosting

Boosting یکی از الگوریتم‌های قدرتمند در یادگیری ماشین است که به‌ویژه در مدل‌های جمعی استفاده می‌شود. هدف این الگوریتم ساخت مدل‌های قوی از طریق ترکیب مدل‌های ضعیف است که معمولاً درخت‌های تصمیم‌گیری هستند. این روش به‌طور تدریجی پیش‌بینی‌های مدل‌های قبلی را اصلاح می‌کند و با به‌کارگیری تکنیک گرادیان نزولی، به بهینه‌سازی تابع هدف می‌پردازد. فرایند کار گرادیان بوستینگ به این صورت است که ابتدا یک مدل ضعیف ایجاد می‌شود؛ سپس این مدل با استفاده از باقی مانده‌ها در خطاهای مدل قبلی اصلاح می‌گردد و مدل‌های جدید به‌طور متوالی به ترکیب مدل قبلی اضافه می‌شوند. درنهایت،

تفکیک کننده بهینه‌ای میان داده‌های مربوط به ضایعات مغزی و بافت سالم ایجاد سازد. این مرز تفکیک کننده به SVM کمک می‌کند تا با دقت بالا ضایعات اماس را شناسایی نماید. استفاده از SVM در این روش باعث می‌شود که مدل در برابر داده‌های نویزی مقاوم باشد و توانایی خوبی در شناسایی ضایعات کوچک و پیچیده در مراحل اولیه بیماری داشته باشد. در مقاله لیانگ و همکاران (۲۱)، با استفاده از یادگیری ماشین و تحلیل fMRI چندسطوحی تلاش می‌کند تا میان MS و اختلالات طیف نورومیلت اپتیکا تمایز قائل گردد. ویژگی‌های اتصال عملکردی، مورفولوژیکی و شبکه‌های مغزی استخراج و با مدل‌هایی مانند SVM، جنگل تصادفی و شبکه عصبی تجزیه و تحلیل شدنند. نتایج نشان داد که SVM با هسته RBF با دقت ۸۵ تا ۹۰ درصد، عملکرد برتری در تشخیص این بیماری‌ها دارد.

شبکه‌های عصبی کانولوشنالی

روش دیگر برای تشخیص بیماری اماس استفاده از ام آر آی به کمک شبکه‌های عصبی کانولوشنالی است. به طور خاص، شبکه‌های عصبی کانولوشنال عملکرد شکستناپذیری را در حوزه‌های مختلف از جمله تقسیم‌بندی معنایی یعنی رایانه و در ک زبان طبیعی نشان داده‌اند (۲۲). ابتدا تصاویر ام آر آی بیماران مبتلا به اماس و گروه‌های کنترل جمع‌آوری می‌شود. این تصاویر معمولاً شامل ضایعات مغزی مرتبط با اماس هستند. پیش‌پردازش شامل حذف نویز، نرمال‌سازی شدت تصویر و تقویت ویژگی‌ها برای بهبود کیفیت داده‌ها است. شبکه عصبی کانولوشنی نوعی شبکه عصبی مصنوعی است که به طور ویژه برای پردازش داده‌های تصویری طراحی شده است. این شبکه از لایه‌های مختلفی تشکیل گردیده است که به طور خاص برای شناسایی و استخراج ویژگی‌های پیچیده از تصاویر کاربرد دارند. در ابتدا، لایه‌های کانولوشن برای استخراج ویژگی‌ها مانند لبه‌ها، بافت‌ها و الگوهای خاص در تصاویر استفاده می‌شوند؛ سپس لایه‌های Pooling برای کاهش ابعاد داده‌ها و افزایش کارایی مدل به کار می‌روند. درنهایت، لایه‌های کاملاً متصل به یادگیری الگوهای پیچیده‌تر کمک می‌کنند و برای طبقه‌بندی

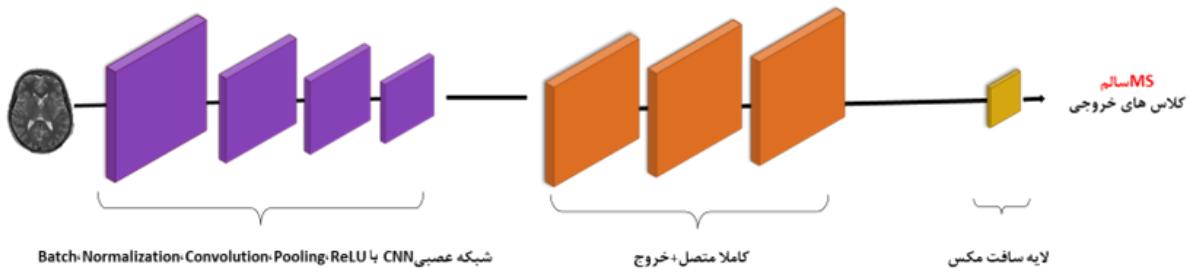
بهینه‌ای که داده‌ها را به بهترین شکل ممکن از یکدیگر جدا می‌کند، عمل می‌نماید. در مشکلات پیچیده و غیرخطی، SVM از تکنیک هسته‌ای kernel برای تبدیل داده‌ها به فضایی با ابعاد بالاتر استفاده می‌کند تا مرز تفکیک کننده‌ای با دقت پیشرفت ایجاد گردد. SVM برای دسته‌بندی داده‌ها و شناسایی ویژگی‌های کلیدی در تصاویر ام آر آی استفاده می‌شوند و به خوبی در تفکیک میان گروه‌های مختلف بیماران عمل می‌کند. در مقاله اسلام و همکاران (۱۹)، این الگوریتم برای تشخیص بیماری اماس با استفاده از تصاویر ام آر آی به کار گرفته شده است. مدل SVM بر روی مجموعه‌ای از داده‌های تصویری ام آر آی آموزش داده شده و سپس با استفاده از داده‌های تست، عملکرد آن ارزیابی گردیده است. نتایج نشان می‌دهد که SVM توانسته است دقیقی بین ۸۵ تا ۹۰ درصد، در شناسایی و تمایز اماس از دیگر بیماری‌ها با استفاده از تصاویر ام آر آی به دست آورد. این دقت بالا به طور چشمگیری به عواملی مانند کیفیت تصاویر ام آر آی، روش‌های پیش‌پردازش داده‌ها (حذف نویز، نرمال‌سازی تصاویر) و انتخاب ویژگی‌های مرتبط با بیماری بستگی دارد. به ویژه یکی از ویژگی‌های برجسته SVM این است که می‌تواند به طور مؤثری با داده‌های نویزی یا دورافتاده مقابله کند که این ویژگی در داده‌های پزشکی که به طور معمول حاوی نویز هستند، از اهمیت ویژه‌ای برخوردار است. علاوه بر این، SVM به حجم داده‌های آموزشی کمتری نسبت به برخی دیگر از الگوریتم‌ها نیاز دارد که این ویژگی در شرایطی که دسترسی به داده‌های پزشکی گستره‌مدود است، یک مزیت عمدۀ محسوب می‌شود. در مقایسه با دیگر الگوریتم‌های یادگیری، ماشین SVM به علت سادگی و توانایی آن در مقابله با داده‌های پیچیده و کم حجم، همچنان یکی از انتخاب‌های برتر در تشخیص بیماری‌های مختلف از جمله اماس است (۱۹). در مقاله شن و همکاران (۲۰)، ابتدا ویژگی‌های مختلف از تصاویر ام آر آی استخراج می‌شود، از جمله ویژگی‌های بافتی و هندسی؛ سپس این ویژگی‌ها به الگوریتم SVM وارد می‌گردند. با استفاده از فنون هسته‌ای، داده‌ها را به فضایی با ابعاد بالاتر نقشه‌برداری می‌کند، جایی که قادر است مرز

ساقه مغز محاسبه می‌گردد. این مراحل به تعیین قابلیت اطمینان مدل در شناسایی و طبقه‌بندی ضایعات کمک می‌کند. نتایج نشان‌دهنده عملکرد بالای این شبکه‌ها در همه زمینه‌های ارزیابی شده است و نقش مؤثری در تشخیص سریع و دقیق اماس دارند. شکل شماره ۴ نشان‌دهنده ساختار یک شبکه عصبی کانولوشنی برای شناسایی ضایعات اماس در تصاویر ام آر آی است. مدل از لایه‌های مختلف کانولوشن، همگرایی، تابع فعال‌سازی و نرمال‌سازی دسته‌ای، برای استخراج و پردازش ویژگی‌ها استفاده می‌کند؛ سپس ویژگی‌های استخراج شده به لایه‌های متصل کامل منتقل می‌شوند که برای پیش‌بینی نهایی استفاده می‌گردد. درنهایت، لایه خروجی با استفاده از تابع Softmax نتیجه‌گیری می‌کند و تشخیص می‌دهد که آیا ضایعه‌ای مرتبط با اماس در تصویر وجود دارد یا خیر. این ساختار به طور مؤثری، اطلاعات پیچیده را از تصاویر ام آر آی استخراج می‌کند و به شناسایی دقیق ضایعات اماس کمک می‌نماید. در مقاله هچمی و همکاران (۲۶)، از CNN برای استخراج خودکار ویژگی‌ها از تصاویر MRI بیماران مبتلا به MS استفاده شده است. این روش به علت توانایی بالا در شناسایی الگوهای پیچیده، در تحلیل تصاویر پزشکی بهویژه برای تشخیص یماری‌های عصبی مانند MS بسیار مؤثر است. ابتدا تصاویر MRI بیماران و افراد سالم در دو نمای سجیتال و آکسیال جمع‌آوری گشته‌اند و به بعد چندین لایه کانولوشن برای استخراج ویژگی‌ها، لایه‌های تجمعی برای کاهش ابعاد و لایه‌های کاملاً متصل برای پردازش نهایی داده‌ها است. پس از استخراج ویژگی‌های مهم، این داده‌ها به یک کلاسه‌بند K-نزدیک‌ترین همسایه (KNN) Fold Cross-Validation-۱۰ داده شده است که با روش بهینه‌سازی گردیده است. ترکیب CNN برای استخراج ویژگی‌های دقیق و KNN برای تصمیم‌گیری نهایی باعث شده است که مدل به دقت ۹۹/۶۲ درصد و دقت پیش‌بینی ۹۹/۶۶ درصد در تشخیص یماران مبتلا به اماس دست یابد. مقاله سوک و همکاران (۲۷) به تمایز میان اماس و اختلال طیفی نورو-مایلیت اپتیکا پرداخته است. نویسنده‌گان از

نهایی داده‌ها به کار می‌روند. مقالات سوک و همکاران و هاوی و همکاران (۲۳، ۲۴) به عنوان روش‌های قدیمی در زمینه استفاده از CNN برای تحلیل تصاویر ام آر آی و تشخیص یماری‌ها شناخته می‌شوند؛ زیرا آن‌ها از ساختارهای اویله و ساده‌تر CNN بهره می‌برند که نسبت به فنون مدرن‌تر پیچیدگی و قابلیت‌های کمتری دارند. این روش‌ها به طور عمده بر مدل‌های کم‌عمق و بدون استفاده از فنونی مانند یادگیری انتقالی یا ساختارهای پیچیده‌تر مثل ResNet یا DenseNet متمرکر بودند. در ابتدا، تصاویر ام آر آی پیش‌پردازش می‌گرددند تا ویژگی‌هایی مانند تغییرات در بافت مغز استخراج شوند که نمایانگر ضایعات اماس هستند؛ سپس شبکه‌های CNN با استفاده از این ویژگی‌ها آموزش داده می‌شوند تا بتوانند ضایعات مغزی مرتبط با اماس را شناسایی کنند. این مدل‌ها با استفاده از الگوریتم‌های بهروزرسانی وزن‌ها مانند پس‌انتشار، به طور مداوم بهبود می‌یابند تا دقت پیش‌بینی افزایش یابد؛ برای مثال، در مطالعه دقاق و همکاران (۲۵) CNN برای پیش‌بینی و تشخیص ضایعات اماس در تصاویر ام آر آی استفاده شده است. این شبکه‌ها در دو نوع ساختار ۲ D-CNN^۲ و ۳ D-CNN^۳ طراحی گردیده‌اند و در اهداف مختلف بررسی شده‌اند. در طبقه‌بندی شبکه‌های ساختارهای D^۲ و D^۳ استفاده گردید. در طبقه‌بندی شبکه‌های CNN برای تمایز میان ضایعات اماس و سایر شرایط استفاده شدن که برخی مدل‌ها تا ۱۵ لایه داشتند و عملکردی بسیار چشمگیر ارائه کردند. این ساختارها شامل شبکه‌هایی با ۶ لایه‌های Dropout بودند. این ساختارها شامل شبکه‌هایی با ۱۵ لایه پیچشی بوده‌اند و از فنون مختلفی مانند نمونه‌برداری حداقل‌تر یا میانگین و پیش‌پردازش‌هایی مانند کشش هیستوگرام و تبدیل موجک گسسته استفاده شده است. این فرایند شامل بهروزرسانی وزن‌ها و بایاس‌ها است تا دقت پیش‌بینی افزایش یابد. عملکرد مدل با استفاده از معیارهای دقت، حساسیت، ویژگی و ضریب تشابه دایس ارزیابی می‌شود. تفاوت ضریب تشابه دایس و تفاوت حجم میان تصاویر سالم و شیوه‌سازی شده برای ساختارهای زیر قشری و

بالاتر نیاز دارد. مقاله تو سینان و همکاران (۲۹) به پیش‌بینی پیشرفت بیماری در بیماران مبتلا به اماس پرداخته است. نویسنده‌گان از داده‌های چندمحلی استفاده کردند که شامل تصاویر ام آر آی و ویژگی‌های بالینی است. مدل CNN به کاررفته در این مقاله قادر به پیش‌بینی روند پیشرفت بیماری است و دقت آن در این زمینه حدود ۷۰/۱ درصد است. این روش از داده‌های چندمحلی بهره می‌برد که می‌تواند دقت پیش‌بینی را افزایش دهد؛ اما عملکرد کلی مدل در مقایسه با دیگر مدل‌ها متوسط است و نیاز به دیتاست‌های بزرگ‌تر برای بهبود آن احساس می‌شود. مقالاتی که از مدل‌های یادگیری عمیق و شبکه‌های عصبی کانولوشنی برای تحلیل و تشخیص ضایعات مغزی در بیماران مبتلا به اماس استفاده کردند، در جدول شماره ۱ مقایسه شده‌اند.

مدل‌های CNN برای تجزیه و تحلیل تصاویر MRI FLAIR سه‌بعدی استفاده کردند. مدل پیشنهادی توانسته است دقت تشخیص را بهبود بخشد و این دو بیماری را از یکدیگر تمایز دهد. دقت مدل در این مقاله حدود ۷۶/۱ درصد گزارش شده است. با این حال، مدل محدود به استفاده از یک نوع داده تصویری است و دقت آن نسبت به سایر مدل‌ها کمتر است. در مقاله چیچک و همکاران (۲۸)، مدل ۳ U-Net D برای تقسیم‌بندی دقیق ضایعات مغزی در تصاویر ام آر آی سه‌بعدی معرفی شده است. داده‌های استفاده شده از مجموعه BRATS بهره می‌برد که شامل ۵۰۰ نمونه تصویری از ضایعات مغزی است. این مدل عملکرد عالی با دقت ۹۲ درصد در تقسیم‌بندی ضایعات مغزی نشان داده است. از مزایای این مدل می‌تواند به استفاده از برچسب‌های دقیق در داده‌های آموزشی اشاره کرد؛ اما همچنان به داده‌های آموزشی بیشتری برای دستیابی به دقت



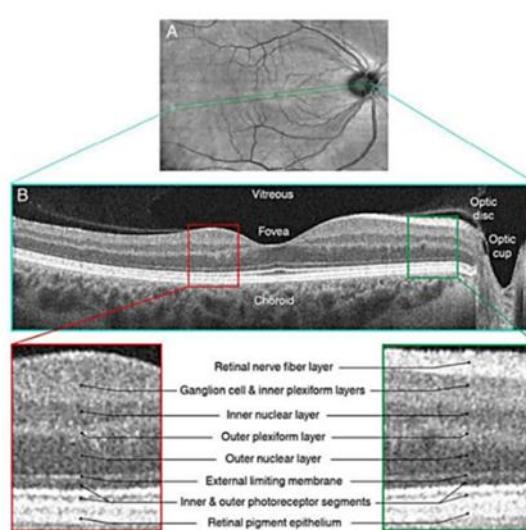
شکل شماره ۴. مراحل شبکه‌های عصبی کانولوشن

جدول شماره ۱. مقایسه روش‌های CNN برای تشخیص ام‌اس

نام نویسنده	نوع داده‌ها و پایگاه داده	ویژگی‌ها	دقت	تعداد لایه‌های کانولوشن	توابع فعال‌سازی	روش‌های پیش‌پردازش و حذف نویز	مزایا	معایب
هجمی و همکاران (۲۶)	تصاویر MRI (اسکن‌های محوری و سطح بالا از تصاویر MS و افراد سالم)	استخراج ویژگی‌های سطح بالا از تصاویر با CNN و ترکیب KNN با MRI	۶۲/۹۹ درصد	ذکر نشده است.	'ReLU Softmax	تغییر اندازه تصاویر به خودکار سازی فرایند، حذف نویز با روش‌های فیلترینگ	دقت بسیار بالا، خودکار سازی فرایند، تشخیص، کاهش نیاز به تحلیل دستی	اطلاعات محدودی درباره تعداد لایه‌ها و توابع فعال‌سازی ارائه شده است.
سنوک و همکاران (۲۷)	تصاویر ام‌آرآی VFLAIR سه‌بعدی ۱۹۹ اسکن MRI از بیماران MS	تمایز میان ام‌اس و NMOSD	۷۶/۱ درصد	۵	'ReLU Softmax	فیلتر کردن تصویر، تقویت داده‌ها	بهبود تمایز میان ام‌اس و NMOSD، تمرکز بر ضایعات ماده سفید	دقت کمتر از سایر، از تنها یک نوع داده تصویری
چیچک و همکاران (۲۸)	تصاویر ام‌آرآی 3D داده‌های سه‌بعدی جنین کلیه Xenopus در مرحله ۳-۷ که با میکروسکوپ Zeiss LSM 510 DUO کانفوکال ثبت شده‌اند.	تقسیم‌بندی دقیق ضایعات مغزی با استفاده از مدل ۳D U-Net	۹۲ درصد	23 (3D U-Net)	ReLU	تقویت داده‌ها، فیلتر کردن نویز	دقت بالای تقسیم‌بندی، کاربرد در داده‌های سه‌بعدی	نیاز به داده‌های آموزش زیاد، پیچیدگی بیشتر در پایه‌سازی
توسینان و همکاران (۲۹)	داده‌های چندمحلی (تصاویر ام‌آرآی و ویژگی‌های بالینی) پایگاه‌های اختصاصی شامل تصاویر چندمحلیه (T1c, T1p, T2w, FLAIR), Pdw	پیش‌پردازش داده‌ها و استفاده از ویژگی‌های سه‌بعدی	۷۰/۱ درصد	۴	ReLU	کاهش نویز با PCA، تقویت داده‌ها	پیش‌بینی پیشرفته ام‌اس	عملکرد متوسط، نیاز به دیتاست بزرگ‌تر

تحت تأثیر کیفیت و تنوع داده‌های اولیه قرار می‌گیرد؛ محدودیت در برخی مقالات	تحلیل دقیق عملکرد مدل‌ها در پیش‌بینی امس با دقت بالا	همسان‌سازی هیستوگرام، تقویت داده‌ها	ReLU	۴	—	ارزیابی عملکرد مدل‌های یادگیری عمیق برای پیش‌بینی امس	تصاویر ام‌آرآی بیماران امس پایگاه‌های PubMed، Cochrane، Embase، Science Google و CINAHL Library مقالاتی را بازیابی کرده است.	دقاق و همکاران (۲۵)
نیاز به منابع محاسباتی بالا	بهبود دقت در تقسیم‌بندی ضایعات امس	نرم‌السازی شدت، تقویت داده‌ها	ReLU Softmax	۱۱ (Cascaded 3D CNN چند مرحله)	—	افزایش دقت تقسیم‌بندی ضایعات امس با ام‌آرآی	ام‌آرآی پایگاه داده MSSEG Challenge	والورده و همکاران (۲۲)

ویژگی‌های مختلف مانند ضخامت لایه‌ها استخراج شود. ضخامت لایه‌های مختلف شبکیه مانند لایهٔ فیر عصبی شبکیه (نشان‌دهنده سلامت عصب‌های بینایی و آسیب‌های عصبی)، لایهٔ سلول‌های گانگلیونی (نشان‌دهنده پیشرفت بیماری اماس)، لایهٔ هستهٔ داخلی که تغییرات در این لایه نیز به آسیب‌های عصبی مرتبط با اماس اشاره دارد و لایه‌های دیگر مانند لایهٔ درونی و بیرونی شبکه استخراج می‌شود (۱). شکل شماره ۵ توانایی‌های تکنیک OCT در تحلیل ساختار شبکیه چشم، به‌ویژه در بیماران مبتلا به اماس را نشان می‌دهد. بخش A تصویر نمای کلی از عصب بینایی را به نمایش می‌گذارد، بخش B مقطع دقیقی از شبکیه را نشان می‌دهد که در آن لایه‌های مختلف شبکیه مانند لایهٔ فیرهای عصبی شبکیه، لایه گانگلیونی سلول‌ها و سایر لایه‌ها به تفکیک قابل مشاهده هستند. OCT به پزشکان این امکان را می‌دهد که این تغییرات را با دقت بالا مشاهده کنند و از آن برای پیگیری پیشرفت بیماری و ارزیابی آسیب‌های مغزی استفاده نمایند. این تصاویر می‌توانند به تشخیص زودهنگام آسیب‌های شبکیه کمک کنند و نقش مهمی در پیش‌بینی روند بیماری و اتخاذ درمان‌های مؤثر داشته باشند (۳۰).



شکل شماره ۵. یک نمونه تصویری OCT بیمار اماس و لایه‌های آن (۳۰)

اماس با OCT به طور چشمگیری افزایش یافته است و می‌تواند به شناسایی زودهنگام تغییرات مرتبط با اماس کمک کند. این پیشرفت‌ها به پژوهشگران و پزشکان کمک می‌نماید تا روند

تشخیص اماس با استفاده از OCT

تکنیک توموگرافی انسجام نور یک روش تصویربرداری غیرتهاجمی است که از نور برای ایجاد تصاویری با وضوح بالا از ساختارهای داخلی چشم، به‌ویژه لایه‌های شبکیه استفاده می‌کند. OCT روش سریع و دقیقی است که برخلاف ام‌آرآی نیازی به تزریق مادهٔ کترارت است ندارد. این تکنیک به‌ویژه برای تشخیص تغییرات دقیق در بافت‌های شبکیه چشم مؤثر است و می‌تواند در شناسایی بیماری‌هایی مانند گلوکوم، دژنراسیون ماکولا و اماس مفید واقع شود. در اماس، آسیب به الیاف عصبی و سلول‌های گانگلیونی شبکیه به کاهش ضخامت لایه‌های شبکیه، به‌ویژه لایه گانگلیونی و لایهٔ فیرهای عصبی منجر می‌گردد. این تغییرات که می‌توانند نشان‌دهنده پیشرفت بیماری باشند، به‌وضوح در تصاویر OCT قابل مشاهده است و به پزشکان این امکان را می‌دهد که به طور دقیق تغییرات جزئی در بافت‌های شبکیه چشم را شناسایی کنند و وضعیت پیشرفت بیماری را ارزیابی نمایند. تصاویر OCT از بیماران مبتلا به اماس و گروه کنترل سالم جمع‌آوری می‌شود؛ سپس بخش‌بندی لایه‌های شبکیه با استفاده از الگوریتم‌های پیشرفته انجام می‌گردد تا

یادگیری عمیق در تجزیه و تحلیل داده‌های OCT
با استفاده از فنون یادگیری عمیق، دقت تشخیص

اطلاعات، وزن‌ها به روزرسانی می‌گردند تا مدل بتواند دقت پیش‌بینی‌های خود را بهبود بخشد. این فرایند به شبکه اجازه می‌دهد تا الگوهای پیچیده‌ای را از داده‌های OCT یاد بگیرد و دقت تشخیص بیماری اماس را افزایش دهد. عملکرد فعال‌سازی (ReLU) برای لایه‌های پنهان شبکه عصبی استفاده شده است. این تابع به شبکه اجازه می‌دهد که از غیرخطی بودن داده‌ها بهره ببرد و ویژگی‌های پیچیده‌تر را از تصاویر OCT استخراج کند. در مطالعه مونتولیو و همکاران (۳۲)، استفاده از ReLU کمک می‌کند تا مدل قادر به یادگیری الگوهای پیچیده و پردازش داده‌های غیرخطی باشد. تابع SoftMax در لایه خروجی برای پیش‌بینی احتمال تعلق نمونه‌ها به دو کلاس مبتلا به اماس و غیرمبتلا به کاررفته است. استفاده از این تابع در طبقه‌بندی چند کلاسه امکان می‌دهد تا مدل با دقت بالا پیش‌بینی‌های خود را درباره وضعیت بیماری انجام دهد؛ همچنین از روش کاهش ابعاد LASSO برای انتخاب ویژگی‌های مؤثر از داده‌های OCT استفاده شده است. این روش کمک می‌کند تا از ویژگی‌های کم‌همیت و نامرتب جلوگیری شود. LASSO به شبکه این امکان را می‌دهد که تنها ویژگی‌هایی را که واقعاً در تشخیص بیماری مفید هستند، برای آموزش مدل استفاده کند که موجب جلوگیری از بیش‌پرازش می‌گردد. در پژوهش شویی و همکاران (۳۳)، ابتدا تصاویر OCT پیش‌پردازش می‌شوند تا نویزها کاهش یابد و تصاویر برای تحلیل آماده گردند؛ سپس از لایه‌های کانولوشنی برای استخراج ویژگی‌های معنایی و پیچیده تصاویر استفاده می‌شود. لایه‌های پیچشی ویژگی‌هایی از قبیل لبه‌ها، ساختارهای هندسی و تغییرات در ضخامت لایه‌های شبکه مثل RNFL و GCL را شناسایی می‌کنند که از تغییرات ساختاری ناشی از اماس نشأت می‌گیرند. در مرحله بعد، لایه‌های جمع‌آوری با کاهش ابعاد ویژگی‌های استخراج شده از لایه‌های پیچشی، تنها ویژگی‌های کلیدی و مؤثر را حفظ می‌کنند که برای فرایند طبقه‌بندی اهمیت دارند. ویژگی‌های مهم و حیاتی برای طبقه‌بندی حفظ می‌شوند. این لایه‌ها باعث کاهش پیچیدگی محاسباتی و جلوگیری از بیش‌پرازش می‌گردند. پس از آن، ویژگی‌های به دست آمده

بیماری را پیش‌بینی کنند و درمان‌های مؤثری را در زمان مناسب آغاز نمایند. این روش‌ها به طور خاص برای داده‌های بزرگ و پیچیده طراحی شده‌اند و از شبکه‌های عصبی عمیق برای بهبود دقت و عملکرد استفاده می‌کنند. بر اساس تحقیقاتی مانند لکون و همکاران (۳۱)، این الگوریتم‌ها با قابلیت تعمیم بالا، از داده‌های خام ویژگی‌های مهم را استخراج می‌نمایند و باعث پیشرفت‌های قابل توجه در هوش مصنوعی شده‌اند (۳۱). در این روش، ضخامت لایه سلولی گانگلیونی ماکولا به عنوان یک بیومارکر مهم بررسی می‌شود. کتراست میام mGCL و لایه پلکسی شکل داخلی مجاور در OCT بسیار کم است؛ بنابراین، این دو لایه معمولاً برای تشکیل mGCIPL ترکیب می‌گردند. شبکه‌های عصبی عمیق به کاررفته در مطالعه مونتولیو و همکاران (۳۲) توانستند دقت ۹۰/۳ درصد را در تشخیص بیماران مبتلا به اماس به دست آورند. روش ارائه شده مونتولیو و همکاران (۳۲) برای تشخیص اماس مبتنی بر استفاده از فنون یادگیری عمیق و اندازه‌گیری ضخامت لایه سلولی گانگلیونی ماکولا با استفاده از OCT است که شامل یک بررسی مقطعی از بیماران اماس و افراد سالم است که در آن، از شبکه‌های عصبی عمیق به عنوان یک طبقه‌بند خود کار استفاده شده است. نتایج فنون یادگیری عمیق برای تشخیص اماس با استفاده از ۱۷ ویژگی به عنوان ورودی، به دقت ۹۰/۳ درصد رسید و برای پیش‌بینی پیشرفت ناتوانی دقت ۸۱/۹ درصد به دست آمد. در ادامه، به بررسی روش‌هایی از یادگیری عمیق پرداخته می‌شود.

شبکه‌های عصبی عمیق در طبقه‌بندی مبتلایان اماس

شبکه‌های عصبی عمیق برای طبقه‌بندی خودکار بیماران مبتلا به اماس و بیماران غیر مبتلا به طور گستردۀ استفاده می‌گردد؛ همچنین از شبکه‌های عصبی پیش‌خور با یک یا چند لایه پنهان برای پردازش داده‌ها استفاده شده است (۳۲). در ادامه، عملکرد بازگشتهای شبکه‌های عصبی عمیق بررسی می‌شود. در این روش، ابتدا خطای تفاوت میان خروجی پیش‌بینی شده و خروجی واقعی محاسبه می‌گردد؛ سپس این خطای تفاوت میان را باعث کاهش پیچیدگی محاسباتی و جلوگیری از تغییرات خطا نسبت به وزن‌ها محاسبه می‌شود. با استفاده از این

تصویر از افراد سالم است؛ سپس این تصاویر از طریق CAE پردازش شد و ویژگی‌های مرتبط با شبکه استخراج گردید. این تحقیق تأکید دارد که استفاده از IR-SLO به عنوان ابزاری مکمل برای OCT می‌تواند به شناسایی دقیق‌تر آسیب‌های شبکه در بیماران اماس کمک کند و به عنوان یک روش قابل اعتماد برای ارزیابی تغییرات شبکه در این بیماران معرفی می‌شود.

شبکه‌های پیش‌آموزشی (ResNet152V2)

شبکه‌های پیش‌آموزشی مانند ResNet152V2 یکی از انواع پیشرفته ساختارهای یادگیری عمیق هستند که برای شناسایی ویژگی‌های پیچیده‌تر و دقیق‌تر از داده‌ها طراحی شده‌اند. این شبکه‌ها از چندین لایه کانولوشن عمیق برای استخراج ویژگی‌های پیچیده و دقیق از داده‌ها استفاده می‌کنند. در این ساختار، بهویژه در ResNet152V2، به کارگیری فنونی نظری اتصال‌های باقی‌مانده به مدل کمک می‌کند تا مشکلات رایج در شبکه‌های عصبی عمیق مانند از دست دادن اطلاعات در لایه‌های عمیق‌تر را کاهش دهد. این ویژگی باعث می‌شود که ResNet152V2 قادر به یادگیری ویژگی‌های دقیق‌تر و پیچیده‌تر از تصاویر پزشکی باشد. بهویژه برای شناسایی ضایعات مغزی، آسیب‌های شبکه و سایر تغییرات مرتبط با بیماری‌های عصبی، مدل‌های پیش‌آموزشی مانند ResNet152V2 می‌توانند دقت بالایی را ارائه دهند. در صورتی که داده‌های ورودی کافی و متنوع باشند، این شبکه‌ها قادرند ویژگی‌های پنهان را از داده‌های پیچیده استخراج کنند و الگوهای راشناسایی نمایند که در روش‌های سنتی قابل شناسایی نبوده‌اند. از دیگر مزایای این ساختار می‌توان به سرعت بالای یادگیری و قابلیت تعمیم‌پذیری بالای آن اشاره کرد. در مقاله السویابی و همکاران (۳۵)، از شبکه پیش‌آموزشی ResNet152V2 برای شناسایی ضایعات شبکه و تشخیص تغییرات مغزی در بیماران مبتلا به اماس استفاده شده است. در این مقاله، نتایج حاکی از دقت ۹۷/۳ درصد در شناسایی ضایعات شبکه و تغییرات مغزی بیماران اماس با استفاده از این ساختار پیش‌آموزشی بوده است. جدول شماره ۲ به مقایسه روش‌های تشخیص اماس با استفاده از تکنیک

به لایه‌های کاملاً متصل فرستاده می‌شوند که در آنجا مدل از این ویژگی‌ها برای طبقه‌بندی استفاده می‌کند. در مرحله طبقه‌بندی، از تابع فعال‌سازی Softmax برای پیش‌بینی احتمال تعلق نمونه‌ها به دسته‌های مختلف مبتلا به اماس یا سالم استفاده می‌گردد. برای بهبود عملکرد و جلوگیری از بیش‌پرازش، از فنونی مانند Dropout و الگوریتم‌های بهینه‌سازی همچون الگوریتم Adam استفاده می‌شود. Adam یک روش بهینه‌سازی است که از ترکیب گرادیان‌های اول و دوم برای بهروزرسانی وزن‌ها در شبکه‌های عصبی استفاده می‌کند. این الگوریتم به طور خودکار نرخ یادگیری را برای هر مؤلفه تنظیم می‌کند و بهویژه در حل مشکلات پیچیده مانند بیش‌پرازش و نوسانات فراوان در طول آموزش مؤثر است تا دقت مدل به طور مؤثری افزایش یابد.

Autoencoder

Autoencoders مدل یادگیری عمیقی است که برای فشرده‌سازی داده‌ها و سپس بازسازی آن‌ها به کار می‌رود. این مدل از دو بخش اصلی تشکیل شده است که شامل رمزگذار و رمزگشا است. در بخش رمزگذار، داده‌های ورودی به یک فضای کم‌بعدتر و فشرده تبدیل می‌شوند، جایی که ویژگی‌های مهم و پنهان آن‌ها استخراج می‌گردد. این ویژگی‌های فشرده‌شده سپس به بخش رمزگشا وارد می‌شوند تا تلاش کنند داده‌ها را تا حد امکان به حالت اولیه خود بازسازی نمایند. هدف اصلی این است که مدل ویژگی‌های اصلی داده‌ها را شناسایی کند و به شکلی فشرده در فضای کم‌بعدتر نگه دارد، به‌طوری که بازسازی دقیق‌تری از داده‌ها صورت گیرد. این فن‌ها بهویژه در برداش تصاویر، شناسایی الگوها و همچنین تحلیل داده‌های پزشکی مانند تصاویر OCT و آرآی استفاده می‌شوند، جایی که استخراج ویژگی‌های مهم از داده‌های پیچیده ضروری است. در مطالعه اقبابی و همکاران (۳۶)، از Autoencoder برای تحلیل تصاویر IR-SLO (تصاویر شبکه با اسکن لیزر مادون‌قرمز) به منظور شناسایی تغییرات شبکه در بیماران مبتلا به اماس استفاده شده است. داده‌های تصاویر از دو مرکز مختلف جمع‌آوری شده که شامل ۱۶۴ تصویر از بیماران اماس و ۱۵۰

OCT و شبکه‌های عصبی می‌پردازد.

جدول شماره ۲. مقایسه روش‌های تشخیص اماس با استفاده از فنون OCT و شبکه‌های عصبی

معایب	مزایا	ویژگی‌ها	روش	پایگاه داده‌ها	نام نویسنده
بدون مطالعات موردنی خاص برای ارزیابی	بهبود عملکرد در مسائل پیچیده (تصویر، صدا و متن)، کاهش نیاز به مهندسی دستی ویژگی‌ها، قابلیت انطباق با دامنه‌های مختلف	معماری‌های چندلایه برای یادگیری و شناسایی الگوهای پردازش داده‌های خام و بهره‌گیری از سخت‌افزار پیشرفته مانند GPU	DNN	داده‌های عمومی	لکون و همکاران (۳۱)
وابستگی به کیفیت تصاویر OCT	غیرتهاجمی بودن روش OCT، فراهم کردن داده‌های طولانی‌مدت و قابل اعتماد برای بررسی آتروفی مغز، ایجاد ارتباط میان تغییرات اماس شبکیه و پیشرفت	برای استفاده از OCT اندازه‌گیری آتروفی مغز، ارتباط میان تغییرات شبکیه و اماس بیماری	DNN	۱۰۷ بیمار داده‌های OCT و MRI در یک دوره پیگیری متوسط ۴۶ ماهه	سیدها و همکاران (۳۰)
نیاز به تصاویر با کیفیت بالا و داده‌های فراوان	تشخیص و پیش‌بینی دقیق تر اماس، کاهش نیاز به بیماری روش‌های تهاجمی، استفاده از یادگیری عمیق برای افزایش دقت و سرعت تحلیل داده‌های چشمی	استفاده از لایه‌های گانگلیونی شبکیه به عنوان بیومارک برای تشخیص و اماس، به کار گیری پیش‌بینی یادگیری عمیق برای تجزیه و تحلیل داده‌ها	DNN	۷۲ بیمار بخش نورولوژی Miguel Servet	مونتولیو و همکاران (۳۲)
نیاز به پیش‌پردازش و وضوح بالا در تصاویر	استخراج ویژگی‌ها به صورت خودکار، کاهش پیچیدگی	استخراج ویژگی‌های شبکیه با استفاده از Autoencoder برای شناسایی تغییرات اماس	Autoencoder	۱۶۴ بیمار اماس و ۱۵۰ فرد سالم (مرکز پزشکی در اصفهان و مرکز جانز هاپکیتر)	اقبایی و همکاران (۳۴)
نیاز به داده‌های فراوان و متنوع برای آموزش مدل	افزایش دقت از طریق ترکیب داده‌های چندمنبعی (MRI) و OCT، بهبود عملکرد مدل افزایش دقت از طریق ترکیب داده‌های چندمنبعی (MRI) و OCT، بهبود عملکرد مدل	استخراج ویژگی‌های ترکیبی از MRI و OCT، استفاده از Autoencoder برای بهبود دقت تشخیص	Autoencoder	MRI، OCT داده‌های	السویانی و همکاران (۳۵)

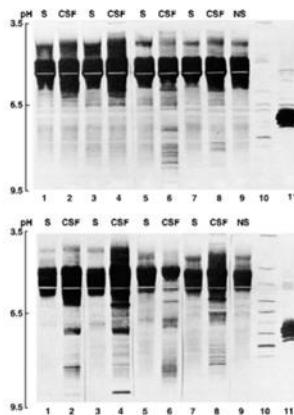
می‌شوند. این آزمایش‌ها امکان شناسایی بیومارک‌های خاصی را فراهم می‌کنند که می‌توانند اطلاعات ارزشمندی درباره فعالیت‌های التهابی و آسیب‌های عصبی در دستگاه عصبی مرکزی ارائه دهند. پژوهش‌ها نشان می‌دهند که از بیومارک‌ها

تشخیص اماس با استفاده از آزمایش‌های مایع مغزی نخاعی

آزمایش‌های مایع مغزی نخاعی به عنوان یکی از ابزارهای کلیدی در تشخیص و پایش بیماری اماس شناخته

C که به عنوان پروتئین γ-شناخته می‌شود. الگوهای IEF سرم و مایع مغزی نخاعی در بیماران اماس نشان می‌دهد که حضور IgG OB در CSF نشان دهنده احتمال ابتلا به اماس است. در عفونت‌های مزمن، شناسایی هدف مولکولی OCBs هدایت می‌گردد؛ بنابراین، شناسایی هدف مولکولی OCBs در بیماران مبتلا به اماس می‌تواند علل بالقوه‌ای برای بروز این بیماری باشد. با این حال، همچنین می‌توان تصور کرد که OCBs مخصوصاً این بیماری هستند که ممکن است بر پیش‌آگهی یا اثر درمانی منعکس نشود (۳۷). تحقیقات نشان می‌دهند که سطح این بیومارکرهای در مایع مغزی نخاعی نه تنها با شدت علائم بالینی مرتبط است، بلکه می‌تواند تغییرات بیماری را در طول زمان ردیابی کند؛ به عنوان مثال، سطوح بالای GFAP با پیشرفت بیماری و آسیب‌های مزمن مرتبط هستند، در حالی که NfL به عنوان نشانه‌ای از آسیب‌های عصبی حاد عمل می‌کند. این یافته‌ها نشان می‌دهند که آزمایش‌های مایع مغزی نخاعی می‌توانند نقش مهمی در ارزیابی و مدیریت بیماران مبتلا به اماس ایفا نمایند.

برای تشخیص و پیش‌آگهی بیماری اماس استفاده می‌شود. نوارهای الیگوکلونال که شامل ایمونوگلوبولین‌های IgG و IgA هستند، توسط سلول‌های پلاسمای در دستگاه عصبی مرکزی تولید می‌گردند و نشان دهنده یک پاسخ ایمنی غیرطبیعی در آزمایش‌های مایع مغزی نخاعی هستند. حضور نوارهای الیگوکلونال در مایع مغزی-نخاعی (OCB) در آزمایش‌های مایع مغزی نخاعی به طور چشمگیری با اماس مرتبط است و به عنوان یکی از ابزارهای اصلی در تشخیص و تمایز این بیماری از اختلالات مشابه عمل می‌کند. این بیومارکر می‌تواند به تشخیص دقیق تر و ارزیابی فعالیت التهابی بیماری کمک نماید. زنجیره سبک نوروفیلامنت به عنوان یک بیومار کرمه‌ای برای ارزیابی آسیب‌های آکسونی در اماس شناخته شده است. افزایش سطح NfL در آزمایش‌های مایع مغزی نخاعی به طور مستقیم با شدت بیماری و فعالیت التهابی در اماس ارتباط دارد (۳۶). در شکل شماره ۶ در چهار بیمار اماس، پروتئین‌های اضافی در آزمایش‌های مایع مغزی نخاعی مشاهده شده است که به CNS مرتبط هستند؛ از جمله سیستاتین



شکل شماره ۶. کاربرد شناسایی باندهای الیگوکلونال در آزمایش‌های مایع مغزی نخاعی با استفاده از ایزوالکتریک فوکوسینگ در تشخیص اماس (۳۸)

جدید در مایع مغزی نخاعی برای ارزیابی فعالیت و پیشرفت بیماری اماس پرداخته است. هدف اصلی مقاله شناسایی ارتباط این بیومارکرهای با ویژگی‌های بالینی بیماری و پیش‌بینی پیشرفت آن بوده است. نتایج نشان داد که این بیومارکرها می‌توانند به تشخیص زودهنگام و نظارت بر درمان‌های مختلف، از جمله داروهای تغیردهنده بیماری کمک کنند در این مقاله، بعد از جمع‌آوری داده‌های بالینی و مایع مغزی

بررسی بیومارکرها در آزمایش‌های مایع مغزی نخاعی برای تشخیص اماس

بررسی بیومارکرها در آزمایش‌های مایع مغزی نخاعی در تشخیص اماس حائز اهمیت است. این بیومارکرها با بررسی گروه آزمایشی بیمارانی با اماس عودکننده و اماس پیشرفته اولیه شروع می‌شود که تحت درمان با داروی اکرلیزوماب قرار گرفتند. مقاله کراس و همکاران (۳۹) به بررسی بیومارکرها

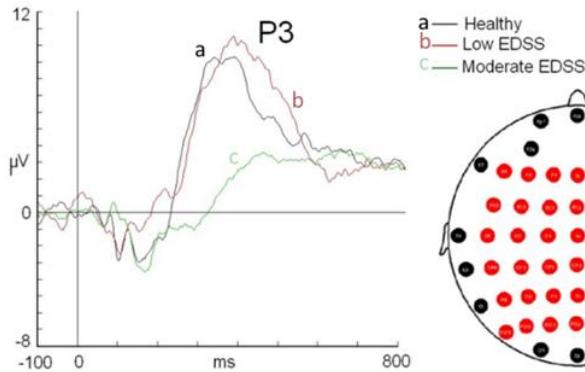
بیشتر با فعالیت‌های التهابی حاد مرتبط هستند. GFAP با تعداد ضایعات کند-گسترش‌یابنده (SELS) و شدت آسیب مغزی رابطه مثبت دارد؛ اما نشانگرهای لنفوستی و سیتوکینی ارتباطی با بیماری اماس نداشتند؛ همچنین درمان با Ocrelizumab (ضد CD20) سطح نشانگرهای التهابی حاد در آزمایش‌های مایع مغزی نخاعی را کاهش داد؛ اما تأثیر کمتری بر نشانگرهای گلیالی مانند GFAP داشت.

روش مکدونالد

در گام دیگری، به دیدگاه و معیارهای مکدونالد در کار مارتين و همکاران (۴۱)، در به کار گیری آزمایش‌های مایع مغزی نخاعی برای تشخیص اماس اشاره می‌شود. این روش به بررسی قابلیت زنجیره نوروفیلامنت مایع مغزی نخاعی در پیش‌بینی تبدیل به اماس در بیماران مبتلا به نوریت اپتیک می‌پردازد. نتایج نشان می‌دهد، cNfL در شناسایی بیمارانی که در معرض خطر بالای اماس هستند، کمک کننده است. در بیماران مبتلا به اماس نوع عود کننده بهبود یابنده (RRMS)، سطح cNfL در مراحل عود بیماری و همچنین طی بهبودی، به طور معناداری بیشتر از گروه کنترل گزارش شده است. در روش مکدونالد، cNfL در نمونه‌های تشخیصی ۷۴ بیمار مبتلا به التهاب عصب بینایی (ON) بر اساس معیارهای این روش اندازه گیری شده است. بیماران کارهای معیار مکدونالد شامل بررسی زنجیره نوروفیلامنت سبک در مایع مغزی نخاعی و وجود نوارهای اولیگوکلونال معیارهای انتشار در فضاست. نمونه‌های مایع مغزی نخاعی از بیماران گرفته شده است و بلا فاصله برای اندازه گیری cNfL به آزمایشگاه منتقل گردیده است. بیماران تحت ام آر آی مغز و نخاع قرار گرفتند تا معیارهای انتشار در فضا و زمان بررسی شود. cNfL با استفاده از روش‌های اینتوآنزیمی اندازه گیری و نتایج با توجه به معیارهای تشخیصی تجزیه و تحلیل شد. افزایش دقت و حساسیت در تشخیص اماس از ویژگی‌های مطلوب استفاده از شاخص cNfL است. امکان شناسایی بیماران در معرض خطر، پیش از بروز علائم بالینی اماس، دیگر نکته مثبت این روش است. کاهش قابلیت تشخیص در برخی موارد با استفاده از cNfL به عنوان جایگزینی برای معیارهای ام آر آی و نیاز به

بیماران مبتلا به اماس عود کننده و پیشرفت اولیه، به تجزیه و تحلیل و مقایسه بیومارکرهای آزمایش‌های مایع مغزی نخاعی مانند GFAP و نوروفیلامنت‌ها پرداختند. آنان ارتباط این بیومارکرهای را با ویژگی‌های بالینی بیماری، مانند میزان فعالیت بیماری و پیشرفت آن بررسی کردند؛ سپس نتایج نشان داد که این بیومارکرهای می‌توانند در شناسایی آسیب عصبی و پیش‌بینی پیشرفت بیماری نقش داشته باشند؛ همچنین به بررسی آثار درمان‌های مختلف از جمله داروهایی مانند اکرلیزوماب بر روی این بیومارکرها پرداختند و نشان دادند که بیومارکرهای آزمایش‌های مایع مغزی نخاعی می‌توانند به نظارت بر پاسخ به درمان و پیگیری فعالیت بیماری کمک کنند. طی فرایندهای پاتولوژیک دستگاه عصبی مرکزی، هر دو NFL و GFAP ممکن است در مایع مغزی نخاعی می‌توانند به شوند. افزایش سطح NFL که نشان‌دهنده آسیب آکسون‌های میلین دار است. در بیماری‌های نورودژنراتیو، عفونت‌های CNS و بیماری‌های التهابی CNS از جمله اماس یافت شده است (۴۰). بیومارکرهای بررسی شده شامل پروتئین GFAP نشان‌دهنده فعالیت آسترتوسیت‌ها، پروتئین‌های نوروفیلامنت لایت‌چین و نوروفیلامنت سنگین‌چین می‌شود که به آسیب عصبی اشاره دارند؛ همچنین سایر نشانگرهای اینمنی مانند سیتوکین‌ها و شیمیوکین‌ها را در برمی‌گیرد که به پاسخ‌های التهابی مرتبط هستند. بیماری اماس در روش CSF زمانی تأیید می‌شود که نشانه‌هایی چون وجود بیومارکرهای خاص (مانند GFAP یا NFL) که با بیولوژی پیشرفت غیرعادی بیماری مرتبط باشند و یا عدم وجود نشانه‌های التهاب حاد در نظارت بر آزمایش‌های مایع مغزی نخاعی، به ویژه در زمینه عود کننده بیماری تأیید شود. ارتباط میان سطوح بیومارکرها و معیارهای بالینی و تصویربرداری (مانند شدت بیماری و تعداد ضایعات) بررسی می‌گردد و سپس برای تعیین ارتباطات معنادار از آزمون‌های آماری مانند همبستگی اسپیرمن و رگرسیون خطی استفاده می‌شود. درنهایت، واضح است که پروتئین GFAP و زنجیره سنگین نوروفیلامنت با پیشرفت غیر عود کننده بیماری ارتباط دارند، در حالی که نشانگرهای اینمنی مانند CD3+ T-cell و CD19+

ارزیابی عملکرد شناختی و پیشرفت بیماری کمک کند. در شکل شماره ۷ تغییرات فعالیت مغزی در سه گروه مختلف افراد نشان داده شده است: افراد سالم، بیماران مبتلا به اماس با ناتوانی کم و بیماران با ناتوانی متوسط. این شکل شامل نمودارهای پاسخ‌های P3 و ERD است که در آن‌ها تفاوت‌های آشکاری میان گروه‌ها مشاهده می‌شود. در بیماران با ناتوانی بیشتر پاسخ‌های P3 و ERD کاهش می‌یابد که این امر نشان‌دهنده تغییرات در پردازش شناختی و هم‌زمانی فعالیت مغزی است. علاوه بر این، نقشهٔ موقعیت الکترودهای الکتروانسفالوگرافی را نشان می‌دهد که الکترودهای سیاه به افراد سالم و الکترودهای قرمز به بیماران مبتلا به ناتوانی بیشتر اختصاص دارد که نشان‌دهنده تأثیر ناتوانی بر فعالیت‌های مغزی است. محور X نشان‌دهنده «زمان» بیان شده در میلی ثانیه و محور Y نشان‌دهنده «دامنه» ERP/ERD در میکروولت است. خط‌چین عمودی نشان‌دهنده شروع محرک است. رد سیاه مربوط به گروه سالم است و قرمز مربوط به گروه کم و سبز مربوط به گروه متوسط EDSS است.



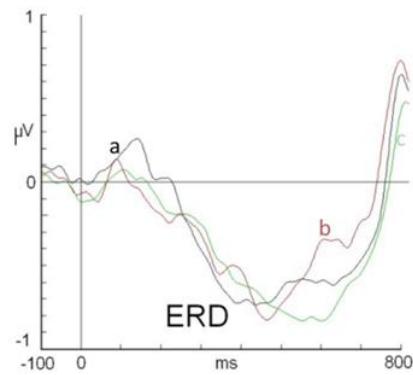
شکل شماره ۴۴. آرایه الکتروانسفالوگرافی مربوط به میکامگازدایی مرتبط با رویداد آلفا و جزء P3

تتا (۴ تا ۸ هرتز) که به پردازش اطلاعات عمیق‌تر مربوط می‌شود، در بیماران اماس با افزایش قدرت این باند در نواحی فرونتو-تمپورال همراه است که می‌تواند نشانه‌هایی از اختلالات شناختی و پردازش اطلاعات باشد (شکل شماره ۸). تحلیل سیگنال‌های الکتروانسفالوگرافی و بررسی تغییرات در این باندها می‌تواند ابزاری مؤثر برای شناسایی و تشخیص بیماری اماس باشد. علاوه بر این، این تحلیل‌ها به درک بهتر از وضعیت شناختی بیماران کمک می‌کند و می‌توانند به طراحی برنامه‌های درمانی مناسب و مدیریت بهتر بیماری کمک نمایند.

انجام مطالعات بیشتر برای تأیید یافته‌ها و بهینه‌سازی آستانه‌های NfL و cNfL از نکات منفی محسوب می‌شود. نتایج نشان می‌دهد که زودهنگام اماس در بیماران مبتلا به ON استفاده گردد و بهبود در حساسیت و دقت تشخیص را فراهم کند، گرچه ممکن است به توانایی شناسایی آسیب رساند (۴۲).

تشخیص MS با استفاده از الکتروانسفالوگرافی

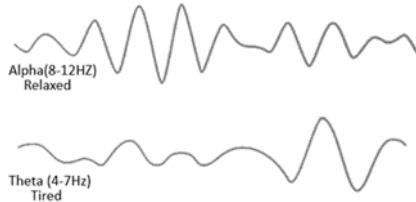
تحلیل سیگنال‌های الکتروانسفالوگرافی به علت توانایی در شناسایی الگوهای الکتریکی مغز می‌تواند تفاوت‌های چشمگیری میان بیماران اماس و افراد سالم را نشان دهد. ناهنجاری‌های الکتروانسفالوگرافی را می‌توان در ۲۰ تا ۶۰ درصد بیماران اماس مشاهده کرد که مربوط به محل ضایعات، مدت و مرحله بیماری و سیر آن است (۴۳). با توجه به اینکه ارزیابی‌های سنتی معمولاً بر مبنای آزمون‌های روان‌شناسی انجام می‌شود، استفاده از داده‌های الکتروانسفالوگرافی می‌تواند به ایجاد معیارهای عینی‌تری برای



در تشخیص بیماری اماس، تحلیل باندهای آلفا و تتا در سیگنال‌های الکتروانسفالوگرافی اهمیت فراوانی دارند. این باندها اطلاعات مهمی درباره وضعیت شناختی و عملکردی بیماران به پزشکان ارائه می‌دهند. باند آلفا (۸ تا ۱۲ هرتز) به آرامش و تمرکز مربوط است. در بیماران مبتلا به اماس، کاهش همدوسي در این باند، بهویژه در نواحی فرونتو-تمپورال، نشان‌دهنده اختلالات قشری و مشکلات شناختی است. این تغییرات در همدوسي می‌توانند با بار ضایعات مغزی و اختلالات حافظه مرتبط باشند؛ همچنین باند

درواقع، تحلیل دقیق این باندها در سیگنال‌های الکتروانسفالوگرافی می‌تواند نقش مهمی در تشخیص

زودهنگام و پیش‌بینی اختلالات شناختی و عملکردی مرتبط با اماس ایفا کند (۴۴، ۴۵).



شکل شماره ۸ سیگنال آلفا و تتا الکتروانسفالوگرافی

ویژگی‌های مهم سیگنال‌های مغزی را شناسایی کند که به تغییرات ناشی از اماس مربوط می‌شوند. یکی از ویژگی‌های برجسته CATBoost، توانایی آن در مدیریت داده‌های دسته‌بندی است. این ویژگی به این معنی است که CATBoost به طور خودکار می‌تواند داده‌های دسته‌بندی شده را پردازش کند و آن‌ها را به نحوی بهینه استفاده نماید، بدون آنکه نیازی به پیش‌پردازش پیچیده داشته باشد. علاوه بر این، CATBoost از فنون خاصی برای جلوگیری از پیش‌پردازش استفاده می‌کند که به عملکرد بهتر آن در داده‌های پیچیده کمک می‌کند. در مقاله موروش و همکاران (۴۷) از الگوریتم CATBoost برای تحلیل داده‌های الکتروانسفالوگرافی و تشخیص بیماری اماس استفاده شده است. در این تحقیق، ویژگی‌های مختلف داده‌های الکتروانسفالوگرافی از جمله باندهای فرکانسی مختلف (آلفا، بتا، دلتا و گاما) و وضعیت‌های مغزی استخراج شده است. وضعیت‌های مغزی به عنوان ویژگی‌هایی هستند که نشان‌دهنده الگوهای فعالیت مغز در شرایط مختلف مانند چشم‌باز و چشم‌بسته هستند؛ سپس داده‌ها به دو مجموعه آموزشی (۶۰ درصد) و آزمون (۴۰ درصد) تقسیم شدند تا مدل الگوریتم CATBoost آموزش داده شود. نتایج این مطالعه نشان داد که دقت مدل CATBoost در تشخیص بیماری اماس به ۸۲ درصد رسید که این مقدار به طور چشمگیری بیشتر از ۶۴ درصد دقت حاصل از استفاده صرف از باندهای فرکانسی الکتروانسفالوگرافی بود. این نشان می‌دهد که ترکیب وضعیت‌های مغزی با ویژگی‌های فرکانسی الکتروانسفالوگرافی می‌تواند دقت مدل را به طور چشمگیری افزایش دهد.

شکل شماره ۸ سیگنال آلفا و تتا الکتروانسفالوگرافی هوش مصنوعی در تجزیه و تحلیل داده‌های الکتروانسفالوگرافی: استفاده از هوش مصنوعی در تجزیه و تحلیل داده‌های الکتروانسفالوگرافی برای تشخیص بیماری اماس روزبه روز در حال گسترش است. این تکنیک با تحلیل وضعیت‌های مغزی و باندهای فرکانسی مختلف الکتروانسفالوگرافی، به شناسایی الگوهای ناهنجار کمک می‌کند؛ همچنین یادگیری ماشینی با بهره‌گیری از ترکیب آمار و علوم کامپیوتر می‌تواند با کاهش خطاهای میان پیش‌بینی‌ها و داده‌های مشاهده شده، روابط پیچیده و غیرخطی میان متغیرها را شناسایی کند (۴۵). روش‌هایی تحت عنوان CATBoost و تحلیل چندفرکتالی در پژوهش‌های مختلف استفاده شده است (۴۶، ۴۷) که در ادامه معرفی می‌گردد. استفاده از ترکیب CATBoost و تحلیل چندفرکتالی می‌تواند ابزاری قدرتمند برای پیش‌بینی و شناسایی تغییرات مغزی در بیماران مبتلا به اماس فراهم آورد و به پزشکان کمک کند تا به درمان‌های دقیق‌تر و سریع‌تر دست یابند.

CAT Boost: CATBoost روشی است که برای پردازش داده‌های پیچیده، به ویژه داده‌های دسته‌بندی طراحی شده است. الگوریتم CATBoost مدلی مبتنی بر گرادیان بوسینگ برای پردازش داده‌ها و پیش‌بینی نتایج است این الگوریتم با استفاده از درخت‌های تصمیم و یادگیری تقویتی می‌تواند مدل‌های پیش‌بینی دقیقی بسازد. این الگوریتم به علت توانایی در یادگیری الگوهای پیچیده و ارتباطات غیرخطی بین ویژگی‌ها، به طور ویژه برای تجزیه و تحلیل داده‌های الکتروانسفالوگرافی مفید است. این الگوریتم می‌تواند

آریفکت‌های مانند پلک زدن و نویزهای عضلاتی نیز به کار می‌روند. این مراحل باعث بهبود کیفیت داده‌های الکتروانسفالوگرافی و افزایش دقت تحلیل‌ها می‌گردد (۴۶). سیگنال‌ها به صورت تجمعی محاسبه و پروفایل سیگنال ایجاد می‌شود، به طوری که میانگین سیگنال از هر نقطه کم می‌گردد. فرایند تحلیل چندرک탈ی سیگنال‌های الکتروانسفالوگرافی برای تشخیص بیماری اماس، پس از اعمال پیش‌پردازش‌های لازم (حذف نویز و آریفکت‌ها)، سیگنال به طور ویژه با استفاده از روش‌های دترندينگ و واریانس دترنده شده تجزیه و تحلیل می‌شود. در ابتدا، پروفایل سیگنال از طریق کم کردن میانگین سیگنال از هر نقطه محاسبه می‌گردد تا نوسانات غیرمرتب حذف شوند. برای تحلیل ویژگی‌های فرکتالی سیگنال و استخراج اطلاعات مرتبط با پیچیدگی آن، ابتدا پروفایل سیگنال تعریف می‌گردد. این پروفایل به ما کمک می‌کند تا نوسانات خالص سیگنال را از مقادیر اصلی آن جدا کنیم و رفتار کلی سیگنال را بررسی نماییم. مراحل این تحلیل به شرح زیر است. پروفایل سیگنال:

تحلیل چندرک탈ی و پردازش سیگنال‌های الکتروانسفالوگرافی برای تشخیص اماس: تحلیل چندرک탈ی روشی است که به مطالعه پیچیدگی‌های غیرخطی و ساختار تصادفی سیگنال‌های الکتروانسفالوگرافی می‌پردازد. این روش قادر است الگوهای پنهانی را در سیگنال‌ها شناسایی کند که ممکن است توسط سایر فن‌ها نادیده گرفته شوند. در پژوهش واتورک و همکاران (۴۶)، برای تحلیل داده‌های الکتروانسفالوگرافی و تشخیص بیماری اماس، از تحلیل چندرک탈ی استفاده می‌گردد که شامل جمع‌آوری داده‌های الکتروانسفالوگرافی از بیماران مبتلا به اماس و گروه کنترل سالم است؛ سپس پیش‌پردازش داده‌ها با فیلتر کردن و حذف نویزها و آریفکت‌ها آغاز می‌شود. داده‌های الکتروانسفالوگرافی در شرایط چشمان باز و بسته ضبط می‌گردد و با فیلتر باندپاس، نویزهای پایین تر از ۰/۵ هرتز و بالاتر از ۵۰ هرتز حذف می‌شوند؛ همچنین از معیار کورتوز برای شناسایی کانال‌های معیوب استفاده می‌گردد و کانال‌های با انحراف معیار بیش از ۵ به طور خودکار حذف می‌شوند. بازبینی بصری و تحلیل مؤلفه‌های مستقل (ICA) برای حذف

$$Y(i) = \sum_{k=1}^i [X(k) - \langle X \rangle]. \quad (1)$$

میانگین سیگنال $\langle X \rangle$ مقدار سیگنال و (k) :

واریانس تعدیل شده برای هر بخش محاسبه و میانگین‌گیری می‌شود:

$$F^2(v, s) = \frac{1}{s} \sum_{i=1}^s \{Y[(v-1)s+i] - y_v(i)\}^2 \quad (2)$$

$y_v(i)$ پروفایل سیگنال، v چندجمله‌ای برآش شده در بخش s ، طول بخش (مقیاس)، i شماره بخش

می‌توان ویژگی‌های دقیق‌تری از سیگنال‌های الکتروانسفالوگرافی استخراج کرد. در ادامه، نمای Hurst با محاسبه شبیه رگرسیون لگاریتمی $\ln F_q(s)$ بر $\ln s$ به دست می‌آید:

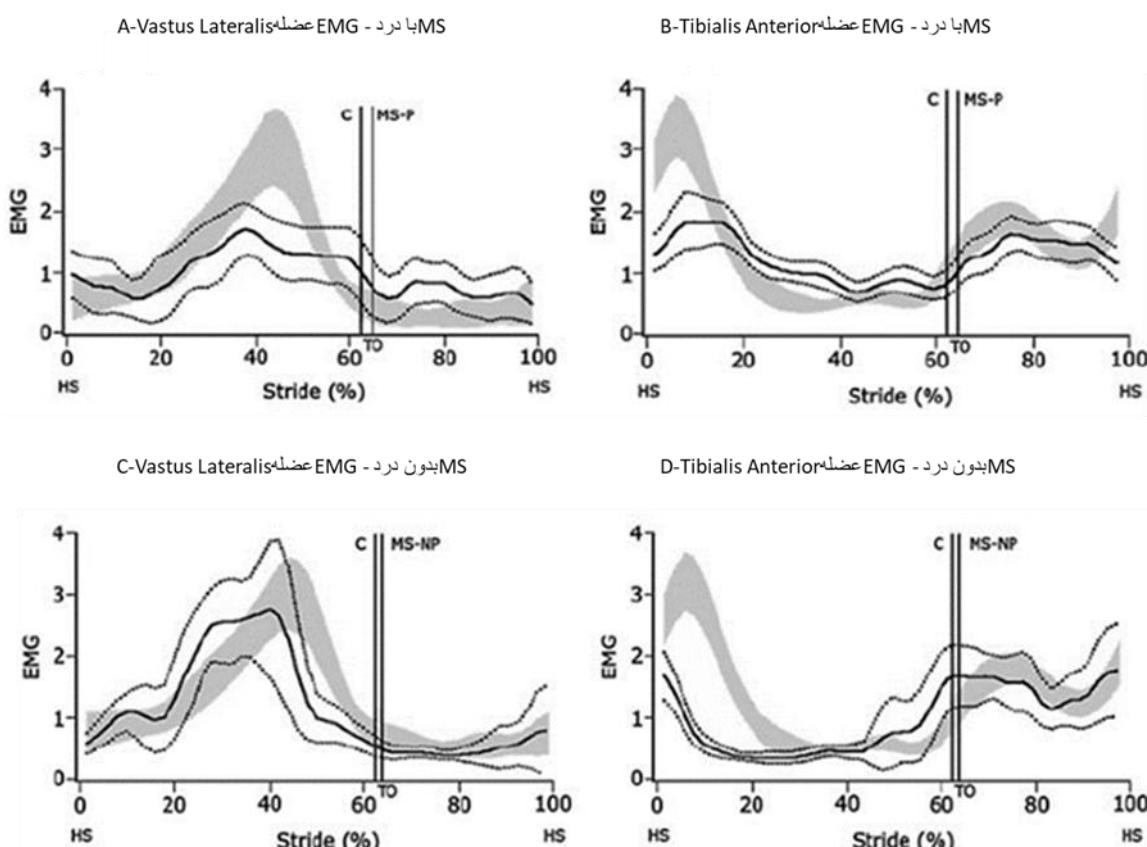
$$\frac{\ln f_q(s)}{\ln s} = h(q) \quad (3)$$

درنهایت، طیف چندرک탈ی $f(\alpha)$ از طریق تبدیل

سپس سیگنال به بخش‌های کوچک‌تر تقسیم می‌گردد و برای هر بخش یک چندجمله‌ای برآش داده می‌شود تا نوسانات خالص از سیگنال استخراج گردد.

که درنهایت تابع نوسان به دست می‌آید. در ادامه، نمای Hurst برای بررسی ویژگی‌های فرکتالی سیگنال محاسبه می‌گردد. این نمای Hurst که به عنوان معیاری برای پیچیدگی سیگنال در مقیاس‌های مختلف q عمل می‌کند، برای سیگنال‌های چندرک탈ی تغییر می‌نماید و می‌تواند به تحلیل دقیق‌تر ویژگی‌های فرکتالی سیگنال کمک کند. با استفاده از این نمای Hurst و محاسبه طیف چندرک탈ی

توسط فیرهای عضلانی تولید می‌شود (۴۸). استفاده از الکترومیوگرافی در ارزیابی عملکرد عضلات و شناسایی الگوهای غیرطبیعی، بهویژه در بیماران با اختلالات حرکتی شدید، امکان درمان هدفمند و مؤثر را فراهم می‌سازد. این تکنیک می‌تواند ناهنجاری‌های مرتبط با ضعف عضلانی، آتروفی و تغییرات در الگوهای الکتریکی را شناسایی کند. با ترکیب نتایج الکترومیوگرافی با سایر ارزیابی‌ها می‌توان به بهینه‌سازی روش‌های توانبخشی و افزایش اثربخشی درمان‌ها دست یافت که این خود اهمیت ویژه‌ای در مدیریت بیماری‌های مزمن مانند اماس دارد. در شکل شماره ۹ فعالیت عضلانی الکترومیوگرافی را در طول چرخه گام برای گروه‌های مختلف کنترل، بیماران اماس با لرزش، بیماران اماس بدون لرزش و پارکینسونی مقایسه شده است. تفاوت‌ها در شدت فعالیت عضلانی نشان‌دهنده مشکلات حرکتی در بیماران اماس و پارکینسون بهویژه در مراحل خاصی از چرخه گام است.



شکل شماره ۹. پروفایل‌های میانگین الکترومیوگرافی فعالیت عضلات در گروه‌های MS و گروه‌های کنترل. نمودار A فعالیت عضله Vastus Lateralis در بیماران MS با درد و گروه کنترل، نمودار C فعالیت عضله Tibialis Anterior در بیماران MS با درد و گروه کنترل، نمودار B فعالیت عضله Tibialis Anterior در بیماران MS با درد و گروه کنترل، نمودار D فعالیت عضله Tibialis Anterior در بیماران MS بدون درد و گروه کنترل.

لاندر تابع مقیاس دهنده $\tau(q)=q \cdot h(q)^{-1}$ محاسبه می‌شود:

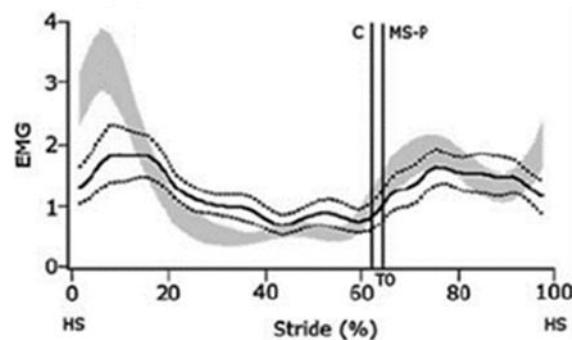
$$f(\alpha) = q \alpha - \tau(q) \quad (4).$$

در این تحقیق، ارتباط میان درجه چندفرکتالی، مدت زمان بیماری و سطح ناتوانی بررسی می‌گردد. درنهایت، با استفاده از طیف چندفرکتالی که از طریق نمای Hurst و قدرت نشانه‌ها محاسبه می‌شود، اطلاعاتی به دست می‌آید که نشان‌دهنده ساختار پیچیده مغز افراد مبتلا به اماس است. این اطلاعات می‌تواند به تشخیص دقیق تر و پیگیری پیشرفت بیماری اماس کمک کند، بهویژه در مراحل اولیه که تغییرات مغزی به طور معمول قابل مشاهده نیستند.

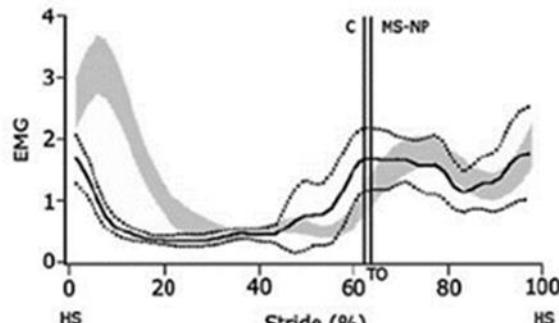
تشخیص اماس با استفاده از الکترومیوگرافی

الکترومیوگرافی ابزاری حیاتی در تشخیص و مدیریت بیماری‌های عصبی، بهویژه در تشخیص اماس است. این روش با اندازه گیری فعالیت الکتریکی عضلات می‌تواند الگوهای حرکتی و اختلالات عملکردی را شناسایی کند. سیگال الکترومیوگرافی جریان الکتریکی کوچکی است که

B-Tibialis Anterior EMG با درد - عضله MS



D-Tibialis Anterior EMG بدون درد - عضله MS



فعالیت عضله Tibialis Anterior در بیماران MS بدون درد و گروه کنترل و نمودار MS در بیماران Vastus Lateralis بدون درد و گروه کنترل را نشان می‌دهد (۴۹)

زندگی بیماران است. در این مطالعه، برای ارزیابی و تشخیص اختلالات حرکتی و بررسی تأثیر برنامه توانبخشی چندرشتی ای فشرده در بیماران مبتلا به مولتیپل اسکلروزیس، از ترکیب حس‌گرهای حرکتی بی‌سیم و الکترومویوگرافی سطحی استفاده شده است. حس‌گرهای اطلاعات دقیقی از سطحی استفاده شده است. حس‌گرهای اطلاعات دقیقی از معیارهای حرکتی مانند سرعت، طول قدم و مدت زمان فازهای گام برداری ارائه کردند و الکترومویوگرافی سطحی نیز فعالیت عضلات و هماهنگی آنها را تحلیل نمود. آزمون‌های کلینیکی و عملکردی مانند آزمون ۱۰ متری، مقیاس اشورث، مقیاس برگه و پرسشنامه‌های گزارش بیمار نیز برای سنجش شاخص‌هایی چون اسپاستیسیته، تعادل و کیفیت راه رفتن استفاده شدند. تحلیل داده‌ها با روش‌های آماری انجام گردید. تا تغییرات پیش و پس از توانبخشی به دقت بررسی شود. تحلیل آماری در این مقاله با استفاده از آزمون‌های آزوچی برای مقایسه نتایج پیش و پس از درمان انجام شد. برای بررسی حساسیت مؤلفه‌های حرکتی در ارزیابی نتایج نورساینس پژوهشکی، بیماران به دو گروه تقسیم گردیدند: افرادی که کاهش در مقیاس EDSS داشتند و افرادی که این کاهش را نداشتند؛ همچنین از ضریب همبستگی پرسون و اسپیرمن برای بررسی ارتباطات میان ویژگی‌های بالینی و تفاوت‌های پیش و پس از درمان استفاده شده است. این رویکرد چندبعدی امکان ارزیابی جامع اختلالات حرکتی و تأثیر مداخلات درمانی را فراهم کرد.

تجزیه موجک تصمیم‌گیری نرم

روش تجزیه موجک تصمیم‌گیری نرم یک تکیک پیشرفته برای استخراج ویژگی‌ها در مسائل شناسایی الگو و طبقه‌بندی است. روش موجک نرم ترکیبی از تبدیل موجک و فرایند نرم‌سازی است که برای کاهش نویز و حفظ ویژگی‌های اصلی سیگنال طراحی شده است. در این روش، پس از تجزیه سیگنال با تبدیل موجک، آستانه نرمی برای حذف ضرایب کوچک که نمایانگر نویز هستند، اعمال می‌شود و تنها ویژگی‌های مهم سیگنال حفظ می‌گردد. این

الکترومویوگرافی به تمایز میان آسیب‌های آکسونال و میلین می‌پردازد که برای تشخیص صحیح و تعیین نوع اختلال ضروری است (۵۰). یکی از این روش‌ها مطالعه هدایت عصبی است که با بررسی سرعت هدایت عصبی و زمان تأخیر در اعصاب حسی و حرکتی انجام می‌گیرد. روش دیگر، الکترومویوگرافی واحد حرکتی است که در آن تعداد واحدهای حرکتی فعال در عضلات تخمین زده می‌شود و می‌تواند نشان‌دهنده تغییرات در عملکرد عصبی باشد؛ همچنین الکترومویوگرافی تک الیاف برای ارزیابی جیتری در اتصالات عصبی-عضلانی به کار می‌رود و به عنوان حساس‌ترین آزمون در شناسایی اختلالات این ناحیه شناخته می‌شود. علاوه بر این، بررسی آماره‌های عضلانی نظری قدرت عضلانی، توده عضلانی و تغییرات در بازتاب‌های تاندونی عمیق نیز انجام می‌گردد. این مجموعه آزمایش‌ها به طور دقیق تغییرات در عملکرد عصبی و عضلانی را ارزیابی و به تشخیص افتراقی اماس کمک می‌کنند (۵۱). معتبرترین روش برای پایش بیماری، شاخص عدد واحد حرکتی است. بالاتر بودن MUNIX به معنای وجود تعداد بیشتری از واحدهای حرکتی سالم است؛ درنتیجه، MUNIX در بیماران مبتلا به بیماری نورون حرکتی (ALS) به طور چشمگیری پایین‌تر از افراد سالم است (۵۲). این آزمایش‌ها به تفکیک میان آسیب‌های آکسونال و میلین مربوط به پلی‌نورپاتی کمک می‌کنند و می‌توانند برای تعیین نوع و شدت بیماری استفاده شوند. در مقاله هوانگ و همکاران (۵۲) به ارزیابی اختلالات حرکتی در بیماران مبتلا اماس پرداخته شده است. از روش الکترومویوگرافی سطحی برای تحلیل فعالیت عضلات و شناسایی الگوهای غیرطبیعی در آنها استفاده می‌گردد. در این روش، داده‌های خام الکترومویوگرافی با استفاده از حسگرهای بی‌سیم جمع‌آوری می‌شوند و پس از ثبت سیگنال‌ها با نرخ نمونه‌برداری ۱۰۰۰ هرتز، داده‌ها تحت پردازش‌های مختلف قرار می‌گیرند. هدف اصلی این تحلیل‌ها شناسایی اختلالات حرکتی و بررسی تأثیر آنها بر کیفیت

فرایند باعث تقویت سیگنال اصلی و افزایش دقت در شناسایی ویژگی‌های پیچیده می‌شود. از مزایای این روش می‌توان به کاهش نویز، انعطاف‌پذیری بالا در پردازش انواع سیگنال‌ها و قابلیت استخراج ویژگی‌های مهم برای مدل‌های طبقه‌بندی اشاره کرد. کاربردهای آن شامل شناسایی گفتار، تشخیص ناهنجاری‌ها در سیگنال‌های پزشکی و پردازش تصویر است (۵۳). روش موجک نرم از تبدیل موجک معمولی شروع می‌شود؛ اما در آن یک فرایند نرم‌سازی (مانند اعمال یک آستانه نرم) به سیگنال‌های تجزیه‌شده افزوده می‌گردد تا تأثیرات نویز کاهش یابد و ویژگی‌های اصلی سیگنال حفظ شود. در روش نرم‌سازی که اغلب برای کاهش نویز و بهبود ویژگی‌ها از یک آستانه نرم استفاده می‌گردد، برای هر سطح از تجزیه موجک، ویژگی‌های کوچک و غیرمفید (که معمولاً نویز هستند) حذف می‌شوند و ویژگی‌های بزرگ و مهم باقی می‌مانند. این کار سبب می‌گردد که دستگاه در برابر نویز مقاوم‌تر شود و به استخراج ویژگی‌های اصلی سیگنال کمک کند. روش تجزیه موجک تصمیم‌گیری نرم ترکیبی از شبکه‌های خودرمندگذار پیچشی و تحلیل موجک است که برای حذف نویز و بازسازی سیگنال به کار می‌رود. در این روش، لایه‌های رمزگذار از واحدهای آستانه‌بندی نرم استفاده می‌کنند که به طور تطبیقی در حین آموزش تنظیم می‌شوند و لایه‌های رمزگشا از واحدهای خطی برای بازسازی داده بهره می‌برند. این مدل از داده‌های بزرگ برای یادگیری آستانه‌ها و فیلترهای موجک استفاده می‌کند و نسبت به روش‌های کلاسیک مانند VisuShrink و BayesShrink تطبیق‌پذیری و کارایی بیشتری دارد. این مدل با حفظ جزئیات اصلی سیگنال و حذف نویز، تفسیرپذیری بالایی دارد و در کاربردهایی مانند کاهش نویز تصاویر و بازسازی داده‌ها بسیار مؤثر است (۵۴).

تشخیص لرزش‌های مرتبط با مولتیپل اسکلروزیس نیز با الکتروموگرافی بررسی می‌شوند. لرزش‌ها در بیماران اماس شایع و ناتوان‌کننده هستند و تشخیص آن‌ها از سایر انواع لرزش‌ها مانند لرزش ضروری و لرزش پارکینسونی چالش‌برانگیز است. تخمین زده می‌شود که لرزش در حدود ۲۵ تا ۶۰ درصد از بیماران مبتلا به مولتیپل اسکلروزیس رخ

دهد. در این دیدگاه (۵۵)، روش جدیدی به نام SDWD برای تشخیص این لرزش‌ها معرفی شده است. در این روش، داده‌های الکتروموگرافی، شتاب‌سنج و داده‌های بالینی از ۱۲۰ بیمار (۴۰ بیمار اماس، ۴۱ بیمار لرزش ضروری و ۳۹ بیمار پارکینسون) جمع‌آوری گردیده است. این داده‌ها برای محاسبه چگالی طیفی توان و تحلیل ROC برای طبقه‌بندی خودکار لرزش‌ها استفاده شد؛ همچنین ارتباط میان ویژگی‌های طیفی و بالینی با استفاده از مدل رگرسیون بردار پشتیبانی بررسی گردید. دقت بالای طبقه‌بندی تا ۹۱/۶۷ درصد با استفاده از داده‌های شتاب‌سنج و ۹۱/۶۰ درصد با استفاده از سیگنال‌های الکتروموگرافی، توانایی روش در شناسایی ارتباط‌های معنادار میان ویژگی‌ها و نمرات بالینی که می‌تواند در بهبود فرایند تشخیص مؤثر باشد، از مزایای این روش هستند. وابستگی به انتخاب داده‌های آموزشی که ممکن است بر دقت تأثیر بگذارد و همچنین نیاز به تحقیقات بیشتر با استفاده از این روش برای تأیید کارایی آن در بیماری‌های مختلف، از محدودیت‌ها در این روش هستند.

تشخیص اماس با استفاده از داده‌های بالینی

تشخیص زودهنگام و مؤثر بیماری اماس به ویژه در کشورهای در حال توسعه، نیازمند استفاده از داده‌های بالینی به عنوان یک ابزار کلیدی است. تشخیص اماس نیازمند ترکیبی از تاریخچه بالینی، داده‌های تصویربرداری و معیارهای تشخیصی است. از نظر بالینی، اماس با اپیزودهای مجرا («حملات» یا «تشدید» یا «عود») اختلال عملکرد عصبی مشخص می‌شود. تشخیص اماس بر اساس علائم بالینی و شرح حال بیمار شامل وجود حملات یا علائم عصبی است که بسته به محل در گیری در دستگاه عصبی مرکزی، متغیر است. این حملات ممکن است با یا بدون بهبودی کامل دنبال گردد که می‌تواند شامل نوریت اپتیک، میلیت، دوبینی، نیستاگموس، سرگیجه، بی‌حسی صورت و اختلال در بلع با گفتار باشند (۵۶). نوع و شدت علائم ناشی از این اپیزودها به طور چشمگیری میان بیماران متفاوت است و به محل در گیری عصبی بستگی دارد. کارایی ضایعات قشری و نشانه ورید مرکزی به عنوان ابزارهای تشخیصی تحلیل گردید (۵۷).

گره به صورت تصادفی تقسیم می‌گردد و داده‌های ورودی مستقیماً برای ساخت درخت‌ها استفاده می‌شوند. این تصادفی‌سازی مضاعف باعث کاهش وابستگی میان درخت‌ها و افزایش توانایی مدل در تعیین دهی می‌گردد. در این مقاله، روش الگوریتم ارشد درختان روی داده‌های پیچیده آزمایش شد و نتایج نشان داد که این روش دقیق‌تر بسیار بالایی دارد و به سبب تصادفی‌سازی بالا، این روش به طور خاص در برابر پیش‌پرداز مقاوم است و علاوه بر آن، سرعت اجرای بالایی در فرایند آموزش و پیش‌بینی دارد. در تشخیص یماری اماس، الگوریتم ارشد درختان توانسته است دقیق ۹۶/۷۴ درصد را به دست آورد. این الگوریتم در شبیه‌سازی روابط پیچیده و غیرخطی در داده‌های بالینی و تصویری ییمارانی که مبتلا به اماس هستند، به شکل مؤثری عمل می‌کند.

الگوریتم جنگل تصادفی

الگوریتم جنگل تصادفی یکی از پرکاربردترین الگوریتم‌های یادگیری ماشین است که به سبب ساختار ترکیبی خود، دقیق‌تر و پیش‌بینی‌تر است. الگوریتم جنگل تصادفی یک مدل یادگیری ماشین مبتنی بر روش‌های ensemble است که از ترکیب چندین درخت تصمیم‌گیری برای پیش‌بینی استفاده می‌کند. این الگوریتم با ایجاد مجموعه‌ای از درخت‌های تصمیم‌گیری بر پایه نمونه‌گیری‌های تصادفی از داده‌ها و انتخاب ویژگی‌ها، تنوع مدل‌ها را افزایش و مشکل پیش‌پردازش را کاهش می‌دهد. برای پیش‌بینی، نتایج همه درخت‌ها تجمعی می‌گردد (میانگین برای رگرسیون و رأی‌گیری اکثریت برای طبقه‌بندی) تا خروجی نهایی تولید شود. جنگل تصادفی به سبب مقاومت در برابر نویز و دقیق‌تر باشد، در مسائل مختلف کاربرد دارد (۵۹). یکی از مزایای جنگل تصادفی قابلیت آن در انتخاب ویژگی‌های مؤثر است که به الگوریتم اجازه می‌دهد تا در مواجهه با داده‌های پیچیده و دارای نویز، عملکرد بهتری از خود نشان دهد. در مقاله بیو و همکاران (۵۹)، روش جنگل تصادفی از نظر نظری تحلیل شده و رفتار، پایداری و قدرت تفسیر آن بررسی گردیده است. جنگل تصادفی از مجموعه‌ای از درخت‌های تصمیم‌گیری تشکیل شده است که هر درخت

تحقیقات برای یافتن راه حل‌هایی به دنبال ایجاد مدل‌های قابل فهم ماشین یادگیری برای تشخیص پیشگیرانه اماس با استفاده از داده‌های بالینی صورت گرفته است. تجزیه داده‌های بالینی برای رسیدن به دقیق‌ترین روش تشخیص اماس فرایندی ساخت و فرازه از توان انسانی است؛ بنابراین، برای رسیدن به نتیجه مطلوب، از الگوریتم‌های یادگیری ماشین برای تحلیل داده‌ها استفاده می‌گردد. در ادامه، الگوریتم‌های ارشد درختان، جنگل تصادفی و XGBoost معرفی می‌شوند.

الگوریتم ارشد درختان

الگوریتم ارشد درختان (GBDT) یکی از نسخه‌های بهبود یافته الگوریتم‌های درخت تصمیم‌گیری است که در مقایسه با مدل‌های ساده‌تر، از قدرت پیشرفتی در پیش‌بینی و تحلیل داده‌های پیچیده برخوردار است. الگوریتم درختان گسترش یافته از روش‌های پیشرفته در یادگیری ماشین است که به بیرونی دقیق‌تر مدل‌های درخت تصمیم‌گیری ممکن می‌کند. در این الگوریتم، مانند جنگل‌های تصادفی، از تعدادی درخت تصمیم‌گیری برای پیش‌بینی استفاده می‌شود؛ اما برخلاف روش‌های دیگر که از نمونه‌گیری با جایگزینی استفاده می‌کنند، درختان در ET از نمونه‌گیری تصادفی ویژگی‌ها در هنگام تقسیم هر گره بدون جایگزینی استفاده می‌نمایند. این فرایند موجب کاهش انحراف و بهبود عملکرد مدل در داده‌های پیچیده می‌گردد. درختان ET معمولاً از ویژگی‌های تصادفی برای انتخاب نقاط برش استفاده می‌کنند که این امر به کاهش واریانس مدل کمک می‌نماید. این الگوریتم به ویژه در مسائلی با ویژگی‌های پیچیده و نویز بالا عملکرد خوبی دارد. در مقاله گرتس و همکاران (۵۸)، روش الگوریتم ارشد درختان به عنوان یک الگوریتم مجموعه‌ای معرفی شده است که از چندین درخت تصمیم‌گیری برای پیش‌بینی استفاده می‌کند. این الگوریتم با افزایش سطح تصادفی‌سازی در فرایند ساخت درخت‌ها، نسبت به جنگل‌های تصادفی، از ویژگی‌های متفاوتی بهره‌مند است. تصادفی‌سازی در این روش در دو بخش کلیدی اعمال می‌شود. برخلاف جنگل‌های تصادفی که از نمونه‌گیری بوت‌استرپ استفاده می‌کنند، در این نوع نیازی به این نوع نمونه‌گیری نیست. به جای آن، مقادیر در هر

پیچیده در داده‌ها دارد. XGBoost از فنونی مانند بهینه‌سازی نرخ یادگیری و جلوگیری از بیش برآش با استفاده از Regularization بهره می‌برد که موجب می‌شود، این الگوریتم در مواجهه با داده‌های دارای نویز و پیچیده بهتری داشته باشد. این الگوریتم در شبیه‌سازی روابط پیچیده میان مؤلفه‌های بالینی، آزمایش‌های و داده‌های تصویری موفق عمل کرده است. یکی از ویژگی‌های برجسته XGBoost این است که حتی در داده‌های پیچیده و با نویز زیاد نیز می‌تواند الگوهای پنهان را شناسایی کند و به دقت بالایی در پیش‌بینی بیماری دست یابد (۶۰). در تشخیص بیماری اماس، XGBoost توانسته است دقت ۹۲/۱۱ درصد را به دست آورد. عملکرد سه الگوریتم ارشد درختان، جنگل تصادفی و XGBoost در جدول شماره ۳ مقایسه شده است. الگوریتم XGBoost با F1-Score ۹۴/۶۷ درصد و بازخوانی بالا (۹۷/۲۶ درصد) بهترین عملکرد را دارد و برای شناسایی نمونه‌های مثبت مناسب‌تر است. جنگل تصادفی با F1-Score برابر ۹۲/۷۴ درصد عملکرد متوازنی بین دقت (۹۳/۴۲ درصد) و بازخوانی (۹۳/۱۵ درصد) ارائه می‌دهد. الگوریتم XGBoost با F1-Score ۹۱/۷۲ درصد و دقت کمتر، ضعیف‌ترین عملکرد را در این مقایسه دارد.

روی نمونه‌ای بوت استرپ شده از داده‌های ورودی آموزش داده می‌شود. در هر گره درخت، یک زیرمجموعه تصادفی از ویژگی‌ها انتخاب می‌گردد و بهترین تقسیم تنها بر اساس این زیرمجموعه انجام می‌گیرد. این تصادفی‌سازی در انتخاب ویژگی‌ها و نمونه‌ها، تنوع بالای میان درخت‌ها ایجاد می‌کند و از همبستگی فراوان میان آن‌ها جلوگیری می‌نماید. نتیجه نهایی پیش‌بینی‌ها از طریق رأی گیری اکثریت در طبقه‌بندی یا میانگین گیری در رگرسیون تعیین می‌شود. نتایج این مقاله نشان می‌دهد که الگوریتم جنگل تصادفی در بسیاری از مسائل طبقه‌بندی و رگرسیون عملکرد بسیار خوبی دارد و دقت آن معمولاً بالای ۹۰ درصد است. الگوریتم بهویژه در تحلیل روابط پیچیده میان ویژگی‌های بالینی و پاراکلینیکی بسیار مؤثر است و می‌تواند به پژوهشکاران در شناسایی الگوهای پنهان در داده‌های مربوط به بیماران کمک کند.

XGBoost

یکی از شناخته‌شده‌ترین و کارآمدترین الگوریتم‌های یادگیری ماشین XGBoost است که از روش تقویت تدریجی برای بهبود دقت مدل‌ها استفاده می‌کند. این الگوریتم بهویژه برای پردازش داده‌های پیچیده و حجمی طراحی شده است و توانایی بالایی در شبیه‌سازی الگوهای

جدول شماره ۳. مقایسه XGBoost، RF و ET

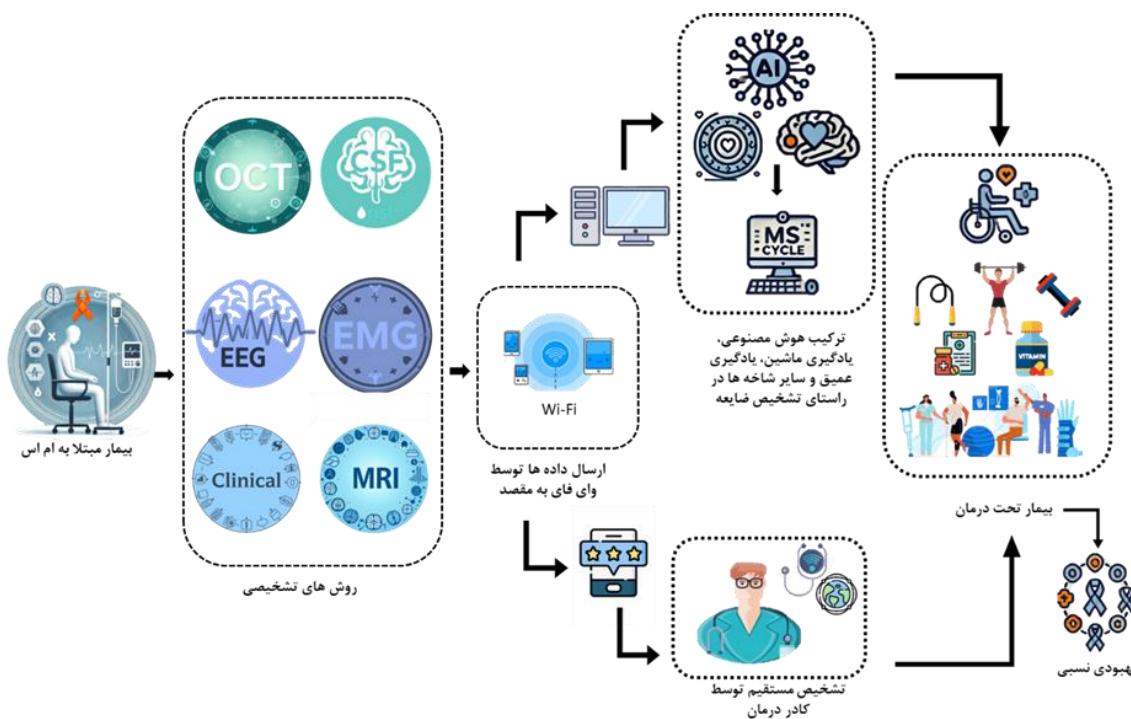
الگوریتم	دقت	Recal	F1-score
ارشد درختان (ET)	۷۴/۹۴	۲۶/۹۷	۶۷/۹۴
جنگل تصادفی (RF)	۴۲/۹۳	۱۵/۹۳	۷۴/۹۲
XGBoost	۱۱/۹۲	۱۵/۹۳	۷۲/۹۱

و تصویربرداری دارند. الگوریتم‌های پیشرفته یادگیری عمیق مانند شبکه‌های عصبی کانولوشنی توانمندند که الگوهای پیچیده را در تصاویر ام آر آی شناسایی کنند و دقت تشخیص را به طور قابل توجهی بالا برند. فنون تصویربرداری پیشرفته، آسیب‌های مغزی مرتبط با اماس را با دقت بیشتری شناسایی می‌کنند؛ همچنین حس گرهای هوشمند بیومتریک

پلتفرم پیشنهادی برای تشخیص خودکار اماس تشخیص اماس به عنوان یک بیماری خودایمنی پیچیده، نیازمند استفاده از فناوری‌های نوین برای افزایش دقت و سرعت تشخیص و کنترل هدفمند آن است. با بررسی‌های انجام شده دریافتیم که فناوری‌های هوش مصنوعی و یادگیری ماشین، یادگیری عمیق نقش مؤثری در تحلیل داده‌های بالینی

شناسایی می‌کند. این ویژگی به پزشکان این امکان را می‌دهد که به سرعت به وضعیت بیمار واکنش نشان دهند و اقدامات لازم را انجام دهند. یکی از ویژگی‌های کلیدی این پلتفرم استفاده از داده‌های کلان و فنون پیشرفته یادگیری ماشین برای پیش‌بینی روند پیشرفت بیماری و کمک به پزشکان در اتخاذ تصمیمات درمانی بهینه است. تحلیل داده‌های تاریخی و بالینی دقت تشخیص را افزایش می‌دهد و کیفیت درمان را بهبود می‌بخشد؛ همچنین دستگاه می‌تواند به عنوان زیرساختی برای پشتیبانی از تصمیم‌گیری بالینی عمل کند و اطلاعات و تحلیل‌های دقیقی را در اختیار پزشکان قرار دهد تا تصمیمات درمانی با دقت بیشتری اتخاذ شوند. برای سهولت استفاده، این پلتفرم یک رابط کاربری ساده و کاربرپسند دارد که قابلیت ادغام به عنوان مژوی در دستگاه‌های مدیریت اطلاعات سلامت یا نرم‌افزارهای بیمارستانی را دارد. این ویژگی به پزشکان و کادر درمانی کمک می‌کند تا به راحتی از قابلیت‌های جدید بهره‌برداری نمایند. پلتفرم تشخیصی پیشنهادی ما، برخلاف روش‌های موجود که معمولاً به یک نوع داده مانند فقط MRI تکیه دارند، از داده‌های چندمدلی شامل MRI، OCT و CSF استفاده می‌کند. این رویکرد ترکیبی به ما این امکان را می‌دهد که ابعاد مختلف بیماری را بررسی نماییم و به تشخیص دقیق‌تری دست یابیم. این فناوری‌ها و رویکردهای خلاقانه اتفاق‌های تازه‌ای در تشخیص و مدیریت امراض می‌گشاید و امید به آینده‌ای روشن‌تر برای بیماران را افزایش خواهند داد.

امکان پایش مداوم وضعیت بیمار را فراهم می‌سازند و به تشخیص سریع کمک می‌کنند. ترکیب روش‌های تشخیصی نظیر ام آر آئی، الکتروانسفالوگرافی و آزمایش‌های مایع مغزی نخاعی به کاهش احتمال تشخیص نادرست و افزایش دقت در شناسایی این بیماری کمک می‌نمایند. این رویکرد چندوجهی کادر درمان را در تصمیم‌گیری‌های پیچیده یاری می‌دهد. دستگاهی برای تشخیص هوشمند و خودکار ام اس پیشنهاد می‌گردد (شکل شماره ۱۰). این دستگاه با ترکیب روش‌های سنتی نظیر MRI، الکتروانسفالوگرافی و آزمایش‌های مایع مغزی نخاعی به همراه الگوریتم‌های پیشرفته، دقت و سرعت تشخیص را به طور چشمگیری افزایش می‌دهد و امکان پایش مستمر وضعیت بیماران را فراهم می‌آورد. پلتفرم از الگوریتم‌های یادگیری عمیق، به ویژه شبکه‌های عصبی کانولوشنی، برای شناسایی الگوهای پیچیده در تصاویر MRI استفاده می‌کند که به افزایش دقت در تشخیص ضایعات مغزی و کاهش خطای ناشی از روش‌های دستی سنتی کمک می‌نماید. این دستگاه همچنین قابلیت جمع‌آوری و پردازش داده‌های متنوع از منابع مختلف، از جمله تصویربرداری پزشکی، نتایج آزمایشگاهی و اطلاعات حسگرهای بیومتریک را به صورت یکپارچه دارد. این فرایند از طریق API‌ها و دستورالعمل‌های استاندارد انجام می‌شود و امکان ادغام با دستگاه‌های اطلاعاتی بیمارستانی را فراهم می‌آورد. با بهره‌گیری از فناوری اینترنت اشیا، پلتفرم به طور لحظه‌ای وضعیت بیمار را پایش و تغییرات غیرمعمول را سریعاً



شکل شماره ۱۰. دستگاه پیشنهادی برای تشخیص ام اس

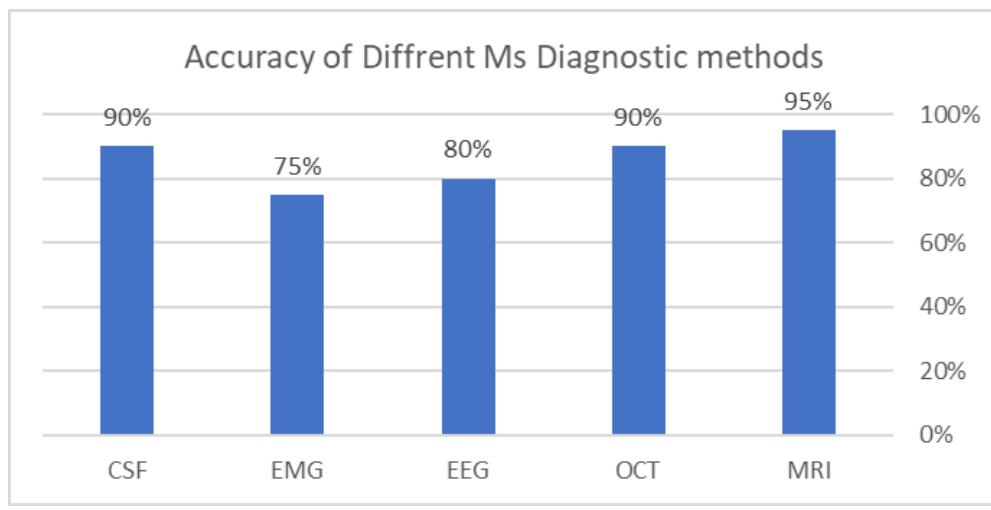
اما استفاده از هوش مصنوعی در تشخیص بیماری ام اس با محدودیت‌ها و چالش‌های متعددی مواجه است. هوش مصنوعی به‌ویژه در شبکه‌های عصبی عمیق، به داده‌های آموزشی بزرگ و کیفیت بالا نیاز دارد. در حال حاضر، جمع‌آوری داده‌های پزشکی ممکن است به علی‌مانند محدودیت دسترسی به تجهیزات پیشرفته، هزینه‌های بالا و استانداردسازی نکردن فرایند جمع‌آوری داده‌ها مشکل باشد. استفاده از روش‌های یادگیری انتقالی و شبکه‌های پیش‌آموزشی مانند ResNet152V2 می‌تواند به کاهش نیاز به داده‌های بزرگ کمک کند؛ همچنین استانداردسازی فرایند جمع‌آوری داده‌ها و توسعه دیتاست‌های مشترک میان مرکزهای پزشکی می‌تواند این مشکل را کاهش دهد. تعمیم‌پذیری مدل‌ها از دیگر موارد است. مدل‌هایی که بر اساس داده‌های خاصی آموزش دیده‌اند، ممکن است هنگام مواجهه با داده‌های جدید از مراکز مختلف عملکرد ضعیفی داشته باشند؛ همچنین تفسیر‌پذیری پایین از موارد دیگری است که این مدل‌ها، به‌ویژه در شبکه‌های عصبی کانولوشنی، باعث کاهش اعتماد پزشکان به نتایج می‌شود و تصمیم‌گیری نهایی همچنان نیاز به بررسی انسانی دارد. نیاز به محاسبات سنگین و منابع پردازشی قوی نیز از دیگر چالش‌های است. پردازش

یافته‌های پژوهش

روش‌های بررسی شده نشان‌دهنده تنوع و پیشرفت‌های انجام شده در تشخیص بیماری ام اس با استفاده از روش‌های مختلف هستند. استفاده از سیگنال‌های الکتروانسفالوگرافی و تحلیل چندفراکتالی (MF DFA) به شناسایی الگوهای پیچیده و غیرخطی در بیماران کمک می‌کند. این روش به علت دقت بالا و نیاز نداشتن به فرایندهای تهاجمی، به‌ویژه در مراحل اولیه بیماری، به عنوان گزینه‌ای مناسب مطرح شده است. شناسایی نشانگرهای یولوژیکی از مایع مغزی نخاعی و پروتئین‌های خاص مانند GFAP و NFL، اطلاعات دقیقی درباره پیشرفت بیماری و فعالیت‌های التهابی ارائه می‌دهد. هرچند که این روش از دقت بالایی برخوردار است، هزینه بالای آن و نیاز به تهاجم در نمونه‌برداری ممکن است برای برخی بیماران مشکل ساز باشد. آزمایش‌های مایع مغزی نخاعی به شناسایی نشانگرهای التهاب دستگاه هوش مصنوعی، به‌ویژه شبکه‌های عصبی کانولوشنی، در تشخیص از طریق تصاویر OCT، دقت بسیار بالایی را به همراه دارد و می‌تواند به کاهش استرس و زمان انتظار بیماران کمک کند؛

بررسی عملکرد عصبی-عضلاتی هستند که در تشخیص مشکلات حرکتی کاربرد دارند. در نمودار شماره ۱ دقت پنج روش مختلف به تفکیک نمایش داده شده است. میانگین دقت‌های مربوط به استفاده از روش ام آر آی که عمدتاً تأکید بر استفاده از هوش مصنوعی و الگوریتم‌های پیشرفته را دارد، دقت ۹۵ درصدی حاصل شده است، داده‌ها بر اساس تحلیل OCT با مدل‌های هوش مصنوعی مانند شبکه‌های عصبی کانولوشنی نشان می‌دهد که دقت استفاده از این روش ۹۰ درصد است. داده‌های مربوط به الکتروانسفالوگرافی نشان می‌دهد تحلیل این سیگنال‌های با روش‌های چندفراکتالی دقت را به ۸۰ درصد می‌رساند و میانگینی از تحلیل سیگنال‌های الکترومیوگرافی دقیقی معادل ۷۵ درصد را ثبت می‌کند؛ همچنین با بررسی میانگین دقت استفاده از روش آزمایش‌های مایع مغزی نخاعی دقت ۹۰ درصد به دست آمده است. به طور کلی، روش ام آر آی با ۹۵ درصد بالاترین دقت را به خود اختصاص داده است، در حالی که روش الکترومیوگرافی با دقت ۷۵ درصد کمترین دقت را دارد. سایر روش‌ها، یعنی OCT و آزمایش‌های مایع مغزی نخاعی، هر دو با دقت ۹۰ درصد با داشتن کارایی مناسب در تشخیص بیماری اماس، رتبه یکسانی را کسب نموده‌اند. این نمودار به‌وضوح نشان می‌دهد که انتخاب روش مناسب برای تشخیص می‌تواند تأثیر فراوانی بر دقت نتایج داشته باشد. بر اساس مقایسه‌های انجام شده، بهره‌گیری از فنون پیشرفته تصویربرداری MRI در کنار الگوریتم‌های هوش مصنوعی و تلفیق نشانگرهای زیستی، دقیق‌ترین و کارآمدترین رویکرد در ابعاد تشخیصی و روان‌شناختی محسوب می‌شود.

داده‌های تصویری حجمی نیازمند سخت‌افزارهای قدرتمند است که در مراکز درمانی کوچک ممکن است در دسترس نباشد. علاوه بر این، ریسک پیش‌پردازش در مدل‌های هوش مصنوعی، بهویژه در صورت تنوع نداشتن داده‌ها می‌تواند عملکرد آنها را تحت تأثیر قرار دهد. با وجود این، ترکیب روش‌های تصویربرداری مانند ضایعات قشری (CLs) و نشانه رگ مرکزی (CVS) نیز دقت تشخیص را به میزان چشمگیری افزایش می‌دهد و می‌تواند به بهبود تجربه کلی بیماران و پزشکان کمک کند. مهم‌ترین ابزار تشخیصی ام آر آی است که با دقت بالا می‌تواند ضایعات مغزی و نخاعی را شناسایی و پیشرفته بیماری را ردیابی نماید. با وجود اینکه تصویربرداری MRI یکی از بهترین روش‌ها برای تشخیص اماس است؛ اما در شناسایی ضایعات کوچک یا تغییرات اولیه محدودیت‌هایی دارد؛ همچنین چالش‌های استفاده از OCT در تشخیص اماس وجود دارد؛ زیرا تغییرات ضخامت شبکیه ممکن است با دیگر بیماری‌ها اشتباه گرفته شوند. نبود معیارهای استاندارد برای ترکیب روش‌های تصویربرداری با الگوریتم‌های هوش مصنوعی نیز پیچیدگی‌ها را افزایش می‌دهد. محدودیت‌های هزینه‌ای و زیرساختی در مراکز درمانی نیز مانع از دسترسی به تجهیزات پیشرفته می‌گردد؛ بنابراین، تفاوت در کیفیت داده‌ها و استانداردهای تصویربرداری، نیاز به یکسان‌سازی و نرم‌افزاری تصاویر را ضروری می‌کند؛ همچنین روش‌های مبتنی بر هوش مصنوعی مانند CNN در تحلیل تصاویر ام آر آی و شناسایی الگوهای پیچیده، دقت بسیار بالایی دارند و به عنوان یکی از پیشرفته‌ترین روش‌ها شناخته می‌شوند. از دیگر روش‌ها، پتانسیل‌های برانگیخته برای ثبت پاسخ‌های عصبی و الکترومیوگرافی برای



نمودار شماره ۱. مقایسه دقت روش‌های بررسی شده

قابل قبولی به همراه داشته است. گفتنی است، در کنار همه فواید ارزشمند استفاده از هوش مصنوعی چالش‌هایی نمایان است. مدل‌های هوش مصنوعی به داده‌های باکیفیت و متنوع نیاز دارند. داده‌های پزشکی معمولاً به سبب مسائل حريم خصوصی محدود هستند و ممکن است کیفیت پایین یا نویر بسیار داشته باشند. مدل‌هایی که بر اساس مجموعه‌ای خاص از داده‌ها آموزش می‌یابند، ممکن است در مواجهه با داده‌های جدید از مراکز مختلف عملکرد ضعیفی داشته باشند. پردازش داده‌های تصویری حجمی نیازمند سخت‌افزارهای قدرتمند است که ممکن است در دسترس همه مراکز درمانی نباشد. مدل‌ها ممکن است ویژگی‌های خاص داده‌های آموزشی را یاد بگیرند و در داده‌های جدید عملکرد مطلوبی نداشته باشند؛ همچنین پیاده‌سازی الگوریتم‌های هوش مصنوعی و نیاز به آموزش کارکنان برای استفاده از این فناوری‌ها ممکن است برای بسیاری از مراکز درمانی چالش‌برانگیز باشد. این چالش‌ها می‌توانند در روند تشخیص و درمان بیماران مبتلا به امراض تأثیرگذار باشند و نیاز به راهکارهای مناسب برای غلبه بر آن‌ها احساس می‌شود. امید است که در آینده، ترکیب و ادغام روش‌ها و شخصی‌سازی روند درمان و تشخیص بتواند به پایش پیشرفت بیماری و ارزیابی تأثیر درمان‌ها کمک کند و با ارائه درمان‌های شخصی‌سازی شده، کیفیت زندگی بیماران را بهبود بخشد. با توجه به پلتفرم پیشنهادی می‌توان درصد و میزان خطای را به کمترین حالت ممکن رساند؛ زیرا

بحث و نتیجه‌گیری

در این مقاله به بررسی روش‌های تشخیص اماس با دقت و حساسیت بالا در مسیرهای مختلف مانند یادگیری ماشین، یادگیری عمیق، هوش مصنوعی و داده‌های گوناگون از جمله تصاویر ام آر آی، OCT، داده‌های بالینی، الکتروانسفالوگرافی، آزمایش‌های مایع مغزی نخاعی و الکترومیوگرافی پرداخته شد. ابتدا به صورت جامع بر روش‌های تشخیص بیماری اماس مطالعاتی صورت گرفت و در میان آن‌ها، معتبرترین روش‌ها که جامعیت بیشتری در علم پزشکی داشتند، برای بررسی بیشتر استفاده شدند. مهم‌ترین گام در درمان این بیماری، دقت بالا و خطای حداقل در تشخیص سریع آن است؛ زیرا این بیماری درمان مؤثر و قلعی ندارد و تلاش بر به حداقل رساندن تخریب و پیشرفت بیماری است. نتایج بررسی‌ها نشان می‌دهد که روش مبتنی بر ام آر آی کارآمدترین است و ترکیب این روش‌ها در درمان بیماران تأثیر بسیاری دارد. استفاده همزمان از فنونی مانند الکتروانسفالوگرافی، ام آر آی و آزمایش‌های مایع مغزی نخاعی کمک می‌کند تا پزشکان تصویر جامع‌تری از وضعیت بیماری به دست آورند و درمان‌های مؤثرتری تجویز کنند. ترکیب تصاویر ام آر آی با الگوریتم‌های هوش مصنوعی مانند شبکه‌های عصبی کانولوشن دقت تشخیص را به طرز چشمگیری افزایش می‌دهد؛ همچنین استفاده از الگوریتم درختان تصمیم و یادگیری عمیق در تصاویر OCT نیز نتایج

به کار بردن چندین روش کارآمد به صورت همزمان و در پی آن، استفاده از الگوریتم‌های هوش مصنوعی و دیگر روش‌های خودکار تشخیص، در کنار تشخیص کادر درمان می‌تواند به کوتاه شدن مسیر تشخیص و بالا رفتن درصد دقت منجر شود و میزان آسیب توسط بیماری را کاهش دهد.

تعارض منافع

نویسنده‌گان هیچ تعارض منافعی ندارند.

کد اخلاق

با توجه به بررسی داده‌های موجود با دسترسی آزاد نیازی به کد اخلاق نداشت.

حمایت مالی

در جهت انجام این مطالعه از هیچ سازمانی حمایت مالی دریافت نشده است.

مشارکت نویسنده‌گان

تمامی نویسنده‌گان در نگارش مقاله مشارکت نموده اند.

References

- Khodabandeh Z, Rabbani H, Shirani Bidabadi N, Bonyani M, Kafieh R. Comprehensive evaluation of artificial intelligence models for diagnosis of multiple sclerosis using information from retinal layers multicenter OCT images. *MedRxiv*. 2024;2024.03.05.24303789. doi:10.1101/2024.03.05.24303789.
- Eshaghi A, Young AL, Wijeratne PA, Prados F, Arnold DL, Narayanan S, et al. Identifying multiple sclerosis subtypes using unsupervised machine learning and MRI data. *Nat Commun*. 2021; 12:2078. doi: 10.1038/s41467-021-22265-2.
- Zhao Y, Healy BC, Rotstein D, Guttmann CR, Bakshi R, Weiner HL, et al. Exploration of machine learning techniques in predicting multiple sclerosis disease course. *PLoS One*. 2017;12: e0174866. doi: 10.1371/journal.pone.0174866.
- Dobson R, Giovannoni G. Multiple sclerosis-a review. *Eur J Neurol*. 2019; 26: 27-40.doi:10.1111/ene.13819.
- Kapucu S, Akkuş Y, Akdemir N. Knowledge of patients with multiple sclerosis about their disease and prevention of complications. *J Neurol Sci*. 2011; 30:149-53.
- Filippi M, Brück W, Chard D, Fazekas F, Geurts JJ, Enzinger C, et al. Association between pathological and MRI findings in multiple sclerosis. *Lancet Neurol*. 2019; 18:198-210. doi:10.1016/S1474-4422(18)30451-4.
- Rocca MA, Preziosa P, Barkhof F, Brownlee W, Calabrese M, De Stefano N, et al. Current and future role of MRI in the diagnosis and prognosis of multiple sclerosis. *Lancet Reg Health Eur*. 2024;44: 100954. doi: 10.1016/j.lanepe.2024.100978.
- Filippi M, Preziosa P, Banwell BL, Barkhof F, Ciccarelli O, De Stefano N, et al. Assessment of lesions on magnetic resonance imaging in multiple sclerosis: practical guidelines. *Brain*. 2019; 142:1858-75. doi: 10.1093/brain/awz144.
- Coles A. Multiple sclerosis: the bare essentials. *Pract Neurol*. 2009; 9:118-26. doi: 0.1136/jnnp.2008.171132.
- Wattjes MP, Steenwijk MD, Stangel M. MRI in the diagnosis and monitoring of multiple sclerosis: an update. *Clin Neuroradiol*. 2015; 25:157-65. doi:10.1007/s00062-015-0430-y.
- Tomassini V, Sinclair A, Sawlani V, Overell J, Pearson OR, Hall J, et al. Diagnosis and management of multiple sclerosis: MRI in clinical practice. *J Neurol*. 2020;267:2917-25. doi: 10.1007/s00415-020-09930-0.
- Granziera C, Wuerfel J, Barkhof F, Calabrese M, De Stefano N, Enzinger C, et al. Quantitative magnetic resonance imaging towards clinical application in multiple sclerosis. *Brain*. 2021; 144:1296-311. doi: 10.1093/brain/awab029.
- Davanian F, Adibi I, Tajmirriahi M, Monemian M, Zojaji Z, Montazerolghaem A, et al. Isfahan Artificial Intelligence Event 2023: lesion segmentation and localization in magnetic resonance images of patients with multiple sclerosis. *J Med Signals Sens*. 2025; 15:5. doi: 10.4103/jmss.jmss_55_24.
- Filippi M, Rocca MA, De Stefano N, Enzinger C, Fisher E, Horsfield MA, et al. Magnetic resonance techniques in multiple sclerosis: the present and the future. *Arch Neurol*. 2011; 68:1514-20. doi:10.1001/archneurol.2011.914.
- Okuda DT, Lebrun-Fréney C. Transforming grayscale MRI images to color utilizing generative artificial intelligence to better understand multiple sclerosis. *J Cent Nerv Syst Dis*. 2025; 17:11795735241310138. doi: 10.1177/11795735241310138.
- Collorone S, Coll L, Lorenzi M, Lladó X, Sastre-Garriga J, Tintoré M, et al. Artificial intelligence applied to MRI data to tackle key challenges in multiple sclerosis. *Mult Scler*. 2024; 30:13524585241249422. doi:10.1177/13524585241249422
- Campanioni S, Veiga C, Prieto-González JM, González-Nóvoa JA, Bustó L, Martínez C, et al. Explainable machine learning on baseline MRI predicts multiple sclerosis trajectory descriptors. *PLoS One*. 2024;19: e0306999. doi: 10.1371/journal.pone.0306999.
- Ananthavarathan P, Sahi N, Chard DT. An update on the role of magnetic resonance imaging in predicting and monitoring multiple sclerosis progression. *Expert Rev Neurother*. 2024; 24:201-16. doi: 10.1080/14737175.2024.2304116.
- Aslam N, Khan IU, Bashamakh A, Alghool FA, Aboulnour M, Alsuwaiyan NM, et al. Multiple sclerosis diagnosis using machine learning and deep learning: challenges and opportunities. *Sensors (Basel)*. 2022; 22:7856. doi:10.3390/s22207856.
- Shen D, Wu G, Suk H-I. Deep learning in medical image analysis. *Annu Rev Biomed Eng*. 2017; 19:221-48. doi:10.1146/annurev-bioeng-071516-044442.
- Liang X, Zeng Q, Zhu Y, Wang Y, He T, Wu L, et al. Differentiation between multiple sclerosis and neuromyelitis optic spectrum disorders with multilevel fMRI features: a machine learning analysis. *Sci Rep*. 2025; 15:1909. doi:10.1038/s41598-024-84508-8
- Valverde S, Cabezas M, Roura E, González-Villà S, Pareto D, Vilanova JC, et al. Improving automated multiple sclerosis lesion segmentation with a cascaded 3D

- convolutional neural network approach. *Neuroimage*. 2017; 155:159-68. doi: 10.1016/j.neuroimage.2017.04.034.
23. Suk HI, Lee SW, Shen D; Alzheimer's Disease Neuroimaging Initiative. Deep sparse multi-task learning for feature selection in Alzheimer's disease diagnosis. *Brain Struct Funct*. 2016; 221:2569-87. doi:10.1007/s00429-015-1059-y.
 24. Havaei M, Davy A, Warde-Farley D, Biard A, Courville A, Bengio Y, et al. Brain tumor segmentation with deep neural networks. *Med Image Anal*. 2017; 35:18-31. doi: 10.1016/j.media.2016.05.004
 25. Daqqaq TS, Alhasan AS, Ghunaim HA. Diagnostic effectiveness of deep learning-based MRI in predicting multiple sclerosis: a meta-analysis. *Neurosciences (Riyadh)*. 2024; 29:77-89. doi: 10.17712/nsj.2024.2.20230103.
 26. Hechmi C, Bouzidi D, Jemai O, editors. Convolutional neural network and k-nearest neighbors classifier for enhanced detection of multiple sclerosis. In: Proc SPIE 13178, International Conference on Machine Vision (ICMV 2024); 2025. p. 131781F. doi: 10.1117/12.3055064.
 27. Seok JM, Cho W, Chung YH, Ju H, Kim ST, Seong JK, et al. Differentiation between multiple sclerosis and neuromyelitis optica spectrum disorder using a deep learning model. *Sci Rep*. 2023; 13:11625. doi: 10.1212/WNL.0000000000001729.
 28. Çiçek Ö, Abdulkadir A, Lienkamp SS, Brox T, Ronneberger O, editors. 3D U-Net: learning dense volumetric segmentation from sparse annotation. In: Medical Image Computing and Computer-Assisted Intervention – MICCAI 2016. Lect Notes Comput Sci. Cham: Springer; 2016; 9902: 424-32. doi: 10.1007/978-3-319-46723-8_49.
 29. Tousignant A, Lemaître P, Precup D, Arnold DL, Arbel T, editors. Prediction of disease progression in multiple sclerosis patients using deep learning analysis of MRI data. In: Proceedings of the International Conference on Medical Imaging with Deep Learning (MIDL 2019). Proc Mach Learn Res. 2019; 102: 556-65.
 30. Saidha S, Al-Louzi O, Ratchford JN, Bhargava P, Oh J, Newsome SD, et al. Optical coherence tomography reflects brain atrophy in multiple sclerosis: a four-year study. *Ann Neurol*. 2015; 78:801-13. doi: 10.1002/ana.24487.
 31. LeCun Y, Bengio Y, Hinton G. Deep learning. *Nature*. 2015; 521:436-44. doi:10.1038/nature14539.
 32. Montolí A, Cegoñino J, García-Martín E, Pérez del Palomar A. The macular retinal ganglion cell layer as a biomarker for diagnosis and prognosis in multiple sclerosis: a deep learning approach. *Acta Ophthalmol*. 2024;102: e272-e84. doi: 10.1111/aos.15722.
 33. Shoeibi A, Khodatars M, Jafari M, Moridian P, Rezaei M, Alizadehsani R, et al. Applications of deep learning techniques for automated multiple sclerosis detection using magnetic resonance imaging: a review. *Comput Biol Med*. 2021; 136:104697. doi: 10.1016/j.combiomed.2021.104697.
 34. Aghababaei A, Arian R, Soltanipour A, Ashtari F, Rabbani H, Kafieh R. Discrimination of multiple sclerosis using scanning laser ophthalmoscopy images with autoencoder-based feature extraction. *Mult Scler Relat Disord*. 2024; 85:105743. doi: 10.1016/j.msard.2024.105743.
 35. Alsubaie MG, Alharbi FK, Albalawi AM, Almutairi AF, Alqahtani MM, Alzahrani AM, et al. Improving multiple sclerosis detection with autoencoder-based feature extraction from MRI and OCT images. *J Comput Neurosci*. 2024; 52:1-14.
 36. Giancucchi E, Delfino DV, Fierabracci A. Recent insights on the putative role of autophagy in autoimmune diseases. *Autoimmun Rev*. 2014; 13:231-41. doi: 10.1016/j.autrev.2013.10.007.
 37. Awad A, Hemmer B, Hartung H-P, Kieseier B, Bennett JL, Stuve O. Analyses of cerebrospinal fluid in the diagnosis and monitoring of multiple sclerosis. *J Neuroimmunol*. 2010; 219:1-7. doi: 10.1016/j.jneuroim.2009.09.002.
 38. Link H, Huang Y-M. Oligoclonal bands in multiple sclerosis cerebrospinal fluid: an update on methodology and clinical usefulness. *J Neuroimmunol*. 2006; 180:17-28. doi: 10.1016/j.jneuroim.2006.07.006.
 39. Cross AH, Gelfand JM, Thebaud S, Bennett JL, Von Büdingen HC, Cameron B, et al. Emerging cerebrospinal fluid biomarkers of disease activity and progression in multiple sclerosis. *JAMA Neurol*. 2024; 81:373-83. doi:10.1001/jamaneurol.2024.0017.
 40. Axelsson M, Malmeström C, Nilsson S, Haghghi S, Rosengren L, Lycke J. Glial fibrillary acidic protein: a potential biomarker for progression in multiple sclerosis. *J Neurol*. 2011; 258:882-8. doi:10.1007/s00415-010-5863-2.
 41. Martin S-J, McGlasson S, Hunt D, Overell J. Cerebrospinal fluid neurofilament light chain in multiple sclerosis and its subtypes: a meta-analysis of case-control studies. *J Neurol Neurosurg Psychiatry*. 2019; 90:1059-67. doi: 10.1136/jnnp-2018-319190.
 42. Passali M, Galea I, Knudsen MH, Lau LC, Cramer SP, Frederiksen JL. Cerebrospinal fluid neurofilament light chain in acute optic

- neuritis and its predictive ability of multiple sclerosis. *J Neurol.* 2024; 271:6127-35. doi: 10.1007/s00415-022-11193-w.
43. Striano P, Orefice G, Brescia Morra V, Boccella P, Sarappa C, Lanzillo R, et al. Epileptic seizures in multiple sclerosis: clinical and EEG correlations. *Neurol Sci.* 2003; 24:322-8. doi: 10.1007/s10072-003-0183-2.
 44. Vázquez-Marrufo M, Galvao-Carmona A, Caballero-Díaz R, Borges M, Paramo MD, Benítez-Lugo ML, et al. Altered individual behavioral and EEG parameters are related to the EDSS score in relapsing-remitting multiple sclerosis patients. *PLoS One.* 2019;14: e0219594. doi: 10.1371/journal.pone.0219594.
 45. Zhang X, Wang M, Wei W, Xu Y, Gao L, Sun Y, et al., editors. An accurate diagnosis of coronary heart disease by Catboost, with easily accessible data. *J Phys Conf Ser.* 2021; 1865:012023. doi:10.1088/1742-6596/1955/1/012027.
 46. Wątorek M, Tomczyk W, Gawłowska M, Golonka-Afek N, Źyrkowska A, Marona M, et al. Multifractal organization of EEG signals in multiple sclerosis. *Biomed Signal Process Control.* 2024; 91:105916. doi: 10.1016/j.bspc.2023.105916.
 47. Mórocz I, Jouzizadeh M, Ghaderi AH, Cheraghmakan H, Baghbanian SM, Khanbabaei R, et al. Brain states analysis of EEG data distinguishes multiple sclerosis. *arXiv.* arXiv:2406.15665. 2024. doi:10.48550/arXiv.2406.15665.
 48. Mokdad A, Debbal SMEA, Meziani F. Diagnosis of amyotrophic lateral sclerosis (ALS) disorders based on electromyogram (EMG) signal analysis and feature selection. *Pol J Med Phys Eng.* 2020; 26:155-60. doi: 10.2478/pjmpe-2020-0018.
 49. Ferahtia A. Surface water quality assessment in semi-arid region (El Hodna watershed, Algeria) based on water quality index (WQI). *J Mater Environ Sci.* 2021; 12:301-11. doi: 10.24193/subbchem.2021.1.10.
 50. Qader TM, Abdullah Q. Utility of single fibre electromyography (SFEMG) and motor unit number estimation technique (MUNE) in the diagnosis and differentiation of polyneuropathies of different aetiology. *J Pak Med Assoc.* 2024; 74:677-82. doi: 10.47391/JPMA.9364.
 51. Bashford J, Mills K, Shaw CE. The evolving role of surface electromyography in amyotrophic lateral sclerosis: a systematic review. *Clin Neuro physiol.* 2020; 131:942-50. doi: 10.1016/j.clinph.2019.12.007.
 52. Huang S-C, Guerreri S, Dalla Costa G, Pisa M, Leccabue G, Gregoris L, et al. Intensive neurorehabilitation and gait improvement in progressive multiple sclerosis: clinical, kinematic and electromyographic analysis. *Brain Sci.* 2022; 12:258. doi: 10.3390/brainsci12020258.
 53. Dai J. Sparse discrete wavelet decomposition and filter bank techniques for speech recognition [dissertation]. West Lafayette (IN): Purdue University; 2019.
 54. Fan F, Li M, Teng Y, Wang G. Soft autoencoder and its wavelet adaptation interpretation. *IEEE Trans Comput Imaging.* 2020; 6:1245-57. doi: 10.1109/TCI.2020.3013796.
 55. Hossen A, Anwar AR, Koirala N, Ding H, Budker D, Wickenbrock A, et al. Machine learning aided classification of tremor in multiple sclerosis. *EBioMedicine.* 2022; 82:104157. doi: 10.1016/j.ebiom.2022.104152.
 56. Ford H. Clinical presentation and diagnosis of multiple sclerosis. *Clin Med (Lond).* 2020; 20:380-3. doi: 10.7861/clinmed.2020-0292.
 57. Cagol A, Cortese R, Barakovic M, Schaedelin S, Ruberte E, Absinta M, et al. Diagnostic performance of cortical lesions and the central vein sign in multiple sclerosis. *JAMA Neurol.* 2024; 81:143-53. doi: 10.1001/jamaneurol.2023.4737.
 58. Geurts P, Ernst D, Wehenkel L. Extremely randomized trees. *Mach Learn.* 2006; 63:3-42. doi: 10.1007/s10994-006-6226-1.
 59. Biau G. Analysis of a random forests model. *J Mach Learn Res.* 2012; 13:1063-95.
 60. Chen T, Guestrin C, editors. XGBoost: a scalable tree boosting system. In: Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York: ACM; 2016. p. 785-94. doi: 10.1145/2939672.2939785.