

# مروری بر الگوریتم‌های یادگیری ماشین جهت تشخیص اوتیسم با استفاده از سیگنال EEG

زهره شریفی<sup>۱\*</sup>، مربی، هاجر مومنی<sup>۲</sup>، استادیار، حبیب ادبی اردکانی<sup>۳</sup>، دانشجوی دکتری

<sup>۱</sup> زهره شریفی - گروه مهندسی برق - دانشگاه فنی و حرفه ای - تهران - ایران - zsharifi@tvu.ac.ir

<sup>۲</sup> هاجر مومنی - گروه مهندسی برق - دانشگاه اردکان - اردکان - ایران - h.momeni@ardakan.ac.ir

<sup>۳</sup> حبیب ادبی اردکانی - گروه مهندسی برق - دانشگاه یزد - یزد - ایران - habibadabiardakani@gmail.com

چکیده: بیماری اوتیسم یک اختلال عصبی و تکاملی است که اشخاص مبتلا به آن اغلب علائم یا رفتارهای محدود را نشان می‌دهند و بر اساس آزمون رفتاری تشخیص داده می‌شود. این اختلال عصبی با دیگر اختلالات عصبی مشابه می‌باشد به این علت تشخیص بیماری اوتیسم کار پیچیده‌ای است. اگر بیماری در سنین کم و به موقع تشخیص داده شود شدت بیماری و عوارض آن کم می‌شود. در سال‌های اخیر محققان با استفاده از بررسی سیگنال الکتروانسفالوگرافی (EEG) به تشخیص بیماری اوتیسم پرداخته‌اند. در تشخیص بیماری اوتیسم با استفاده از سیگنال EEG از الگوریتم‌های یادگیری ماشین استفاده شده است که کاربر انسانی توانسته است با تجزیه و تحلیل ویژگی‌های استخراج شده با درصد دقت خوبی این بیماری را تشخیص دهد. در این پژوهش الگوریتم‌های مورد استفاده در هریک از مقالات، بررسی شده و نتایج بدست آمده از بررسی داده‌های متناسب با آن‌ها مبنای ادامه کار برای پژوهش‌های آتی می‌باشد. در این پژوهش ضمن بررسی روش‌های ارائه شده پیشین، مزایا و معایب روش‌ها بررسی می‌شود. نتایج نشان می‌دهد نقش روش‌های بکار گرفته شده به منظور پیش پردازش، استخراج و انتخاب ویژگی از روی تصاویر EEG و نوع طبقه‌بندها، عوامل موثر در دقت طبقه بندی می‌باشند. شبکه‌های عصبی کانولوشنی با توجه به ارائه بهترین نتایج دقت، بیشترین کاربرد را در مقایسه با سایر روش‌های مبتنی بر یادگیری داشته‌اند.

واژه‌های کلیدی: الکتروانسفالوگرافی، الگوریتم‌های نظارت شده، اوتیسم، یادگیری عمیق، یادگیری ماشین.

# A review of machine learning algorithms to diagnose autism using EEG signal

Zohre Sharifi <sup>1\*</sup>, Instructor, hajar Momeni <sup>2</sup>, assistant professor, Habib Adabi Ardakani <sup>3</sup>

<sup>1</sup> Department of Electrical Engineering, Technical and Vocational University, Tehran, Iran, zsharifi@tvu.ac.ir

<sup>2</sup> Department of Electrical Engineering, Ardakan University, Ardakan, Iran, h.momeni@ardakan.ac.ir

<sup>3</sup> Department of Electrical Engineering, Yazd University, Yazd, Iran, habibadabiardakani@gmail.com

**Abstract:** Autism is a neurological and developmental disorder in which individuals often show limited symptoms or behaviors and are diagnosed based on a behavioral test. This neurological disorder is similar to other neurological disorders; therefore, diagnosing autism is a complicated task. If the disease is diagnosed at an early age, the severity of the disease and its complications will be reduced. In recent years, researchers have used electroencephalography (EEG) to diagnose autism. In the diagnosis of autism using EEG signals, machine learning algorithms have been used, and the human user has been able to diagnose this disease with a good percentage of accuracy by analyzing the extracted features. Here, the algorithms used in each of the articles have been reviewed, and the results obtained from the corresponding data review are the basis for further research. While examining the previously presented methods, the advantages and disadvantages of the methods are examined. The results show that the role of the methods used for pre-processing, extracting and selecting features from EEG images and the type of classifiers are effective factors in classification accuracy. Convolutional neural networks have been the most popular compared to other learning-based methods due to their ability to provide the best accuracy results.

**Keywords:** Autism, Deep learning, Machine learning, Electroencephalography, Supervised learning.

\* corresponding author, zsharifi@tvu.ac.ir

## ۱. مقدمه

افراد مبتلا به اختلال طیف اوتیسم (ASD<sup>۱</sup>) در دنیای درونی خود هستند و از آنجایی که ایجاد ارتباطات مناسب اجتماعی نیازمند دریافت و پردازش صحیح اطلاعات حسی و اتخاذ رفتار مبتنی بر این اطلاعات است، ارتباط افراد با دنیای بیرون وجود ندارد و ارتباطات مناسب اجتماعی اشخاص را مختل می‌کند. امروزه، پژوهشگران در مقالات تلاش می‌کنند با بررسی الکتروانسفالوگرافی EEG<sup>۲</sup>، این بیماری عصبی را تشخیص دهند. در مطالعات اخیر پژوهش بر روی افراد مبتلا به ASD استفاده از EEG به علت دسترسی گسترده پزشکان به این سیگنال، وضوح زمانی بالا و قیمت ارزان، افزایش یافته است. برای ثبت فعالیت‌های الکتریکی مغز از سیگنال EEG استفاده می‌شود. سیگنال EEG شامل اطلاعات زیادی در مورد فعالیت‌های مغز است. پردازش سیگنال EEG بسیار زمان‌بر است و کار تخصصی است، اخیراً در مقالات سیگنال‌های EEG با استفاده روش‌های پردازش سیگنال و مدل‌های یادگیری ماشین (ML<sup>۳</sup>) پردازش و طبقه‌بندی می‌شوند. در پژوهش‌های تشخیص بیماری اوتیسم مبتنی بر EEG از الگوریتم‌های یادگیری ماشین استفاده شده‌اند تا با بررسی ویژگی‌های بدست آمده با استفاده از کاربر انسانی و ماشین با درصد دقت بالایی بیماری اوتیسم را تشخیص می‌دهند [۱].

امروزه از فناوری‌های پیشرفته‌ی هوش مصنوعی در بسیاری از علوم استفاده شده است. در اصل هوش مصنوعی برنامه‌ای است که ساختاری را برای اجرای عملیات هوشمند در رایانه

ایجاد می‌کند. انسان به کمک هوش مصنوعی موفق به ساخت ماشین‌های هوشمند و بهتر شده است [۲]. در یادگیری ماشین فرایند یادگیری با مدلی بیان می‌شود که با استفاده از داده‌های آموزش یا تجربیات گذشته آموزش صورت می‌گیرد و این مدل را می‌توان برای بدست آوردن فهمی از داده‌ها یا پیش‌بینی آینده استفاده کرد. علم آمار در الگوریتم‌های یادگیری ماشین در ساخت مدل‌های ریاضی به کار برده می‌شود، چون دریافت نتایجی از یک مجموعه داده کار اصلی الگوریتم‌های یادگیری ماشین است [۳].

هدف از پژوهش حاضر، بررسی روش‌های یادگیری ماشین در تشخیص بیماری اوتیسم می‌باشد. تکنیک‌های یادگیری ماشین بسیار گسترده هستند، بنابراین پیش‌بینی می‌شود که این تکنیک‌ها راه حل‌های بهینه‌ای برای تشخیص بیماری اوتیسم ارائه دهند. در بخش اول پژوهش تعاریف مربوط به هوش مصنوعی و الگوریتم‌های یادگیری ماشین ارائه می‌شود. سپس مقالات مرتبط با کاربرد الگوریتم‌های یادگیری ماشین در تشخیص بیماری اوتیسم و مزایا و معایب الگوریتم‌ها بحث و بررسی می‌شود. در این مقاله از کلید واژه‌های هوش مصنوعی، یادگیری ماشین، شبکه‌های عصبی و تشخیص بیماری اوتیسم با استفاده از سیگنال EEG برای انجام یک جستجوی کامل و جامع در زمینه کاربردهای الگوریتم‌های یادگیری ماشین در تشخیص بیماری اوتیسم استفاده شده است. در این پژوهش ۷۰ مقاله مطالعه شده است که از میان این مقالات ۴۵ مقاله با موضوع کاربرد الگوریتم‌های یادگیری ماشین در تشخیص بیماری اوتیسم با استفاده از سیگنال EEG مرتبط می‌باشد.

## ۲. تعاریف

<sup>1</sup>Autism Spectrum Disorder

<sup>2</sup>Electroencephalogram

<sup>3</sup>Machine Learning

## ۱.۱.۲ اوتیسم

تغییرات فعالیت الکتریکی نورون‌ها حساس باشد. الکترودهای نصب شده روی سر، اثر الکتریکی فعالیت نورون‌ها را به پیش تقویت‌کننده‌های EEG انتقال می‌دهند و در نهایت این اثر الکتریکی به صورت سیگنال زمانی قابل مشاهده خواهد بود. به طور کلی امواج مغزی قابل ثبت در سطح جمجمه به ۵ باند فرکانسی مختلف، شامل ریتم‌های دلتا، تتا، آلفا، بتا و گاما تقسیم می‌شوند. مقدار این امواج در نوار مغزی به عوامل متعددی مانند سن، جنسیت و وضعیت فرد (استراحت، فعالیت شناختی، خواب و...) بستگی خواهد داشت. الکتروانسفالوگرام پس از تحلیل می‌تواند به عنوان شاخص مهمی برای سنجش هوشیاری و یا انواعی از اختلالات مغزی قرار گیرد و علاوه بر آن کاربرد گسترده‌ای در مطالعات علوم اعصاب داشته باشد [۵].

EEG، سری‌های زمانی از ولتاژهای بدست آمده توسط فعالیت میلیاردها سلول مغز است. سیگنال EEG توسط الکترودهایی که بر روی سر قرار می‌گیرد ثبت می‌شود. رنج ولتاژ ثبت شده در حد ۱۰ تا ۱۰۰ میکروولت می‌باشد. پردازش‌های خطی و غیر خطی متعددی بر روی این سیگنال به منظورهای خاص همانند ارزیابی مراحل خواب، تعیین میزان هیپنوتیزم پذیری اشخاص، تعیین سطح عمق بیهوشی افراد و کاربردهای تشخیصی در اوتیسم، صرع، آلزایمر و همچنین در کاربرد و ارتباط با کامپیوتر و بسیاری کاربردهای دیگر استفاده شده است [۴]. سیگنال نوار مغز در مقایسه با تصاویر MRI و روش‌های تهاجمی مزیت غیرتهاجمی و ارزان بودن را دارند. از آنجایی که تصاویر EEG بصورت سیگنال‌هایی پیچیده قابل رویت می‌باشند، پزشک نمی‌تواند با مشاهده چشمی، افراد مبتلا به اوتیسم و افراد سالم را تشخیص دهد. این پیچیدگی طلب می‌کند که از روش‌های مبتنی بر هوش مصنوعی برای

ASD نوعی بیماری رشدی است که علائمی مانند رفتارهای محدود، رفتار اجتماعی غیر معمول و تکراری و علائق غیر معمول دارد. بیماری اوتیسم به واسطه مجموعه‌ای از رفتارهای مشخص تعریف شده و به صورت یک طیف بوده که بر افراد مختلف به شکل و درجات متفاوت تاثیر می‌گذارد. درحالی‌که هیچ دلیل واحدی برای اوتیسم شناخته نشده، تشخیص‌های زودهنگام، به افراد در دریافت حمایت و خدماتی که نیاز دارند کمک می‌کنند. این حمایت‌ها، کیفیت زندگی و فرصت‌های بیشماری را برای آنها فراهم می‌نمایند. در آمریکا آمار کودکان مبتلا به اوتیسم یک نفر از هر ۱۱۰ نفر در سال ۲۰۱۰ اعلام شده است. در ایران میزان ابتلا به اوتیسم ۹۵,۲ در هر ۱۰ هزار نفر اعلام شده است [۶].

## ۲.۲ الکتروانسفالوگرافی

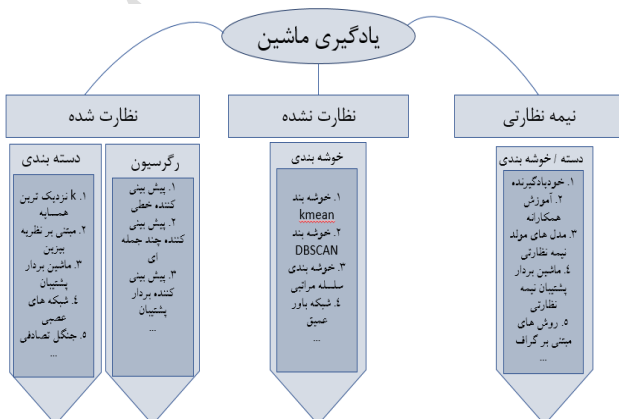
مغز هر انسانی از میلیاردها سلول تشکیل شده که به این سلول‌های عصبی نورون می‌گویند. نورون‌ها به منظور ارتباط با هم از پیام عصبی استفاده می‌کنند. ارسال میلیون‌ها سیگنال به هم، باعث ایجاد فعالیت‌های الکتریکی در مغز می‌شود. به دستگاهی که این امواج مغزی را ثبت می‌کند، الکتروانسفالوگرام گفته می‌شود. امواجی که از سیگنال‌های الکتروانسفالوگرام دریافت می‌شوند، نشان دهنده فعالیت امواج فرآیندهای سیناپسی هستند [۴]. دستگاه الکتروانسفالوگرافی به کمک الکترودهایی که بر روی سر قرار می‌گیرد، فعالیت الکتریکی نورون‌ها را اندازه‌گیری و ثبت می‌کند. سیگنال‌های ثبت شده حاصل از فعالیت نورونی تحت عنوان نوار مغزی یا الکتروانسفالوگرام شناخته می‌شود. EEG در مقایسه با روش‌هایی مانند fMRI و PET از دقت زمانی بالاتری برخوردار است و می‌تواند در حد میلی‌ثانیه به

از داده‌ها و اطلاعات آموزش ببیند بدون اینکه از قبل برنامه‌ی‌ی‌ شوند [7].

### ۲.۳. یادگیری ماشین

یکی از زیر مجموعه‌های هوش مصنوعی، یادگیری ماشین یا ماشین لرنینگ (Machine Learning) می‌باشد که سیستم می‌تواند به صورت خودکار یادگیری و پیشرفت داشته باشد بدون اینکه برنامه‌نویسی صریحی برای آن داشته باشیم. هدف از الگوریتم‌های یادگیری ماشین این است که چگونه سیستم کامپیوتری بسازیم که کارکرد آن به صورت اتوماتیک از طریق تجربه بهتر شود. الگوریتم‌های یادگیری ماشین برنامه‌های رایانه‌ای را توسعه می‌دهند که این برنامه‌ها قادر باشند به داده‌ها دسترسی پیدا کنند و از آن آموزش ببینند. شروع فرایند آموزش با مشاهدات یا داده‌ها می‌باشد، مانند مثال‌ها، تجربه‌های مستقیم و یا دستورالعمل‌ها، تا به یک الگو در داده‌ها برسند و بر اساس این مثال‌هایی که ارائه می‌شود، تصمیمات بهتری گرفته شود. هدف اصلی آن است که به کامپیوتر این اجازه داده شود تا بدون دخالت انسان به طور اتوماتیک آموزش انجام شود و بتوان اقدامات خود را مطابق با آن تنظیم کرد [3].

در شکل ۱ بخش‌های مختلف الگوریتم‌های یادگیری ماشین نشان داده شده است.



تشخیص اوتیسم استفاده شود. در حالت کلی پنج نوع امواج مغزی داریم: دلتا، تتا، آلفا، بتا و گاما. در ادامه ۵ الگوی فرکانسی توضیح داده خواهد شد.

دلتا: آخرین نوع امواج مغزی، موج دلتاست. این امواج بیشترین دامنه و آهسته ترین بسامد را دارند. بسامد امواج دلتا بین ۱,۵ تا ۴ هرتز است.

تتا: این امواج بسامدی بین ۵ تا ۸ هرتز دارند.

آلفا: فرکانس امواج آلفا بین ۹ تا ۱۴ هرتز است.

بتا: دامنه نسبتاً پایینی دارند و فرکانس امواج بتا بین ۱۵ تا ۴۰ هرتز است.

گاما: موج گاما بین همه امواج مغزی بیشترین بسامد دارد. این امواج بسامدی بین ۳۲ تا ۱۰۰ هرتز دارند.

### ۳. مبانی نظری

#### ۱.۳. هوش مصنوعی

یکی از شاخه‌های علوم کامپیوتر هوش مصنوعی است که اصطلاحات بسیاری در خصوص آن در این حوزه وجود دارند. برای اینکه بتوان کامپیوترها را برای انجام آنچه در توان انسان است به کار گرفت، نیاز به مقدار داده‌های بسیار زیادی وجود دارد. مجموعه داده‌های بزرگ باعث می‌شوند تا بتوان با استفاده از الگوریتم‌های هوش مصنوعی الگوها را تشخیص داد، پیش‌بینی انجام گیرد و در خصوص اقدامات مورد نیاز توصیه‌هایی را بیان کرد. هوش مصنوعی یک مفهوم بزرگ‌تر از یادگیری ماشین است و ماشین هوشمندی ایجاد می‌کند که این ماشین توانایی را دارد که توانایی‌های رفتاری و تفکر انسان را مدل‌سازی کند، در حالی که، هوش مصنوعی زیر مجموعه یادگیری ماشین است که به ماشین‌ها اجازه می‌دهد

شکل (۱): روش‌های مختلف یادگیری ماشین

در ادامه انواع دسته‌بندی الگوریتم‌های یادگیری ماشین توضیح داده می‌شود:

یادگیری نظارت شده: یک الگوریتم یادگیری تحت نظارت می‌بایست آموزش داده شود؛ این الگوریتم در طول آموزش به دنبال الگوهایی در داده‌ها است که با خروجی‌های مورد نظر مرتبط است. پس از مرحله آموزش، الگوریتم یادگیری تحت نظارت ورودی‌های جدید در نظر گرفته خواهد شد و تعیین خواهد کرد که کدام ورودی‌های جدید براساس داده‌های آموزشی قبلی دسته‌بندی می‌شوند. هدف از یک مدل یادگیری تحت نظارت، پیش‌بینی برچسب درست برای داده‌های ورودی جدید است. در طول پروسه یادگیری ماشین، مدلی ارائه می‌شود که متغیرهای آن را برای نمایش دادن ورودی به خروجی متناظر تنظیم می‌کند. ورودی و خروجی در روش یادگیری نظارت شده از ابتدا مشخص شده است. الگوریتم یادگیری ماشین نظارت شده، شروع به بررسی بر روی مجموعه داده‌های ورودی می‌کند. پس از آموزش در نهایت، الگوریتم یادگیری نظارت شده روی مجموعه داده دارای خروجی‌های مشخص، یک الگو و یا به بیان بهتر، مدلی را استنباط می‌کند که داده‌های ورودی بر اساس آن به داده‌های خروجی تبدیل می‌شوند. برخی از الگوریتم‌هایی که تحت یادگیری نظارت شده عبارتند از:

رگرسیون خطی: این الگوریتم به پیش‌بینی‌هایی منجر می‌شود که از الگوی خطی پیروی می‌کنند. در رگرسیون خطی، رابطه خطی بین دو یا چند متغیر اندازه‌گیری می‌شود.

جنگل تصادفی: این الگوریتم جزء الگوریتم‌های یادگیری گروهی می‌باشد که برای کلاسه‌بندی، رگرسیون و همچنین سایر کارها از روش ساخت درختان تصمیم‌گیری و بدست

آوردن خروجی به عنوان یک کلاس که مُد یا میانگین درختان منحصر به فرد اصلی است، انجام می‌گیرند.

تقویت گرادیان: یکی از روش‌های یادگیری گروهی، تقویت گرادیان است که از چندین درخت تصمیم‌گیری ضعیف تشکیل شده است که منجر به یک کلاسه‌بند قدرتمند می‌شود.

ماشین بردار پشتیبان: SVM<sup>۴</sup>ها طبقه‌بندهای قدرتمندی هستند که با کمک ابرصفحه‌ها، برای دسته‌بندی مجموعه داده‌های دودویی به دو کلاس، استفاده می‌شوند [۸-۱۰].

رگرسیون لجستیک: این الگوریتم از منحنی S زنگوله‌ای ساخته می‌شود که با استفاده تابع logit برای دسته‌بندی داده‌ها در کلاس مربوطه‌شان ایجاد می‌شود.

شبکه‌های عصبی مصنوعی: شبکه‌های عصبی مصنوعی از مغز انسان ایده می‌گیرند و داده‌ها در طول زمان شبکه را آموزش می‌دهد. شبکه‌های عصبی مصنوعی، بخش وسیعی از الگوریتم‌های یادگیری ماشین می‌باشند که یادگیری عمیق نام برده می‌شوند [۱۱].

یادگیری بدون نظارت: یادگیری بدون نظارت از روش‌های یادگیری ماشین محسوب می‌شود که کاربر ناظر بر مدل ندارد و این خود مدل است که به تنهایی برای کشف الگوها و اطلاعات داده، کار می‌کند. این الگوریتم‌ها بدون نیاز به برچسب و دخالت انسان، گروه‌های مختلف موجود یا الگوهای پنهان در داده‌ها را کشف می‌کنند. یادگیری بدون نظارت بر دو نوع است: خوشه‌بندی و غیرخوشه‌بندی. در نوع «خوشه‌بندی»، الگوریتم، داده‌ها را بر اساس آنچه خود درک می‌کند، دسته‌بندی می‌کند. در روش «غیرخوشه‌بندی» این الگوریتم، داده‌های دریافتی را از یکدیگر تفکیک می‌کند [۱۲].

<sup>4</sup> Support Vector Machine

۳- خوشه بندی سلسله مراتبی: در این نوع خوشه بندی، سلسله مراتبی از خوشه ها ساخته می شود.

تشخیص ناهنجاری: تکنیک های تشخیص ناهنجاری، با استفاده از این فرض که اکثر نمونه های داده با مشاهده مواردی که متناسب با بقیه مجموعه داده هستند، نرمال می باشد، داده های پرت را از داده های بدون برچسب تشخیص می دهند.

خودرمزگذارها Autoencoders: خودرمزگذارها نوعی از شبکه های عصبی هستند که در یادگیری بدون نظارت برای یادگیری بازنمایی مورد استفاده قرار می گیرند. آن ها در حذف نویز و کاهش ابعاد به کار می روند.

شبکه باور عمیق: شبکه باور عمیق یک مدل گرافیکی مولد و همچنین یک کلاس از شبکه عصبی است که برای یادگیری بدون نظارت طراحی شده است. این مدل، به این جهت با شبکه های عصبی نظارت شده، متفاوت است که ورودی های خود را به طور احتمالی بازسازی می کند تا به عنوان تشخیص دهنده ویژگی عمل کند [۱۱-۱۳].

روش های نیمه نظارت شده: در یادگیری ماشین، برچسب گذاری داده ها، به فرایند تشخیص داده های خام (تصاویر، فایل های ویدیویی و غیره) و افزودن یک یا چند برچسب معنادار و یا آموزنده جهت ارائه اطلاعات در مورد آن اطلاق می شود. برچسب ها ممکن است حاوی اطلاعاتی نظیر وجود پرند یا ماشین در یک عکس، تلفظ یک کلمه در یک فایل صوتی و یا وجود تومور در یک عکس اشعه ایکس باشند. اطلاعاتی که در قالب برچسب داده ها ارائه می شود، نقش بسزایی در آموزش مدل های یادگیری ماشین در حوزه های مختلف هوش مصنوعی نظیر بینایی ماشین، پردازش زبان طبیعی و پردازش گفتار ایفا می نماید. بسیاری از

در دسته بندی بدست آمده برای تولید خروجی هدفی وجود ندارد بلکه الگوریتم های مورد استفاده، داده ها را به گروه های مختلف طبقه بندی می کنند. این الگوریتم ها در داده های مورد کاربرد جهت آموزش ماشین، زمانی استفاده می شوند که خروجی سیستم از ابتدا مشخص نباشد. در اینجا، هدف ارتباط میان ورودی و خروجی نیست؛ بلکه الگوریتم یادگیری ماشین به دنبال جستجوی تابعی برای توصیف ساختار پنهان و خاص موجود در داده ها است (منظور داده های ورودی است که خروجی آنها مشخص نیست). در روش یادگیری نظارت نشده، الگوریتم با تحلیل تفاوت ها و شباهت های میان داده ها، یک الگو برای خوشه بندی کردن داده ها بدست می آورد و بر اساس این الگو، قادر است برای نمونه داده های جدید خروجی را پیش بینی کند. برخی از الگوریتم هایی که در این رشته قرار می گیرند خوشه بندی هستند که به عنوان آنالیز خوشه ای نیز شناخته می شود؛ تکنیکی برای گروه بندی مجموعه اشیا مشابه در همان گروه می باشد که متفاوت از اشیای گ—روه دیگر است.

برخی از روش های مهم خوشه بندی به شرح زیر هستند:

۱- K-means: این الگوریتم راه حلی برای مشکلات خوشه بندی دارد و جزء دسته الگوریتم های بدون نظارت است. این الگوریتم به دنبال راه حلی برای ایجاد خوشه هایی است که شامل نقاط داده همگن هستند.

۲- DBSCAN: جز روش های خوشه بندی است که داده ها بر اساس تراکم، گروه بندی می شود. این روش نقاطی که در فضا داده می شوند را گروه بندی کرده و نقاط خارج از منطقه کم تراکم را علامت گذاری می کند.

استدلال فضایی و دانش عمومی جواب‌های قابل اعتماد پیشنهاد دهند. نتایج، منجر به حذف نویزها می‌شود و در بسیاری از موارد نسبت به تشخیص متخصصان عملکرد بهتر دارد. این قانون در مورد برنامه‌های هوش مصنوعی که وابسته به الگوریتم‌های یادگیری ماشین است (یکی از شاخه‌های هوش مصنوعی که نتایج را بر اساس مدل‌های ریاضی پیش‌بینی می‌کند) اجرا می‌شود. در الگوریتم‌های یادگیری ماشین، خرد جمعی از الگوریتم‌های یادگیری گروهی حاصل می‌شود. برای بسیاری از مشکلات، نتیجه‌ای که از یک گروه حاصل می‌شود، ترکیبی از مدل‌های یادگیری ماشین، از هر یک از اعضای گروه دقیق‌تر می‌باشد. یادگیری جمعی با ترکیب چند مدل منجر به بهتر شدن نتیجه‌های یادگیری ماشین می‌شود [۱۸].

یادگیری مبتنی بر نمونه: روش یادگیری مبتنی بر نمونه، یکی از روش‌های مفید برای ساخت مدل‌های یادگیری ماشین است که با اعمال تعمیم بر اساس داده ورودی، این کار را انجام می‌دهد. این روش بر خلاف سایر روش‌های یادگیری است که پیش‌تر مطالعه شد؛ به این صورت که این نوع از یادگیری علاوه بر سیستم‌های یادگیری ماشین، شامل روش‌هایی است که از نقاط داده خام برای ترسیم خروجی برای نمونه‌های جدیدتر استفاده می‌کند، بدون اینکه یک مدل صریح روی داده آموزشی بسازد. به بیان ساده‌تر، اساساً یادگیری مبتنی بر نمونه، با نگاه به نقاط داده ورودی کار را شروع می‌کند و سپس با استفاده از یک معیار تشابه، نقاط داده جدید را تعمیم و پیش‌بینی می‌کند [۱۹].

### ۳.۳. یادگیری عمیق

در یادگیری عمیق (Deep Learning)، از شبکه‌های عصبی مصنوعی برای انجام محاسبات پیچیده استفاده می‌شود.

موفقیت‌های اخیر در آموزش شبکه‌های یادگیری عمیق، وجود داده‌های برچسب‌گذاری شده است. با این حال جمع‌آوری این مجموعه داده بسیار زمانبر، نیازمند نیروی متخصص و یا به طور کلی گران می‌باشد. علاوه بر این، در خیلی از اوقات، برچسب داده‌ها حاوی اطلاعات خصوصی است که تأمین امنیت فرآیندهای گردآوری و نگهداری آنها بسیار پرچالش است. روش یادگیری نیمه نظارتی به عنوان یکی از مدل‌های یادگیری ماشین، راهکاری مؤثر جهت رفع چالش‌های مربوط به داده‌های برچسب‌دار می‌باشد. در یادگیری نیمه نظارتی به طور همزمان از داده‌های برچسب خورده و از داده‌های برچسب نخورده استفاده می‌شود تا بتوان دقت یادگیری را بهبود بخشید. این نوع از مدل یادگیری به عنوان روشی که می‌تواند از داده‌های بدون برچسب بیشترین استفاده را داشته باشد، از منظر کاربرد عملی از ارزش فوق‌العاده‌ای برخوردار است [۱۴، ۱۵].

روش یادگیری تقویتی: رویکرد یادگیری تقویتی کاملاً با روش‌های قبلی متفاوت است. در این الگوریتم، یک عامل در محیط قرار می‌گیرد تا با آزمون و خطا آموزش ببیند کدام کارها مفید و کدام کارها غیرمفید هستند و در نهایت یک هدف مشخص بدست آید. در مورد یادگیری تقویتی هدف از یادگیری مشخص است، از این جهت مانند یادگیری نظارتی می‌باشد. وقتی که اهداف و پاداش‌ها مشخص شدند، الگوریتم به صورت مستقل اجرا می‌شود و نسبت به الگوریتم‌های یادگیری نظارتی تصمیمات آزادانه‌تری می‌گیرد. به همین دلیل برخی از محققان یادگیری تقویتی را در گروه نیمه نظارتی در نظر می‌گیرند [۱۷، ۱۶].

یادگیری گروهی یا یادگیری ترکیبی: در این الگوریتم گروه بزرگی از اشخاص که سطح دانش متوسطی دارند در مورد یک موضوع قادر هستند به سوالاتی مانند پیش‌بینی کمیت،



هستند؛ زیرا آن‌ها داده‌های ورودی پیشین را به یاد می‌آورند. شبکه‌های حافظه طولانی کوتاه-مدت، ساختار زنجیره ماندنی دارند که در آن چهار لایه تعاملی هر یک به شیوه‌ای منحصر به فرد ارتباط برقرار می‌کنند. LSTM ها معمولاً برای تشخیص گفتمان‌ها، ترکیب موزیک و توسعه دارویی استفاده می‌شوند.

شبکه‌های عصبی بازگشتی RNN: شبکه‌های عصبی بازگشتی دارای ارتباطاتی هستند که چرخه‌های جهت‌دار را ایجاد می‌کنند که به خروجی‌های LSTM این امکان را می‌دهد تا به عنوان ورودی برای مرحله جاری تغذیه شوند. خروجی از LSTM تبدیل به یک ورودی برای مرحله جاری می‌شود و می‌تواند داده‌های ورودی پیشین را برای حافظه داخلی خودش ذخیره سازی کند. شبکه‌های عصبی بازگشتی، معمولاً به منظور توضیح‌نویسی برای تصاویر، آنالیز سری زمانی، ماشین ترجمه، شناسایی دستخط و پردازش زبان طبیعی استفاده می‌شوند.

شبکه‌های تابع پایه شعاعی RBFN: (RBFNs)ها، نوع خاصی از شبکه‌های عصبی پیش رونده هستند که از توابع پایه شعاعی برای فعال سازی توابع استفاده می‌کنند. آن‌ها یک لایه ورودی، یک لایه پنهان و یک لایه خروجی دارند و از آنها بیشتر برای طبقه‌بندی، رگرسیون و پیش‌بینی سری‌های زمانی استفاده می‌شود.

نورون‌های پرسپترون چند لایه MLPs: نورون‌های پرسپترون چند لایه، یک مکان عالی برای شروع یادگیری درباره تکنولوژی یادگیری عمیق است. نورون‌های پرسپترون چندلایه، سطحی از شبکه‌های عصبی پیشخور و شامل چندین لایه پرسپترون هستند که دارای توابع فعال است. نورون‌های پرسپترون چند لایه، شامل یک لایه ورودی و لایه خروجی تماماً متصل است. آن‌ها به میزان یکسانی دارای لایه‌های

محاسبات بر روی حجم زیادی از داده‌ها انجام می‌شود. یکی از انواع الگوریتم‌های یادگیری ماشین، یادگیری عمیق است که مشابه عملکرد مغز انسان کار می‌کند. در الگوریتم‌های یادگیری عمیق با استفاده مثال‌ها و نمونه‌ها ماشین آموزش دیده می‌شود. در صنایع متعددی مانند سرگرمی، مراقبت‌های بهداشتی، تجارت الکترونیک و تبلیغات، معمولاً از یادگیری عمیق استفاده می‌شود. یک شبکه عصبی neural network ساختاری شبیه مغز انسان دارد و از نورون‌های مصنوعی با عنوان "گره" تشکیل شده است. این گره‌ها از سه لایه تشکیل می‌شوند: لایه ورودی، لایه‌های مخفی، لایه خروجی. داده‌ها اطلاعاتی را در قالب ورودی برای هر گره تعیین می‌کنند. گره، ورودی‌ها را در وزن‌های تصادفی ضرب می‌کند، آن‌ها را حساب کرده و یک بایاس به آن اضافه می‌کند. در نهایت، توابع غیرخطی که "توابع فعال سازی" نامیده می‌شوند، برای تعیین اینکه کدام نورون شلیک کند، اعمال می‌شوند. در ادامه چند مورد از مهمترین الگوریتم‌های یادگیری عمیق بیان شده است:

شبکه‌های عصبی پیش‌بینی CNN: شبکه‌های عصبی کانولوشنی، از چندین لایه تشکیل شده و در بیشتر موارد برای تشخیص اشیا و پردازش تصویر کاربرد دارد. یان لیکان اولین شبکه عصبی مصنوعی که LeNet نامیده می‌شود را در سال ۱۹۸۸ ارائه داد. این فناوری برای شناسایی کاراکترهایی مانند ارقام و کدهای پستی استفاده می‌شد.

شبکه‌های حافظه طولانی کوتاه-مدت (LSTM): LSTM ها نوعی شبکه عصبی بازگشتی هستند که وابستگی‌های بلند مدت را یادگیری و ذخیره‌سازی می‌کنند. در این نوع شبکه‌ها، یادآوری اطلاعات پیشین برای درازمدت، یک رفتار پیش فرض است که اطلاعات را در طول زمان حفظ می‌کند. این شبکه‌های عصبی برای پیش‌بینی سری‌های زمانی بسیار مفید

MobileNetV2 یک معماری شبکه عصبی کانولوشن است که بر اساس یک ساختار باقیمانده معکوس کار کرده و در آن اتصالات باقیمانده بین لایه‌های میانی قرار دارند. لایه انبساط میانی از کانولوشن‌های عمقی سبک برای فیلتر کردن ویژگی‌ها به عنوان منبع غیرخطی استفاده می‌کند [۳۳].

ShuffleNet یک شبکه عصبی کانولوشن است که معماری آن از دو عملیات جدید کانولوشن گروهی (pointwise group convolution) و پخش کانال (channel shuffle)، برای کاهش هزینه محاسباتی در عین حفظ دقت استفاده می‌کند [۳۳].

RBF یک نوع شبکه عصبی مصنوعی متداول برای مسائل تقریب تابع می‌باشد که به دلیل تقریب فراگیر و سرعت یادگیری سریعترا، از سایر شبکه‌های عصبی متمایز شده است [۳۴].

#### ۴. مطالعات انجام شده برای تشخیص اوتیسم با

##### کمک EEG و الگوریتم‌های یادگیری ماشین

امروزه در مقالات با استفاده از هوش مصنوعی به طبقه‌بندی سیگنال‌های EEG جهت تشخیص اوتیسم، تشخیص احساسات، تشخیص تشنج، مطالعه خواب و ... پرداخته می‌شود. ثبت داده برای هر یک از موارد ذکر شده باید طبق دستورالعمل ثبت خاص خود انجام شود. در مقالات تحلیل احساسات افراد مورد مطالعه در هنگام ثبت سیگنال، ویدئویی را می‌بینند که احساسات خاصی در شخص ایجاد می‌کند یا در مطالعه‌ی دیگر، برای پژوهش‌های مبتنی بر تشخیص بیماری صرع، از دو گروه افراد دارای بیماری صرع و سالم استفاده می‌کنند. در مقاله [۲۱] تکنیک‌های مبتنی بر هوش مصنوعی مورد استفاده برای تشخیص اوتیسم (ASD) بحث شده است. این تحقیق با شرح مختصری از ASD و روش غیر تهاجمی فعلی برای طبقه‌بندی بین افراد دارای اوتیسم و

ورودی و خروجی هستند؛ اما ممکن است چندین لایه پنهان هم داشته باشند که می‌تواند در مواردی همچون تشخیص گفتار، شناسایی تصاویر و نرم افزار ماشین ترجمه استفاده شوند.

خود رمزگذارها Autoencoder: خود رمزگذارها، نوع خاصی از شبکه‌های عصبی پیشخور است که در آن، میزان داده‌های ورودی و خروجی به صورت یکسان است. جفری هیتون، خود رمزگذارها را در سال ۱۹۸۰ و به منظور حل مسائل مربوط به یادگیری بدون نظارت طراحی کرد. آن‌ها شبکه‌های عصبی را آموزش دادند که داده‌ها را از لایه ورودی به سمت لایه خروجی کپی برداری می‌کنند. خود رمزگذارها برای اهدافی همچون اکتشافات پزشکی، پیش‌بینی‌های عمومی و پردازش تصاویر استفاده می‌شوند [۲۰].

GoogLeNet نوعی شبکه عصبی کانولوشن است که مبتنی بر معماری موازی کاری Inception است. از ماژول‌های Inception استفاده می‌کند که به شبکه اجازه می‌دهد بین چندین فیلتر کانولوشنال با اندازه متفاوت در هر بلوک انتخاب کند. یک شبکه Inception این ماژول‌ها را روی هم قرار می‌دهد تا با لایه‌های ادغام کننده‌ی max-pooling با گام ۲ تا وضوح شبکه را به نصف کاهش دهد [۲۳].

در شبکه ResNet، ارتباط خارج از ساختار کانولوشنالی وجود دارد این ارتباطات بین لایه‌ها هم هست. ورودی‌های لایه قبلی بدون واسطه به لایه بعدی انتقال داده می‌شود و در مرحله back propagation یا اصلاح شبکه، خطای هر لایه به لایه قبلی انتقال داده می‌شود تا شبکه عمیق‌تر شود و منجر به آموزش سریع‌تر شود. این ارتباطات skip connections نامیده می‌شود. به ساختار بدست آمده از آن Residual block گفته می‌شود [۲۹].

دیده برای طبقه‌بندی افراد ASD و کنترل‌های عادی با استفاده از سیگنال‌های EEG استفاده شده است. دقت به دست آمده با استفاده از GoogLeNet و SqueezeNet به ترتیب ۷۵٪ و ۸۲٪ در طبقه‌بندی اسکالوگرام‌های تولید شده از سیگنال‌های EEG افراد ASD و افراد عادی بود. نتایج به دست آمده نشان می‌دهد که این روش می‌تواند به طبقه‌بندی افراد ASD و افراد عادی با استفاده از سیگنال‌های EEG کمک کند [۲۳]. در مطالعه [۲۴] اثربخشی الگوریتم‌های مختلف یادگیری ماشین و تکنیک‌های پیش پردازش برای کار طبقه‌بندی برای مجموعه داده‌های پزشکی که برای پیش بینی صفات اولیه اوتیسم در کودکان نوپا و بزرگسالان استفاده می‌شود ارزیابی شده است. مراحل پیش پردازش همراه با کدگذاری مناسب داده‌ها و الگوریتم‌های طبقه‌بندی مختلف مانند رگرسیون لجستیک، KNN و جنگل تصادفی نتایج قابل مقایسه‌ای را در مقایسه با مقالات موجود نشان می‌دهند.

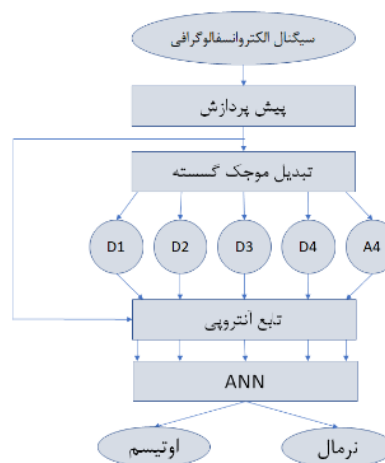
در مقاله [۲۵] نوآوری مقاله تشخیص بیماری اوتیسم با استفاده از آنروپی شانون SE، تبدیل موجک گسسته DWT و الگوریتم ANN می‌باشد. DWT برای محاسبه زیرباندهای سیگنال EEG کاربرد دارد. سپس مقدار SE برای استخراج ویژگی در هر زیر بانده محاسبه شده است. در مرحله نهایی با استفاده از الگوریتم ANN بر اساس ویژگی‌های استخراج شده از سیگنال EEG داده‌های افراد سالم و مبتلا به اوتیسم طبقه‌بندی شده است. داده‌های استفاده شده در این پژوهش از دانشگاه عبدالعزیز عربستان می‌باشد. بهترین نتیجه حاصل از الگوریتم ANN بر روی این داده‌ها دقتی حدود ۱۰۰٪ را منجر شده است. شکل ۲ بلوک دیاگرام روش پیشنهادی مقاله ارائه شده است.

افراد سالم استفاده می‌شود. با هوش مصنوعی، مدل‌های جدید مبتنی بر تکنیک‌های یادگیری عمیق نیز شرح داده شده‌اند. مطالعات اخیر نشان داده است که مداخله زودهنگام برای بهبود وضعیت بسیار موثر است. با این حال، معیارهای تشخیصی ASD فعلی، تشخیص زودهنگام را به چالش می‌کشد زیرا تست‌های پزشکی کاملاً تعریف شده برای تشخیص ASD در دسترس نیستند. در چندین سال گذشته، چندین معیار عینی با استفاده از ناهنجاری‌های موجود در سیگنال‌های EEG و تجزیه و تحلیل آماری پیشنهاد شده است. روش‌های مبتنی بر یادگیری ماشین انعطاف پذیری بیشتری را فراهم می‌کنند و نتایج بهتری را در طبقه‌بندی ASD کسب نموده‌اند. پژوهش [۲۲] یک بررسی از ASD مبتنی بر EEG ارائه می‌کند. رویکردهای طبقه‌بندی از ۲۰۱۰ تا ۲۰۱۸ انتخاب شده‌اند و روش‌ها به چهار مرحله تقسیم می‌شود: جمع‌آوری داده‌های EEG، پیش پردازش، استخراج ویژگی و طبقه‌بندی. این مطالعه تکنیک‌ها و ابزارهای مختلف مورد استفاده برای پیش پردازش، استخراج و انتخاب ویژگی، مدل‌های طبقه‌بندی و اقداماتی برای ارزیابی مدل‌ها را مورد تجزیه و تحلیل قرار می‌دهد. علاوه بر این، خلاصه‌ای از طبقه‌بندی ASD و چالش‌های موجود را مورد بررسی قرار می‌دهد و محدودیت‌ها و مسیرهای آینده را بحث می‌کند [۲۲].

بیماری‌های مختلفی مانند صرع و بیماری آلزایمر با استفاده از EEG شناسایی می‌شوند. اختلال طیف اوتیسم که یک اختلال عصبی است، اجتماعی شدن، ارتباط و رفتار افراد مبتلا به آن را مختل می‌کند. مطالعات مختلفی برای یافتن ناهنجاری‌های EEG در افراد ASD و افراد عادی انجام شده است؛ به طوری که ASD را می‌توان با استفاده از EEG تشخیص داد. در این مطالعه، از رویکرد یادگیری انتقال برای آموزش CNN، GoogLeNet و SqueezeNet از پیش آموزش

عنوان موثرترین داده در دسترس در نظر گرفته شده است. در میان انواع روش‌ها، سیگنال مغزی EEG، یک روش نسبتاً آسان و همچنین کم هزینه است. بنابراین برای تشخیص ASD امیدوارکننده است. در این مطالعه، تشخیص ASD مبتنی بر EEG با نمایش داده‌های کانال‌های مجزا به شکل دوبعدی و سپس طبقه‌بندی آن با ResNet of CNN انجام می‌شود. پژوهش حاضر، بررسی روش‌ها بر روی مجموعه داده‌هایی است که حجم زیادی دارند. تحقیقات اختلال طیف اوتیسم هنوز نتوانسته است از داده‌های بزرگ در مقیاسی مشابه با سایر زمینه‌ها استفاده کند. با این حال، پیشرفت در جمع‌آوری و تجزیه و تحلیل داده‌های آسان و مقرون به صرفه ممکن است به زودی این امر را به واقعیت تبدیل کند. در واقع، افزایش قابل توجهی در ادبیات تحقیقاتی در ارزیابی اثربخشی روش‌های یادگیری ماشین برای تشخیص ASD، بررسی زیربنای ژنتیکی آن و طراحی مداخلات موثر وجود داشته است. این مقاله مروری جامع از ۴۵ مقاله با استفاده از روش‌های یادگیری ماشین نظارت شده برای تشخیص ASD ارائه می‌کند. هدف این مقاله شناسایی و توصیف روندهای یادگیری ماشین نظارت شده در ادبیات ASD و همچنین اطلاع‌رسانی و راهنمایی محققان علاقه مند به گسترش بدنه رویکردهای بالینی، محاسباتی و آماری صحیح برای استخراج داده‌های ASD است. مقادیر زیادی از داده‌های اختلال طیف اوتیسم از طریق بیمارستان‌ها، مراکز درمانی و برنامه‌های تلفن همراه ایجاد می‌شود. با این حال، بسیاری از این داده‌های غنی برچسب ندارند. مقادیر زیادی داده - هر دو ژنتیکی و رفتاری - که به عنوان بخشی از مطالعات علمی یا بخشی از درمان جمع‌آوری شده‌اند، می‌بایست با دقت بیشتر در تشخیص اختلال اوتیسم به کار برده شوند.

در پژوهش [۳۰]، ۴۳ مقاله در زمینه تشخیص اوتیسم با استفاده از یادگیری بدون نظارت بررسی شده است؛ شامل



شکل (۲): بلوک دیاگرام الگوریتم پیشنهادی [۲۵]

در مقاله [۲۶] جهت تشخیص اختلال اوتیسم و صرع از تحلیل سیگنال‌های EEG استفاده شده است. پزشکان با تلاش و تخصص خود تشخیص بیماری اوتیسم را غالباً کاری دشواری می‌دانند. امروزه با پیشرفت در علوم پردازش سیگنال و الگوریتم‌های یادگیری ماشین، سیستم‌های مبتنی بر کامپیوتر قادر به انجام کارهای پیچیده‌تر، از جمله بررسی سیگنال‌های EEG هستند. تحلیل سیگنال‌های EEG ممکن است علائمی از شرایط و آسیب‌های مغزی را بیان کند. در پژوهش‌های اخیر از سیگنال‌های ثبت شده به عنوان ابزاری برای تشخیص بیماری‌های صرع و اوتیسم استفاده می‌شود [۲۷، ۲۸].

مقاله [۲۹] به بررسی تشخیص ASD مبتنی بر EEG با استفاده از CNN، یعنی روش یادگیری عمیق شناخته شده برای تجزیه و تحلیل و طبقه‌بندی تصویر می‌پردازد. در ابتدا، داده‌های کانال EEG منفرد با استفاده از ضریب همبستگی پیرسون به شکل دوبعدی تبدیل می‌شوند و سپس با استفاده از شبکه عصبی باقی‌مانده مدل CNN طبقه‌بندی می‌شوند. آزمایش‌های انجام شده بر روی داده‌های EEG بالینی نشان می‌دهد که رویکرد پیشنهادی به دقت طبقه‌بندی ۱۰۰ درصد دست یافته است. از آنجایی که ASD یک اختلال عصبی رشدی است، بر اساس تشخیص بر روی فعالیت مغز به

خوشه‌بندی k-means، خوشه‌بندی سلسله مراتبی، خوشه‌بندی مبتنی بر مدل و نقشه‌های خودسازماندهی می‌باشد. هدف این مقاله بررسی کاربردهای فعلی الگوریتم‌های یادگیری ماشین بدون نظارت در تحقیقات ASD می‌باشد.

در پژوهش [۳۱] تشخیص بیماری اوتیسم با استفاده از EEG و شبکه عصبی کانولوشن عمیق دو بعدی (2D\_DCNN) انجام شده است. با توجه به این که در سال‌های اخیر شبکه عصبی کانولوشن عمیق عملکرد خوبی در مطالعات و کاربردهای تصویری مختلف داشته است؛ در این مطالعه سیگنال‌های ثبت شده از افراد سالم و اوتیسم را به صورت تصویر دو بعدی به نحوی که کانال‌ها عرض تصویر است و نمونه‌های کانال طول تصویر است در نظر گرفته است. 2D\_DCNN برای این که عملکرد مناسبی در یادگیری داشته باشد نیاز به تعداد داده نسبتاً زیادی دارند. در مطالعات مبتنی بر EEG امکان دسترسی به داده کافی وجود ندارد و بر همین اساس از افزایش داده استفاده شده است. افزایش داده‌های استفاده شده در این مطالعه شامل روش‌هایی از جمله افزودن نویز NA، ترکیب کانال ChC و ترکیب ChC و NA است. در NA نویز گوسی هم بعد با داده و با واریانس‌های مختلف به داده اضافه می‌شود. در ChC با ترکیب کانال‌های مربوط به افراد سالم یا افراد اوتیسم به ایجاد داده جدید پرداخته است؛ به این صورت که اگر به عنوان مثال دو فرد مبتلا به اوتیسم را در نظر بگیرید، کانال‌های با شماره فرد مربوط به نفر اول را با کانال‌های زوج مربوط به نفر دوم را به صورت یک در میان در کنار هم قرار داده و یک داده جدید به عنوان نفر سوم ایجاد شده است. 2D\_DCNN آموزش دیده با داده‌های افزایش یافته با روش ترکیب کانال بهترین عملکرد (۸۸ درصد) را داشته است.

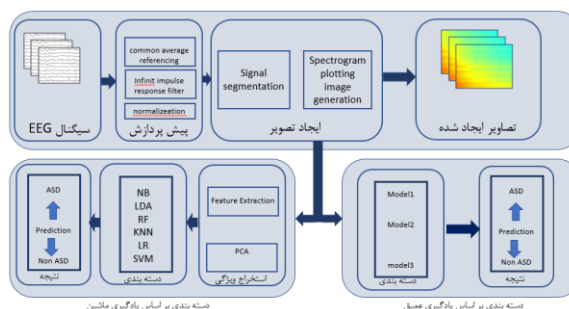
در مقاله [۳۲] به تشخیص بیماری اوتیسم با یک چهارچوب مبتنی بر تصاویر طیف‌نگار زمان-فرکانس سیگنال‌های EEG پرداخته است. در سیستم پیشنهادی این مطالعه، ابتدا، سیگنال‌های EEG خام با استفاده از مرجع گذاری مجدد، فیلتر کردن و نرمال‌سازی پیش پردازش شده است. سپس تبدیل فوری کوتاه مدت برای تبدیل سیگنال‌های پیش پردازش شده به تصاویر طیف نگاری دو بعدی استفاده شده است. در مرحله نهایی، آن تصاویر توسط مدل‌های یادگیری ماشین (ML) و یادگیری عمیق (DL) دسته بندی شده‌اند. در فرآیند ML، ویژگی‌های بافتی استخراج می‌شوند و ویژگی‌های مهم با استفاده از پردازش و بررسی مؤلفه‌های اصلی (PCA) انتخاب شده و آنها را به شش طبقه‌بندی کننده مختلف ML برای طبقه‌بندی کردن به عنوان ورودی می‌دهد. در فرآیند DL، سه مدل شبکه عصبی کانولوشنال مختلف مورد بررسی قرار گرفته است. مدل مبتنی بر DL پیشنهادی دقت بالاتری (۹۹٫۱۵٪) در مقایسه با مدل مبتنی بر ML بر روی یک مجموعه داده به دست آورده و همچنین از روش‌های موجود بهتر عمل کرده است. یافته‌های این مطالعه نشان داد که ساختار مبتنی بر DL می‌تواند نشانگرهای زیستی مهمی را برای تشخیص کارآمد و خودکار ASD از EEG کشف کند و ممکن است به توسعه سیستم تشخیص به کمک رایانه کمک کند. شکل ۳ مراحل پیشنهادی مقاله شامل ثبت سیگنال، پیش پردازش داده‌ها، استخراج ویژگی و چند نمونه طبقه بندی کننده‌های الگوریتم‌های یادگیری ماشین را نشان می‌دهد.

برای تشخیص اوتیسم با استفاده از سیگنال‌های EEG مناسب است. این مدل به عنوان بخشی از ابزار کمکی که به متخصصان مغز و اعصاب در هنگام تشخیص اوتیسم در مراکز پزشکی کمک می‌کند، آماده شده است.

در [۳۱-۳۹] به منظور تشخیص بیماری اوتیسم بعد فراکتال (FD) را برای اندازه‌گیری پیچیدگی و تغییرات دینامیکی در مغز بررسی نموده است.

در [۳۴] سیگنال نوار مغز ۹ کودک ASD و ۸ کودک غیر اوتیسم به عنوان مجموعه داده بر اساس سیستم بین‌المللی ۱۰-۲۰ ثبت شد که هر کدام از ۱۹ کانال تشکیل شده بود و با نرخ نمونه برداری ۲۵۶ هرتز دیجیتالی شد. دقت ۹۰ درصد با استفاده از دسته بندی کننده SVM به دست آمد. در ادامه، همان گروه تشخیص ASD را با استفاده از طبقه بندی کننده فازی و دسته بندی کننده شبکه عصبی فازی بهبود یافته ارائه کردند. دو روش پیشنهادی حدود ۹۵,۵ درصد دقت را ارائه دادند. در مقاله [۳۵] با هدف تشخیص بیماری اوتیسم بر روی یک مجموعه EEG (متشکل از ۷۹ نفر: ۴۶ نفر مبتلا به اوتیسم و ۳۳ نفر سالم) بررسی انجام شد. در این مطالعه از حداقل میانگین مربعات خطا (MMSE) به عنوان بردار ویژگی استفاده شد و سپس از الگوریتم‌های طبقه بندی k نزدیک‌ترین همسایه (KNN)<sup>۵</sup>، الگوریتم ماشین بردار پشتیبان (SVM) و الگوریتم‌های طبقه بندی ساده بییزی (NB)<sup>۶</sup> برای طبقه بندی سیگنال‌های معمولی و اوتیسم استفاده شد که SVM بهترین دقت را بدست آورد.

در مرجع [۳۷] از ضریب همبستگی پیرسون (PCC)<sup>۷</sup> استفاده شده است تا تصاویر EEG را به ویژگی از نوع ضرایب



شکل (۳): ساختار الگوریتم یادگیری ماشین [۳۲]

در مقاله [۳۳] برای تشخیص خودکار بیماری اوتیسم یک استخراج کننده ویژگی عمیق ترکیبی سبک وزن به منظور بهبود عملکرد طبقه بندی پیشنهاد شده است. این سیستم با یک مجموعه داده بزرگ EEG طراحی و آزمایش شد که حاوی سیگنال‌هایی از بیماران اوتیسم و افراد عادی بود. چهارچوب کلی این مطالعه به ۴ بخش اصلی به شرح زیر است: (۱) یک مدل جدید تبدیل سیگنال به تصویر در این مطالعه ارائه شده است. در این کار، ویژگی‌ها از سیگنال EEG با استفاده از الگوی باینری محلی یک بعدی (D\_LBPI) استخراج شده و ویژگی‌های تولید شده به عنوان ورودی تبدیل فوریه کوتاه مدت (STFT) برای تولید تصاویر طیف‌نگاری استفاده شده است. (۲) ویژگی‌های عمیق تصاویر طیف‌نگاری تولید شده با استفاده از ترکیبی از مدل‌های ShuffleNet، MobileNetV2 و SqueezeNet از پیش آموزش دیده استخراج شده که این روش تولید کننده ویژگی‌های سبک وزن عمیق هیبریدی نام دارد. (۳) یک الگوریتم ReliefF دو لایه برای رتبه بندی ویژگی و انتخاب ویژگی استفاده می‌شود. (۴) متمایزترین ویژگی‌ها به طبقه بندی کننده‌های مختلف کم عمق داده شد که با استفاده از یک استراتژی اعتبارسنجی ۱۰-fold متقابل برای تشخیص خودکار اوتیسم توسعه یافته است. طبقه بندی کننده ماشین بردار پشتیبان (SVM) بر اساس ویژگی‌های مدل پیشنهادی به دقت ۹۶,۴۴ درصد رسید. نتایج نشان می‌دهد که استخراج کننده ویژگی سبک وزن عمیق هیبریدی پیشنهادی

<sup>5</sup> K-Nearest Neighbors

<sup>6</sup> Naive Bayse

<sup>7</sup> Pearson Correlation Coefficient

مروری بر روی مطالعات انجام شده توسط انواع روش‌های یادگیری ماشین نشان می‌دهد که غالباً طبقه‌بند ماشین بردار پشتیبان (SVM) منجر به دقت بهتری در مقایسه با سایر روش‌های یادگیری ماشین شده است [۳۶،۳۸،۳۹،۴۱،۴۴،۴۵].

در مجموع می‌توان نقش روش‌های بکار گرفته شده به منظور پیش پردازش (حذف نویز و آرتیفکت)، استخراج و انتخاب ویژگی از روی تصاویر EEG و نوع طبقه‌بند را عوامل موثر در دقت طبقه‌بندی ذکر نمود.

در تحقیقاتی که از روش‌های یادگیری ماشین برای طبقه‌بندی استفاده کرده‌اند، SVM در اکثر موارد بهترین دقت را کسب نموده و شبکه‌های عصبی کانولوشنی (CNN) برای روش‌های یادگیری عمیق همین نتیجه را رقم زده است. هر چند که روش‌های پیش پردازش موثر و انتخاب ویژگی‌های مناسب در کارایی طبقه‌بندها نقش شایانی ایفا می‌کند.

مجموعه نتایج تفکیکی مقاله‌های مروری مطالعه شده با بیان مشخصات مجموعه داده، طبقه‌بند پیشنهادی و نتیجه ارزیابی در جدول ۱ آورده شده است.

همبستگی تبدیل کند. سپس شبکه عصبی کانولوشنی (Resnet) برای تشخیص اوتیسم ارائه شد. نتایج بر روی دادگان آموزش ۸۸ درصد و بر روی دادگان تست ۱۰۰ درصد گزارش شده است. همچنین عیب روش خود را نداشتن دادگان زیاد و همچنین بررسی معیارهای دیگر برای ویژگی همبستگی ذکر کرده‌اند.

استفاده از ویژگی‌های تنک (sparse) بر روی تصاویر EEG نکته قابل توجهی است که در مرجع [۴۰] به آن اشاره شده است. این نوع از استخراج ویژگی به همراه بکارگیری روش‌های خودرمزگذار برای افزایش دادگان و طبقه‌بند CNN منجر شده تا نتیجه دقت ۹۸٫۸۸ درصد بدست آید. محققان مزیت روش پیشنهادی را عدم نیاز به ناحیه بندی (segmentation) تصاویر EEG بیان کرده‌اند که ممکن است باعث از دست رفتن اطلاعات مهمی شود.

مرجع [۴۳] مزیت روش پیشنهادی خود را استفاده از تبدیل موجک مرتبه دوم برای استخراج ویژگی ذکر می‌کند که به همراه طبقه‌بند LSTM و CNN به ترتیب منجر به نتایج دقت ۹۲ و ۹۵ درصد شد. استفاده از ویژگی‌های مذکور می‌تواند بر روی دادگان کم بدون آن که روش‌های افزایش داده بکار گرفته شود موثر واقع شود و زمان اجرا را کاهش دهد.

جدول (۱). نتایج حاصل از مقالات مرور شده با بیان مشخصات مجموعه داده، طبقه‌بند پیشنهادی و نتیجه ارزیابی

مرجع	سال انتشار	روش طبقه‌بندی	مجموعه داده	نتیجه ارزیابی (درصد دقت)
[23]	۲۰۲۱	GoogLeNet SqueezeNet	داده‌ها مطابق با نظر هیئت بررسی دانشگاه عبدالعزیز عربستان سعودی، سیگنال‌های EEG با فرکانس ۲۵۶ هرتز، ۱۶ کانال، ۱۳ فرد مبتلا به اوتیسم و ۴ فرد سالم	۷۵٪ ۸۲٪
[24]	۲۰۲۰	LR KNN RF	مجموعه داده با ۲۰ ویژگی مرتبط با بیماری اوتیسم	۶۸٫۶٪ ۶۹٫۲٪ ۶۷٫۸٪
[25]	۲۰۱۷	ANN	دانشگاه عبدالعزیز عربستان سعودی، سیگنال‌های EEG با فرکانس ۲۵۶ هرتز، ۱۶ کانال	تقریباً ۱۰۰٪
[26]	۲۰۱۸	KNN	دیتاست اول دانشگاه بن، سیگنال‌های EEG با فرکانس ۱۷۳ هرتز، ۱۶ کانال/دیتا ست دوم دانشگاه MIT، سیگنال‌های EEG با فرکانس ۲۵۶ هرتز، ۲۳ کانال/دیتا ست سوم دانشگاه عبدالعزیز عربستان سعودی، سیگنال‌های EEG با فرکانس ۲۵۶ هرتز، ۱۶ کانال	۹۴٫۶٪

سیگنال‌های EEG با فرکانس ۲۵۶ هرتز، ۱۹ کانال، ۱۳ فرد مبتلا به اوتیسم و ۴ فرد سالم	Resnet (CNN)	۲۰۲۰	[29]
داده‌ها مطابق با نظر هیئت بررسی دانشگاه کالیفرنیا، سیگنال‌های EEG با فرکانس ۵۰۰ هرتز، ۱۲۹ کانال، ۱۰ فرد مبتلا به اوتیسم و ۹ فرد سالم	2D-DCNN	۲۰۲۲	[31]
سیگنال‌های EEG با فرکانس ۲۵۶ هرتز، ۱۶ کانال، ۱۲ فرد مبتلا به اوتیسم و ۴ فرد سالم	CNN-SVM	۲۰۲۱	[32]
سیگنال‌های EEG با فرکانس ۵۰۰ هرتز، ۶۴ کانال، ۶۱ فرد مبتلا به اوتیسم و ۶۱ فرد سالم	SVM	۲۰۲۱	[33]
سیگنال‌های EEG با فرکانس ۱۹ کانال، ۱۵ فرد مبتلا به اوتیسم و ۱۰ فرد سالم	PCC-CNN	۲۰۲۲	[37]
سیگنال‌های EEG با فرکانس ۱۶ کانال، ۲۰ فرد مبتلا به اوتیسم و ۹ فرد سالم	CNN	۲۰۲۲	[40]
سیگنال‌های EEG با فرکانس ۲۵۶ هرتز، ۱۲۸ کانال، ۱۴ فرد مبتلا به اوتیسم و ۱۴ فرد سالم	LSTM-CNN	۲۰۲۲	[43]
CNN ۹۹٪ SVM ۹۵،۳٪ ۹۶،۴۴٪ ۱۰۰٪ ٪ ۹۸،۸۸			
LSTM ۹۲٪ CNN ۹۲٪			

## ۵. بحث و پیشنهاد‌های کاربردی

در این مطالعه به یک مسئله طبقه بندی به دو کلاس افراد سالم و افراد مبتلا به اوتیسم پرداخته شده است. داده‌های قابل اخذ از افراد، سیگنال نوار مغز (EEG) انتخاب شده است. سیگنال نوار مغز در مقایسه با تصاویر MRI و روش‌های تهاجمی مزیت غیرتهاجمی و ارزان بودن را دارند. بیش از ۷۰ مقاله مرور شده است که در اینجا خلاصه‌ای از اطلاعات ۴۵ مقاله ذکر شده است. مجموعه دادگان مورد استفاده، دادگانی بوده که محققان آن مقاله، خودشان تهیه کرده بودند. از آنجایی که تصاویر EEG بصورت سیگنال‌هایی پیچیده قابل رویت می‌باشند، پزشک نمی‌تواند با مشاهده چشمی، اوتیسم و سالم را تشخیص دهد. این پیچیدگی طلب می‌کند که از روش‌های مبتنی بر هوش مصنوعی برای تشخیص اوتیسم استفاده شود. از این رو مقالاتی که در این مطالعه انتخاب شده‌اند عمدتاً از روش‌های یادگیری ماشین و یادگیری عمیق بهره برده‌اند تا به تشخیص اوتیسم بپردازند. در تحقیقات ارائه شده می‌توان بطور کلی روند زیر را برای عموم بیان نمود: (۱) از آنجایی که دادگان برچسب دار بودند، از روش‌های یادگیری نظارت شده استفاده شده است. (۲) مدل آموزشی شامل بلوک‌های پیش‌پردازش، استخراج ویژگی و طبقه‌بندی می‌باشد. (۳) از معیارهای ارزیابی دقت طبقه‌بندی برای مقایسه روش‌ها استفاده شده است.

نکاتی که وجه تمایز تحقیقات را تعیین می‌کند به شرح زیر است: (۱) روشی که برای استخراج ویژگی‌ها بکار گرفته شده است. (۲) روشی که برای طبقه بندی به دو کلاس سالم و اوتیسم بکار گرفته شده است.

معیارهای ارزیابی دقت طبقه بندی که مقالات از آنها استفاده کرده‌اند عبارتند از:

(۱) معیار صحت یا Precision که فرمول آن در (۱) ذکر شده است.  
(۲) معیار حساسیت یا Recall که فرمول آن در (۲) آمده است.

(۳) نرخ دقت یا F1-score که میانگین همساز معیارهای صحت و حساسیت می‌باشد و فرمول آن در (۳) بیان شده است.

(۴) منحنی ROC یا نرخ مثبت صحیح  $\left(\frac{TP}{TP+FN}\right)$  بر حسب نرخ مثبت کاذب  $\left(\frac{FP}{FP+TN}\right)$ .

$$Precision = \frac{TP}{TP+FP} \quad (1)$$

$$Recall = \frac{TP}{TP+FN} \quad (2)$$

$$F1 - score = \frac{2 * (precision * recall)}{(precision + recall)} \quad (3)$$

- True Positive (TP): تشخیص در دسته مثبت (کلاس واقعی مثبت)



همچنین زمان اجرا نیز می تواند یک معیار ارزیابی باشد اما معیار قابل بحثی در مقالات نبوده است.

- True Negative (TN): تشخیص در دسته منفی (کلاس واقعی منفی)
- False Positive (FP): تشخیص در دسته مثبت (کلاس واقعی منفی)
- False Negative (FN): تشخیص در دسته منفی (کلاس واقعی مثبت)

جدول (۲). نقاط قوت و ضعف الگوریتم‌های یادگیری ماشین مقالات مرور شده در جدول ۱

مراجع	مدل	نوآوری مقاله	نقاط قوت	نقاط ضعف
[23]	GoogLeNet SqueezeNet	استفاده از تکنیک یادگیری انتقالی موجود در الگوریتم‌های SqueezeNet و GoogLeNet	استفاده از شبکه‌های عصبی از پیش آموزش دیده	زمان بر بودن فرایند با توجه به CPU مورد استفاده
[24]	LR KNN RF	اثربخشی تکنیک‌های پیش‌پردازش و الگوریتم‌های مختلف یادگیری ماشین به منظور طبقه بندی برای پیش بینی صفات اولیه اوتیسم در کودکان نوپا و بزرگسالان	استفاده از تکنیک پیش‌پردازش موثر نتایج دقیق‌تر الگوریتم KNN	نیاز به حجم داده زیاد برای آموزش بهتر عدم دسترسی آسان محققان به داده‌های قابل اطمینان در مراکز پزشکی
[25]	ANN	تشخیص اختلال اوتیسم با استفاده از آنتروپی شانون SE تبدیل موجک گسسته DWT و الگوریتم ANN	سادگی روش پیاده‌سازی الگوریتم استخراج ویژگی کاهش زمان استخراج ویژگی افزایش دقت تشخیص با ترکیب تبدیل موجک و آنتروپی و شبکه عصبی	مجموعه داده کوچک است نیاز به داده زیاد و متفاوت با داده فعلی برای انجام تست‌های بیشتر نیاز به انجام تکنیک‌های پیش‌پردازش قویتر
[26]	KNN	تشخیص اختلال اوتیسم با استفاده از آنتروپی شانون SE تبدیل موجک گسسته DWT و الگوریتم ANN	بهبود سرعت و دقت در تشخیص بیماری اوتیسم بررسی جامع و انجام انواع آزمایش‌ها در انتخاب ویژگی و طبقه بندی دقت طبقه بندی بهتر برای مجموعه داده های جامع تر در مقایسه با سایر الگوریتم‌ها	فرایند محاسباتی پیچیده نیاز به حجم داده زیاد
[29]	Resnet (CNN)	نمایش تصویر دوبعدی داده های EEG و بررسی تشخیص بیماری اوتیسم مبتنی بر EEG با استفاده از Resnet (CNN)	دقت بالا در تشخیص بیماری اوتیسم به دلیل دوبعدی کردن سیگنال EEG	نیاز به حجم داده زیاد فرایند پیچیده
[31]	2D_DCNN	تشخیص بیماری اوتیسم با استفاده از EEG و شبکه عصبی کانولوشن عمیق دو بعدی، استفاده از تکنیک‌های افزایش داده	بهبود عملکرد یادگیری و دقت تشخیص بیماری به دلیل استفاده از تکنیک‌های افزایش داده	فرایند پیچیده حساس به تنظیم پارامترها زمان بر بودن مراحل الگوریتم
[32]	SVM CNN	تشخیص بیماری اوتیسم با یک چهارچوب مبتنی بر تصاویر طیف‌نگار زمان-فرکانس سیگنال‌های EEG	استفاده از تبدیل فوریه STFT به عنوان نقطه قوت تحقیق نتایج دقیق‌تر الگوریتم‌های یادگیری عمیق CNN در مقایسه با الگوریتم‌های یادگیری ماشین	عملکرد ضعیف‌تر الگوریتم SVM نسبت به الگوریتم‌های شبکه عصبی کانولوشنال
[33]	SVM	تشخیص خودکار بیماری اوتیسم با استفاده یک استخراج کننده ویژگی عمیق ترکیبی سبک وزن	دقت بالا در تشخیص بیماری اوتیسم به دلیل استخراج کننده ویژگی بسیار قوی	بررسی طبقه بندی کننده‌های دیگر به غیر از طبقه بندهای مبتنی بر یادگیری ماشین
[37]	CNN (CNN)	تشخیص بیماری اوتیسم مبتنی بر EEG با استفاده از Resnet (CNN)	دقت بالا در تشخیص بیماری اوتیسم به دلیل ترکیب ضرایب همبستگی و شبکه کانولوشنی	نداشتن داده زیاد و همچنین بررسی معیارهای دیگر برای ویژگی همبستگی
[40]		تشخیص دقیق بیماری اوتیسم با استفاده از الگوریتم متفاوت	عملکرد دقیق در رویکردهای تشخیص	نیاز به بررسی الگوریتم پیشنهادی بر روی

CNN	استخراج ویژگی (ترکیب الگوریتم داکلاس-پوکر و تبدیل موجک و بکارگیری ویژگی‌های تنک) و شبکه عصبی کانولوشنال	بیماری اوتیسم به دلیل ترکیب استخراج کننده ویژگی و طبقه بند بسیار قوی	داده‌های با حجم بیشتر وداده‌های پزشکی حساس به تنظیم پارامترها
CNN	استفاده از تبدیل موجک مرتبه دوم برای استخراج ویژگی و استفاده از طبقه بند LSTM و CNN	نتیجه بخش بودن ویژگی‌های استخراج شده موثر بر روی دادگان با حجم کم بدون نیاز به اعمال روش‌های افزایش داده سادگی الگوریتم استخراج ویژگی و کاهش زمان اجرا	نیاز به بررسی روش پیشنهادی بر روی داده‌های کلینیک
LSTM	[43]		

تشخیص خواهد داشت. پس از بیان مزایا و معایب هر کدام از روش‌های بکارگرفته شده در مقالات می‌توان نتیجه گرفت که طبقه‌بندهای مبتنی بر یادگیری عمیق به مراتب بهتر از طبقه‌بندهای مبتنی بر الگوریتم‌های یادگیری ماشین عمل کرده‌اند. دلیل آن هم پیچیدگی فرایند یادگیری به همراه نوع ویژگی‌های استفاده شده و روش‌های اتخاذ شده به منظور افزایش داده می‌تواند باشد.

## ۶. نتیجه گیری

اختلال اوتیسم یک اختلال عصبی است که در همه جای دنیا افراد را درگیر کرده است. اگر بتوان در سنین خردسالی این اختلال را هر چه زودتر تشخیص داد، هزینه‌های درمان به مراتب کاهش می‌یابد. در این مطالعه مروری بر الگوریتم‌های مبتنی بر هوش مصنوعی که از سیگنال‌های EEG برای تشخیص خودکار اوتیسم استفاده شده بود، انجام شد. در مقاله مروری حاضر ۴۵ مقاله مرتبط با کاربرد الگوریتم‌های یادگیری ماشین و یادگیری عمیق در تشخیص بیماری اوتیسم با استفاده از سیگنال EEG مورد بررسی قرار گرفت. نتایج نشان داد که الگوریتم‌های شبکه‌های عصبی کانولوشنی با ارائه بهترین نتایج دقت، پر کاربرد و مورد توجه محققین بوده است، البته نقش تکنیک‌های پیش پردازش مفید و استخراج کننده ویژگی موثر و در عین حال ساده را نمی‌توان در کارایی روش‌های پیشنهادی نادیده گرفت.

## مراجع

- [1] Grossi E., Valbusa G., and Buscema M., "Detection of an autism EEG signature from only

نقاط قوت و ضعف الگوریتم‌های پیشنهاد شده در مقالات جدول ۱ در تشخیص بیماری اوتیسم در جدول ۲ بیان شده است. با جمع‌بندی نقاط قوت و ضعف روش‌های مذکور در جدول ۲، پراکنده بودن تحقیقات در این زمینه نمایان است؛ بطوری که محققان سعی کردند در مراحل مختلف مثل پیش‌پردازش، استخراج و انتخاب ویژگی و طبقه‌بندی، روش‌های مختلفی را با هم ترکیب کنند و با انجام آزمایش‌ها نتیجه روش پیشنهادی را بیان کنند. به نظر می‌رسد اگر در تحقیقات پیش رو یک ارزیابی جامع انجام شود، راه را برای تحقیقات منسجم باز می‌کند. اکثر مقالات محدودیت روش خود را عدم دسترسی به یک پایگاه داده مرجع با حجم دادگان زیاد ذکر می‌کنند. بنابراین پیشنهادی که به عنوان فرصت پژوهشی می‌توان بیان کرد، دسترسی محققان به مجموعه دادگان استاندارد می‌باشد. همچنین هر محقق بعد از بیان نتایج روش پیشنهادی خود، استفاده از روش استخراج ویژگی مناسب‌تر یا طبقه بند دیگر را برای پژوهش‌های بعدی پیشنهاد می‌دهد زیرا نمی‌توان بدون شبیه سازی اذعان کرد که ترکیب یک استخراج کننده ویژگی دیگری به غیر از آنچه در آن تحقیق استفاده شده با یک طبقه‌بند دیگر می‌تواند نتایج بهتری کسب کند یا نه. با توجه به موارد ذکر شده در جداول ۱ و ۲، فرصت‌های پژوهشی می‌توانند استفاده از CNN در بلوک استخراج ویژگی، ترکیب هر کدام از روش‌های استخراج ویژگی ذکر شده در جدول ۲ با طبقه‌بندهای بکار گرفته در تحقیق‌های مختلف باشد. بکارگیری روش‌های افزایش داده برای دادگان کم تعداد، اثر ملموسی بر روی دقت

- [11] Dhall, D., Kaur, R., and Juneja, M., "Machine learning: a review of the algorithms and its applications", *Proceedings of ICRIC 2019*, pp. 47-63, 2020, [https://doi.org/10.1007/978-3-030-29407-6\\_5](https://doi.org/10.1007/978-3-030-29407-6_5).
- [12] Kotsiantis, S.B., Zaharakis I., and Pintelas, P., "Supervised machine learning: A review of classification techniques. Emerging artificial intelligence applications in computer engineering", *Vol. 160, No. 1*, pp. 3-24, 2007, <https://doi.org/10.1080/08839514.2021.2012001>.
- [13] Carbonell, J.G., Michalski, R.S., and Mitchell, T.M., "An overview of machine learning. Machine learning", pp. 3-23, 1983, <https://doi.org/10.1016/B978-0-08-051054-5.50005-4>.
- [14] Zhu, X., and A.B. Goldberg, "Introduction to semi-supervised learning. Synthesis lectures on artificial intelligence and machine learning", *Vol. 3, No. 1*, pp. 1-130, 2009.
- [15] Zhu, X.J., *Semi-supervised learning literature survey*, 2005.
- [16] Nanduri, V., and Das, T.K., "A reinforcement learning model to assess market power under auction-based energy pricing", *IEEE transactions on Power Systems*, *Vol. 22, No. 1*, pp. 85-95, 2007, <https://doi.org/10.1109/TPWRS.2006.888977>.
- [17] Sutton, R.S. and Barto, A.G., "Reinforcement learning", *Journal of Cognitive Neuroscience*, *Vol. 11, No. 1*, pp. 126-134, 1999.
- [18] Polikar, R., *Ensemble learning*, in *Ensemble machine learning*, Springer, pp. 1-34, 2012.
- [19] Aha, D.W., Kibler, D., and Albert, M.K., "Instance-based learning algorithms", *Machine learning*, *Vol. 6, No. 1*, pp. 37-66, 1991, <https://doi.org/10.1007/BF00153759>.
- [20] Vargas, R., Mosavi, A., and Ruiz, R., *Deep learning: a review*, 2019, <https://doi.org/10.20944/preprints201810.0218.v1>.
- [21] Chaddad, A., et al., "Can autism be diagnosed with artificial intelligence? A narrative review", *Diagnostics*, *Vol. 11, No. 11*, pp. 2032, 2021, <https://doi.org/10.3390/diagnostics11112032>.
- [22] Brihadiswaran, G., et al., "EEG-based processing and classification methodologies for autism spectrum disorder: A review," *Journal of Computer Science*, *Vol. 15, No. 8*, 2019, <https://doi.org/10.3844/jcssp.2019.1161.1183>.
- [23] Mohi-ud-Din, Q., and Jayanthi, A., "Detection of Autism Spectrum Disorder from EEG signals using pre-trained deep convolution neural networks," in *2021 Seventh International conference on Bio Signals, Images, and Instrumentation (ICBSII)*, IEEE, pp. 1-5, 2021, <https://doi.org/10.1109/ICBSII51839.2021.9445193>
- two EEG channels through features extraction and advanced machine learning analysis", *Clinical EEG and Neuroscience*, *vol. 52, no. 5*, pp. 330-337, 2021, <https://doi.org/10.1177/1550059420982424>.
- [2] Tayyebi A., and Pijanowski B.C., "Modeling multiple land use changes using ANN, CART and MARS: Comparing tradeoffs in goodness of fit and explanatory power of data mining tools", *International Journal of Applied Earth Observation and Geoinformation*, *Vol. 28*, pp. 102-116, May, 2014, <https://doi.org/10.1016/j.jag.2013.11.008>.
- [3] Coelho, L. P., and Richert, W., *Building machine learning systems with Python*. Packt Publishing Ltd, 2015.
- [4] Kumar, J.S., and P. Bhuvaneshwari, "Analysis of Electroencephalography (EEG) signals and its categorization—a study", *Procedia engineering*, *Vol. 38*, pp. 2525-2536, 2012, <https://doi.org/10.1016/j.proeng.2012.06.298>.
- [5] Radhamani, R., et al., "Computational analysis of cortical EEG biosignals and neural dynamics underlying an integrated mind-body relaxation technique", *Procedia Computer Science*, *Vol. 171*, pp. 341-349, 2020, <https://doi.org/10.1016/j.procs.2020.04.035>.
- [6] Samadi, S., and Mcconkey, R., "The impact on Iranian mothers and fathers who have children with an autism spectrum disorder", *Journal of Intellectual Disability Research*, *Vol. 58, No. 3*, pp. 243-254, 2014, <https://doi.org/10.1111/jir.12005>.
- [7] Kantarjian, H. and P.P. Yu, "Artificial intelligence, big data, and cancer", *JAMA oncology*, *Vol. 1, No. 5*, pp. 573-574, 2015, doi:10.1001/jamaoncol.2015.1203.
- [۸] ویسی ه.، قایدشرف ح.، ابراهیمی م.، «بهبود کارایی الگوریتم‌های یادگیری ماشین در تشخیص بیماری‌های قلبی با بهینه‌سازی داده‌ها و ویژگی‌ها»، *مجله محاسبات نرم*، جلد ۸، شماره ۱، ص. ۷۰-۸۵، ۱۳۹۸. <https://doi.org/10.22052/8.1.70>
- [۹] وثیقی‌ذاکر ا.، جلیلی س.، «پیش‌بینی ژن‌های بیماری با استفاده از دسته‌بند تک‌کلاسی ماشین بردار پشتیبان»، *مجله محاسبات نرم*، جلد ۴، شماره ۱، ص. ۷۴-۸۳، ۱۳۹۴. <https://doi.org/20.1001.1.23223707.1394.4.1.60.8>
- [۱۰] رزاق‌زاده ش.، نوروزی‌کیوی پ.، پناهی ب.، «الگوریتم ترکیبی مبتنی بر معماری گوسیپ با استفاده از SVM برای زمانبندی وظایف در رایانش ابری»، *مجله محاسبات نرم*، جلد ۹، شماره ۲، ص. ۸۴-۹۳، ۱۳۹۹. <https://doi.org/10.22052/SCJ.2021.242822.0>

- 2010,  
<https://doi.org/10.1097/WNP.0b013e3181f40dc8>.
- [35] Bosl, W., et al., "EEG complexity as a biomarker for autism spectrum disorder risk", *BMC medicine*, Vol. 9, No. 1, pp. 1-16, 2011.
- [36] Boeve, S., "Can machine learning capture differences in EEG of infants at elevated likelihood and typical likelihood of Autism?", Diss. Ghent University, 2022.
- [37] Peya, Z. J., Akhand, M. A. H., Srabonee, J. F., and Siddique, N., "Autism Detection from 2D Transformed EEG Signal using Convolutional Neural Network", *Journal of Computer Science*, Vol. 18, No. 8, pp. 695-704, 2022, <https://doi.org/10.3844/jcssp.2022.695.704>.
- [38] Zubair, K. M., Mashkur, B. S., and Nor, N. M., "Early Detection On Autistic Children by Using EEG Signals", *International Journal on Perceptive and Cognitive Computing* Vol. 8, No. 1, pp. 59-64, 2022.
- [39] Kresnia, G. M., and Parikesit, A. A., "Use of Artificial Intelligence in the Diagnostics of Autism Spectrum Disorder", *Cermin Dunia Kedokteran*, Vol. 49, No. 6, pp. 341-344, 2022.
- [40] Berna, A., et al. "Accurate detection of autism using Douglas-Peucker algorithm, sparse coding based feature mapping and convolutional neural network techniques with EEG signals", *Computers in Biology and Medicine*, Vol. 143, pp. 105311, 2022, <https://doi.org/10.1016/j.compbimed.2022.105311>.
- [41] Liao, M., Duan, H., and Wang, G., "Application of machine learning techniques to detect the children with autism spectrum disorder", *Journal of Healthcare Engineering*, 2022, <https://doi.org/10.1155/2022/9340027>.
- [42] Alhassan, S., Soudani, A., and Almusallam, M., "Energy-efficient EEG-based scheme for autism spectrum disorder detection using wearable sensors", *Sensors*, Vol. 23, No. 4, pp. 2228, 2023, <https://doi.org/10.3390/s23042228>.
- [43] Din, Q. M., and Jayanthi, A. K., "Wavelet Scattering Transform and Deep Learning Networks Based Autism Spectrum Disorder Identification Using EEG Signals", *Traitement du Signal*, Vol. 39, No. 6, pp. 2069, 2022, <https://doi.org/10.18280/ts.390619>
- [44] Das, S., et al., "Machine learning approaches for electroencephalography and magnetoencephalography analyses in autism spectrum disorder: A systematic review", *Progress in Neuro-Psychopharmacology and Biological Psychiatry*, pp. 110705, 2022, <https://doi.org/10.1016/j.pnpbp.2022.110705>.
- [45] Abdolzadegan, D., Moattar, M. H., and Ghoshuni, M., "A robust method for early diagnosis of autism spectrum disorder from EEG signals based
- [24] Devika Varshini, G., and Chinnaiyan, R., "Optimized machine learning classification approaches for prediction of autism spectrum disorder", *Ann Autism Dev Disord*, Vol. 1, No. 1, pp. 1001, 2020.
- [25] Djemal, R., et al., "EEG-based computer aided diagnosis of autism spectrum disorder using wavelet, entropy, and ANN", *BioMed research international*, 2017, <https://doi.org/10.1155/2017/9816591>.
- [26] Ibrahim, S., Djemal, R., and Alsuwailam, A., "Electroencephalography (EEG) signal processing for epilepsy and autism spectrum disorder diagnosis. *Biocybernetics and Biomedical Engineering*, Vol. 38, No. 1, pp. 16-26, 2018, <https://doi.org/10.1016/j.bbe.2017.08.006>.
- [27] Noachtar, S. and Rémi, J., "The role of EEG in epilepsy: a critical review", *Epilepsy & Behavior*, Vol. 15, No. 1, pp. 22-33, 2009, <https://doi.org/10.1016/j.yebeh.2009.02.035>.
- [28] Bhat, S., et al., "Automated diagnosis of autism: in search of a mathematical marker", *Reviews in the Neurosciences*, Vol. 25, No. 6, pp. 851-861, 2014, <https://doi.org/10.1515/revneuro-2014-0036>.
- [29] Peya, Z.J., et al., "EEG Based Autism Detection Using CNN through Correlation Based Transformation of Channels' Data", in *2020 IEEE Region 10 Symposium (TENSYP)*, 2020, <https://doi.org/10.1109/TENSYP50017.2020.9230928>.
- [30] Hyde, K.K., et al., "Applications of supervised machine learning in autism spectrum disorder research: a review", *Review Journal of Autism and Developmental Disorders*, Vol. 6, No. 2, pp. 128-146, 2019, <https://doi.org/10.1007/s40489-019-00158-x>.
- [31] Ardakani, H.A., Taghizadeh, M., and Shayegh, F., "Diagnosis of Autism Disorder Based on Deep Network Trained by Augmented EEG Signals", *International Journal of Neural Systems*, Vol. 32, No. 11, pp. 2250046, 2022, <https://doi.org/10.1142/s0129065722500460>.
- [32] Tawhid, M.N.A., et al., "A spectrogram image based intelligent technique for automatic detection of autism spectrum disorder from EEG", *Plos one*, 2021. 16(6): p. e0253094, <https://doi.org/10.1371/journal.pone.0253094>.
- [33] Baygin, M., et al., "Automated ASD detection using hybrid deep lightweight features extracted from EEG signals", *Computers in Biology and Medicine*, Vol. 134, pp. 104548, 2021, <https://doi.org/10.1016/j.compbimed.2021.104548>.
- [34] Ahmaddlou, M., Adeli, H., and Adeli, A., "Fractality and a wavelet-chaos-neural network methodology for EEG-based diagnosis of autistic spectrum disorder", *Journal of Clinical Neurophysiology*, Vol. 27, No. 5, pp. 328-333,

on feature selection and DBSCAN method”,  
Biocybernetics and Biomedical Engineering, Vol.  
40, No. 1, pp. 482-493, 2020,  
<https://doi.org/10.1016/j.bbe.2020.01.008>.

پذیرفته شده در مجله محاسبات نرم