



University of Kashan

مجله محاسبات نرم

SOFT COMPUTING JOURNAL

تارنمای مجله: scj.kashanu.ac.ir



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

زهره شریفی مهرجرد^{۱*}، مربی، هاجر مومنی^۲، استادیار، حبیب ادبی اردکانی^۳، دانشجوی دکتری

^۱ گروه مهندسی برق، دانشگاه فنی و حرفه‌ای، تهران، ایران.

^۲ گروه مهندسی برق، دانشگاه اردکان، اردکان، ایران.

^۳ گروه مهندسی برق، دانشگاه یزد، یزد، ایران.

چکیده

اطلاعات مقاله

تاریخچه مقاله:

دریافت ۱۹ آبان ماه ۱۴۰۱

پذیرش ۹ شهریور ماه ۱۴۰۲

کلمات کلیدی:

الکتروانسفالوگرافی

الگوریتم‌های نظارت شده

اوتیسم

یادگیری عمیق

یادگیری ماشین

بیماری اوتیسم یک اختلال عصبی و تکاملی است که اشخاص مبتلا به آن اغلب علایم 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 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 هر یک از مقالات، بررسی شده و نتایج به دست 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 می‌شوند. نتایج نشان می‌دهد که نقش روش‌های بکار گرفته شده به منظور پیش‌پردازش، استخراج و انتخاب ویژگی از روی تصاویر EEG و نوع طبقه‌بندها، عوامل موثر در دقت طبقه‌بندی می‌باشند. شبکه‌های عصبی کانولوشنی با توجه به ارائه بهترین نتایج دقت، بیشترین کاربرد را در مقایسه با سایر روش‌های مبتنی بر یادگیری داشته‌اند.

© ۱۴۰۲ نویسندگان. مقاله با دسترسی آزاد تحت مجوز CC-BY

۱. مقدمه

افراد مبتلا به اختلال طیف اوتیسم (ASD)^۱ 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^۲ EEG، این بیماری عصبی را تشخیص دهند. در مطالعات اخیر پژوهش بر روی افراد مبتلا به اختلال طیف اوتیسم استفاده از EEG به علت دسترسی گسترده پزشکان

✧ نوع مقاله: مروری

* نویسنده مسئول

پست(های) الکترونیک: zsharifi@tvu.ac.ir (شریفی مهرجرد)

h.momeni@ardakan.ac.ir (مومنی)

habibadabiardakani@gmail.com (ادبی اردکانی)

² Electroencephalogram

¹ Autism Spectrum Disorder

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 بوده و کار تخصصی است. اخیراً در مقالات سیگنال‌های EEG با استفاده روش‌های پردازش سیگنال و مدل‌های یادگیری ماشین (ML)^۱ پردازش و طبقه‌بندی می‌شوند. در پژوهش‌های تشخیص بیماری اوتیسم مبتنی بر EEG از الگوریتم‌های یادگیری ماشین استفاده شده‌اند تا با بررسی ویژگی‌های به دست آمده با استفاده از کاربر انسانی و ماشین با درصد دقت بالایی بیماری اوتیسم را تشخیص می‌دهند [۱]. امروزه از فناوری‌های پیشرفته 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 فرآیند یادگیری با مدلی بیان می‌شود که با استفاده از داده‌های آموزش یا تجربیات گذشته آموزش صورت می‌گیرد و این مدل را می‌توان برای به دست 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. رویکردهای یادگیری ماشین بسیار گسترده هستند، بنابراین پیش‌بینی می‌شود که این رویکردها راه‌حل‌های بهینه‌ای برای تشخیص بیماری اوتیسم ارائه دهند. در بخش اول این 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

۲. تعاریف

۱.۲. اوتیسم

اختلال طیف اوتیسم نوعی بیماری رشدی است که علائمی مانند رفتارهای محدود، رفتار اجتماعی غیرمعمول و تکراری و علائق غیرمعمول 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. درحالی که 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 بیشتری 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، نشان‌دهنده فعالیت امواج فرآیندهای سیناپسی هستند [۴]. دستگاه الکتروانسفالوگرافی به کمک الکترودهایی که بر روی سر قرار می‌گیرد، فعالیت الکتریکی نورون‌ها را

¹ Machine Learning

- ادامه این ۵ الگوی فرکانسی توضیح داده خواهد شد.
- دلتا: آخرین نوع امواج مغزی، موج دلتا است. این امواج بیشترین دامنه و آهسته‌ترین 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 به نسبت پائینی 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 بکار گرفت، نیاز به مقدار داده‌های بسیار زیادی وجود دارد. مجموعه داده‌های بزرگ باعث می‌شوند بتوان با استفاده از الگوریتم‌های هوش مصنوعی الگوها را تشخیص داد، پیش‌بینی کرد و در خصوص اقدامات مورد نیاز توصیه‌هایی را بیان نمود. هوش مصنوعی یک مفهوم بزرگ‌تر از یادگیری ماشین است و ماشین هوشمندی ایجاد می‌کند که این ماشین توانایی‌های رفتاری و تفکر انسان را مدل‌سازی می‌کند. در حالی که، هوش مصنوعی زیرمجموعه یادگیری ماشین است که به ماشین‌ها اجازه می‌دهد از داده‌ها و اطلاعات آموزش ببیند بدون اینکه از قبل برنامه‌ریزی شوند [۷].

۲.۳. یادگیری ماشین

یکی از زیرمجموعه‌های هوش مصنوعی، یادگیری ماشین 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

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 تغییرات فعالیت الکتریکی نوروها حساس باشد. الکترودهای نصب شده روی سر، اثر الکتریکی فعالیت نوروها 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 مجموعه 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].

سیگنال EEG، سری‌های زمانی از ولتاژهای به دست آمده توسط فعالیت میلیاردها سلول مغز است. این سیگنال توسط الکترودهایی که بر روی سر قرار می‌گیرد ثبت می‌شود. رنج ولتاژ ثبت شده در حد ۱۰ تا ۱۰۰ میکروولت می‌باشد. پردازش‌های خطی و غیرخطی متعددی بر روی این سیگنال به منظورهای خاص همانند ارزیابی مراحل خواب، تعیین میزان هیپنوتیزم‌پذیری 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 به شکل 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 تشخیص اوتیسم استفاده شود. همانطور که بیان شد، پنج نوع امواج مغزی شامل دلتا، تتا، آلفا، بتا و گاما وجود دارد که در

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 درنهایت، 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 در ادامه بیان می‌شوند.

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 به دست آوردن خروجی به عنوان یک کلاس که مد 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.

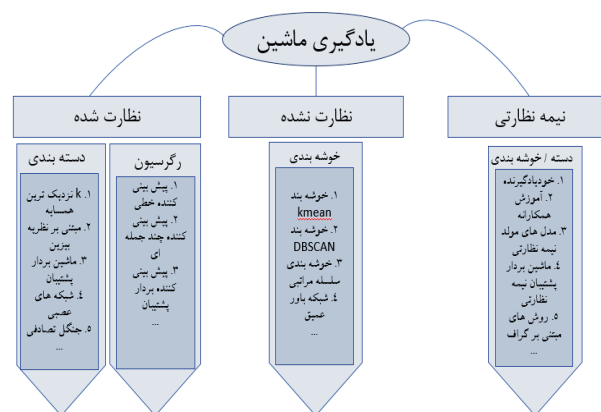
ماشین بردار پشتیبان: SVM^۱ها طبقه‌بندهای قدرتمندی هستند که با کمک ابرصفحه‌ها، برای دسته‌بندی مجموعه داده‌های دودویی به دو کلاس، استفاده می‌شوند [۸] - [۱۰].

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

شبکه‌های عصبی مصنوعی: شبکه‌های عصبی مصنوعی از مغز انسان ایده می‌گیرند و داده‌ها در طول زمان شبکه را آموزش می‌دهد. این شبکه‌ها 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

چگونه سیستم کامپیوتری بسازیم که کارکرد آن به صورت خودکار 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 فرآیند 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 خودکار آموزش انجام شود و بتوان اقدامات خود را مطابق با آن تنظیم کرد [۳]. شکل (۱) بخش‌های مختلف الگوریتم‌های یادگیری ماشین را نشان 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 بر اساس داده‌های آموزشی قبلی دسته‌بندی می‌شوند. هدف از یک مدل یادگیری تحت نظارت، پیش‌بینی برچسب درست برای داده‌های ورودی جدید است. در طول فرآیند یادگیری ماشین، مدلی ارائه می‌شود که متغیرهای آن را برای نمایش دادن ورودی به خروجی متناظر

^۱ Support Vector Machine

تشخیص ناهنجاری: رویکردهای تشخیص ناهنجاری، با استفاده از این فرض که اکثر نمونه‌های داده با مشاهده مواردی که متناسب با بقیه مجموعه داده هستند، نرمال می‌باشد، داده‌های پرت را از داده‌های بدون برچسب تشخیص می‌دهند.

خودرمزگذارها Autoencoders: خودرمزگذارها نوعی از شبکه‌های عصبی هستند که در یادگیری بدون نظارت برای یادگیری بازنمایی مورد استفاده قرار می‌گیرند. آنها در حذف نویز و کاهش ابعاد بکار می‌روند.

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 شبکه‌های عصبی نظارت شده، متفاوت است که ورودی‌های خود را به طور احتمالی بازسازی می‌کند تا به عنوان تشخیص‌دهنده ویژگی عمل کند [۱۱] - [۱۳].

روش‌های نیمه نظارت شده: در یادگیری ماشین، برچسب‌گذاری داده‌ها، به فرآیند تشخیص داده‌های خام (تصاویر، فایل‌های ویدیویی و غیره) و افزودن یک یا چند برچسب معنادار و یا آموزنده جهت ارائه اطلاعات در مورد آن اطلاق می‌شود. برچسب‌ها ممکن است حاوی اطلاعاتی نظیر وجود پرنده 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 داده‌ها ارائه می‌شود، نقش بسزایی در آموزش مدل‌های یادگیری ماشین در حوزه‌های مختلف هوش مصنوعی نظیر بینایی ماشین، پردازش زبان طبیعی و پردازش گفتار ایفا می‌نماید. بسیاری از 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 تامین امنیت فرآیندهای گردآوری و نگهداری آنها بسیار پرچالش است. روش یادگیری نیمه نظارتی به عنوان یکی از مدل‌های یادگیری ماشین، راهکاری موثر جهت رفع چالش‌های مربوط به داده‌های برچسب‌دار می‌باشد. در یادگیری نیمه نظارتی

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 شامل دو نوع خوشه‌بندی و غیرخوشه‌بندی هستند. 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]. در دسته‌بندی به دست آمده برای تولید خروجی هدفی وجود ندارد بلکه الگوریتم‌های مورد استفاده، داده‌ها را به گروه‌های مختلف طبقه‌بندی می‌کنند. این الگوریتم‌ها در داده‌های مورد کاربرد جهت آموزش ماشین، زمانی استفاده می‌شوند 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 داده‌ها است (منظور داده‌های ورودی است که خروجی آنها مشخص نیست). در روش یادگیری نظارت نشده، الگوریتم با تحلیل تفاوت‌ها و شباهت‌های میان داده‌ها، یک الگو برای خوشه‌بندی کردن داده‌ها به دست می‌آورد و بر اساس این الگو، قادر است برای نمونه داده‌های جدید خروجی را پیش‌بینی کند. برخی از الگوریتم‌هایی که در این دسته قرار می‌گیرند، خوشه‌بندی هستند که به عنوان آنالیز خوشه‌ای نیز شناخته می‌شود؛ روشی برای گروه‌بندی مجموعه اشیاء مشابه در همان گروه می‌باشد که متفاوت از اشیای گروه دیگر است. برخی از روش‌های مهم خوشه‌بندی به شرح زیر هستند.

K-means: این الگوریتم راه‌حلی برای مشکلات خوشه‌بندی دارد و جزء دسته الگوریتم‌های بدون نظارت است. این الگوریتم به دنبال راه‌حلی برای ایجاد خوشه‌هایی است که شامل نقاط داده همگن هستند.

DBSCAN: این روش، جز روش‌های خوشه‌بندی است که داده‌ها را بر اساس تراکم، گروه‌بندی می‌کند. این روش نقاطی که در فضا داده می‌شوند را گروه‌بندی کرده و نقاط خارج از منطقه کم‌تراکم را علامت‌گذاری می‌کند.

خوشه‌بندی سلسله مراتبی: در این نوع خوشه‌بندی، سلسله مراتبی از خوشه‌ها ساخته می‌شود.

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].

۲.۳. یادگیری عمیق

در یادگیری عمیق، از شبکه‌های عصبی مصنوعی برای انجام محاسبات پیچیده استفاده می‌شود. 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، به طور معمول 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 شامل لایه ورودی، لایه‌های مخفی و لایه خروجی تشکیل می‌شوند. 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 فعال‌سازی» 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 پیچشی (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

به طور همزمان از داده‌های برجسب خورده و از داده‌های برجسب نخورده استفاده می‌شود تا بتوان دقت یادگیری را بهبود بخشید. این نوع از مدل یادگیری به عنوان روشی که می‌تواند از داده‌های بدون برجسب بیشترین استفاده را داشته باشد، از منظر کاربرد عملی از ارزش فوق‌العاده‌ای برخوردار است [۱۴]، [۱۵].

روش یادگیری تقویتی: رویکرد یادگیری تقویتی به طور کامل 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 به دست 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 [۱۶]، [۱۷].

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، 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.

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 دراز مدت، یک رفتار پیشفرض است که اطلاعات را در طول زمان حفظ می‌کند. این شبکه‌های عصبی برای پیش‌بینی سری‌های زمانی بسیار مفید هستند؛ زیرا آنها داده‌های ورودی پیشین را به یاد می‌آورند. شبکه‌های حافظه طولانی کوتاه-مدت، ساختار زنجیره‌مانندی دارند که در آن چهار لایه تعاملی هر یک به شیوه‌ای منحصر به فرد ارتباط برقرار می‌کنند. شبکه‌های LSTM به طور معمول 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 کند. شبکه‌های عصبی بازگشتی، به طور معمول به منظور توضیح‌نویسی برای تصاویر، تحلیل سری زمانی، ماشین ترجمه، شناسایی دستخط و پردازش زبان طبیعی استفاده می‌شوند.

شبکه‌های تابع پایه شعاعی (RBFNs): RBFNs ها، نوع خاصی از شبکه‌های عصبی پیش‌رونده هستند که از توابع پایه شعاعی برای فعال‌سازی 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 فناوری 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 ورودی و خروجی هستند؛ اما ممکن است چندین لایه پنهان هم داشته باشند که می‌تواند در مواردی همچون تشخیص گفتار، شناسایی تصاویر و نرم‌افزار ماشین ترجمه استفاده شوند.

خودرمزگذارها (Autoencoder): خودرمزگذارها، نوع خاصی از شبکه‌های عصبی پیشخور است که در آن، میزان داده‌های ورودی و خروجی به صورت یکسان است. جفری هینتون، خودرمزگذارها 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 کپی‌برداری می‌کند. خودرمزگذارها برای اهدافی همچون اکتشافات پزشکی، پیش‌بینی‌های عمومی و پردازش تصاویر استفاده می‌شوند [۲۰].

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

شبکه ResNet: در این شبکه، 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 به دست آمده از آن Residual block گفته می‌شود [۲۹].

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

اختلال طیف اوتیسم مبتنی بر EEG ارائه می‌کند. رویکردهای طبقه‌بندی از ۲۰۱۰ تا ۲۰۱۸ انتخاب شده‌اند و روش‌ها به چهار مرحله تقسیم می‌شود: جمع‌آوری داده‌های EEG، پیش‌پردازش، استخراج ویژگی و طبقه‌بندی. این مطالعه رویکردها و ابزارهای مختلف مورد استفاده برای پیش‌پردازش، استخراج و انتخاب ویژگی، مدل‌های طبقه‌بندی و اقداماتی برای ارزیابی مدل‌ها را مورد تجزیه و تحلیل قرار می‌دهد. علاوه بر این، خلاصه‌ای از طبقه‌بندی اختلال طیف اوتیسم 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 مبتلا به اوتیسم و افراد عادی انجام شده است؛ به طوری که اختلال طیف اوتیسم را می‌توان با استفاده از EEG تشخیص داد. در این مطالعه، از رویکرد یادگیری انتقال برای آموزش CNN، GoogLeNet و SqueezeNet از پیش آموزش دیده برای طبقه‌بندی افراد مبتلا به اوتیسم 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 مبتلا به اوتیسم و افراد عادی بود. نتایج به دست آمده نشان می‌دهد که این روش می‌تواند به طبقه‌بندی افراد مبتلا به اوتیسم و افراد عادی با استفاده از سیگنال‌های EEG کمک کند [۲۳]. در مطالعه [۲۴]، اثربخشی الگوریتم‌های مختلف یادگیری ماشین و رویکردهای پیش‌پردازش برای کار طبقه‌بندی برای مجموعه داده‌های پزشکی که برای پیش‌بینی صفات اولیه اوتیسم در کودکان نوپا و بزرگسالان استفاده می‌شود، ارزیابی شده است. مراحل پیش‌پردازش همراه با کدگذاری مناسب داده‌ها و الگوریتم‌های طبقه‌بندی مختلف مانند رگرسیون لجستیک، KNN و جنگل تصادفی نتایج قابل توجهی را در مقایسه با مقالات موجود نشان می‌دهند.

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 سریعتر، 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، ویدیویی را می‌بینند که احساسات خاصی در شخص ایجاد می‌کند یا در مطالعه دیگر، برای پژوهش‌های مبتنی بر تشخیص بیماری صرع، از دو گروه افراد دارای بیماری صرع و سالم استفاده می‌کنند. در مقاله [۲۱]، رویکردهای مبتنی بر هوش مصنوعی مورد استفاده برای تشخیص اوتیسم بحث شده است. این تحقیق با شرح مختصری از اختلال طیف اوتیسم و روش غیرتهاجمی فعلی برای طبقه‌بندی بین افراد دارای اوتیسم و افراد سالم استفاده می‌شود. با هوش مصنوعی، مدل‌های جدید مبتنی بر رویکردهای 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 اختلال طیف اوتیسم فعلی، تشخیص زودهنگام را به چالش می‌کشد زیرا آزمایش‌های پزشکی کاملاً تعریف شده برای تشخیص اختلال طیف اوتیسم 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 انعطاف‌پذیری بیشتری را فراهم می‌کنند و نتایج بهتری را در طبقه‌بندی اختلال طیف اوتیسم کسب نموده‌اند. پژوهش [۲۲]، یک بررسی از

در مقاله [۲۵]، نوآوری مقاله تشخیص بیماری اوتیسم با استفاده از آنتروپی شانون SE، تبدیل موجک گسسته و الگوریتم ANN می‌باشد. در این مقاله از DWT برای محاسبه زیرباندهای سیگنال EEG بهره برده شده است. سپس مقدار SE برای استخراج ویژگی در هر زیرباند 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 این مقاله را نشان می‌دهد.



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 دشوار 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 علایمی 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 اوتیسم 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 اختلال طیف اوتیسم یک اختلال عصبی رشدی است، بر اساس تشخیص بر روی فعالیت مغز به عنوان موثرترین داده در دسترس در نظر گرفته شده است. در میان انواع روش‌ها، سیگنال مغزی EEG، یک روش به نسبت آسان و همچنین کم هزینه است. بنابراین برای تشخیص اختلال طیف اوتیسم امیدوارکننده است. در این مطالعه، تشخیص اختلال طیف اوتیسم 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 اختلال طیف اوتیسم، 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 اختلال اوتیسم ارائه می‌کند. هدف این مقاله شناسایی و توصیف روندهای یادگیری ماشین نظارت شده در ادبیات اوتیسم و همچنین اطلاع‌رسانی و راهنمایی محققان علاقه‌مند به گسترش بدنه رویکردهای بالینی، محاسباتی و آماری صحیح برای استخراج داده‌های اختلال اوتیسم 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 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 اختلال طیف اوتیسم می‌باشد.

در پژوهش [۳۱]، تشخیص بیماری اوتیسم با استفاده از EEG و شبکه عصبی کانولوشن عمیق دوبعدی (2D_DCNN) انجام شده است. با توجه به اینکه 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 دوبعدی 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 به نسبت زیادی دارد. 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 مرجع‌گذاری مجدد، فیلتر کردن و نرمال‌سازی پیش‌پردازش شده است. سپس تبدیل فوریه کوتاه مدت برای تبدیل سیگنال‌های پیش‌پردازش شده به تصاویر طیف‌نگاری دوبعدی استفاده شده است. در مرحله نهایی، آن تصاویر توسط مدل‌های یادگیری ماشین و یادگیری عمیق دسته‌بندی شده‌اند. در فرآیند یادگیری ماشین، ویژگی‌های بافتی استخراج می‌شوند و ویژگی‌های مهم با استفاده از پردازش و بررسی مولفه‌های اصلی (PCA) انتخاب شده و آنها را به شش طبقه‌بندی‌کننده مختلف یادگیری ماشین برای طبقه‌بندی کردن به عنوان ورودی می‌دهد. در فرآیند یادگیری عمیق، سه مدل شبکه عصبی کانولوشن مختلف مورد بررسی قرار گرفته است. مدل مبتنی بر یادگیری عمیق پیشنهادی دقت بالاتری (۹۹/۱۵٪) در مقایسه با مدل مبتنی بر یادگیری ماشین 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 یادگیری عمیق می‌تواند نشانگرهای زیستی مهمی را برای تشخیص کارآمد و خودکار اختلال طیف اوتیسم از EEG کشف کند و ممکن است به توسعه سیستم تشخیص با رایانه کمک کند. شکل (۳) مراحل پیشنهادی این مقاله شامل ثبت سیگنال، پیش‌پردازش داده‌ها، استخراج ویژگی و چند نمونه طبقه‌بندی کننده‌های الگوریتم‌های یادگیری ماشین را نشان می‌دهد.



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

در مقاله [۳۳]، برای تشخیص خودکار بیماری اوتیسم یک استخراج‌کننده ویژگی عمیق ترکیبی سبک وزن به منظور بهبود عملکرد طبقه‌بندی پیشنهاد شده است. این سیستم با یک مجموعه داده بزرگ EEG طراحی و آزمایش شده که حاوی سیگنال‌هایی از بیماران اوتیسم و افراد عادی است. چهارچوب کلی این مطالعه به ۴ بخش اصلی تقسیم شده 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 یک‌بعدی (D_LBP1) 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 MobileNetV2، ShuffleNet و SqueezeNet از پیش آموزش دیده استخراج شده که این روش تولیدکننده ویژگی‌های سبک وزن عمیق هیبریدی نام دارد. (۳) یک الگوریتم ReliefF دو لایه برای رتبه‌بندی ویژگی و انتخاب ویژگی استفاده می‌شود. (۴) متمایزترین ویژگی‌ها به طبقه‌بندی‌کننده‌های مختلف کم‌عمق داده شد که با استفاده از یک استراتژی اعتبارسنجی ۱۰-fold متقابل برای تشخیص خودکار اوتیسم توسعه یافته است. طبقه‌بندی‌کننده ماشین بردار پشتیبان بر اساس ویژگی‌های مدل پیشنهادی به دقت ۹۶/۴۴ درصد رسید. نتایج نشان می‌دهد که استخراج‌کننده ویژگی سبک وزن عمیق هیبریدی پیشنهادی 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.

مراجع [۳۱]–[۳۹] به منظور تشخیص بیماری اوتیسم بعد فراکتال را برای اندازه‌گیری پیچیدگی و تغییرات دینامیکی در مغز بررسی نموده‌اند.

در مقاله [۳۴]، سیگنال نوار مغز ۹ کودک مبتلا به اوتیسم و ۸ کودک غیراوتیسم 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 دسته‌بندی‌کننده SVM به دست آمد. در ادامه، همان گروه تشخیص اختلال طیف اوتیسم را با استفاده از طبقه‌بندی‌کننده فازی و دسته‌بندی‌کننده 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 شامل ۴۶ نفر مبتلا به اوتیسم و ۳۳ نفر سالم) بررسی انجام شد. در این مطالعه از حداقل میانگین مربعات خطا به عنوان بردار ویژگی استفاده شده است و سپس از الگوریتم‌های طبقه‌بندی k نزدیک‌ترین همسایه (KNN)^۱، الگوریتم ماشین بردار پشتیبان و الگوریتم‌های طبقه‌بندی ساده بیزی (NB)^۲ برای طبقه‌بندی سیگنال‌های معمولی و اوتیسم استفاده شده که ماشین بردار پشتیبان بهترین دقت را به دست آورده است.

در مرجع [۳۷]، از ضریب همبستگی پیرسون (PCC)^۳ استفاده شده است تا تصاویر EEG را به ویژگی از نوع ضرایب همبستگی تبدیل کند. سپس شبکه عصبی کانولوشنی (ResNet) برای تشخیص اوتیسم ارائه شده است. نتایج بر روی دادگان آموزش ۸۸ درصد و بر روی دادگان آزمون ۱۰۰ درصد گزارش شده است. همچنین عیب روش نداشتن دادگان زیاد و همچنین بررسی معیارهای دیگر برای ویژگی همبستگی ذکر شده است. 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 خودمزمگذار برای افزایش دادگان و طبقه‌بند CNN منجر شده تا نتیجه دقت ۹۸/۸۸ درصد به دست آید. محققان مزیت روش پیشنهادی را عدم نیاز به ناحیه‌بندی (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

^۱ K-Nearest Neighbors

^۲ Naive Bayse

^۳ Pearson Correlation Coefficient

طبقه‌بند LSTM و CNN به ترتیب منجر به نتایج دقت ۹۲ و ۹۵ درصد شده است. استفاده از ویژگی‌های مذکور می‌تواند بر روی دادگان کم بدون آن که روش‌های افزایش داده بکار گرفته شود، موثر واقع شده و زمان اجرا را کاهش دهد.

مروری بر روی مطالعات انجام شده توسط انواع روش‌های یادگیری ماشین نشان می‌دهد که اغلب طبقه‌بند ماشین بردار پشتیبان 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 پیش‌پردازش (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 برای روش‌های یادگیری عمیق همین نتیجه را رقم زده است. هر چند که روش‌های پیش‌پردازش موثر و انتخاب ویژگی‌های مناسب در کارایی طبقه‌بند 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.

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)
[۲۳]	۲۰۲۱	GoogLeNet SqueezeNet	داده‌ها مطابق با نظر هیات بررسی دانشگاه عبدالعزیز عربستان سعودی، سیگنال‌های EEG با فرکانس ۲۵۶ هرتز، ۱۶ کانال، ۱۳ فرد مبتلا به اوتیسم و ۴ فرد سالم	GoogleNet :٪۷۵ SqueezeNet :٪۸۲
[۲۴]	۲۰۲۰	LR KNN RF	مجموعه داده با ۲۰ ویژگی مرتبط با بیماری اوتیسم	LR :٪۶۸/۶ KNN :٪۶۹/۲ RF :٪۶۷/۸
[۲۵]	۲۰۱۷	ANN	دانشگاه عبدالعزیز عربستان سعودی، سیگنال‌های EEG با فرکانس ۲۵۶ هرتز، ۱۶ کانال	تقریباً ٪۱۰۰
[۲۶]	۲۰۱۸	KNN	مجموعه داده اول دانشگاه بن، سیگنال‌های EEG با فرکانس ۱۷۳ هرتز، ۱۶ کانال / مجموعه داده دوم دانشگاه MIT، سیگنال‌های EEG با فرکانس ۲۵۶ هرتز، ۲۳ کانال / مجموعه داده سوم دانشگاه عبدالعزیز عربستان سعودی، سیگنال‌های EEG با فرکانس ۲۵۶ هرتز، ۱۶ کانال	٪۹۴/۶
[۲۹]	۲۰۲۰	Resnet (CNN)	سیگنال‌های EEG با فرکانس ۲۵۶ هرتز، ۱۹ کانال، ۱۳ فرد مبتلا به اوتیسم و ۴ فرد سالم	٪۱۰۰
[۳۱]	۲۰۲۲	2D_DCNN	داده‌ها مطابق با نظر هیات بررسی دانشگاه کالیفرنیا، سیگنال‌های EEG با فرکانس ۵۰۰ هرتز، ۱۲۹ کانال، ۱۰ فرد مبتلا به اوتیسم و ۹ فرد سالم	٪۸۸
[۳۲]	۲۰۲۱	CNN-SVM	سیگنال‌های EEG با فرکانس ۲۵۶ هرتز، ۱۶ کانال، ۱۲ فرد مبتلا به اوتیسم و ۴ فرد سالم	CNN :٪۹۹ SVM :٪۹۵/۲
[۳۳]	۲۰۲۱	SVM	سیگنال‌های EEG با فرکانس ۵۰۰ هرتز، ۶۴ کانال، ۶۱ فرد مبتلا به اوتیسم و ۶۱ فرد سالم	٪۹۶/۴۴
[۳۷]	۲۰۲۲	PCC-CNN	سیگنال‌های EEG ۱۹ کانال، ۱۵ فرد مبتلا به اوتیسم و ۱۰ فرد سالم	٪۱۰۰
[۴۰]	۲۰۲۲	CNN	سیگنال‌های EEG ۱۶ کانال، ۲۰ فرد مبتلا به اوتیسم و ۹ فرد سالم	٪۹۸/۸۸
[۴۳]	۲۰۲۲	LSTM-CNN	سیگنال‌های EEG با فرکانس ۲۵۶ هرتز، ۱۲۸ کانال، ۱۴ فرد مبتلا به اوتیسم و ۱۴ فرد سالم	LSTM :٪۹۴ CNN :٪۹۲

۵. بحث و پیشنهادهای کاربردی

در این مطالعه به یک مساله طبقه‌بندی 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، خود تهیه کرده بودند. از آنجایی که تصاویر EEG به صورت 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 به طور کلی روند زیر را برای عموم بیان نمود. (۱) از آنجایی که دادگان برچسب‌دار بودند، از روش‌های یادگیری نظارت شده استفاده شده است، (۲) مدل آموزشی شامل بلوک‌های پیش‌پردازش، استخراج ویژگی و طبقه‌بندی می‌باشد و (۳) از معیارهای ارزیابی دقت طبقه‌بندی برای مقایسه روش‌ها استفاده شده است. در کل نکاتی که وجه تمایز تحقیقات را تعیین می‌کند شامل روشی استخراج ویژگی‌ها و روش طبقه‌بندی دو کلاس سالم و اوتیسم است. معیارهای ارزیابی دقت طبقه‌بندی که مقالات از آنها استفاده شده است عبارتند از:

(۱) معیار صحت (Precision) که فرمول آن در رابطه (۱) ذکر شده است.

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

(۲) معیار حساسیت (Recall) که فرمول آن در رابطه (۲) آمده است.

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

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

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

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

در این روابط True Positive (TP) نشان‌دهنده تشخیص دسته مثبت (کلاس واقعی مثبت)، True Negative (TN) بیانگر تشخیص در دسته منفی (کلاس واقعی منفی)، False Positive (FP) نماینده تشخیص در دسته مثبت (کلاس واقعی منفی) و False Negative (FN) نشان‌دهنده تشخیص در دسته منفی (کلاس واقعی مثبت) است. در ضمن زمان اجرا نیز می‌تواند یک معیار ارزیابی باشد اما معیار قابل بحثی در مقالات نبوده است.

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 این جدول، پراکنده بودن تحقیقات در این زمینه نمایان است؛ به طوری 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 پیش‌رو 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 طبقه‌بند دیگر را برای پژوهش‌های بعدی پیشنهاد می‌دهد زیرا نمی‌توان بدون شبیه‌سازی اذعان کرد که ترکیب یک استخراج‌کننده ویژگی دیگری به غیر از آنچه در آن تحقیق استفاده شده با یک طبقه‌بند دیگر می‌تواند نتایج بهتری کسب کند یا نه.

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

مراجع	نوآوری مقاله	نقاط قوت	نقاط ضعف
[۲۳]	استفاده از رویکرد یادگیری انتقالی موجود در الگوریتم‌های GoogLeNet و SqueezeNet	• استفاده از شبکه‌های عصبی از پیش آموزش دیده	• زمانبر بودن فرآیند با توجه به CPU مورد استفاده • نیاز به حجم داده زیاد برای آموزش بهتر
[۲۴]	اثربخشی روش‌های پیش‌پردازش و الگوریتم‌های مختلف یادگیری ماشین به منظور طبقه‌بندی برای پیش‌بینی صفات اولیه اوتیسم در کودکان نوپا و بزرگسالان	• استفاده از رویکرد پیش‌پردازش موثر • نتایج دقیق‌تر الگوریتم KNN	• عدم دسترسی آسان محققان به داده‌های قابل اطمینان در مراکز پزشکی
[۲۵]	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 آزمایش‌های بیشتر • نیاز به انجام رویکردهای پیش‌پردازش قویتر
[۲۶]	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 طبقه‌بندی • دقت طبقه‌بندی بهتر برای مجموعه داده‌های جامع‌تر در مقایسه با سایر الگوریتم‌ها	• فرآیند محاسباتی پیچیده • نیاز به حجم داده زیاد
[۲۹]	نمایش تصویر دوبعدی داده‌های 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 • فرآیند پیچیده
[۳۱]	تشخیص بیماری اوتیسم با استفاده از EEG و شبکه عصبی کانولوشن عمیق دوبعدی، استفاده از روش‌های افزایش داده	• بهبود عملکرد یادگیری و دقت تشخیص بیماری به دلیل استفاده از رویکردهای افزایش داده	• فرآیند پیچیده • حساس به تنظیم پارامترها • زمانبر بودن مراحل الگوریتم
[۳۲]	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
[۳۳]	تشخیص خودکار بیماری اوتیسم با استفاده یک استخراج‌کننده ویژگی عمیق ترکیبی سبک وزن	• دقت بالا در تشخیص بیماری اوتیسم به دلیل استخراج‌کننده ویژگی بسیار قوی	• بررسی طبقه‌بندی‌کننده‌های دیگر به غیر از طبقه‌بند‌های مبتنی بر یادگیری ماشین
[۳۷]	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
[۴۰]	تشخیص دقیق بیماری اوتیسم با استفاده از الگوریتم متفاوت استخراج ویژگی (ترکیب الگوریتم داگلاس-پوکر و تبدیل موجک و بکارگیری ویژگی‌های تنک) و شبکه عصبی کانولوشنال	• عملکرد دقیق در رویکردهای تشخیص بیماری اوتیسم به دلیل ترکیب استخراج‌کننده ویژگی و طبقه‌بند بسیار قوی	• نیاز به بررسی الگوریتم پیشنهادی بر روی داده‌های با حجم بیشتر و داده‌های پزشکی حساس به تنظیم پارامترها
[۴۳]	استفاده از تبدیل موجک مرتبه دوم برای استخراج ویژگی و استفاده از طبقه‌بند 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

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، پرباربرد و مورد توجه محققین بوده است، البته نقش رویکردهای پیش‌پردازش مفید و استخراج‌کننده ویژگی موثر و در عین حال ساده را نمی‌توان در کارایی روش‌های پیشنهادی نادیده گرفت.

تعارض منافع: نویسندگان اعلام می‌کنند که هیچ تعارض منافی ندارند.

با توجه به موارد ذکر شده در جدول‌های (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 نرفته در تحقیقات مختلف باشد. بکارگیری روش‌های افزایش داده برای دادگان کم تعداد، اثر ملموسی بر روی دقت تشخیص خواهد داشت. پس از بیان مزایا و معایب هر کدام از روش‌های بکار گرفته 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 فرآیند یادگیری به همراه نوع ویژگی‌های استفاده شده و روش‌های اتخاذ شده به منظور افزایش داده می‌تواند باشد.

۶. نتیجه‌گیری

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

مراجع

- [1] E. Grossi, G. Valbusa, and M. Buscema, "Detection of an autism EEG signature from only two EEG channels through features extraction and advanced machine learning analysis," Clin. EEG Neurosci., vol. 52, no. 5, pp. 330-337, 2021, doi: 10.1177/1550059420982424.
- [2] A. Tayyebi and B.C. Pijanowski, "Modeling multiple land use changes using ANN, CART and MARS: Comparing tradeoffs in goodness of fit and explanatory power of data mining tools," Int. J. Appl. Earth Obs. Geoinform., vol. 28, pp. 102-116, 2014, doi: 10.1016/j.jag.2013.11.008.
- [3] L.P. Coelho and W. Richert, Building machine learning systems with Python. Packt Publishing Ltd, 2015.
- [4] J.S. Kumar and P. Bhuvaneswari, "Analysis of Electroencephalography (EEG) signals and its categorization—a study," Proc. Eng., vol. 38, pp. 2525-2536, 2012, doi: 10.1016/j.proeng.2012.06.298.
- [5] R. Radhamani, et al., "Computational analysis of cortical EEG biosignals and neural dynamics underlying an integrated mind-body relaxation technique," Proc. Comput. Sci., vol. 171, pp. 341-349, 2020, doi: 10.1016/j.procs.2020.04.035.
- [6] S.A. Samadi and R. Mcconkey, "The impact on Iranian mothers and fathers who have children with

- an autism spectrum disorder,” *J. Intellect. Disabil. Res.*, vol. 58, no. 3, pp. 243-254, 2014, doi: 10.1111/jir.12005.
- [7] H. Kantarjian and P.P. Yu, “Artificial intelligence, big data, and cancer,” *JAMA Oncol.*, vol. 1, no. 5, pp. 573-574, 2015, doi:10.1001/jamaoncol.2015.1203.
- [8] H. Veisi, H.R. Ghaedsharaf, and M. Ebrahimi, “Improving the Performance of Machine Learning Algorithms for Heart Disease Diagnosis by Optimizing Data and Features,” *Soft Comput. J.*, vol. 8, no. 1, pp. 70-85, 2019, doi: 10.22052/8.1.70 [In Persian].
- [9] A. Vasighi Zaker and S. Jalili, “Candidate disease gene prediction using One-Class classification,” *Soft Comput. J.*, vol. 4, no. 1, pp. 74-83, 2015, doi: 10.22052/8.1.70 [In Persian].
- [10] S. Razzaghzadeh, P. Norouzi Kivi, and B. Panahi, “A hybrid algorithm based on Gossip architecture using SVM for task scheduling in cloud computing,” *Soft Comput. J.*, vol. 9, no. 2, pp. 84-93, doi: 10.22052/scj.2021.242822.0 [In Persian].
- [11] D. Dhall, R. Kaur, and M. Juneja, “Machine learning: a review of the algorithms and its applications,” in P. Singh, A. Kar, Y. Singh, M. Kolekar, and S. Tanwar, (eds) *Proc. ICRIC 2019, Lecture Notes in Electrical Engineering*, vol 597, Springer, Cham., 2020, doi: 10.1007/978-3-030-29407-6_5.
- [12] S.B. Kotsiantis, I. Zaharakis, and P. Pintelas, “Supervised machine learning: A review of classification techniques,” in *Proc. Conf. Emerg. Artif. Intell. Appl. Comput. Eng.: Real Word AI Syst. Appl. eHealth, HCI, Inf. Retr. Pervasive Technol.*, 2007, pp. 3-24.
- [13] J.G. Carbonell, R.S. Michalski, and T.M. Mitchell, “An overview of machine learning,” *Mach. Learn.*, vol. 1, pp. 3-23, 1983, doi: 10.1016/B978-0-08-051054-5.50005-4.
- [14] X. Zhu and A.B. Goldberg, “Introduction to semi-supervised learning,” in *Synthesis lectures on artificial intelligence and machine learning*, Springer, Cham, 2009, doi: 10.1007/978-3-031-01548-9.
- [15] X. Zhu, *Semi-supervised learning literature survey*, Computer Sciences TR 1530, University of Wisconsin, Madison, 2008.
- [16] V. Nanduri and T.K. Das, “A Reinforcement Learning Model to Assess Market Power Under Auction-Based Energy Pricing,” *IEEE Trans. Power Syst.*, vol. 22, no. 1, pp. 85-95, 2007, doi: 10.1109/TPWRS.2006.888977.
- [17] R. Sutton and A.G. Barto, “Reinforcement learning,” *J. Cogn. Neurosci.*, vol. 11, pp. 126-134, 1999.
- [18] R. Polikar, “Ensemble learning,” in C. Zhang and Y. Ma, (eds) *Ensemble Machine Learning*, Springer, New York, NY, 2012, doi: 10.1007/978-1-4419-9326-7_1.
- [19] D.W. Aha, D. Kibler, and M.K. Albert, “Instance-based learning algorithms,” *Mach. Learn.*, vol. 6, pp. 37-66, 1991, doi: 10.1007/BF00153759.
- [20] R. Vargas, A. Mosavi, and R. Ruiz, “Deep learning: a review,” *Adv. Intell. Syst. Comput.*, vol. 5, no. 2, pp. 1-10, 2017.
- [21] A.Chaddad, et al., “Can autism be diagnosed with artificial intelligence? A narrative review,” *Diagnostics*, vol. 11, no. 11, pp. 2032, 2021, doi: 10.3390/diagnostics11112032.
- [22] G. Brihadiswaran, D. Haputhanthri, S. Gunathilaka, D. Meedeniya, and S. Jayarathna, “EEG-based processing and classification methodologies for autism spectrum disorder: A review,” *J. Comput. Sci.*, vol. 15, no. 8, pp. 1161-1183, 2019, doi: 10.3844/jcssp.2019.1161.1183.
- [23] Q. Mohi-ud-Din and A.K. Jayanthi, “Detection of Autism Spectrum Disorder from EEG signals using pre-trained deep convolution neural networks,” in *7th Int. Conf. Bio Signals Images Instrum. (ICBSII)*, Chennai, India, 2021, pp. 1-5, doi: 10.1109/ICBSII51839.2021.9445193.
- [24] G.D. Varshini and R. Chinnaiyan, “Optimized machine learning classification approaches for prediction of autism spectrum disorder”, *Ann. Autism. Dev. Disord.*, vol. 1, no. 1, pp. 1001, 2020.
- [25] R. Djemal, K. AlSharabi, S. Ibrahim, and A. Alsuwailam, “EEG-based computer aided diagnosis of autism spectrum disorder using wavelet, entropy, and ANN,” *BioMed Res. Int.*, vol. 2017, no. 1, p. 9816591, 2017, doi: 10.1155/2017/9816591.
- [26] S. Ibrahim, R. Djemal, and A. Alsuwailam,

- "Electroencephalography (EEG) signal processing for epilepsy and autism spectrum disorder diagnosis," *Biocybern. Biomed. Eng.*, vol. 38, no. 1, pp. 16-26, 2018, doi: 10.1016/j.bbe.2017.08.006.
- [27] S. Noachtar and J. Remi, "The role of EEG in epilepsy: a critical review," *Epilepsy Behav.*, vol. 15, no. 1, pp. 22-33, 2009, doi: 10.1016/j.yebeh.2009.02.035.
- [28] S. Bhat, U.R. Acharya, H. Adeli, G.M. Bairy, and A. Adeli, "Automated diagnosis of autism: in search of a mathematical marker," *Rev. Neurosci.*, vol. 25, no. 6, pp. 851-861, 2014, doi: 10.1515/revneuro-2014-0036.
- [29] Z.J. Peya, M.A.H. Akhand, J. Ferdous Srabonee, and N. Siddique, "EEG Based Autism Detection Using CNN Through Correlation Based Transformation of Channels' Data," in *IEEE Region 10 Symp. (TENSYPMP)*, Dhaka, Bangladesh, 2020, pp. 1278-1281, doi: 10.1109/TENSYPMP50017.2020.9230928..
- [30] K. Hyde, et al., "Applications of supervised machine learning in autism spectrum disorder research: a review," *Rev. J. Autism Dev. Disord.*, vol. 6, pp. 128-146, 2019, doi: 10.1007/s40489-019-00158-x.
- [31] H.A. Ardakani, M. Taghizadeh, and F. Shayegh, "Diagnosis of Autism Disorder Based on Deep Network Trained by Augmented EEG Signals," *Int. J. Neural Syst.*, vol. 32, no. 11, p. 2250046, 2022, doi: 10.1142/s0129065722500460.
- [32] M.N.A. Tawhid, S. Siuly, H. Wang, F. Whittaker, K. Wang, and Y. Zhang, "A spectrogram image based intelligent technique for automatic detection of autism spectrum disorder from EEG," *PLoS One*, vol. 16, no. 6, p. e0253094, 2021, doi: 10.1371/journal.pone.0253094.
- [33] M. Baygin, et al., "Automated ASD detection using hybrid deep lightweight features extracted from EEG signals," *Comput. Biol. Med.*, vol. 134, p. 104548, 2021, doi: 10.1016/j.compbiomed.2021.104548.
- [34] M. Ahmadlou, H. Adeli, and A. Adeli, "Fractality and a wavelet-chaos-neural network methodology for EEG-based diagnosis of autistic spectrum disorder," *J. Clin. Neurophysiol.*, vol. 27, no. 5, pp. 328-333, 2010, doi: 10.1097/WNP.0b013e3181f40dc8.
- [35] W. Bosl, A. Tierney, H. Tager-Flusberg, and C. Nelson, "EEG complexity as a biomarker for autism spectrum disorder risk," *BMC Med.*, vol. 9, p. 18, 2011, doi: 10.1186/1741-7015-9-18.
- [36] S. Boeve, "Can machine learning capture differences in EEG of infants at elevated likelihood and typical likelihood of Autism?," Thesis for Master of Science, Theoretical and Experimental Psychology, Diss. Ghent University, 2022.
- [37] Z.J. Peya, M.H.A. Akhand, J.F. Srabonee, and N. Siddique, "Autism Detection from 2D Transformed EEG Signal using Convolutional Neural Network," *J. Comput. Sci.*, vol. 18, no. 8, pp. 695-704, 2022, doi: 10.3844/jcssp.2022.695.704.
- [38] K.M. Zubair, B.S. Mashkur, and N.M. Nor, "Early Detection on Autistic Children by Using EEG Signals," *Int. J. Percept. Cogn. Comput.*, vol. 8, no. 1, pp. 59-64, 2022.
- [39] G.M. Kresnia and A.A. Parikesit, "Use of Artificial Intelligence in the Diagnostics of Autism Spectrum Disorder," *Cermin Dunia Kedokteran*, vol. 49, no. 6, pp. 341-344, 2022, doi: 10.55175/cdk.v49i6.246
- [40] B. Ari, N. Sobahi, O.F. Alcin, A. Sengur, and U.R. Acharya, "Accurate detection of autism using Douglas-Peucker algorithm, sparse coding based feature mapping and convolutional neural network techniques with EEG signals," *Comput. Biol. Med.*, vol. 143, p. 105311, 2022, doi: 10.1016/j.compbiomed.2022.105311.
- [41] M. Liao, H. Duan, and G. Wang, "Application of machine learning techniques to detect the children with autism spectrum disorder," *J. Healthc. Eng.*, vol. 2022, no. 1, p. 9340027, 2022, doi: 10.1155/2022/9340027.
- [42] S. Alhassan, A. Soudani, and M. Almusallam, "Energy-efficient EEG-based scheme for autism spectrum disorder detection using wearable sensors," *Sensors*, vol. 23, no. 4, p. 2228, 2023, doi: 10.3390/s23042228.
- [43] Q.M. Din and A.K. Jayanthi, "Wavelet Scattering Transform and Deep Learning Networks Based Autism Spectrum Disorder Identification Using EEG Signals," *Traitement du Signal*, vol. 39, no. 6, p. 2069, 2022, doi: 10.18280/ts.390619
- [44] S. Das, et al., "Machine learning approaches for electroencephalography and magnetoencephalography analyses in autism

spectrum disorder: A systematic review,” *Prog. Neuro-Psychopharmacol. Biol. Psychiatry*, vol. 123, p. 110705, 2023, doi: 10.1016/j.pnpbp.2022.110705.

- [45] D. Abdolzadegan, M.H. Moattar, and M. Ghoshuni, “A robust method for early diagnosis of autism spectrum disorder from EEG signals based on feature selection and DBSCAN method,” *Biocybern. Biomed. Eng.*, vol. 40, no. 1, pp. 482-493, 2020, doi: 10.1016/j.bbe.2020.01.008.