

کاربرد هوش مصنوعی در بیماری‌ها و اختلالات روان؛ مطالعه مروری

سارا جنیدی¹، باقر باباعلی²، حمیدرضا نقوی³

¹دانشگاه تهران، پردیس بین الملل، دانشکده علوم کامپیوتر sara.joneydi@ut.ac.ir

²دانشگاه تهران، دانشکده علوم کامپیوتر babaali@ut.ac.ir

³دانشگاه تهران، دانشکده علوم پزشکی naghaviah@tums.ac.ir

چکیده - فناوری در حال پیشرفت، ابزار اولیه برای پیاده‌سازی و همگرایی ایده‌ها است. بنابراین، استفاده از هوش مصنوعی و فناوری‌های مرتبط یک انتخاب نیست، بلکه روندی است که باید آن را پذیرفت. ظهور رویکردهای هوش مصنوعی به‌ویژه یادگیری ماشین و یادگیری عمیق، به سلامت روان، در توسعه راهکارهای پیش‌بینی، تشخیص، درمان و مراقبت‌های سلامت به سرعت در حال پیشرفت است. از نظر درمان، هوش مصنوعی در مداخلات دیجیتال، به‌ویژه اپلیکیشن‌ها و گوشی‌های هوشمند، برای بهینه‌سازی مراقبت‌های سلامت روان گنجانده شده است. از نظر پیش‌بینی و تشخیص، بروز جریان‌های داده به این معنی است که نیاز به بکارگیری الگوریتم‌های هوش مصنوعی مبتنی بر داده‌های بزرگ و چندوجهی برای کشف روابط پیچیده و غیرخطی بین آنها و توسعه و بهبود مدل‌های پیش‌بینی/تشخیص را نمی‌توان نادیده گرفت. مقاله پیش‌رو به مطالعه مروری پژوهش‌های اخیر در این حوزه پرداخته است.

واژه‌های کلیدی - بیماری‌ها و اختلالات روان، سلامت روان، یادگیری عمیق، پردازش زبان طبیعی، داده‌های چندوجهی

1- مقدمه

مربوط به وضعیت سلامت روان، فناوری‌های هوش مصنوعی و یادگیری ماشین برای بهبود درک ما از شرایط روان و برای بهبود و تسریع در تصمیم‌گیری بالینی استفاده می‌شوند. [4-5] به‌عنوان یکی از آخرین پیشرفت‌ها در هوش مصنوعی و یادگیری ماشین، یادگیری عمیق، را می‌توان نام برد. در سال‌های اخیر، الگوریتم‌های یادگیری عمیق و پردازش زبان طبیعی عملکرد بهتری را در بسیاری از سناریوهای مبتنی بر داده، از جمله در مراقبت‌های بهداشتی نشان داده‌اند. [6-8] بررسی کاربرد این تکنیک‌ها در سلامت روان تمرکز بر چهار حوزه اصلی را نشان می‌دهد: تشخیص، پیش‌آگهی و درمان، بهداشت عمومی، تحقیقات و مدیریت بالینی. [9] همچنین، مطالعه تحقیقات انجام‌شده در این چهار حوزه نشان می‌دهد داده‌های مورد استفاده برای پیاده‌سازی تکنیک‌های یادگیری ماشین و یادگیری عمیق، عمدتاً مبتنی بر چهار گروه اصلی می‌باشند:

داده‌های بالینی - منبعی بسیار مهم برای پیشبرد مراقبت‌های بهداشتی هستند. این داده‌ها چه در طول فعالیت‌های توسعه محصول مانند آزمایش‌ها و مطالعات بالینی، چه به‌عنوان بخشی از فرآیند تشخیص و درمان، برای ارائه مراقبت‌های به‌موقع به بیماران و برای ساختن سیستم‌های مراقبت سلامت، ضروری هستند. سیستم‌هایی که به طور مداوم یاد می‌گیرند و مراقبت‌های ارائه شده را بهبود می‌بخشد. این داده‌ها شامل داده‌های تصویر عصبی⁵، پرونده الکترونیک سلامت (EHR⁶) و ... هستند.

داده‌های ژنوم و ژنتیک - با پیشرفت‌های اخیر در تکنیک‌های توالی‌یابی، حجم عظیمی از داده‌های ژنوم یا اگزوم با کارایی بالا در حال تولید است که محققان را قادر می‌سازد تا بیماران مبتلا به اختلالات سلامت روان را با

بیماری‌های سلامت روان یکی از جدی‌ترین و شایع‌ترین مشکلات بهداشت عمومی است. بیماری روانی نوعی از وضعیت سلامتی است که ذهن، عواطف و رفتار فرد را تغییر می‌دهد و بر سلامت جسمی او تأثیر می‌گذارد. در سال 2020، سازمان بهداشت جهانی¹ تخمین زده است که تنها افسردگی 264 میلیون نفر را در سراسر جهان تحت تأثیر قرار داده است. و پیش‌بینی می‌شود تا سال 2030 عامل اصلی دیگر بیماری‌های روانی در جهان باشد که این، خود بر خطر و هزینه‌های پزشکی بسیاری از بیماری‌های روانی و فیزیکی دیگر می‌افزاید. [1-2] همچنین، مشکلات مربوط به سلامت روان از جمله افسردگی، اسکیزوفرنی، اختلال کم‌توجهی بیش‌فعالی (ADHD²) و اختلال طیف اوتیسم (ASD³) و غیره امروزه بسیار شایع هستند و تخمین زده می‌شود که حدود 450 میلیون نفر در سراسر جهان از چنین مشکلاتی رنج می‌برند. علاوه بر بزرگسالان، کودکان و نوجوانان زیر 18 سال نیز در معرض خطر اختلالات سلامت روان هستند. [3] به‌همین سبب، برای درک بهتر شرایط سلامت روان و ارائه مراقبت بهتر از بیمار، تشخیص زودهنگام مشکلات روان یک گام اساسی است. متفاوت از تشخیص سایر بیماری‌های مزمن که به آزمایش‌ها و اندازه‌گیری‌های آزمایشگاهی متکی هستند، بیماری‌های روانی معمولاً بر اساس خوداظهاری⁴ و پاسخ به پرسشنامه‌های مشخص که برای تشخیص الگوهای خاص از احساسات یا تعاملات اجتماعی طراحی شده‌اند، تشخیص داده می‌شوند. [4] امروزه با توجه به دردسترس بودن داده‌های

1 World Health Organization

2 Attention Deficit Hyperactivity Disorder

3 Autism Spectrum Disorder

4 Self-report and declaration

⁵ Neuro image

⁶ Electronic Health Record

Deep learning for/in (Mental health and/or Mental Health Care and/or mental illness and/or Mental disorder and/or mental disease)

Machine learning for/in (Mental health and/or Mental Health Care and/or mental illness and/or Mental disorder and/or mental disease)

3- معرفی ابزارهای هوش مصنوعی⁹ در سلامت روان

دهه گذشته شاهد افزایش استفاده از مدل‌های یادگیری ماشین¹⁰ برای تجزیه و تحلیل داده‌های مراقبت‌های بهداشتی بوده است. [9-10] [13] یادگیری ماشین- از رویکردهای هوش مصنوعی است که شامل روش‌های مختلفی برای توانمندسازی یک الگوریتم برای یادگیری است. الگوریتم‌های یادگیری ماشین را می‌توان به دو دسته اصلی تقسیم کرد: یادگیری بدون- نظارت که به استخراج ویژگی‌ها کمک می‌کند و یادگیری تحت نظارت، که برای پیش‌بینی، پس از کاهش مؤلفه‌های اصلی، به تجزیه و تحلیل می‌پردازد و همچنین حالت نیمه‌نظارت‌شده نیز پلی است میان این دو حالت.

یادگیری عمیق¹¹ - بعنوان تازه‌ترین فناوری هوش مصنوعی، ویژگی‌های خام ورودی را مستقیماً در خروجی‌ها از طریق یک ساختار شبکه چندلایه که قادر به ثبت الگوهای پنهان درون خروجی است، ترسیم می‌کند. از مدل‌های رایج یادگیری عمیق در حوزه سلامت روان و مراقبت‌های بهداشتی، شبکه عصبی پیشخور عمیق¹²، که در مقایسه با مدل‌های سنتی یادگیری ماشین، عملکرد برتری را در بسیاری از وظایف داده‌کاوی نشان داده است و برای تجزیه و تحلیل داده‌های بالینی و داده‌های ژنتیکی برای پیش‌بینی شرایط سلامت روان معرفی شده است. [14-15] همچنین، شبکه عصبی بازگشتی¹³، برای تجزیه و تحلیل داده‌های متوالی مانند زبان طبیعی، گفتار و ویدئو، شبکه عصبی پیچشی¹⁴ برای تجزیه و تحلیل تصاویر پزشکی و اسکن مغزی و رمزگذار خودکار¹⁵ را می‌توان نام برد. [13-14] [16]

پردازش زبان طبیعی¹⁶ - همگام با پیشرفت در زمینه هوش مصنوعی، پردازش زبان طبیعی و تجزیه و تحلیل صوتی، منجر به ظهور تحقیقاتی درباره ارتباط بین زبان، ویژگی‌های صوتی و سلامت روان شده است. رونوشت مصاحبه‌ها یا جلسات بالینی منابع سنتی محتوای متنی برای تجزیه و تحلیل زبان روان هستند. امروزه، فناوری‌های مبتنی بر اینترنت مانند رسانه‌های اجتماعی، گفتگوهای آنلاین و پیام‌رسان‌ها منابع غنی و جدید از متن غیر بالینی را برای چنین تحلیل‌هایی ارائه می‌دهند. [17] به دلیل حجم بالای داده‌های ورودی خام در قالب متن همچون یادداشت‌های بالینی، زبان نوشتاری و مکالمه مانند جلسات مشاوره، حوزه سلامت روان پیش از استفاده از سایر تکنیک‌های هوش مصنوعی، به شدت به پردازش زبان طبیعی متکی است.

بررسی انواع تغییرات ژنتیکی در ژنوم یک فرد مطالعه کنند. برای شناسایی عوامل خطر ژنتیکی مرتبط با بیماری‌های روانی، از ظرفیت‌های یادگیری عمیق در شناسایی الگوهای پیچیده در مجموعه داده‌های بزرگ، استفاده شده است.

داده‌های بیان صوتی و بصری - داده‌های بیان صوتی (صدا یا گفتار) و بصری (ویدئو یا تصویر رفتارهای صورت یا بدن) توجه بسیاری از مطالعات در زمینه اختلالات سلامت روان را به خود جلب کرده است. اخیراً توجه زیادی به استفاده از این داده‌ها در مدل‌سازی حالات عاطفی افراد برای شناسایی وضعیت سلامت روان شده است. داده‌های صوتی سیگنال‌های پیوسته و متراکم هستند، در حالی که داده‌های ویدئویی دنباله‌ای از فریم‌ها، یعنی تصاویر هستند. هر چند مدل‌های یادگیری ماشین برای تجزیه و تحلیل چنین نوع داده‌هایی در فرآیند استخراج ویژگی‌های پیچیده رنج می‌برند. اما استفاده از یادگیری عمیق در مدل‌سازی توالی داده‌ها، برای تجزیه و تحلیل داده‌های بیان صوتی و/یا بصری موفق بوده است.

داده‌های رسانه‌های اجتماعی - با گسترش پلتفرم‌های رسانه‌های اجتماعی، مانند توییتر و تلگرام و ... افراد به طور فزاینده و عمومی اطلاعاتی را در مورد خلق و خو، رفتار و یا بیماری که ممکن است از آن رنج ببرند به اشتراک می‌گذارند. مطالعات مختلف با بکارگیری تکنیک‌های یادگیری عمیق از چنین داده‌هایی - عمدتاً داده‌های متنی - برای شناسایی و تحلیل وضعیت سلامت روان کاربران بهره برده است. مطالعه‌ی پیش‌رو، در کنار بیان چالش‌ها و فرصت‌های کاربرد هوش مصنوعی در سلامت روان و مراقبت‌های بهداشتی، نگاهی به جهت‌گیری‌های تحقیقاتی آینده خواهد داشت. از نگاهی دیگر، می‌توان داده‌های مورد استفاده در حوزه سلامت روان و مراقبت‌های بهداشتی را به دو گروه اصلی تقسیم کرد: داده‌های ساخت‌یافته، مانند تصاویر پزشکی، داده‌های ژنتیکی، الکتروفیزیولوژی (EP)⁷، مدارک پزشکی الکترونیک (EMR)⁸ و داده‌های بدون ساختار، مانند یادداشت‌های بالینی و پزشکی که عمدتاً استخراج اطلاعات از آنها با روش‌های پردازش زبان طبیعی صورت می‌گیرد. [10-12]

2- روش تهیه مقاله

این مقاله، به بررسی مطالعات موجود در پایگاه داده PubMed، بر اساس معیارهای انتخاب از پیش تعریف‌شده با دو سطح غربالگری پرداخته است: بررسی عنوان و چکیده، و بررسی کامل مقالاتی که معیارهای ورود داشتند. سپس با مرور تحقیقات منتخب و طبقه‌بندی داده‌های موجود، نحوه انتشار کاربردهای هوش مصنوعی در مراقبت‌های سلامت روان و بیماری‌های روان، مورد بررسی قرار گرفته است. در روند جستجوی مقالات در پایگاه داده فوق‌الذکر، از کلیدواژه‌های زیر بهره گرفته شده است:

Artificial intelligence for/in (Mental health and/or Mental Health Care and/or mental illness and/or Mental disorder and/or mental disease)

⁹ Artificial Intelligence

¹⁰ Machine Learning

¹¹ Deep Learning (DL)

¹² Deep feedforward neural network (DFNN)

¹³ Recurrent neural network (RNN)

¹⁴ Convolutional neural network (CNN)

¹⁵ Autoencoder

¹⁶ Natural Language Processing

⁷ Electrophysiology Procedure

⁸ Electronic medical records

چراکه توانایی یک الگوریتم برای درک خودکار معانی کلمات بنیادی، پیشرفتی قابل توجه در فناوری است که در کاربردهای مراقبت از سلامت روان ضروری است. [18-19]

1-3- کاربرد هوش مصنوعی در مراقبت‌های بهداشتی

هوش مصنوعی در حال حاضر راه خود را در زندگی مدرن (به‌عنوان مثال برای دسترسی به اطلاعات، تسهیل تعاملات و رسانه‌های اجتماعی و سیستم‌های امنیتی) باز کرده است. در حالی که استفاده از هوش مصنوعی در داده‌های بالینی (به‌عنوان مثال، تصویربرداری پزشکی، آزمایش ژنتیک) و تحلیل آنها بسیار جوان است، و هنوز با پذیرش معمول هوش مصنوعی در مراقبت‌های بهداشتی فاصله داریم، اما ورود هوش مصنوعی در زمینه‌هایی از مراقبت‌های بهداشتی را نمی‌توان نادیده گرفت؛ این زمینه‌ها عبارتند از: غربالگری انبوه^{۱۷}، تصویربرداری تشخیصی^{۱۸}، داده‌های آزمایشگاهی^{۱۹}، تشخیص الکترونی^{۲۰}، تشخیص ژنتیکی^{۲۱}، داده‌های بالینی^{۲۲}، یادداشت‌های عملیاتی^{۲۳}، پرونده الکترونیک سلامت^{۲۴}، و سوابق حاصل از دستگاه‌های پوشیدنی^{۲۵}. [11-12]

قضاوت در مورد رفتارهای بهینه در زندگی به دلیل پویایی و شرایط محیط اجتماعی اغلب بسیار پیچیده و دشوار است. چراکه، در این تصمیم‌گیری، مناطق مختلفی از مغز و مدارهای عصبی دخیل هستند. [20] بسیاری از مطالعات عصب‌بیولوژیکی در مورد تصمیم‌گیری نشان می‌دهند که رفتارها از طریق هماهنگی بین سیستم‌های متعدد شبکه عصبی انتخاب می‌شوند که هر کدام مجموعه‌ای متمایز از الگوریتم‌های محاسباتی را اجرا می‌کنند. بدین‌رو، اعمال تکنیک‌های داده کاوی [21] و رویکردهای یادگیری ماشین بر مجموعه داده‌های چندوجهی نه تنها از نظر آسیب‌شناسی بیماری‌های روانی را بازتعریف می‌کنند، بلکه در نتایج درمانی نیز بهبود بیشتری کسب کرده‌اند. این امر خود، گواه تاثیر قابل‌تأمل استفاده از تکنیک‌ها و ابزار هوش مصنوعی در تشخیص و درمان است. [22-24]

2-3- کاربرد هوش مصنوعی در بیماری‌ها و اختلالات روان

در سال‌های اخیر بویژه، هوش مصنوعی در پیش‌آگهی، تشخیص و درمان، به اختلالات و بیماری‌هایی از سلامت روان که براساس طبقه‌بندی بین‌المللی بیماری‌ها^{۲۶}، و راهنمای تشخیصی و آماری اختلالات روان^{۲۷}، شایع‌ترین تهدیدهای این حوزه هستند، ورود کرده است. [20] شی‌زوفرنی، اختلالات اضطراب و نگرانی، اختلالات افسردگی، اوتیسم و آلزایمر^{۲۸} بیشترین تهدید

¹⁷ Mass screening

¹⁸ Diagnostic imaging

¹⁹ Laboratory data

²⁰ Electro-diagnosis

²¹ Genetic diagnosis

²² Clinical data

²³ Operation notes

²⁴ Electronic health records

²⁵ Records from wearable devices

²⁶ International Classification of Diseases (ICD) and Diagnostic

²⁷ Statistical Manual of Mental Disorders (DSM)

²⁸ Alzheimer Disease (AD)

برای سلامت‌روان هستند. [25-28] مطالعه پیش‌رو، با توجه به طبقه‌بندی جهانی بیماری‌ها و اختلالات روان و با تمرکز بر دسته‌بندی فوق به مرور حوزه‌های ورود هوش مصنوعی به این تهدیدها پرداخته است.

آل‌زایمر - شامل فرآیند تدریجی کاهش حجم و کیفیت اتصال نورون در مغز است که منجر به یکپارچگی تدریجی سیناپسی و از دست دادن عملکردهای شناختی است. [29-30] این بیماری، بعنوان یک اختلال مغزی پیش‌رونده، به موضوعی حیاتی از نظر سلامت جهانی، سلامت عمومی و سلامت جمعیت در جهان تبدیل شده است. [31] درک پیشرفت بیماری و تسهیل تشخیص زودهنگام آن کانون توجه در تصویربرداری عصبی و ژنومیک در دهه گذشته بوده است. [32-33] هرچند جمع آوری ترکیبی از داده‌ها می‌تواند گران، پیچیده و خسته‌کننده باشد، اما قابلیت‌های یادگیری ماشین برای پردازش و ادغام مقادیر بزرگ از اطلاعات تعاملی، چندبعدی و چندسطحی را نمی‌توان نادیده گرفت. [34-35] در سال‌های اخیر، توجه زیادی به طبقه‌بندی این بیماری، تشخیص زودهنگام و یا شناسایی ژن‌های محافظ [36] در برابر این بیماری، با الگوریتم‌های یادگیری ماشین شده است. درحالی‌که، بیشتر محققان بر روی استفاده از شبکه‌های عصبی پیچشی 3 بعدی و 4 بعدی برای طبقه‌بندی الزایمر به دلیل مقادیر قابل‌تأمل داده متمرکز شده‌اند. اما اخیراً، آگاروال و همکاران، در یک مقاله مروری به بررسی نتایج بدست آمده برپایه مدل‌های ترکیبی (یادگیری عمیق و یادگیری انتقالی^{۲۹}) در مقایسه با مدل‌های یادگیری عمیق پرداخته‌اند. در این مطالعه سیستماتیک، دقت نتایج بدست آمده برپایه مدل‌های ترکیبی در تشخیص بیماری آلزایمر از طریق نشانگرهای زیستی تصویربرداری عصبی، بمراتب بهتر از مدل‌های مبتنی بر یادگیری عمیق با استفاده از معماری‌های مبتنی بر شبکه پیچشی سه بعدی از پیش آموزش دیده بوده است. این تحقیق نقش مثبت یادگیری انتقالی در پیش‌آگهی و تشخیص الزایمر را بیش از پیش نمایان می‌کند. [37]

اختلال طیف اوتیسم - وضعیتی عصبی است که عموماً از اوایل کودکی آغاز می‌شود. از آنجایی که پاتوژن^{۳۰} این بیماری هنوز مبهم است، تشخیص بیماری با مشاهده مجموعه‌ای از علائم رفتاری و بهره‌گیری از تکنیک‌های غیرتهاجمی تصویربرداری مغز، مانند تصویربرداری مغناطیسی رزونانس^{۳۱}، حاصل می‌شود. ژو و همکاران، به بررسی پیشرفت‌های مبتنی بر رویکردهای یادگیری ماشین در تشخیص اوتیسم پرداخته‌اند. آنها ضمن بررسی چالش‌های موجود در راه تشخیص اوتیسم، بر لزوم شناسایی نشانگرهای زیستی^{۳۲} متمایز، برای تشخیص بیماری و نقش حیاتی آنها در ایجاد مجموعه داده‌های جامع و تشریح ناهمگونی فردی و گروهی برای دستیابی به عملکرد بهتر در فرایند تشخیص، تاکید می‌کنند. [38] در همین راستا، هوش مصنوعی در برقراری ارتباط با بیماران اوتیسم به پیشرفت‌های چشمگیر دست یافته است. مطالعه تحقیقات انجام شده در این حوزه، نشان می‌دهد

²⁹ Transfer Learning

³⁰ Pathogen

³¹ Magnetic resonance imaging (MRI)

³² Biomarkers

ربات‌ها نقش مهمی در این ارتباط داشته‌اند. روبات‌ها دستگاه‌هایی هستند که از حسگرها برای نظارت بر حرکت و موقعیت انسان استفاده می‌کنند و سپس از این بازخورد برای تعامل با محیط استفاده می‌کنند. ربات‌ها با استفاده از حسگرها و محرک‌ها قادر به اندازه‌گیری و ذخیره پارامترهای عملکرد بیمار هستند. این امر می‌تواند به ارزیابی بالینی در طولانی مدت کمک کند. این دستگاه‌ها با توانایی تشخیص و اندازه‌گیری تغییرات کوچک در حرکات، می‌توانند به درمانگران در فرآیندهای برنامه‌ریزی درمان و تعیین هدف کمک کنند. یوشیکاوا و همکاران، به بررسی اثرات استفاده از ربات در مصاحبه‌های روانپزشکی پرداخته‌اند. آنها بر این باورند مصاحبه مستقیم و رو در رو بین روانپزشک و بیمار در ارزیابی بالینی بسیار مهم است، با این حال، انجام چنین مصاحبه‌هایی به شیوه سنتی به ویژه در دوران همه‌گیری کرونا، به دلیل خطر ابتلا به بیماری دشوار می‌شود. [39] هر چند مصاحبه‌های ویدئویی با استفاده از اینترنت برای ارزیابی و کمک به افراد مبتلا به اختلالات روانی مفید است، با این حال، برخی از بیماران به ویژه آن دسته که به اختلال ترس اجتماعی، افسردگی و اختلال طیف اوتیسم مبتلا هستند در استفاده از ابزارهای چهره به چهره تردید دارند. [40-41] همچنین، بررسی‌ها بر روی چندین ربات چت³³ که برای طیف وسیعی از بیماری‌های روانی، از جمله افسردگی، اختلال طیف اوتیسم (بویژه برای کودکان که با کمبود عاطفی درگیر هستند) و اضطراب ساخته شده‌اند، رضایت کاربران از چت‌بات‌ها را نشان می‌دهد و شواهد اولیه بر اثربخشی مطلوب، صحت می‌گذارد. [42-45]

شیزوفرنی - بیماری مزمن سلامت روان است که با اختلال در تفکر و رفتار، میلیون‌ها نفر را در سراسر جهان تحت تاثیر قرار داده‌است، این اختلال به طور قابل توجهی روال زندگی روزمره را مختل می‌کند. چندین الگوریتم هوش مصنوعی و یادگیری ماشین برای تجزیه و تحلیل مؤلفه‌های موثر در بروز اسکیزوفرنی، پیش‌بینی بیماری، و ارزیابی روش‌های پیشگیری فعلی، مورد استفاده قرار گرفته‌اند. [46-48] مطالعه تحقیقات بعمل آمده، بویژه در دهه‌های اخیر نشان می‌دهد، پژوهش‌ها برای یافتن همپوشانی میان اختلالات روانی که در طبقه‌بندی سنتی بیماریها، بعنوان اختلالات متمایز در نظر گرفته می‌شوند، در حال گسترش است. لانگلاند حسن، در پژوهشی تحت عنوان «گفتار درون³⁴»، به بررسی پدیده‌ی روانشناختی «صدای درون» یا «صحبت کردن در ذهن» می‌پردازد. او در این مطالعه به بررسی ارتباط گفتار درونی با توهمات شنوایی-شفاهی در شیزوفرنی پرداخته و بیان می‌کند که مبتلایان به توهمات شنوایی-کلامی³⁵ به اشتباه، گفتار خود را به عنوان گفتاری تولید شده توسط شخص دیگر تشخیص می‌دهند - آنچه در مبتلایان به اسکیزوفرنی شایع است - این مطالعه همچنین به کاربرد هوش مصنوعی در ترجمه نشانه‌های عصبی و عصبی-عضلانی گفتار درونی به سیگنال‌های

³³ Chatbots

³⁴ Inner Speech

³⁵ Auditory Verbal Hallucinations(AVH)

گفتاری بیرونی متناظر پرداخته و بر این باور است که این امر می‌تواند زمینه را برای مداخلات جدید از سوی هوش مصنوعی در این حوزه فراهم کند. [49] اضطراب و نگرانی - اختلالات خلقی و اضطرابی یکی از رایج‌ترین تشخیص‌هایی است که در راهنمای تشخیصی و آماری اختلالات روانی، ویرایش پنجم (DSM-5) و یازدهمین ویرایش طبقه‌بندی آماری بین‌المللی بیماری‌ها و مشکلات سلامت (ICD-11) دسته‌بندی شده است. [3] شیوع اختلالات سلامت روان به ویژه در جمعیت کودکان و جوانان به طور مداوم در حال افزایش است. همین امر در مورد اختلالات اضطرابی، شایع‌ترین بیماری روانی، که تقریباً یک‌سوم کودکان و نوجوانان را تحت تأثیر قرار می‌دهد. نیز صدق می‌کند. [50-52] در بررسی رویکردهای یادگیری ماشین برای پیش‌بینی اختلالات اضطرابی، مشاهده شده که SVM و ANN متداول‌ترین روش‌ها برای پیش‌بینی اختلال اضطراب اجتماعی هستند. همچنین استفاده از ویژگی‌های چند سطحی مانند یادگیری چند هسته‌ای، عملکرد طبقه‌بندی را برای پیش‌بینی اختلال استرس پس از سانحه (PTSD) افزایش می‌دهد. وضعیت سلامت ذهنی، نوشیدن الکل، سیگار کشیدن، فشار خون بالا و ورزش منظم نیز می‌تواند بعنوان ویژگی‌های موثر³⁶ در پیش‌بینی GAD، SAD و PTSD مفید باشند. [53] در همین حوزه، اوپوکو آساره و همکاران، به مطالعه پیش‌بینی اختلالات افسردگی از طریق نشانگرهای رفتاری گوشی‌های هوشمند با استفاده از روش‌های یادگیری ماشین، پرداخته‌اند. در این تحقیق میدانی 629 نفر از حداقل 56 کشور مشارکت داشته‌اند. همچنین اطلاعات مربوط به سن، جنس، تحصیلات و شغل افراد نیز مورد رصد قرار گرفت. 22 ویژگی از گوشی‌های هوشمند در استخراج ویژگی مدل مورد استفاده قرار گرفت. در این پژوهش از الگوریتم‌های یادگیری نظارتی برای طبقه‌بندی استفاده شده‌است. یافته‌ها نشان می‌دهد نشانگرهای حسگرهای نشان‌دهنده افسردگی را می‌توان به‌طور نامحسوسی از داده‌های حسگرهای تلفن هوشمند شناسایی کرد. در نتیجه ارزیابی سنتی افسردگی را می‌توان با نشانگرهای رفتاری از تلفن‌های هوشمند برای تشخیص و نظارت بر افسردگی تقویت کرد. [54] در پژوهشی دیگر، اسمرکه و همکاران، مطالعه‌ای محدود بر پژوهش‌های انجام شده در حوزه اختلالات افسردگی در بازماندگان بیماری سرطان انجام داده‌اند. نتایج حاصل از مطالعه نشان می‌دهد شناسایی ویژگی‌های قابل مشاهده همچون زبان، گفتار و بیان چهره برای تشخیص زودهنگام افسردگی و غربالگری در این دسته از بیماران، با روش‌های مبتنی بر هوش مصنوعی قابل رهگیری است. [55] شیمورا و همکاران، در تحقیقی نشان دادند که کار از راه دور با کاهش پاسخ‌های استرس روانی و فیزیکی و اختلال خواب مرتبط است. در این تحقیق، اثرات کار از راه دور بر پاسخ‌های استرس روانی و فیزیکی با تجزیه و تحلیل رگرسیون لجستیک چند متغیره، با تعدیل سن، جنسیت، اضافه‌کاری، استرس‌های شغلی، حمایت اجتماعی و وضعیت خواب مورد توجه قرار گرفت. نتایج حاصل از مطالعه همچنین نشان

می‌دهد که کار کاملاً از راه دور سبب افزایش اعلام حضور افراد می‌شود اما همزمان کاهش بهره‌وری را به‌همراه دارد. [56]

4- نتیجه‌گیری

هدف متخصصان سلامت روان، ادغام اطلاعات ژنتیکی، محیطی، بالینی و شیوه زندگی برای شخصی سازی درمان ها و تکمیل قضاوت بالینی است. بدین رو، شناسایی معیارهای بالینی قوی و نشانگرهای زیستی برای هدایت انتخاب درمان بسیار موثر است. در نتیجه، بهره گیری از انواع داده‌های مختلف در پیش‌آگهی، تشخیص، درمان و مراقبت بهداشتی انواع بیماریها بویژه بیماریها و اختلالات سلامت روان، نتایج و اثرات مثبت قابل تامل را در پی دارد، اما از سویی دیگر سبب پدیدار شدن داده‌های بزرگ و پیچیده (هم به لحاظ ماهیت داده‌ها و هم ارتباطات میان انواع داده) شده است. این امر بعنوان بزرگترین چالش، نیاز به ابزارها و تکنیک‌هایی قابل اعتماد برای تجزیه و تحلیل داده‌های بزرگ را بوجود آورده است. در پاسخ به این چالش، در سال‌های اخیر، توجه و علاقه بر معرفی و استفاده از مدل‌های مبتنی بر هوش مصنوعی چندوجهی و ترکیبی افزایش یافته است. اشتیاق در معرفی پتانسیل روش‌های مبتنی بر هوش مصنوعی برای شکستن بن بست تشخیص و درمان سنتی در افزایش تعداد مطالعات علمی در خصوص کاربرد این تکنیک‌ها در پیش‌بینی و تشخیص، مراقبت و درمان بیماری‌ها و اختلالات روان بخوبی منعکس شده است. هر چند این مطالعات در پاره‌ای موارد پا را فراتر نهاده و به معرفی مدل‌های مبتنی بر یادگیری عمیق برای پیش‌بینی و تشخیص خودکار بیماری پرداخته‌اند، اما آنچه قابل تامل و توجه است؛ نقش هوش مصنوعی در ارائه دیدگاهی متعادل مبتنی بر تجزیه و تحلیل انواع داده‌های بزرگ، در کنار روش‌های سنتی تجزیه و تحلیل است. پیوست مقاله، شامل خلاصه‌ای از مطالعات در حوزه هوش مصنوعی و سلامت روان با تمرکز بر نوع داده‌های مورد استفاده را در بر می‌گیرد. مطالعات، روند رو به رشد کاربرد هوش مصنوعی در سلامت روان و بیماری‌های روان را بیش از پیش نشان می‌دهد.

مراجع

- [1] "depression". Accessed: Oct. 21, 2023. [Online]. Available: <https://www.who.int/news-room/fact-sheets/detail/depression>
- [2] S. Saeb, E. G. Lattie, S. M. Schueller, K. P. Kording, and D. C. Mohr, "The relationship between mobile phone location sensor data and depressive symptom severity", *PeerJ*, vol. 4, no. e2537, p. e2537, Sep. 2016.
- [3] "Mental Health", *Our World in Data*. Accessed: Aug. 18, 2022. [Online]. Available: <https://ourworldindata.org/mental-health>
- [4] A. Macchia, "Depression worsens outcomes in elderly patients with heart failure: an analysis of 48,117 patients in a community setting.", vol. 10, no. 7, pp. 714–21, Jul. 2008, doi: 10.1016/j.ejheart.2008.05.011.
- [5] "Depression costs employers \$210 billion Internet.Behavioral HealthExecutive." <https://www.psychcongress.com/news-item-/depressioncosts-employers-210-billion>.
- [6] Y. LeCun, Y. Bengio and G. Hinton, "Deep learning", vol. 521, no. 7553, pp. 436–444, Oct. 2015, doi: 10.1038/nature14539.
- [7] R. Miotto, F. Wang, S. Wang, X. Jiang and J. T. Dudley, "Deep learning for healthcare: review, opportunities and challenges", vol. 19, pp. 1236–1246, Oct. 2017.
- [8] S. Vieira, W. H. Pinaya and A. Mechelli, "Using deep learning to investigate the neuroimaging correlates of psychiatric and neurological disorders: methods and applications", vol. 74, pp. 58–75, Oct. 2017.

- [9] A. B. Shatte, D. M. Hutchinson and S. J. Teague, "Machine learning in mental health: a scoping review of methods and applications", vol. 49, pp. 1426–1448, Oct. 2019.
- [10] D. Durstewitz, G. Koppe and A. Meyer-Lindenberg "A. deep neural networks in psychiatry", Oct. 2019, doi: 10.1038/s41380-019-0365-9.
- [11] F. Jiang, "Artificial intelligence in healthcare: past, present and future", *Stroke and vascular neurology*, vol. 2, no. 4, pp. 230–243, Oct. 2017, doi: 10.1136/svn-2017-000101.
- [12] M. Hengstler, E. Enkeland S. Duelli, "Applied artificial intelligence and trust—The case of autonomous vehicles and medical assistance devices", vol. 105, no. C, pp. 105–120, Oct. 2016.
- [13] H. J. Murff, "Automated identification of postoperative complications within an electronic medical record using natural language processing", vol. 306, no. 8, pp. 848–855, Oct. 2011, doi: 10.1001/jama.2011.1204.
- [14] K. Cho, B. van Merriboer, D. Bahdanau and Y. Bengio, "On the Properties of Neural Machine Translation: Encoder–Decoder Approaches", pp. 103–111, Oct. 2014, doi: 10.3115/v1/W14-4012.
- [15] P. Vincent, H. Larochelle, I. Lajoie, Y. Bengio and P. Manzagol, "Stacked Denoising Autoencoders: Learning Useful Representations in a Deep Network with a Local Denoising Criterion", vol. 11, no. 110, pp. 3371–3408, Oct. 2010, [Online]. Available: <http://jmlr.org/papers/v11/vincent10a.html>
- [16] A. Wongkoblap, M. A. Vadillo and, "Researching Mental Health Disorders in the Era of Social Media: Systematic Review", vol. 19, no. 6, p. e228, Oct. 2017, doi: <https://doi.org/10.2196/jmir.7215>.
- [17] T. Zhang, A. M. Schoene, S. J. J. S. Ananiadou, "Natural language processing applied to mental illness detection: a narrative review", vol. 5, no. 1, p. 46, Apr. 2022, doi: 10.1038/s41746-022-00589-7.
- [18] D. Demner-Fushman, W. W. Chapman and C. J. McDonald, "What can natural language processing do for clinical decision support?", vol. 42, no. 5, pp. 760–772, Oct. 2009, doi: 10.1016/j.jbi.2009.08.007.
- [19] E. Cambria, B. White, "Jumping NLP Curves: A Review of Natural Language Processing Research", vol. 9, pp. 48–57, Oct. 2014, [Online]. Available: <https://api.semanticscholar.org/CorpusID:206451986>
- [20] T. B. Üstün and R. Ho, *Classification of Mental Disorders: Principles and Concepts*. International Encyclopedia of Public Health (Second Edition), 2017.
- [21] "Depressive disorder (depression)". Accessed: May. 12, 2023. [Online]. Available: <https://www.who.int/news-room/fact-sheets/detail/depression>
- [22] S. Sarraf and G. Tofighi, "Deep Learning-based Pipeline to Recognize Alzheimer's Disease using fMRI Data", Oct. 2016, doi: 10.1109/FTC.2016.7821697.
- [23] J. Lee, S. Chiand M. Lee, "Molecular Biomarkers for Pediatric Depressive Disorders: A Narrative Review", vol. 22, no. 18, p. 10051, Sep. 2021, doi: 10.3390/ijms221810051.
- [24] S. Saeb, M. Zhang, M. M. Kwasny, C. J. Karr, K. Kording and D. C. Mohr, "The Relationship between Clinical, Momentary, and Sensor-based Assessment of Depression", Oct. 2015, doi: 10.4108/icst.pervasivehealth.2015.259034.
- [25] O. Asare, A. Visuri and D. Ferreira, "Towards Early Detection of Depression through Smartphone Sensing", Oct. 2019, doi: 10.1145/3341162.3347075.
- [26] J. M. Amini, M. M. Pedram, A. Moradi, M. Jamshidi and M. Ouchani, "Single and Combined Neuroimaging Techniques for Alzheimer's Disease Detection", Oct. 2021.
- [27] B. Bach, S. Boand J. Keeley, "Diagnostic Systems and Models: DSM-5 Criteria, ICD-11 Guidelines, and Dimensional Horizons", pp. 36–58, Jan. 2022, doi: 10.1016/B978-0-12-818697-8.00111-4.
- [28] J. Ranson, "Modifiable risk factors for dementia and dementia risk profiling", Oct. 2021, doi: 10.1186/s13195-021-00895-4.
- [29] K. Blennow, M. de Leon and H. Zetterberg, "Alzheimer's disease", vol. 368, no. 9533, pp. 387–403, Jul. 2006, doi: 10.1016/S0140-6736(06)9113-7.
- [30] J. A. Weber, "The MicroRNA Spectrum in 12 Body Fluids", vol. 56, no. 11, Nov. 2010, doi: 10.1373/CLINCHEM.2010.147405.
- [31] A. Kumar, A. Singhand Ekavali, "A review on Alzheimer's disease pathophysiology and its management: an update", vol. 67, no. 2, pp. 195–203, Apr. 2015, doi: 10.1016/j.pharep.2014.09.004.
- [32] D. Veitch, "Understanding disease progression and improving Alzheimer's disease clinical trials: Recent highlights from the Alzheimer's Disease Neuroimaging Initiative", vol. 15, no. 1, pp. 106–152, Jan. 2019, doi: 10.1016/j.jalz.2018.08.005.

- [54] K. Opoku Asare, Y. Terhorst, J. Vega, E. Peltonen, E. Lagerspetz and D. Ferreira, "Predicting Depression From Smartphone Behavioral Markers Using Machine Learning Methods, Hyperparameter Optimization, and Feature Importance Analysis: Exploratory Study", vol. 9, no. 7, p. e26540, Oct. 2021, doi: 10.2196/26540.
- [55] U. Smrke, I. Mlakar, S. Lin, B. Musil and N. Plohl, "Language, Speech, and Facial Expression Features for Artificial Intelligence-Based Detection of Cancer Survivors' Depression: Scoping Meta-Review", vol. 8, no. 12, p. e30439, Oct. 2021, doi: 10.2196/30439.
- [56] A. Shimura, K. Yokoi, Y. Ishibashi, Y. Akatsuka and T. Inoue, "Remote Work Decreases Psychological and Physical Stress Responses, but Full-Remote Work Increases Presenteeism", vol. 12, p. 730969, Oct. 2021, doi: 10.3389/fpsyg.2021.730969.
- [57] U. R. Acharya, S. L. Oh, Y. Hagiwara, J. H. Tan, H. Adeli and D. P. Subha, "Automated EEG-based screening of depression using deep convolutional neural network", vol. 161, pp. 103–113, Oct. 2018, doi: 10.1016/j.cmpb.2018.04.012.
- [58] B. Ay, "Automated Depression Detection Using Deep Representation and Sequence Learning with EEG Signals", vol. 43, no. 7, p. 205, Oct. 2019, doi: 10.1007/s10916-019-1345-y.
- [59] O. Bălan, G. Moise, A. Moldoveanu, M. Leordeanu and F. Moldoveanu, "An Investigation of Various Machine and Deep Learning Techniques Applied in Automatic Fear Level Detection and Acrophobia Virtual Therapy", vol. 20, no. 2, p. 496, Oct. 2020, doi: 10.3390/s20020496.
- [60] X. Bi and H. Wang, "Early Alzheimer's disease diagnosis based on EEG spectral images using deep learning", vol. 114, pp. 119–135, Oct. 2019, doi: 10.1016/j.neunet.2019.02.005.
- [61] M. de Bardeci, C. T. Ipan and S. Olbrich, "Deep learning applied to electroencephalogram data in mental disorders: A systematic review", vol. 162, p. 108117, Oct. 2021, doi: 10.1016/j.biopsycho.2021.108117.
- [62] L. Chu, R. Qiu, H. Liu, Z. Ling and X. Shi, "Individual Recognition in Schizophrenia using Deep Learning Methods with Random Forest and Voting Classifiers: Insights from Resting State EEG Streams", Jun. 2017.
- [63] L. Dubreuil-Vall, G. Ruffini and J. A. Camprodon, "Deep learning convolutional neural networks discriminate adult ADHD from healthy individuals on the basis of event-related spectral EEG", vol. 14, p. 251, Oct. 2020, doi: 10.3389/fnins.2020.00251.
- [64] S. Kim, J. Kim and H.-W. Chun, "Wave2Vec: Vectorizing Electroencephalography Bio-Signal for Prediction of Brain Disease", vol. 15, no. 8, p. 1750, Oct. 2018, doi: 10.3390/ijerph15081750.
- [65] X. Li, "EEG-based mild depression recognition using convolutional neural network", vol. 57, no. 6, pp. 1341–1352, Oct. 2019, doi: 10.1007/s11517-019-01959-2.
- [66] X. Li, R. La, Y. Wang, B. Huang, "A Deep Learning Approach for Mild Depression Recognition Based on Functional Connectivity Using Electroencephalography", vol. 14, p. 192, Oct. 2020, doi: 10.3389/fnins.2020.0192.
- [67] M. Moghaddari, M. Z. Lighvan and S. Danishvar, "Diagnose ADHD disorder in children using convolutional neural network based on continuous mental task EEG", vol. 197, p. 105738, Oct. 2020, doi: 10.1016/j.cmpb.2020.105738.
- [68] F. C. Morabito, "Deep Learning Representation from Electroencephalography of Early-Stage Creutzfeldt-Jakob Disease and Features for Differentiation from Rapidly Progressive Dementia", vol. 27, no. 2, p. 1650039, Oct. 2017, doi: 10.1142/S0129065716500398.
- [69] W. Mumtaz and A. Qayyum, "A deep learning framework for automatic diagnosis of unipolar depression", vol. 132, p. 103983, Oct. 2019, doi: 10.1016/j.ijmedinf.2019.103983.
- [70] S. L. Oh, V. Jahmunah, E. J. Ciaccio, R. Yuvaraj and U. R. Acharya, "Deep Convolutional Neural Network Model for Automated Diagnosis of Schizophrenia Using EEG Signals", vol. 9, no. 14, p. 2870, Oct. 2019, doi: 10.3390/app9142870.
- [71] C. R. Phang, F. Noman, H. Hussain, C. M. Ting and H. Ombao, "A Multi-Domain Connectome Convolutional Neural Network for Identifying Schizophrenia From EEG Connectivity Patterns", vol. 24, no. 5, pp. 1333–1343, Oct. 2020, doi: 10.1109/JBHI.2019.2941222.
- [72] M. Shahin, B. Ahmed, S. T. Hamida, F. L. Mulaffer, M. Glos and T. Penzel, "Deep Learning and Insomnia: Assisting Clinicians With Their Diagnosis", vol. 21, no. 6, pp. 1546–1553, Oct. 2017, doi: 10.1109/JBHI.2017.2650199.
- [73] A. Shalhaf, S. Bagherzadeh and A. Maghsoudi, "Transfer learning with deep convolutional neural network for automated detection of
- [33] S. Andrews, B. Fulton-Howard and A. Goate, "Interpretation of risk loci from genome-wide association studies of Alzheimer's disease", Apr. 2020, doi: 10.1016/S1474-4422(19)30435-1.
- [34] M. J. Kas, B. Penninx, B. Sommer, A. Serretti, C. Arango and H. Marston, "A quantitative approach to neuropsychiatry: The why and the how", vol. 97, pp. 3–9, Oct. 2019, doi: 10.1016/j.neubiorev.2017.12.008.
- [35] M. Ferrante, A. D. Redish, M. A. Oquendo, B. B. Averbeck, M. E. Kinnane and J. A. Gordon, "Computational psychiatry: a report from the 2017 NIMH workshop on opportunities and challenges", vol. 24, no. 4, pp. 479–483, Oct. 2019, doi: 10.1038/s41380-018-0063-z.
- [36] M. Seto, R. L. Weiner, L. Dumitrescu, "Protective genes and pathways in Alzheimer's disease: moving towards precision interventions", vol. 16, no. 1, p. 29, Oct. 2021, doi: 10.1186/s13024-021-00452-5.
- [37] D. Agarwal, G. Marques, I. de la Torre-Díez, M. A. Franco Martín, B. García Zapirain and F. Martín Rodríguez, "Transfer Learning for Alzheimer's Disease through Neuroimaging Biomarkers: A Systematic Review", vol. 21, no. 21, p. 7259, Oct. 2021, doi: 10.3390/s21217259.
- [38] M. Xu, V. Calhoun, R. Jiang, W. Yan and J. Sui, "Brain imaging-based machine learning in autism spectrum disorder: methods and applications", vol. 361, p. 109271, Oct. 2021, doi: 10.1016/j.jneumeth.2021.109271.
- [39] Y. Yoshikawa, H. Kumazaki and T. Kato, "Future perspectives of robot psychiatry: can communication robots assist psychiatric evaluation in the COVID-19 pandemic era?", vol. 34, no. 3, pp. 277–286, Oct. 2021, doi: 10.1097/YCO.0000000000000692.
- [40] N. Sartorius, "WPA guidance on how to combat stigmatization of psychiatry and psychiatrists", vol. 9, no. 3, pp. 131–144, Oct. 2010, doi: 10.1002/j.2051-5545.2010.tb00296.x.
- [41] T. A. Kato, N. Sartorius and N. Shinfuku, "Forced social isolation due to COVID-19 and consequent mental health problems: Lessons from hikikomori", vol. 74, no. 9, pp. 506–507, Oct. 2020, doi: 10.1111/pcn.13112.
- [42] A. A. Abd-Alrazaq, M. Alajlani, A. A. Alalwan, B. M. Bewick, P. Gardner and M. Househ, "An overview of the features of chatbots in mental health: A scoping review", vol. 132, p. 103978, Oct. 2019, doi: 10.1016/j.ijmedinf.2019.103978.
- [43] S. D'Alfonso, "Artificial Intelligence-Assisted Online Social Therapy for Youth Mental Health", vol. 8, Oct. 2017, doi: 10.3389/fpsyg.2017.00796.
- [44] S. Cano, C. S. González, R. M. Gil-Iranzo and S. Albiol-Pérez, "Affective Communication for Socially Assistive Robots (SARs) for Children with Autism Spectrum Disorder: A Systematic Review", vol. 21, no. 15, p. 5166, Oct. 2021, doi: 10.3390/s21155166.
- [45] S. Ojha, J. Vitale and M.-A. Williams, "Computational Emotion Models: A Thematic Review", vol. 13, pp. 1253–1279, Oct. 2020, [Online]. Available: <https://api.semanticscholar.org/CorpusID:228808759>
- [46] A. Anticevic, J. D. Murray and D. M. Barch, "Bridging Levels of Understanding in Schizophrenia Through Computational Modeling", vol. 3, no. 3, pp. 433–459, Oct. 2015, doi: 10.1177/2167702614562041.
- [47] A. Fornito and A. Zalesky, "Computational Approaches to Understanding Mental Dysfunction: Progress, Challenges, and New Frontiers", vol. 3, no. 9, pp. 728–730, Oct. 2018, doi: 10.1016/j.bpsc.2018.07.005.
- [48] H. Grunze and M. Cetkovich-Bakmas, "Apples and pears are similar, but still different things. Bipolar disorder and schizophrenia- discrete disorders or just dimensions?", vol. 290, pp. 178–187, Oct. 2021, doi: <https://doi.org/10.1016/j.jad.2021.04.064>.
- [49] P. Langland-Hassan, "Innerspeech", Mar. 2021, doi: 10.1002/wcs.1544.
- [50] K. Merikangas, "Lifetime prevalence of mental disorders in U.S. adolescents: results from the National Comorbidity Survey Replication--Adolescent Supplement (NCS-A)", Oct. 2010, doi: 10.1016/j.jaac.2010.05.017.
- [51] H. L. Egger and A. Angold, "Common emotional and behavioral disorders in preschool children: presentation, nosology, and epidemiology", vol. 47, no. 3–4, pp. 313–337, Oct. 2006, doi: 10.1111/j.1469-7610.2006.01618.x.
- [52] T. Wilens, J. Biederman, S. Brown, S. Tanguay, M. Monuteaux and C. Blake, "Psychiatric comorbidity and functioning in clinically referred preschool children and school-age youths with ADHD", vol. 41, pp. 262–268, Oct. 2002, doi: 10.1097/00004583-200203000-00005.
- [53] E. G. Pintelas, T. Kotsilieris, I. E. Livieris and P. Pintelas, "A Review of Machine Learning Prediction Methods for Anxiety Disorders", pp. 8–15, Oct. 2018, doi: 10.1145/3218585.3218587.

- Comprehensive Review”, vol. 1, pp. 39–53, Oct. 2019, doi: <https://doi.org/10.33969/JIEC.2019.11005>.
- [94] M. Amini, M. Pedram, A. Moradiand M. Ouchani, “Diagnosis of Alzheimer's Disease Severity with fMRI Images Using Robust Multitask Feature Extraction Method and Convolutional Neural Network (CNN)”, Oct. 2021, doi: 10.1155/2021/5514839.
- [95] J. Islam and Y. Zhang, “GAN-based synthetic brain PET image generation”, vol.7, no.1, p.3, Oct.2020, doi: 10.1186/s40708-020-00104-2.
- [96] S. Basaia, “Automated classification of Alzheimer's disease and mild cognitive impairment using a single MRI and deep neural networks”, vol. 21, p. 101645, Oct. 2019, doi: 10.1016/j.nicl.2018.101645.
- [97] A. Abrol, M. Bhattarai, A. Fedorov, Y. Du, S. Plisand V. Calhoun, “Deep Residual Learning for Neuroimaging: An application to Predict Progression to Alzheimer's Disease”, vol. 339, p. 108701, Apr. 2020, doi: 10.1016/j.neumeth.2020.108701.
- [98] M. Hon, N. M. Khan, “Towards Alzheimer's disease classification through transfer learning”, pp. 1166--1169, Oct. 2017, doi: 10.1109/BIBM.2017.8217822.Su,
- [99] M.-H. Su, C.-H. Wu, K.-Y. Huang, Q.-B. Hongand H.-. min . Wang, “Exploring microscopic fluctuation of facial expression for mood disorder classification”, pp. 65–69, Dec. 2017, doi: 10.1109/ICOT.2017.8336090.
- [100] A. Dawood, S. Turnerand P. Perepa, “Affective Computational Model to Extract Natural Affective States of Students With Asperger Syndrome (AS) in Computer-Based Learning Environment”, vol. PP, pp. 1–1, Nov. 2018, doi: 10.1109/ACCESS.2018.2879619.
- [101] S. Harati, A. Crowell, H. Maybergand S. Nemati, “Depression Severity Classification from Speech Emotion”, Oct. 2018, doi:10.1109/EMBC .2018.8513610.
- [102] M. H. Su, C. H. Wu, K. Y. Huangand T. H. Yang, “Cell-Coupled Long Short-Term Memory With L -Skip Fusion Mechanism for Mood Disorder Detection Through Elicited Audiovisual Features”, vol. 31, no. 1, pp. 124–135, Oct. 2020, doi: 10.1109/TNNLS.2019.2899884.
- [103] A. Kacem, Z. Hammal, M. Daoudiand J. Cohn, “Detecting Depression Severity by Interpretable Representations of Motion Dynamics”, May 2018, doi: 10.1109/FG.2018.00116.
- [104] F. Yin, J. Du, X. Xuand L. Zhao, “Depression Detection in Speech Using Transformer and Parallel Convolutional Neural Networks”, vol. 12, no. 2, p. 328, Oct. 2023, doi: 10.3390/electronics12020328.
- [105] F. Makhmudov, A. Kutlimuratov, F. Akhmedov, M. S. Abdallahand Y.-I. Cho, “Modeling Speech Emotion Recognition via Attention-Oriented Parallel CNN Encoders”, vol. 11, no. 23, p. 4047, Oct. 2022, doi: 10.3390/electronics11234047.
- [106] G. Coppersmith, R. Leary, P. Crutchleyand A. Fine, vol. 10, Oct. 2018, doi: <https://doi.org/10.1177/1178222618792860>.
- [107] J. Du, “Extracting psychiatric stressors for suicide from social media using deep learning”, vol. 18, no. Suppl 2, p. 43, Oct. 2018, doi: 10.1186/s12911-018-0632-8.
- [108] B. J. Ricard, L. A. Marsch, B. Crosierand S. Hassanpour, “Exploring the Utility of Community-Generated Social Media Content for Detecting Depression: An Analytical Study on Instagram”, vol. 20, no. 12, p. e11817, Oct. 2018, doi: <https://doi.org/10.2196/11817>.
- [109] Y. Lin, “A deep learning-based model for detecting depression in senior population”, vol. 13, Oct. 2022, doi: 10.3389/fpsy.2022.1016676.
- schizophrenia from EEG signals”, vol. 43, no. 4, pp. 1229–1239, Oct. 2020, doi: 10.1007/s13246-020-00925-9.
- [74] V. Arun, V. Prajwal, M. Krishna, B. Arunkumar, S. Padmaand S. Vasudevarao, “A Boosted Machine Learning Approach For Detection of Depression”, pp. 41–47, Nov. 2018, doi: 10.1109/SSCI.2018.8628945.
- [75] S. B. Choi, W. Lee, J. H. Yoon, J. U. Wonand D. W. Kim, “Ten-year prediction of suicide death using Cox regression and machine learning in a nationwide retrospective cohort study in South Korea”, vol. 231, pp. 8–14, Oct. 2018, doi: 10.1016/j.jad.2018.01.019.
- [76] A. Malafeev, A. Hertig-Godeschalk, D. R. Schreier, J. Skorucak, J. Mathisand P. Achermann, “Automatic Detection of Microsleep Episodes With Deep Learning”, vol. 15, Oct. 2021, doi: 10.3389/fnins.2021.564098.
- [77] C. Uyulan, “Major Depressive Disorder Classification Based on Different Convolutional Neural Network Models: Deep Learning Approach”, vol. 52, no. 1, pp. 38–51, Oct. 2021, doi: 10.1177/1550059420916634.
- [78] A. Vahid, A. Bluschke, V. Roessner, S. Stoberand C. Beste, “Deep Learning Based on Event-Related EEG Differentiates Children with ADHD from Healthy Controls”, vol. 8, no. 7, p. 1055, Oct. 2019, doi: 10.3390/jcm8071055.
- [79] Y. Xie, “Anxiety and Depression Diagnosis Method Based on Brain Networks and Convolutional Neural Networks”, pp. 1503–1506, Oct. 2020, doi: 10.1109/EMBC44109.2020.9176471.
- [80] X. Zhang, “EEG-based Depression Detection Using Convolutional Neural Network with Demographic Attention Mechanism”, pp. 128–133, Oct. 2020, doi: 10.1109/EMBC44109.2020.9175956.
- [81] H. Zhang, F. H. S. Silva, E. F. Ohata, A. G. Medeirosand P. P. Rebouças Filho, “Bi-Dimensional Approach Based on Transfer Learning for Alcoholism Pre-disposition Classification via EEG Signals”, vol. 14, p. 365, Oct. 2020, doi: 10.3389/fnhum.2020.00365.
- [82] X. Deng, X. Fan, X. Lvand K. Sun, “SparNet: A Convolutional Neural Network for EEG Space-Frequency Feature Learning and Depression Discrimination”, vol. 16, p. 914823, Jun. 2022, doi: 10.3389/fninf.2022.914823.
- [83] P. Sandheep, S. Vineeth, M. Poulouseand S. D. Puthankattil, “Performance analysis of deep learning CNN in classification of depression EEG signals”,pp.1339–1344,Oct.2019, doi: 10.1109/TENCON.2019.8929254.
- [84] H. Jebelli, M. Khaliliand S. Lee, “Mobile EEG-based Workers' Stress Recognition by Applying Deep Neural Network”, pp. 173–180, Oct. 2018.
- [85] T. Matsubara, T. Tashiroand K. Uehara, “Deep Neural Generative Model of Functional MRI Images for Psychiatric Disorder Diagnosis”, vol. 66, no. 10, pp. 2768–2779, Oct. 2019, doi: 10.1109/TBME.2019.2895663.
- [86] W. H. L. Pinaya, A. Mechelliand J. R. Sato, “Using deep autoencoders to identify abnormal brain structural patterns in neuropsychiatric disorders: A large-scale multi-sample study”, vol. 40, no. 3, pp. 944–954, Oct. 2019, doi: 10.1002/hbm.24423.
- [87] A. Khan and K. Wang, “A deep learning based scoring system for prioritizing susceptibility variants for mental disorders”, pp. 1698–1705, Nov. 2017, doi: 10.1109/BIBM.2017.8217916.
- [88] J. Zhou, L. Hu, Y. Jiangand L. Liu, “A Correlation Analysis between SNPs and ROIs of Alzheimer's Disease Based on Deep Learning”, vol. 2021, pp. 1–13, Feb. 2021, doi: 10.1155/2021/8890513.
- [89] C. Park, J. Haand S. Park, “Prediction of Alzheimer's Disease Based on Deep Neural Network by Integrating Gene Expression and DNA Methylation Dataset”, vol. 140, p. 112873, Aug. 2019, doi: 10.1016/j.eswa.2019.112873.
- [90] T. Shen, “Predicting Alzheimer Disease From Mild Cognitive Impairment With a Deep Belief Network Based on 18F-FDG-PET Images”, vol. 18, p. 1536012119877285, Oct. 2019, doi: 10.1177/1536012119877285.
- [91] N. T. Duc, S. Ryu, M. N. I. Qureshi, M. Choi, K. H. Leeand B. Lee, “3D-Deep Learning Based Automatic Diagnosis of Alzheimer's Disease with Joint MMSE Prediction Using Resting-State fMRI”, vol.18, no.1, pp. 71–86, Oct. 2020, doi: 10.1007/s12021-019-09419-w.
- [92] F. Ramzan, “A Deep Learning Approach for Automated Diagnosis and Multi-Class Classification of Alzheimer's Disease Stages Using Resting-State fMRI and Residual Neural Networks”, vol. 44, Dec. 2019, doi: 10.1007/s10916-019-1475-2.
- [93] E. Altinkaya, K. Polatand B. Barakli, “Detection of Alzheimer's Disease and Dementia States Based on Deep Learning from MRI Images: A

کنفرانس ملی هوش مصنوعی و مهندسی نرم افزار Ai-SOFT 2023

پیوست - خلاصه‌ای از مطالعات انجام شده در حوزه هوش مصنوعی و سلامت‌روان به تفکیک نوع داده

نویسندگان (سال)	نتایج	داده	مدل	هدف	توضیحات
داده‌های بالینی					
آچاربا وهمکاران 2018 [57]	ACC= 0.96	سیگنالهای مغزی EEG Signals	CNN	تشخیص افسردگی	استفاده از داده‌های بالینی
آی و همکاران 2019 [58]	ACC= 0.99	سیگنالهای مغزی	LSTM	تشخیص افسردگی	استفاده از داده‌های بالینی
بلن و همکاران 2020 [59]	ACC= 0.72	سیگنالهای مغزی	DCNN - stack of 3 autoencoders	تشخیص ترس	استفاده از داده‌های بالینی
بای و همکاران 2019 [60]	ACC= 0.95	سیگنالهای مغزی	Conv. Deep Boltzmann Machine	اختلال شناختی خفیف	استفاده از داده‌های بالینی
چن و همکاران 2019 [61]	ACC= 0.95	سیگنالهای مغزی	3D CNN DL	اختلال کمبود توجه و بیش فعالی	استفاده از داده‌های بالینی
چوو و همکاران 2018 [62]	ACC= 0.99	سیگنالهای مغزی	CNN,RNN,ANN	شیزوفرنی	استفاده از داده‌های بالینی
دوبروی وال همکاران 2020 [63]	ACC= 0.88	سیگنالهای مغزی	CNN	اختلال کمبود توجه و بیش فعالی	استفاده از داده‌های بالینی
کیم و همکاران 2018 [64]	ACC=0.75	سیگنالهای مغزی	CNN,RNN,DNN	الکل، اختلال شناختی خفیف	استفاده از داده‌های بالینی
لی و همکاران 2019 [65]	ACC= 0.85	سیگنالهای مغزی	1D CNN- 2D CNN	تشخیص افسردگی	استفاده از داده‌های بالینی
لی و همکاران 2020 [66]	ACC= 0.81	سیگنالهای مغزی	CNN	تشخیص افسردگی خفیف	استفاده از داده‌های بالینی
مقدری و همکاران 2020 [67]	ACC= 0.98	سیگنالهای مغزی	CNN	اختلال کمبود توجه و بیش فعالی	استفاده از داده‌های بالینی
مورابیتو و همکاران 2017 [68]	ACC= 0.89	سیگنالهای مغزی	stacked autoencoder	زوال عقل	استفاده از داده‌های بالینی
ممتاز و خیوم 2019 [69]	ACC= 0.98	سیگنالهای مغزی	LSTM & 1D CNN	تشخیص افسردگی	استفاده از داده‌های بالینی
اوو و همکاران 2019 [70]	ACC= 0.81	سیگنالهای مغزی	CNN	شیزوفرنی	استفاده از داده‌های بالینی
پانگ و همکاران 2019 [71]	ACC= 0.92	سیگنالهای مغزی	1D CNN- 2D CNN	شیزوفرنی	استفاده از داده‌های بالینی
شاهین و همکاران 2017 [72]	ACC= 0.92	سیگنالهای مغزی	DLM(Deep Learning Model)	اختلال خواب- بی خوابی	استفاده از داده‌های بالینی
شالیاف و همکاران 2020 [73]	ACC= 0.99	سیگنالهای مغزی	ReNet	شیزوفرنی	استفاده از داده‌های بالینی
آرون و همکاران 2018 [74]	ACC=0.98	EHR	SML	پیش‌بینی افسردگی	استفاده از داده‌های بالینی
چوی و همکاران 2018 [75]	ACC=0.72	EHR	SML+DL	پیش‌بینی احتمال مرگ بعلت خودکشی	داده‌های بالینی (سوابق الکترونیک بیمار)
اسکروکاک و همکاران 2020 [76]	ACC= 0.98	سیگنالهای مغزی	LSTM	اختلال خواب	استفاده از داده‌های بالینی
ایولان و همکاران 2020 [77]	ACC= 0.93	سیگنالهای مغزی	ResNet-,MobileNet,Inception3	تشخیص افسردگی	استفاده از داده‌های بالینی
وحید و همکاران 2019 [78]	ACC= 0.83	سیگنالهای مغزی	EEGNet	اختلال کمبود توجه و بیش فعالی در کودکان	استفاده از داده‌های بالینی
ژی و همکاران 2020 [79]	ACC= 0.68	سیگنالهای مغزی	CNN	اختلال افسردگی - اضطراب و نگرانی	استفاده از داده‌های بالینی
ژانگ و همکاران 2020 [80]	ACC= 0.75	داده‌های بالینی و سیگنالهای مغزی	CNN + Attention	افسردگی	استفاده از داده‌های بالینی
ژانگ، سیلوا همکاران 2020 [81]	ACC= 0.95	داده‌های بالینی و سیگنالهای مغزی	CNN + Attention, Mobilenet	تشخیص خودکار بیماران مبتلا به اعتیاد به الکل	استفاده از داده‌های بالینی
ون و همکاران 2020 [82]	ACC=79.8	سیگنالهای مغزی	Hybrid EEGNet	تشخیص افسردگی دوقطبی	استفاده از داده‌های بالینی
سندھیپ و همکاران 2020 [83]	ACC=99.3	سیگنالهای مغزی	3DCNN	تشخیص افسردگی	استفاده از داده‌های بالینی
جیلی و همکاران 2020 [84]	ACC=86.62	سیگنالهای مغزی	CNN+FCNN	تشخیص افسردگی	استفاده از داده‌های بالینی
ماتسوپورا و همکاران 2019 [85]	ACC = 0.766	fMRI	DFNN	تشخیص اختلالات روان	استفاده از داده‌های بالینی (تصاویر ام. آر. آی.)
پینایا و همکاران 2019 [86]	ACC = 0.639 to 0.707	sMRI	Autoencoder	تشخیص اختلالات روان مانند شیزوفرنی و اوتیسم	شناسایی الگوهای ساختاری غیر طبیعی در مغز از طریق روش غیر تهاجمی تصویربرداری مغزی

کنفرانس ملی هوش مصنوعی و مهندسی نرم افزار Ai-SOFT 2023

داده‌های ژنتیک					
	شناسایی انواع غیرکدکننده مرتبط با اختلالات روان	DFNN	توالی ژنوم	ACC = 0.82	خان و ونگ 2018 [87]
	پیش‌بینی ریسک آلزایمر	CNNs	SNPs, MRI	-	ژوو و همکاران 2021 [88]
	پیش‌بینی ریسک آلزایمر	FNNs	بیان ژن، متیلاسیون DNA	AUC = 0.797	پارک و همکاران 2020 [89]
استفاده از روش تهاجمی	تمایز اختلال شناختی خفیف از الزایمر	DBNs	PET	ACC = 0.866	شن و همکاران 2019 [90]
استفاده از روش غیرتهاجمی	تشخیص الزایمر	3D CNN	تصویربرداری عصبی	ACC=0.85	دوک و همکاران 2020 [91]
استفاده از روش غیرتهاجمی	تشخیص الزایمر	CNN-ResNet	تصویربرداری عصبی	ACC=0.98	رمضان و همکاران 2020 [92]
استفاده از روش غیرتهاجمی	تشخیص الزایمر	CNN	تصویربرداری عصبی	ACC=1.00	التینکایا و همکاران 2020 [93]
استفاده از روش غیرتهاجمی	تشخیص الزایمر	CNN	تصویربرداری عصبی	ACC=0.97	امینی و همکاران 2021 [94]
استفاده از روش تهاجمی	الزایمر	3DCNN	تصویربرداری عصبی	ACC=0.89	اسلام و همکاران 2019 [95]
	الزایمر	3DCNN+LocalTransferLearning	نشانه‌های زیستی تصویربرداری عصبی	ACC=0.98	باسایا و همکاران 2019 [96]
	تشخیص الزایمر	3D CNN+DeepResNet	نشانه‌های زیستی تصویربرداری عصبی	ACC=0.91	ابرل و همکاران 2020 [97]
	تشخیص الزایمر	Inception V4+ALexNet	نشانه‌های زیستی تصویربرداری عصبی	ACC=0.96	هان و همکاران 2017 [98]
داده‌های صوتی و بصری					
استفاده از داده‌های بصری	طبقه‌بندی اختلالات خلقی	LSTM+autoencoder	داده‌های بصری	ACC = 0.677	سو و همکاران 2017 [99]
CNN برای یادگیری حالت چهره	تشخیص احساس	CNN+LSTM	داده‌های بصری جمع آوری شده با وب کم	ACC = 0.90	داوود و همکاران 2018 [100]
	پیش‌بینی شدت افسردگی	LSTM	صوت مصاحبه‌ها در طول درمان	AUC = 0.80	هراتی و همکاران 2018 [101]
تشخیص اشتباه (اختلال دوقطبی به عنوان اختلال تک قطبی)	پیش‌بینی روند اختلال خلقی	Autoencoder+LSTM	داده‌های صوتی و بصری	ACC = 0.692	سوو و همکاران 2019 [102]
	پیش‌بینی شدت افسردگی	SML	داده‌های بصری	ACC=0.84	کاسم و همکاران 2018 [103]
	تشخیص depression	Transformer+CNN	داده‌های صوت	UAC=84-93	بن و همکاران 2023 [104]
	تشخیص احساس	CNN+attention	داده صدا IEMOCAP- EMO-DB	Avg.Acc=90	مخمودوفو همکاران 2022 [105]
داده‌های متنی					
	پیش‌بینی ریسک خودکشی	LSTM	پست‌های خوداظهاری در شبکه‌های اجتماعی	AUC = 0.94	کوپراسمیت و مکاران 2018 [106]
ترکیب دو مدل نتایج بهتری را بدست می‌دهد	شناسایی عوامل استرس زای مرتبط با خودکشی	CNN+RNN	پست های توئیتر	ACC 0.74	دوو و همکاران 2018 [107]
استفاده از داده‌های متنی	پیش‌بینی افسردگی	Elastic-net	داده‌های متنی از پست‌های اینستاگرام	AUC=0.71	ریچاردو همکاران 2018 [108]
استفاده از ترکیب داده‌های متنی و صدا	تشخیص افسردگی	BiLSTM + 1D CNN	متن و صدا	F1 Score= 0.85, Recall=0.92, Precision=0.72	لین و همکاران، 2020 [109]

MDD= Major Depressive Disorder; DBNs = Deep belief networks;