



مروری بر رویکردهای هوش مصنوعی در تشخیص اختلال بیش فعالی و نقص توجه

طاهره ضیاءالدینی^(۱) محبوبه هوشمند^(۲) سید عابد حسینی^{(۳)*}

(۱) گروه مهندسی کامپیوتر، واحد مشهد، دانشگاه آزاد اسلامی، مشهد، ایران

(۲) گروه مهندسی کامپیوتر، واحد مشهد، دانشگاه آزاد اسلامی، مشهد، ایران

(۳) گروه مهندسی برق، واحد مشهد، دانشگاه آزاد اسلامی، مشهد، ایران*

(تاریخ دریافت: ۱۴۰۳/۰۵/۰۲ تاریخ پذیرش: ۱۴۰۳/۰۶/۰۵)

چکیده

نقص توجه بیش فعالی (ADHD) یک اختلال رفتاری-عصبی شایع در کودکان و نوجوانان است که توجه محدود، بیش فعالی و تکانش گری را به همراه دارد. تشخیص دقیق و به موقع این اختلال بسیار مهم است تا بتوان مداخلات مناسب درمانی را ارائه داد. در این میان، رویکردهای مبتنی بر هوش مصنوعی می توانند نقش مهمی در بهبود و تسریع فرآیند تشخیص ایفا کنند. این پژوهش به بررسی استفاده از فناوری های هوش مصنوعی در تشخیص ADHD می پردازد. بدین منظور ابتدا به معرفی ویژگی های بالینی و چالش های موجود در تشخیص ADHD پرداخته می شود، سپس انواع رویکردهای هوش مصنوعی مانند یادگیری ماشین، پردازش زبان طبیعی و یادگیری عمیق در این زمینه بررسی می شوند. همچنین مطالعه های موردی و نتایج تجربی استفاده از این فناوری ها مرور می شوند. در نهایت چالش ها و محدودیت های موجود و همچنین چشم انداز آینده پژوهش ها در این حوزه مورد بحث قرار می گیرند. این پژوهش مروری بر آخرین پیشرفت های علمی در استفاده از هوش مصنوعی برای تشخیص ADHD ارائه می دهد و می تواند به عنوان یک منبع برای متخصصان بالینی و پژوهشگران این حوزه مورد استفاده قرار گیرد.

کلمات کلیدی: اختلال نقص توجه بیش فعالی، هوش مصنوعی، یادگیری ماشین، یادگیری عمیق

*عهده دار مکاتبات:

سید عابد حسینی

نشانی: گروه مهندسی برق، واحد مشهد، دانشگاه آزاد اسلامی، مشهد، ایران

پست الکترونیکی: abed_hosseyni@yahoo.com

نقص توجه بیش‌فعالی (ADHD)¹ یکی از شایع‌ترین و آسیب‌زاترین اختلال‌های رفتاری-عصبی در کودکان و نوجوانان است که با علائمی همچون توجه محدود، بیش‌فعالی و تکانش‌گری مشخص می‌شود [1]. ADHD می‌تواند پیامدهای منفی جدی بر عملکرد تحصیلی، شغلی و اجتماعی فرد داشته باشد و در صورت عدم شناسایی و درمان مناسب، تأثیرات طولانی‌مدت آن بر زندگی فرد غیرقابل‌انکار است [2]. در حال حاضر، این بیماری ۵ درصد از کل جمعیت کودکان را تحت تأثیر قرار می‌دهد که باعث اختلال در دوران کودکی آن‌ها می‌شود و ۷۰ درصد آن‌ها را در بزرگسالی و میزان بالاتری از بیماری‌های دیگر همراه می‌کند [3]. به‌طور کلی، اختلال‌های روانی مانند افسردگی، اضطراب، یادگیری، و سواس فکری عملی و سایر مشکل‌های مربوط به یادگیری برخی از اختلال‌های همراه هستند؛ بنابراین تشخیص به‌موقع و درست ADHD یا پرهیز از تشخیص‌های کاذب از دغدغه‌های جدی بسیاری از بالینگران حرفه‌ای است تا مداخله‌های مناسب در زمان مناسب انجام شود [2].

با توجه به اهمیت تشخیص به‌موقع و درست ADHD، شناسایی راهکارهای نوین برای بهبود فرایند تشخیص از اولویت بالایی برخوردار است. فرآیند تشخیص سنتی ADHD که بر اساس مصاحبه‌های بالینی، نظرسنجی از والدین و معلمان و مشاهده‌های رفتاری انجام می‌شود، با چالش‌هایی همچون سوگیری ارزیاب، عدم دسترسی به اطلاعات جامع و هزینه‌بر بودن مواجه است [4]. در این راستا، استفاده از فناوری‌های هوش مصنوعی می‌تواند نقش مهمی در بهبود و تسریع فرایند تشخیص ADHD ایفا کند [5], [6], [7]. رویکردهای مبتنی بر هوش مصنوعی مانند یادگیری ماشین، پردازش زبان طبیعی (NLP)² و یادگیری عمیق، می‌توانند به شناسایی الگوهای پیچیده در داده‌های بالینی، شناختی و رفتاری مرتبط با ADHD کمک کنند و در نتیجه به تشخیص دقیق‌تر و سریع‌تر منجر شوند [3], [5], [6], [7], [8], [9], [10], [11], [12], [13], [14].

هوش مصنوعی به‌طور کلی به مجموعه فناوری‌هایی گفته می‌شود که به‌منظور انجام وظایف هوشمندانه و خودکار طراحی شده‌اند [15]. این فناوری‌ها سعی دارند با الگوبرداری از فرآیندهای ذهنی انسان، توانایی‌های شناختی مشابه را در ماشین‌ها پیاده‌سازی کنند [16]. یکی از رویکردهای اصلی هوش مصنوعی، یادگیری ماشین است. در این رویکرد، سیستم‌های هوش مصنوعی با تحلیل حجم عظیمی از داده‌ها، الگوها و قوانین را کشف می‌کنند و از این طریق

¹ Attention-Deficit Hyperactivity Disorder

² Natural Language Processing

توانایی‌های خود را افزایش می‌دهند [17]. این رویکرد به ماشین‌ها امکان می‌دهد تا بدون برنامه‌ریزی صریح، مسائل را حل کنند و پیش‌بینی‌هایی انجام دهند [10].

همچنین هوش مصنوعی می‌تواند در طراحی ابزارهای ارزیابی و غربالگری ADHD مفید باشد [18]. این ابزارها با استفاده از روش‌های NLP یا تحلیل رفتاری، می‌توانند به صورت خودکار به ارزیابی علائم مرتبط با ADHD بپردازند. علاوه بر این، هوش مصنوعی در طراحی مداخلات درمانی سفارشی شده برای افراد مبتلا به ADHD نیز می‌تواند کاربرد داشته باشد [19]. با تحلیل داده‌های فردی، این سیستم‌ها می‌توانند برنامه‌های درمانی را متناسب با نیازهای هر بیمار تنظیم کنند. در مجموع هوش مصنوعی با ارائه ابزارهای تشخیصی دقیق‌تر و مداخلات درمانی شخصی‌سازی شده، نقش مهمی در بهبود مدیریت و درمان اختلالات عصبی مانند ADHD ایفا می‌کند [18].

رویکرد هوش مصنوعی در تشخیص ADHD دارای اهمیت به سزایی است. یکی از مهم‌ترین مزایای این رویکرد، صحت تشخیصی بالاتر است [20]. الگوریتم‌های یادگیری ماشینی قادرند الگوهای خاصی را در داده‌های بالینی مرتبط با ADHD، مانند رفتار، عملکرد شناختی و فعالیت مغزی، شناسایی کنند. این امر به تشخیص دقیق‌تر این اختلال کمک می‌کند و در مقایسه با روش‌های سنتی مبتنی بر مصاحبه و پرسش‌نامه، بسیار مفید است [21]. [22]

همچنین هوش مصنوعی می‌تواند با پردازش داده‌های موجود، علائم ADHD را در مراحل اولیه شناسایی کند [23]. این به معنای امکان مداخله‌های درمانی زودهنگام و پیشگیری از عوارض بالقوه است؛ بنابراین، رویکرد هوش مصنوعی می‌تواند به تشخیص زودهنگام ADHD کمک کند [24], [23]. علاوه بر این، تحلیل داده‌های فردی با استفاده از هوش مصنوعی، امکان طراحی مداخلات درمانی متناسب با نیازهای هر بیمار را فراهم می‌آورد [25]. این رویکرد درمانی شخصی‌سازی شده، مؤثرتر از درمان‌های استاندارد است و می‌تواند به بهبود کیفیت زندگی بیماران کمک کند [26]. همچنین با ارائه ابزارهای تشخیصی دقیق و برنامه‌های درمانی سفارشی شده، هوش مصنوعی به مدیریت بهتر ADHD کمک می‌کند. این امر در نهایت به ارتقای کیفیت زندگی بیماران منجر می‌شود [12].

در نهایت داده‌های غنی‌تری که توسط سیستم‌های هوش مصنوعی جمع‌آوری می‌شود، می‌تواند به توسعه مطالعات و پژوهش‌های بالینی در زمینه ADHD کمک کند. در مجموع، رویکرد هوش مصنوعی با ارائه ابزارهای تشخیصی و درمانی پیشرفته، نقش مهمی در بهبود فرآیند تشخیص و مدیریت ADHD ایفا می‌کند [27], [28].

این پژوهش با هدف بررسی و ارزیابی روش‌های مبتنی بر رویکردهای هوش مصنوعی برای تشخیص ADHD تهیه شده است. در این راستا، مطالعه‌های انجام‌شده در این زمینه از سال ۲۰۱۹ تا ۲۰۲۴ به ترتیب سال انتشار مورد

مرور و تحلیل قرار می‌گیرند. عمده مقاله‌های بررسی‌شده در این پژوهش، مقاله‌های انگلیسی‌زبان مستخرج از مجله‌های معتبر هستند که از پایگاه‌های گوگل اسکالر و اسکوپوس جمع‌آوری شده‌اند.

این مقاله به مرور استفاده از رویکردهای هوش مصنوعی در تشخیص ADHD می‌پردازد. بدین منظور ابتدا به معرفی ویژگی‌های بالینی و چالش‌های موجود در تشخیص ADHD می‌پردازد. سپس، انواع رویکردهای هوش مصنوعی مورد استفاده در این زمینه را مورد بررسی قرار می‌دهد و مطالعه‌های موردی و نتایج تجربی استفاده از این فناوری‌ها را مرور می‌کند. در نهایت چالش‌ها و محدودیت‌های موجود و همچنین چشم‌انداز آینده پژوهش‌ها در این حوزه مورد بحث قرار می‌گیرد.

۲- پیشینه نظری پژوهش

ADHD مشکلی عصب‌شناختی است که با مهارت‌های توجهی نامناسب، تکانش‌گری و در برخی از موارد توأم با بیش‌فعالی مشخص می‌گردد [2]. بررسی پیشینه نظری این موضوع مطالعات متعددی را نشان می‌دهد که به بررسی مکانیسم‌های عصب‌شناختی و عصب‌روان‌شناختی ADHD پرداخته‌اند. شواهد تجربی نشان می‌دهند که ADHD با اختلال در عملکرد برخی مناطق مغزی نظیر قشر پیش‌پیشانی، هسته‌های قاعده‌ای و مخچه مرتبط است [9]. این نواحی مغزی نقش مهمی در توجه، تنظیم هیجان، بازداری پاسخ و کنترل حرکتی ایفا می‌کنند و اختلال در آنها می‌تواند به بروز نشانه‌های اصلی ADHD منجر شود [3]. همچنین نقص در سیستم‌های نوروشیمیایی مغز از جمله سیستم‌های دوپامینرژیک و نورآدرنرژیک نیز در پاتوژنز ADHD نقش دارند [29]. این سیستم‌ها در تنظیم توجه، هیجان و کنترل حرکتی دخیل هستند و اختلال در عملکرد آنها می‌تواند به‌ویژه در دوره رشد و تکامل مغز، به بروز نشانه‌های ADHD منجر شود [30]. عوامل ژنتیکی و محیطی نیز در بروز و شدت ADHD نقش مؤثری ایفا می‌کنند [24].

۲-۱- معیارهای تشخیص ADHD

به‌طور کلی کتابچه راهنمای تشخیصی و آماری اختلال‌های روانی سه نوع را بر اساس علائم اصلی طبقه‌بندی می‌کند [24]:

- **عمدتاً بی توجه:** این نوع ADHD با مشکلات در تمرکز و توجه پایدار مشخص می‌شود. افراد مبتلا به این نوع اغلب در گوش دادن به صحبت‌های دیگران مشکل دارند، در تکالیف روزمره مرتکب اشتباهات غیرضروری می‌شوند و در سازمان‌دهی و تکمیل کارها دچار چالش هستند. آن‌ها همچنین ممکن است فراموش کار به نظر برسند [24], [30].

- **عمدتاً بیش فعال- تکانشی:** این نوع ADHD با عدم توانایی کنترل تکانه‌ها و رفتارهای بیش‌ازحد فعالانه مشخص می‌شود. افراد مبتلا به این نوع دچار بی‌قراری و تحرک بیش از اندازه هستند، به سختی قادر به نشستن در یک مکان هستند و اغلب بدون فکر قبلی دست به اقداماتی می‌زنند. آن‌ها همچنین مشکلاتی در کنترل رفتار، کلام و هیجانات خود دارند [24], [30], [31].

- **ترکیبی:** این نوع ADHD شامل ویژگی‌های هر دو نوع بیش‌فعال-تکانشی و بی‌توجه است. افراد مبتلا به این نوع هم دچار مشکلات توجهی و هم مشکلات تکانشی و بیش‌فعالی هستند [24], [30].

- هر یک از این انواع ADHD می‌تواند با شدت‌های متفاوت در افراد بروز کند و بر سطوح مختلف عملکرد آن‌ها تأثیر بگذارد. تشخیص دقیق نوع ADHD حائز اهمیت است، زیرا مداخلات درمانی و آموزشی متناسب با هر نوع متفاوت خواهد بود [24].

۲-۲- ابزارهای متداول تشخیص ADHD

یکی از ابزارهای متداول در تشخیص ADHD، استفاده از سیگنال‌های الکتروانسفالوگرافی (EEG)¹ است. EEG یک روش غیرتهاجمی است که فعالیت الکتریکی مغز را با استفاده از الکترودهایی که بر روی سر قرار می‌گیرند، ثبت می‌کند [32]. در افراد مبتلا به ADHD، الگوهای خاصی در این سیگنال‌ها مشاهده می‌شود که می‌تواند به تشخیص کمک کند. به‌طور خاص، افراد مبتلا به ADHD معمولاً دچار اختلال در آلفا، بتا و تتا امواج مغزی هستند [33]. امواج آلفا با توجه و بازداری پاسخ مرتبط هستند و در این بیماران، ممکن است دچار کاهش باشند. همچنین امواج بتا که با توجه و تحرک فعال مرتبط هستند، در این بیماران ممکن است افزایش یابند [34]. به‌علاوه، امواج تتا که با خواب و آرامش مرتبط هستند، در این بیماران ممکن است افزایش یابند. این الگوهای خاص امواج مغزی می‌تواند به‌عنوان نشانه‌های بیولوژیکی ADHD مورد استفاده قرار گیرد [33], [35], [36], [37], [38], [39].

¹ Electroencephalogram

علاوه بر EEG، تصویربرداری تشدید مغناطیسی (MRI) نیز یکی دیگر از ابزارهای رایج در تشخیص ADHD است [40]. MRI یک روش غیرتهاجمی است که به صورت سه بعدی ساختار و عملکرد مغز را نمایش می‌دهد [41]. در افراد مبتلا به ADHD، تغییراتی در حجم و فعالیت برخی مناطق مغزی مشاهده می‌شود [42]. به طور خاص، مطالعه‌ها نشان داده‌اند که در بیماران ADHD، حجم قشر پیش‌پیشانی، هیپوکامپ و سایر مناطق مهم در تنظیم توجه و کنترل حرکتی ممکن است کاهش یابد [36]. همچنین فعالیت مناطق مغزی مرتبط با توجه و کنترل بازداری در این بیماران ممکن است دچار اختلال باشد. این تغییرات ساختاری و عملکردی مغز می‌تواند به عنوان نشانگرهای تصویربرداری برای تشخیص ADHD مورد استفاده قرار گیرد [12].

در مجموع روش‌های EEG و MRI به عنوان ابزارهای غیرتهاجمی و قابل اطمینان در تشخیص ADHD نقش مهمی ایفا می‌کنند. این ابزارها قادرند الگوهای عصبی خاص مرتبط با ADHD را شناسایی کنند و به ارائه تشخیص دقیق‌تر و درک بهتر از مکانیسم‌های زیربنایی آن کمک کنند [36], [37].

۳- الگوریتم‌های پرکاربرد هوش مصنوعی در تشخیص ADHD

پیشرفت‌های اخیر در زمینه هوش مصنوعی و رویکردهای آن، امیدهای تازه‌ای را برای تشخیص دقیق‌تر و عینی‌تر ADHD ایجاد کرده است. رویکردهای هوش مصنوعی توانایی استخراج الگوهای پیچیده از داده‌های ورودی را دارند و می‌توانند در شناسایی ویژگی‌های مرتبط با ADHD در داده‌های عصبی-شناختی، تصویربرداری مغزی و غیره کمک شایانی کنند [44], [43]. استفاده از این فناوری‌های نوین می‌تواند به تشخیص سریع‌تر، دقیق‌تر و عینی‌تر ADHD در مقایسه با روش‌های سنتی منجر شود؛ بنابراین در ادامه به معرفی پرکاربردترین رویکردهای هوش مصنوعی در تشخیص ADHD و ارزیابی پیشرفت‌های حاصل شده در این زمینه خواهیم پرداخت.

۳-۱- الگوریتم‌های یادگیری ماشین

یادگیری ماشین یکی از شاخه‌های هوش مصنوعی است که به طور گسترده در زمینه تشخیص و پیش‌بینی اختلالات روانی مورد استفاده قرار می‌گیرد. الگوریتم‌های یادگیری ماشین با استفاده از داده‌های گسترده و الگوهای موجود در آن‌ها، می‌توانند الگوهای پیچیده و پنهان را کشف کنند و بر اساس آن، تشخیص دقیقی از وضعیت فرد ارائه دهند [45]. [46]. این الگوریتم‌ها می‌توانند با تحلیل داده‌هایی مانند سوابق پزشکی، پاسخ‌های روان‌شناختی، الگوهای رفتاری و

¹ Magnetic Resonance Imaging

فعالیت مغزی، الگوهای منحصربه‌فرد ADHD را شناسایی کنند. آن‌ها می‌توانند با صحت بالا، بیماران دارای ADHD را از افراد سالم تشخیص دهند و حتی میزان شدت آن را پیش‌بینی کنند [10].

همچنین این الگوریتم‌ها قادر هستند که با ترکیب داده‌های مختلف، به درک عمیق‌تری از عوامل زیربنایی ADHD دست یابند. آن‌ها می‌توانند به شناسایی زیرگروه‌های متفاوت ADHD کمک کنند و راهکارهای درمانی متناسب با هر زیرگروه را پیشنهاد دهند. این امر می‌تواند به بهبود پیامدهای درمانی و کاهش هزینه‌های مرتبط با تشخیص و درمان منجر شود [11].

۳-۱-۱- ماشین بردار پشتیبان (SVM)^۱

SVM یکی از الگوریتم‌های یادگیری ماشینی پرکاربرد در حوزه تشخیص اختلالات روانی از جمله ADHD است. این الگوریتم با استفاده از اصول هندسی و مفاهیم فضای ویژگی، قادر به انجام تشخیص دقیق و قدرتمند است. SVM با دریافت داده‌های مربوط به بیماران، مانند سوابق پزشکی، نتایج آزمون‌های روان‌شناختی و الگوهای رفتاری، می‌تواند الگوهای منحصربه‌فرد ADHD را استخراج کند. این الگوریتم با ترسیم یک *siperplane* یا مرز تصمیم‌گیری در فضای ویژگی چندبعدی، قادر است به تفکیک دقیق افراد مبتلا به ADHD از افراد سالم بپردازد [1]. ویژگی منحصربه‌فرد SVM در این حوزه، توانایی آن در یادگیری از داده‌های پیچیده و غیرخطی است. این الگوریتم می‌تواند روابط غیرخطی میان ویژگی‌ها را شناسایی کند و بر اساس آن، تصمیم‌گیری دقیق را انجام دهد. این امر بسیار مهم است زیرا بسیاری از نشانه‌های ADHD ماهیت غیرخطی دارند و الگوریتم‌های خطی قادر به مدل‌سازی آن‌ها نیستند [47]. همچنین SVM قادر است با استفاده از روش‌های هسته‌ای^۲، فضای ویژگی را به فضاهای پر ابعاد تبدیل کند تا روابط پیچیده بین ویژگی‌ها را بهتر مدل‌سازی نماید. این امکان به SVM کمک می‌کند تا مدل‌های پیش‌بینی قدرتمندتری را برای تشخیص ADHD ایجاد کند. علاوه بر این، SVM به‌عنوان یک الگوریتم یادگیری با نظارت، قادر است از تجربیات پزشکان و متخصصان حوزه سلامت روان برای بهبود عملکرد خود استفاده کند. این امر امکان یادگیری مستمر و تطبیق‌پذیری مدل را فراهم می‌کند و به افزایش صحت تشخیص در طول زمان منجر می‌شود [48]. در مجموع، SVM به دلیل قابلیت‌های قدرتمند خود در یادگیری از داده‌های پیچیده، ساخت مدل‌های غیرخطی و پویایی در فرآیند یادگیری، ابزار مفیدی در حوزه تشخیص ADHD است که می‌تواند به بهبود فرآیندهای تشخیصی و درمانی در این زمینه کمک شایانی کند [11].

¹ Support Vector Machine

² Kernel tricks

۳-۱-۲- SVM با هسته چندگانه

SVM با هسته‌های چندگانه یک پیشرفت مهم در استفاده از این الگوریتم در حوزه تشخیص اختلالات روانی مانند ADHD است. در این رویکرد، به جای استفاده از یک تابع هسته خاص، از ترکیبی از چندین تابع هسته مختلف استفاده می‌شود. این امکان را فراهم می‌آورد که SVM بتواند به‌طور هم‌زمان از ویژگی‌های متنوع و چندگانه‌ای که در داده‌های مربوط به بیماران ADHD وجود دارد، استفاده کند.

برای مثال، ممکن است برخی از ویژگی‌های رفتاری بیماران بهتر با یک تابع هسته خطی مدل‌سازی شوند، درحالی‌که ویژگی‌های عصب روان‌شناختی بهتر با یک تابع هسته چند درجه‌ای نمایش داده شوند. ترکیب این توابع هسته گوناگون به SVM امکان می‌دهد تا مرز تصمیم‌گیری پیچیده‌تری را در فضای ویژگی ایجاد کند و در نتیجه صحت تشخیص را افزایش دهد. این رویکرد به‌ویژه زمانی کاربرد دارد که الگوی ADHD پیچیده و چندوجهی باشد. با ترکیب توابع هسته متنوع، SVM می‌تواند به‌طور مؤثرتری روابط غیرخطی و چندگانه میان ویژگی‌های بالینی، شناختی و رفتاری بیماران را مدل‌سازی کند [1].

همچنین SVM با هسته‌های چندگانه می‌تواند انعطاف‌پذیری بیشتری در تنظیم پارامترهای مختلف هسته‌ها داشته باشد. این امر به متخصصان حوزه سلامت روان این امکان را می‌دهد تا با تغییر ترکیب و وزن توابع هسته، مدل را به‌صورت سفارشی برای هر بیمار یا گروه خاصی از بیماران ADHD تنظیم کنند. در نتیجه، SVM با هسته‌های چندگانه با ایجاد مدل‌های پیچیده‌تر و انعطاف‌پذیرتر، می‌تواند به‌طور چشمگیری به بهبود صحت تشخیص و تفکیک بیماران مبتلا به ADHD از افراد سالم کمک کند. این امر نقش مهمی در بهبود فرآیندهای تشخیصی و درمانی این اختلال روانی ایفا می‌کند [11].

۳-۱-۳- درخت تصمیم

درخت تصمیم یک روش یادگیری ماشینی مؤثر در تشخیص ADHD است. این الگوریتم به‌صورت سلسله‌مراتبی و درختی عمل می‌کند تا به تدریج به یک تشخیص نهایی برسد. در حوزه ADHD، درخت تصمیم می‌تواند به‌عنوان یک ابزار قدرتمند برای تحلیل و تفسیر ویژگی‌های مختلف بیماران مورد استفاده قرار گیرد. این الگوریتم با ساختار درختی خود، امکان شناسایی الگوهای پیچیده و روابط غیرخطی میان ویژگی‌های بالینی، شناختی و رفتاری را فراهم می‌کند [10].

به‌عنوان مثال، درخت تصمیم می‌تواند ابتدا ویژگی‌هایی مانند نمرات آزمون‌های روان‌شناختی را بررسی کند و بر اساس آن، بیماران را به گروه‌های مختلف تقسیم کند. سپس، در هر گروه، به بررسی ویژگی‌های دیگری مانند الگوی خواب یا میزان فعالیت حرکتی پردازد. این فرآیند به تدریج و با تقسیم‌بندی‌های متوالی، به یک تشخیص نهایی برای هر بیمار منتهی می‌شود [49]. این ویژگی درخت تصمیم امکان ایجاد مدل‌هایی با تفسیرپذیری بالا را فراهم می‌کند. به این معنی که می‌توان به راحتی مسیر تصمیم‌گیری را از ریشه درخت تا برگ‌های آن دنبال کرد و به‌طور شفاف دریافت که چه ویژگی‌هایی در نهایت به تشخیص ADHD منجر شده‌اند. این قابلیت تفسیرپذیری، درخت تصمیم را به ابزاری ارزشمند در دست متخصصان حوزه سلامت روان تبدیل می‌کند [50]. آن‌ها می‌توانند با بررسی درخت تصمیم، به شناسایی مهم‌ترین عوامل تأثیرگذار بر تشخیص ADHD دست یابند و در نتیجه، فرآیندهای تشخیصی و درمانی را بهبود بخشند. همچنین درخت تصمیم به دلیل ساختار سلسله‌مراتبی خود، امکان ارائه تشخیص‌های چند سطحی و متفاوت را فراهم می‌کند. این امر به متخصصان این امکان را می‌دهد که نه تنها به تشخیص ADHD دست یابند، بلکه اطلاعات مفیدی درباره شدت و زیرنوع‌های احتمالی آن نیز به‌دست آورند [51]. در مجموع درخت تصمیم به‌عنوان یک ابزار تحلیلی قدرتمند، نقش مهمی در بهبود فرآیندهای تشخیصی و درک بهتر ADHD ایفا می‌کند [10], [11].

۳-۱-۴- جنگل تصادفی

جنگل تصادفی یک الگوریتم یادگیری ماشینی است که برای مسائل مختلف از جمله تشخیص ADHD کاربرد دارد. این روش، مدل‌های درخت تصمیم متعددی را ایجاد کرده و نتیجه نهایی را از ترکیب پیش‌بینی‌های این درخت‌ها به‌دست می‌آورد. در حوزه تشخیص ADHD، جنگل تصادفی می‌تواند به‌طور مؤثری از ویژگی‌های مختلف داده‌ها (مانند اطلاعات بالینی، آزمایشگاهی و همچنین داده‌های مربوط به عملکرد شناختی) استفاده کند تا الگوهای پیچیده و غیرخطی بین این ویژگی‌ها و تشخیص ADHD را شناسایی کند. این روش به مدل‌سازی تعامل‌های چندگانه بین ویژگی‌ها کمک می‌کند و در نتیجه صحت بالاتری در تشخیص ارائه می‌دهد.

علاوه بر این جنگل تصادفی مزایای دیگری مانند مقاوم بودن در برابر ویژگی‌های پرتاب و مقادیر گم‌شده، امکان تفسیر مدل و درک اهمیت نسبی ویژگی‌ها را دارد. این ویژگی‌ها آن را به ابزاری قدرتمند برای تشخیص ADHD تبدیل می‌کند که می‌تواند در بالینی استفاده شود. در مجموع جنگل تصادفی با استفاده از ترکیب درخت‌های تصمیم، قادر است پیش‌بینی‌های دقیق و قابل توضیحی را برای تشخیص ADHD ارائه دهد که به پزشکان در فرآیند تشخیص کمک شایانی می‌کند [11].

۳-۱-۵- رگرسیون لجستیک

رگرسیون لجستیک یک روش آماری قدرتمند است که برای پیش‌بینی متغیرهای دودویی (مثل وجود یا عدم وجود یک بیماری) مورد استفاده قرار می‌گیرد. در حوزه تشخیص ADHD، رگرسیون لجستیک می‌تواند به‌عنوان یک ابزار قدرتمند عمل کند. این روش با استفاده از مجموعه‌ای از متغیرها (مانند نتایج آزمون‌های روان‌شناختی، نشانه‌های بالینی و عوامل زمینه‌ای) به‌صورت هم‌زمان، احتمال ابتلا به ADHD را برآورد می‌کند.

در فرآیند رگرسیون لجستیک، مدل آماری بر اساس داده‌های موجود آموزش داده می‌شود تا بتواند احتمال ابتلا به ADHD را برای هر فرد پیش‌بینی کند. این مدل به‌صورت ریاضی تابعی را تعریف می‌کند که متغیرهای ورودی (مثل نتایج آزمون‌ها) را به یک احتمال دودویی (ابتلا یا عدم ابتلا به ADHD) نگاشت می‌کند. مزیت اصلی رگرسیون لجستیک در این است که می‌تواند به‌صورت هم‌زمان اثر چندین متغیر را بر روی متغیر دودویی موردنظر (ابتلا به ADHD) بررسی کند. این امر به متخصصان سلامت روان کمک می‌کند تا با در نظر گرفتن مجموعه‌ای از ویژگی‌های فرد، صحت تشخیص ADHD را افزایش دهند. همچنین رگرسیون لجستیک به‌صورت کمی میزان اثرگذاری هر یک از متغیرها را بر روی احتمال ابتلا به ADHD ارزیابی می‌کند [11].

در کاربرد رگرسیون لجستیک برای تشخیص ADHD، ابتدا باید یک مجموعه داده‌ی آموزشی معتبر جمع‌آوری شود که شامل اطلاعات مربوط به افراد مبتلا و غیرمبتلا به ADHD باشد. این داده‌ها می‌توانند شامل نتایج آزمون‌های روان‌شناختی، مشاهده‌های بالینی، عوامل زمینه‌ای و ویژگی‌های دموگرافیک باشند. سپس مدل رگرسیون لجستیک بر روی این داده‌ها آموزش داده می‌شود تا بتواند الگوهای مرتبط با ابتلا به ADHD را شناسایی کند. پس از آموزش مدل، می‌توان آن را برای ارزیابی افراد جدید به کار برد. مدل رگرسیون لجستیک برای هر فرد احتمال ابتلا به ADHD را محاسبه می‌کند. این احتمال می‌تواند به‌عنوان یک نمره تشخیصی استفاده شود و افراد با احتمال بالای ابتلا را به‌عنوان ADHD در نظر گرفت. در نتیجه رگرسیون لجستیک می‌تواند به تشخیص دقیق‌تر، سریع‌تر و هزینه‌ای‌تر ADHD کمک کند [11].

۳-۱-۶- الگوریتم K نزدیک‌ترین همسایه (KNN)^۱

KNN یک الگوریتم ساده و قدرتمند در زمینه طبقه‌بندی است که بر اساس شباهت و نزدیکی داده‌ها کار می‌کند. در این روش برای طبقه‌بندی یک نمونه جدید، الگوریتم بر اساس K نمونه آموزشی نزدیک‌ترین به نمونه جدید، تصمیم می‌گیرد که آن نمونه به کدام طبقه تعلق دارد. در مورد تشخیص ADHD، این نمونه‌های آموزشی می‌توانند شامل اطلاعات بالینی مثل علائم رفتاری، نتایج آزمایش‌های روان‌شناختی و سایر ویژگی‌های مرتبط با ADHD و غیر ADHD باشند.

الگوریتم KNN به دو مرحله اصلی تقسیم می‌شود: مرحله آموزش و مرحله پیش‌بینی. در مرحله آموزش، مجموعه داده‌های آموزشی (شامل ویژگی‌ها و برچسب طبقات) ذخیره می‌شود. در مرحله پیش‌بینی، برای طبقه‌بندی یک نمونه جدید، الگوریتم فاصله آن نمونه را با همه نمونه‌های آموزشی محاسبه می‌کند و K نمونه نزدیک‌تر را پیدا می‌کند. سپس، بر اساس برچسب اکثریت این K نمونه نزدیک، به نمونه جدید یک برچسب طبقه اختصاص می‌دهد. در زمینه تشخیص ADHD، KNN می‌تواند بسیار مؤثر باشد زیرا این اختلال معمولاً با ترکیبی پیچیده از علائم رفتاری، شناختی و فیزیولوژیکی مشخص می‌شود. KNN می‌تواند به خوبی با چنین مجموعه‌ای از ویژگی‌های ترکیبی کار کند و بر اساس شباهت بالینی افراد، آن‌ها را به طبقات ADHD و غیر ADHD تقسیم کند. علاوه بر این KNN به دلیل سادگی و عملکرد خوب حتی با داده‌های آموزشی محدود، مورد توجه پژوهشگران در زمینه تشخیص ADHD است. این الگوریتم نیاز به پیش‌پردازش و فرض‌های قبلی کمتری دارد و می‌تواند به‌طور مؤثری با ویژگی‌های ناهمگن و پرت در داده‌ها کنار بیاید. همچنین نتایج حاصل از KNN قابل تفسیر هستند که این امر به پزشکان در تصمیم‌گیری بالینی کمک می‌کند [10], [11].

۳-۱-۷- پرسپترون چندلایه (MLP)^۱

شبکه عصبی مصنوعی یک مدل محاسباتی است که ساختار و عملکرد شبکه عصبی بیولوژیکی موجودات زنده را تقلید می‌کند. این شبکه‌ها از واحدهای معروف به نورون‌های مصنوعی ساخته شده‌اند که به‌طور موازی و مرتبط با هم کار می‌کنند. هر نورون مصنوعی، وزنهایی را به ورودی‌های خود اختصاص می‌دهد و با استفاده از یک تابع فعال‌سازی، خروجی خود را محاسبه می‌کند. شبکه‌های عصبی با یادگیری از داده‌های آموزشی و تنظیم این وزنه‌ها،

¹ K-Nearest Neighbor

¹ Multi - Layer Perceptron

می‌توانند مدل‌های پیچیده و غیرخطی را برای انجام وظایف مختلف مانند طبقه‌بندی، پیش‌بینی و کنترل یاد بگیرند [12].

این مدل‌های محاسباتی دارای توانایی تطبیق‌پذیری و یادگیری هستند و می‌توانند به‌طور خودکار از طریق الگوریتم‌های یادگیری ماشینی، الگوهای پنهان در داده‌ها را کشف کنند. شبکه‌های عصبی به‌ویژه در زمینه‌هایی که داده‌های پیچیده و چندبعدی وجود دارد، مانند بینایی کامپیوتری، NLP و تحلیل داده‌های زیستی کاربرد گسترده‌ای دارند. مزایای اصلی آن‌ها شامل توانایی یادگیری، مقاومت در برابر نویز، قابلیت تطبیق با شرایط جدید و قدرت پردازش موازی است. در مقایسه با رویکردهای سنتی، شبکه‌های عصبی می‌توانند مسائل پیچیده را با صحت بالا حل کنند.

MLP یک نوع شبکه عصبی مصنوعی است که از تعدادی لایه پنهان بین لایه ورودی و لایه خروجی تشکیل شده است. این شبکه با استفاده از الگوریتم انتشار خطا آموزش داده می‌شود و توانایی درک و یادگیری الگوهای غیرخطی را دارد. در حوزه تشخیص MLP، ADHD می‌تواند به‌عنوان یک ابزار قدرتمند برای پردازش و تحلیل داده‌های مربوطه باشد.

اصل کار MLP بدین ترتیب است که ابتدا داده‌های مربوط به بیماران مبتلا به ADHD و افراد سالم در قالب ویژگی‌هایی مانند الگوهای امواج EEG، عملکرد شناختی، رفتارهای روزانه و غیره جمع‌آوری می‌شود. این داده‌ها در لایه ورودی شبکه قرار می‌گیرند و با استفاده از لایه‌های پنهان، الگوها و ارتباطات پیچیده میان ویژگی‌ها را شناسایی می‌کند. در نهایت در لایه خروجی، بر اساس این الگوها، مدل می‌تواند به‌طور خودکار افراد مبتلا به ADHD را از افراد سالم تشخیص دهد.

یکی از مزیت‌های اصلی MLP در این کاربرد، توانایی مدل در یادگیری ویژگی‌های پیچیده و غیرخطی مرتبط با ADHD است. این در حالی است که روش‌های سنتی تشخیص مبتنی بر قوانین از توانایی محدودتری برخوردارند. همچنین MLP می‌تواند به‌صورت خودکار و بدون نیاز به دخالت انسان، تشخیص را انجام دهد که در مقایسه با تشخیص‌های بالینی توسط متخصصان، سریع‌تر و کم‌هزینه‌تر است [11].

۳-۱-۸- گرادیان افزایشی^۱

گرادیان افزایشی یک الگوریتم قدرتمند یادگیری ماشین است که بر پایه درخت تصمیم‌گیری استوار است. این روش با ترکیب مدل‌های ضعیف (مانند درخت تصمیم ساده) به صورت تکراری و افزایشی، یک مدل قوی و دقیق را ایجاد می‌کند. در حوزه تشخیص ADHD، گرادیان افزایشی می‌تواند به عنوان یک ابزار قدرتمند برای پردازش و تحلیل داده‌های مربوطه باشد. فرآیند کاربرد گرادیان افزایشی در تشخیص ADHD به این صورت است که ابتدا مجموعه داده‌ای شامل ویژگی‌های مرتبط با بیماران مبتلا به ADHD و افراد سالم جمع‌آوری می‌شود. این ویژگی‌ها می‌تواند شامل الگوهای امواج EEG، عملکرد شناختی، رفتارهای روزانه و سایر داده‌های مرتبط باشد. سپس، الگوریتم گرادیان افزایشی به طور تکراری مدل‌های ضعیفی از درخت تصمیم‌گیری را ایجاد می‌کند و به روش افزایشی، خطاهای مدل‌های قبلی را اصلاح می‌نماید. در نتیجه، در هر مرحله یک مدل قوی‌تر ایجاد می‌شود تا در نهایت یک مدل نهایی با صحت بسیار بالا برای تشخیص ADHD به دست آید [38].

یکی از مزایای اصلی گرادیان افزایشی در این کاربرد، توانایی آن در یادگیری ویژگی‌های پیچیده و غیرخطی مرتبط با ADHD است. این در حالی است که روش‌های سنتی تشخیص مبتنی بر قوانین از توانایی محدودتری برخوردارند. همچنین گرادیان افزایشی می‌تواند به صورت خودکار و بدون نیاز به دخالت انسان، تشخیص را انجام دهد که در مقایسه با تشخیص‌های بالینی توسط متخصصان، سریع‌تر و کم‌هزینه‌تر است [39]. در مجموع گرادیان افزایشی با قابلیت‌های پردازش اطلاعات پیچیده و یادگیری خودکار، ابزار مناسبی برای تشخیص ADHD محسوب می‌شود و می‌تواند در بهبود فرآیند تشخیص و درمان نقش مؤثری ایفا نماید [11].

۳-۲- الگوریتم‌های یادگیری عمیق

یادگیری عمیق یکی از زیرشاخه‌های اصلی هوش مصنوعی است که در سال‌های اخیر پیشرفت چشمگیری داشته است. این رویکرد بر پایه شبکه‌های عصبی عمیق استوار است که می‌توانند به صورت خودکار ویژگی‌های مفید را از داده‌های خام استخراج کنند. در یادگیری عمیق، شبکه‌های عصبی با تعداد زیادی لایه پنهان طراحی می‌شوند که هر لایه ویژگی‌های پیچیده‌تری را از لایه قبلی یاد می‌گیرند. این عمق در معماری شبکه، توان بیان و مدل‌سازی الگوهای پیچیده در داده‌ها را افزایش می‌دهد [52].

¹ Gradient Boosting

در مقایسه با رویکردهای سنتی یادگیری ماشینی که نیاز به استخراج ویژگی‌های دستی داشتند، یادگیری عمیق امکان یادگیری خودکار این ویژگی‌ها را از طریق آموزش بر روی داده‌های خام فراهم می‌کند. این مزیت باعث شده است که یادگیری عمیق در بسیاری از زمینه‌ها مانند بینایی ماشینی، NLP و تشخیص پزشکی کاربردهای گسترده‌ای پیدا کند [44].

در حوزه تشخیص ADHD نیز، رویکردهای مبتنی بر یادگیری عمیق به‌طور فزاینده‌ای مورد توجه قرار گرفته‌اند. این مدل‌ها می‌توانند به‌صورت خودکار ویژگی‌های حرکتی، شناختی و رفتاری مرتبط با بیش‌فعالی را از داده‌های ویدئویی، صوتی و متنی استخراج کرده و بر اساس آن‌ها تشخیص را انجام دهند. عملکرد این مدل‌ها در برخی مطالعات به‌طور قابل توجهی بهتر از تشخیص‌های انسانی بوده است. با این حال، چالش‌هایی مانند نیاز به حجم بالای داده‌های آموزشی، تفسیرپذیری محدود و نگرانی‌های اخلاقی همچنان باقی مانده‌اند که نیاز به پژوهش‌های بیشتری در این زمینه دارند [46].

در مجموع، یادگیری عمیق با توانایی بالا در یادگیری ویژگی‌های مفید از داده‌های خام و قدرت بالای مدل‌سازی الگوهای پیچیده، پتانسیل زیادی برای حل چالش‌های موجود در زمینه‌های مختلف از جمله تشخیص ADHD دارد. با این حال برای استفاده مؤثر از این رویکرد در محیط‌های بالینی واقعی، باید به چالش‌های مرتبط با صحت، تفسیرپذیری، کارآمدی و اخلاقی بودن آن نیز توجه شود [52].

۳-۲-۱- شبکه‌های عصبی کانولوشن (CNNs)^۱

CNNها به‌عنوان یکی از الگوریتم‌های اصلی یادگیری عمیق در بسیاری از زمینه‌ها مانند بینایی رایانه و طبقه‌بندی تصاویر پزشکی و پردازش سیگنال‌های زیست پزشکی و فرآیندهای زبان طبیعی پیشرفت چشمگیری داشته و از محاسبات سریع‌تر و مجموعه داده‌های حاشیه‌دار بزرگ‌تر بهره‌مند شده‌اند. این نوع شبکه‌های عصبی طراحی شده‌اند تا به‌صورت خودکار ویژگی‌های مهم را از داده‌های ورودی (مانند تصاویر مغزی) استخراج کنند. این امر برای شناسایی الگوهای پیچیده در داده‌ها بسیار مفید است. در زمینه تشخیص ADHD، CNNها معمولاً بر روی تصاویر مغزی مانند MRI یا fMRI آموزش داده می‌شوند [33].

این تصاویر ممکن است ساختار مغز، حجم مناطق خاص، یا الگوهای فعالیت عصبی را نشان دهند. CNN به‌طور خاص طراحی شده است تا این الگوها را شناسایی و استخراج کند. سپس، این ویژگی‌های استخراج شده به لایه‌های

¹ Convolutional Neural Networks

تکمیلی شبکه فرستاده می‌شوند تا بر اساس آن‌ها تشخیص ADHD را انجام دهند. معمولاً CNN‌ها چندلایه هستند که شامل لایه‌های کانولوشن، پول کردن و متراکم‌سازی می‌باشند [53]. این ساختار به شبکه امکان می‌دهد تا ویژگی‌های کم‌تر پیچیده را در لایه‌های اولیه و سپس ویژگی‌های پیچیده‌تر را در لایه‌های بعدی استخراج کند. در نهایت لایه‌های تکمیلی شبکه، مانند MLP، این ویژگی‌های استخراج شده را به یک خروجی دوتایی شامل ADHD یا سالم نگاشت می‌کنند [46].

یکی از مزایای اصلی استفاده از CNN‌ها برای تشخیص ADHD این است که این مدل‌ها می‌توانند به‌طور خودکار الگوهای پیچیده در تصاویر مغزی را استخراج کنند. این در مقایسه با روش‌های سنتی که بر اساس ویژگی‌های از پیش تعریف شده کار می‌کنند، بسیار مؤثرتر است [36]. همچنین پژوهش‌ها نشان داده‌اند که CNN‌ها می‌توانند با صحت بالایی (گاهی بیش از ۹۰ درصد) بین مغز افراد مبتلا به ADHD و افراد سالم تمایز قائل شوند. این صحت بالا به این علت است که CNN‌ها می‌توانند الگوهای پیچیده و غیرخطی در داده‌های تصویربرداری مغزی را کشف کنند. علاوه بر این، CNN‌ها قادرند این تشخیص را به‌صورت کاملاً خودکار و بدون نیاز به دخالت دستی خبرگان انجام دهند. این قابلیت به‌ویژه در محیط‌های بالینی که نیاز به سرعت عمل و صحت بالا است، بسیار مفید است [36]. همچنین رویکرد CNN‌ها به این معناست که نیازی به فرضیات پیشین درباره ساختار مغز یا نواحی مغزی دخیل در ADHD نیست. در عوض شبکه به‌صورت داده محور الگوهای مهم را کشف می‌کند. در مجموع CNN‌ها یک ابزار قدرتمند برای تشخیص ADHD هستند که می‌تواند به پیشرفت‌های مهمی در زمینه تشخیص زودهنگام و درمان منجر شوند [32].

۳-۲-۲- شبکه‌های عصبی بازگشتی (RNNs)^۱

RNN‌ها یک نوع شبکه عصبی هستند که برای پردازش داده‌های سری زمانی و توالی‌ها بسیار مناسب می‌باشند. این ویژگی آن‌ها را به ابزار بسیار مفیدی برای تشخیص ADHD تبدیل می‌کند. در زمینه تشخیص ADHD، داده‌های تصویربرداری مغزی مانند EEG یا MRI عملکردی (fMRI)^۲ به‌صورت توالی زمانی به‌عنوان ورودی به RNN داده می‌شوند. این داده‌ها نشان‌دهنده الگوهای فعالیت مغزی در طول زمان هستند که می‌تواند حاوی نشانه‌های مرتبط با ADHD باشد. RNN به لطف معماری منحصر به فرد خود که شامل واحدهای سلول بازگشتی است، قادر است این اطلاعات توالی زمانی را پردازش کند. واحدهای سلول بازگشتی این امکان را فراهم می‌آورند که اطلاعات

^۱ Recurrent Neural Networks

^۲ Functional MRI

قبلی و ورودی فعلی به‌طور هم‌زمان مورد استفاده قرار گیرند. این ویژگی به RNN اجازه می‌دهد تا روابط پیچیده و درهم‌تنیده درون فعالیت مغزی را مدل‌سازی کند. در طول آموزش، RNN به‌صورت بازگشتی داده‌های تصویربرداری را پردازش می‌کند و خطای طبقه‌بندی را محاسبه و به پارامترهای شبکه انتشار می‌دهد. این فرآیند باعث می‌شود که شبکه الگوهای مرتبط با ADHD را شناسایی و یاد بگیرد [54].

برخلاف روش‌های سنتی که بر استخراج ویژگی‌های دستی متکی هستند، RNNها قادرند ویژگی‌های مرتبط با ADHD را به‌طور خودکار و داده‌محور استخراج کنند. این ویژگی‌ها می‌تواند شامل الگوهای خاص فعالیت مغزی در نواحی مغزی خاص یا الگوهای همبستگی بین نواحی مختلف باشد. در نهایت لایه خروجی RNN معمولاً یک تابع طبقه‌بندی است که خروجی را به دو دسته ADHD یا سالم نسبت می‌دهد. این امکان تشخیص ADHD با صحت بالا را فراهم می‌آورد. در مجموع RNNها به دلیل توانایی پردازش اطلاعات سری زمانی و مدل‌سازی ارتباطات پیچیده درون مغز، ابزار قدرتمندی برای تشخیص ADHD بر اساس داده‌های تصویربرداری مغزی هستند [55].

۳-۲-۳- شبکه‌های عصبی عمیق (DNNs)^۲

از DNNها برای تشخیص ADHD استفاده می‌شود. در این روش ابتدا داده‌های مرتبط با ADHD مانند EEG و MRI که ساختار و عملکرد مغز را بررسی می‌کنند و نتایج ارزیابی‌های نوروسایکولوژیکی توجه، تکانش‌گری و کارکردهای اجرایی جمع‌آوری می‌شوند. سپس این داده‌ها پس از پیش‌پردازش و آماده‌سازی، به‌عنوان ورودی شبکه عصبی عمیق قرار می‌گیرند. طراحی شبکه عصبی عمیق به‌گونه‌ای است که بتواند الگوهای پیچیده و غیرخطی موجود در داده‌های ورودی را شناسایی کند. معماری‌هایی مانند CNNها برای پردازش EEG و MRI استفاده می‌شود و RNNها برای پردازش اطلاعات سریالی مانند آزمون‌های نوروسایکولوژیکی مورد استفاده قرار می‌گیرد. همچنین از روش‌های پیشرفته آموزشی مانند انتقال یادگیری، یادگیری فعال و آموزش چندوظیفه‌ای برای بهبود عملکرد مدل استفاده می‌شود.

پس از آموزش شبکه عصبی با داده‌های برچسب‌دار ADHD و غیر ADHD، مدل بر روی داده‌های آزمایشی جداگانه ارزیابی می‌شود تا صحت، حساسیت و ویژگی آن محاسبه شود. تحلیل خطاها و شناسایی نقاط ضعف مدل، به بهبود معماری شبکه عصبی، انتخاب ویژگی‌های ورودی و تنظیم هایپرپارامترهای آموزش کمک می‌کند. در نهایت

² Deep Neural Networks

مدل آموزش دیده به عنوان یک ابزار تشخیصی ADHD پیاده سازی و به کار گرفته می شود تا افراد مشکوک به این اختلال را شناسایی کند. نتایج این مدل در کنار سایر ارزیابی های بالینی تفسیر می شود تا تشخیص نهایی ADHD صورت گیرد. این روش مبتنی بر شبکه های عصبی عمیق می تواند به تشخیص دقیق و غیرتهاجمی ADHD کمک کند و با ادغام چندین نوع داده، بینش جامع تری از پیچیدگی های مغز و رفتار افراد مبتلا ارائه دهد [56].

برای توضیح بیشتر معماری این روش می توان این چنین اظهار نمود که از CNN به عنوان طبقه بندی کننده، استخراج ویژگی و تشخیص الگو برای طبقه بندی بین کودکان سالم و ADHD استفاده می شود. شبکه عمیق شامل ۴ لایه کانولوشن دوبعدی است که در لایه اول و دوم چهار نورون و در لایه سوم و چهارم سه نورون استفاده شده است. بعد از هر لایه یک لایه Maxpooling دوبعدی وجود دارد و در آخر یک لایه flatten، یک لایه Dense، یک لایه Dropout و یک لایه Dense دیگر وجود دارد. در این روش معمولاً از بهینه ساز adam استفاده می شود [24].

۳-۳- یادگیری تقویتی

یادگیری تقویتی یکی از مهم ترین رویکردهای مورد استفاده در زمینه درمان ADHD است. این رویکرد بر اساس اصول رفتارشناسی بنا شده و به طور کلی به فرآیندی اطلاق می شود که در آن رفتارهای مطلوب با ارائه پاداش های مناسب تقویت می شوند. عناصر اصلی این فرآیند شامل محرک، پاداش، تقویت مثبت و تقویت منفی است. درحالیکه تقویت مثبت به افزایش احتمال وقوع رفتار مطلوب با ارائه پاداش مربوط می شود، تقویت منفی به افزایش احتمال وقوع رفتار مطلوب از طریق حذف یک محرک نامطلوب اشاره دارد [57].

از آنجایی که افراد مبتلا به ADHD معمولاً با مشکلاتی در زمینه توجه، تمرکز و کنترل تکانه مواجه هستند، یادگیری تقویتی می تواند نقش بسیار مهمی در بهبود این عملکردها ایفا کند. با استفاده از تقویت های مناسب و به موقع برای رفتارهای مطلوب، این افراد تشویق می شوند تا توانایی های خود را در انجام تکالیف و وظایف افزایش دهند. همچنین ایجاد محیط های ساختارمند و کم تحرک همراه با اهداف روشن، به همراه آموزش والدین و معلمان در زمینه استفاده از تقویت مثبت، از دیگر راهبردهای یادگیری تقویتی برای تشخیص و مدیریت ADHD است [9]. در مجموع یادگیری تقویتی و الگوریتم های موفق آن به عنوان بخشی از رویکرد درمانی جامع ADHD، نقش بسیار مهمی در بهبود عملکرد این افراد در زمینه های مختلف ایفا می کند و می تواند به عنوان ابزاری مفید در تشخیص و مدیریت این اختلال به کار گرفته شوند. در ادامه چند الگوریتم مهم یادگیری تقویتی که در حوزه تشخیص ADHD کاربرد دارند را معرفی خواهیم نمود [58].

۳-۳-۱- الگوریتم Q-Learning

Q-learning در واقع یک الگوریتم یادگیری نظارت نشده است که هدف آن یادگیری بهترین تصمیم (اقدام) در هر وضعیت است. در تشخیص ADHD، ورودی الگوریتم می‌تواند شامل علائم رفتاری، عملکرد شناختی، نتایج آزمایش‌های پزشکی و سایر داده‌های مرتبط با بیمار باشد [59]. خروجی نیز برچسب تشخیصی ADHD یا غیر ADHD خواهد بود. الگوریتم Q-learning با محاسبه یک تابع ارزش (Q-function) که نشان‌دهنده ارزش هر اقدام در هر وضعیت است، تصمیم بهینه را یاد می‌گیرد. این تابع ارزش به‌طور تکراری به‌روزرسانی می‌شود تا مدل تشخیصی بهینه شود. در هر تکرار، الگوریتم یک وضعیت (ویژگی‌های بیمار) را مشاهده کرده، سپس اقدام مناسب (تشخیص) را انتخاب می‌کند. پس از آن، پاداش (صحت تشخیص) را دریافت می‌کند و تابع ارزش را به‌روز می‌نماید. با تکرار این فرآیند، مدل تشخیصی تدریجاً بهبود می‌یابد [60].

Q-learning به دلیل قابلیت‌های انعطاف‌پذیری و عمومیت خود، در مقایسه با سایر روش‌های یادگیری نظارت‌شده، برای مسائل تشخیصی پیچیده مانند ADHD مناسب‌تر است. این الگوریتم می‌تواند به‌طور مؤثر ویژگی‌های پیچیده و غیرخطی را از داده‌های پزشکی استخراج کرده و مدل تشخیصی دقیقی را ایجاد نماید [61]. در مجموع Q-learning یک روش قدرتمند و انعطاف‌پذیر برای تشخیص ADHD است که با آموزش تابع ارزش، به‌طور پیش‌رونده بهترین تصمیمات تشخیصی را یاد می‌گیرد. نتایج پژوهش‌هایی که از Q-learning برای تشخیص زودهنگام ADHD استفاده کردند، صحتی حدود ۷۰ تا ۷۵ درصد ارائه کرده‌اند [2], [60], [61].

۳-۳-۲- الگوریتم SARSA^۱

الگوریتم SARSA نیز مانند Q-learning، یک الگوریتم یادگیری نظارت‌نشده است که هدف آن یادگیری بهترین استراتژی تصمیم‌گیری در یک محیط است. در تشخیص ADHD، ورودی الگوریتم می‌تواند شامل همان داده‌های مورد استفاده در Q-learning باشد؛ یعنی علائم رفتاری، اطلاعات آزمایشگاهی و غیره. عملکرد اصلی SARSA به این صورت است که در هر تکرار، الگوریتم یک وضعیت (ویژگی‌های بیمار) را مشاهده می‌کند، سپس اقدام مناسب (تشخیص) را انتخاب می‌کند. پس از اجرای این اقدام و دریافت پاداش (صحت تشخیص)، الگوریتم وضعیت جدید را مشاهده کرده و اقدام بعدی را انتخاب می‌کند. این فرآیند به‌صورت تکراری انجام می‌شود تا مدل

^۱ State-Action-Reward-State-Action

تشخیصی بهینه شود. در هر تکرار، الگوریتم SARSA تابع ارزش (Q-function) را به روزرسانی می‌کند تا بتواند بهترین تصمیم‌ها را یاد بگیرد [62].

SARSA در مقایسه با Q-learning، رویکرد محافظه‌کارانه‌تری دارد زیرا در اجرای هر اقدام، ارزش آن اقدام را مستقیماً در نظر می‌گیرد. این امر می‌تواند به ثبات بیشتر مدل تشخیصی و همگرایی سریع‌تر منجر شود. همچنین، SARSA می‌تواند به‌طور مؤثری ویژگی‌های پیچیده داده‌های پزشکی را استخراج کرده و مدل تشخیصی دقیقی را برای ADHD ارائه دهد. این الگوریتم به‌طور گسترده در مسائل تشخیصی پزشکی کاربرد دارد. در مجموع، SARSA یک روش قدرتمند و انعطاف‌پذیر برای تشخیص ADHD است که با به‌روزرسانی تابع ارزش در هر اقدام، به‌طور پیش‌رونده بهترین استراتژی تصمیم‌گیری را یاد می‌گیرد. پژوهش‌هایی که از این الگوریتم برای تشخیص زودهنگام ADHD استفاده کرده‌اند، نتایجی با صحت حدود ۷۰ تا ۷۵ درصد ارائه کرده‌اند.

۳-۳-۳- الگوریتم DQN^۱

الگوریتم DQN از شبکه عصبی عمیق برای تقریب زدن تابع ارزش (Q-function) استفاده می‌کند. در تشخیص ADHD، ورودی این شبکه عصبی می‌تواند شامل ویژگی‌های بالینی، آزمایشگاهی و تصویربرداری عصبی بیماران باشد. عملکرد اصلی DQN به این صورت است که در هر تکرار، الگوریتم وضعیت فعلی را به شبکه عصبی داده و از آن خروجی (برآورد تابع ارزش) را دریافت می‌کند. سپس اقدام مناسب (تشخیص) را انتخاب می‌کند. بعد از اجرای این اقدام و دریافت پاداش (صحت تشخیص)، الگوریتم وضعیت جدید را مشاهده کرده و این فرآیند را تکرار می‌کند. با هر تکرار این فرآیند، شبکه عصبی به‌روزرسانی شده و صحت تابع ارزش بهبود می‌یابد. این به‌روزرسانی از طریق روش‌هایی مانند پخش تجربه و هدف‌گذاری شبکه انجام می‌شود [60], [2].

DQN به دلیل توانایی ویژه شبکه‌های عصبی عمیق در استخراج ویژگی‌های پیچیده از داده‌ها، می‌تواند الگوهای پنهان و غیرخطی در داده‌های پزشکی را شناسایی کند. این امر به ارائه مدل‌های تشخیصی دقیق‌تر برای ADHD کمک می‌کند. علاوه بر این، DQN قادر است در فضای حالت و اقدام پیچیده و بزرگ نیز به‌خوبی عمل کند. این امر آن را برای مسائل تشخیصی چندبعدی مانند ADHD بسیار مناسب می‌سازد. در مجموع، DQN با بهره‌گیری از شبکه‌های عصبی عمیق، قدرت بالایی در یادگیری تابع ارزش و ارائه مدل‌های تشخیصی دقیق برای ADHD دارد.

¹ Deep Q-network

[63]. پژوهش‌هایی که از این الگوریتم برای تشخیص زودهنگام ADHD استفاده کرده‌اند، نتایجی با صحت حدود ۸۰ تا ۸۵ درصد ارائه کرده‌اند.

۳-۳-۴- الگوریتم بهینه‌سازی سیاست پروگزیمال (PPO)^۱

الگوریتم PPO به‌عنوان یک الگوریتم بهینه‌سازی سیاست عمل می‌کند. در تشخیص ADHD، سیاست PPO می‌تواند تابع نداشت وضعیت‌های بیمار (ویژگی‌های بالینی، آزمایشگاهی و تصویربرداری) به اقدامات تشخیصی (مثل تشخیص شخص دارای ADHD یا سالم) باشد. روند کار PPO به این صورت است که در هر تکرار، الگوریتم اقدام فعلی را بر اساس سیاست موجود انتخاب می‌کند. سپس با اجرای این اقدام و دریافت پاداش (صحت تشخیص)، سیاست به‌روزرسانی می‌شود. این به‌روزرسانی به‌گونه‌ای انجام می‌شود که سیاست جدید به سمت افزایش پاداش (بهبود صحت تشخیص) حرکت کند.

PPO برای این به‌روزرسانی از روش‌هایی مانند کلیپ کردن نسبت احتمال سیاست و استفاده از تخمین‌زننده‌های پایدار ارزش استفاده می‌کند. این روش‌ها باعث می‌شوند که به‌روزرسانی سیاست به‌صورت تدریجی و پایدار انجام شود. مزیت اصلی PPO در مقایسه با سایر الگوریتم‌های یادگیری تقویتی، ثبات و پایداری آن در به‌روزرسانی سیاست است. این امر به PPO امکان می‌دهد که بدون ایجاد نوسانات شدید در عملکرد، به‌طور پیوسته صحت تشخیص ADHD را بهبود بخشد. علاوه بر این PPO قادر است با محدودیت‌های منابع محاسباتی (مثل محاسبات کم و حافظه محدود) به‌خوبی کنار بیاید. این ویژگی آن را برای کاربردهای پزشکی با منابع محدود مانند تشخیص ADHD مناسب می‌سازد. در مجموع، PPO با ویژگی‌های منحصر به فرد خود می‌تواند مدل‌های تشخیصی دقیق و پایداری را برای ADHD ارائه دهد. پژوهش‌هایی که از این الگوریتم برای تشخیص زودهنگام ADHD استفاده کرده‌اند، نتایجی با صحت حدود ۸۰ تا ۸۵ درصد ارائه کرده‌اند [64].

۳-۳-۵- الگوریتم آموزش خصمانه پاداش تجسم (RIAT)^۲

الگوریتم RIAT در واقع ترکیبی از دو روش مهم در یادگیری ماشین است: یادگیری تقویتی و مدل‌های توجه‌دار. در تشخیص ADHD، RIAT می‌تواند به‌عنوان یک سیستم تصمیم‌گیری هوشمند عمل کند که وضعیت‌های بالینی،

^۱ Proximal Policy Optimization

^۲ Reward Incarnation Adversarial Training

آزمایشگاهی و تصویربرداری بیمار را به تصمیمات تشخیصی نگاشت می‌کند. روند کار RIAT به این صورت است که ابتدا با استفاده از مکانیسم توجه، ویژگی‌های مهم و تأثیرگذار در تشخیص ADHD را شناسایی می‌کند. این امر به الگوریتم کمک می‌کند تا بر روی جنبه‌های مهم تمرکز کند و از اطلاعات حاشیه‌ای اجتناب کند. سپس با استفاده از یادگیری تقویتی، الگوریتم به‌طور پیوسته سیاست تصمیم‌گیری خود را بهبود می‌بخشد. به این صورت که با دریافت پاداش (صحت تشخیص)، سیاست به‌روزرسانی می‌شود تا به سمت افزایش پاداش حرکت کند. مزیت اصلی RIAT در این است که نه تنها به بهبود صحت تشخیص می‌پردازد، بلکه هم‌زمان قابلیت تفسیرپذیری مدل را نیز افزایش می‌دهد. به این معنا که الگوریتم قادر است توضیح دهد که چه ویژگی‌هایی در تصمیم‌گیری نقش داشته‌اند. این قابلیت تفسیرپذیری، RIAT را به ابزاری قدرتمند در دست پزشکان تبدیل می‌کند؛ زیرا پزشکان می‌توانند مسیر استدلال الگوریتم را درک کرده و تصمیمات آن را بهتر تفسیر کنند. در مجموع RIAT با ترکیب یادگیری تقویتی و مدل‌های توجه دار، الگوریتمی قدرتمند و تفسیرپذیر را برای تشخیص ADHD ارائه می‌دهد که می‌تواند به پزشکان در تصمیم‌گیری کمک کند. پژوهش‌هایی که از این الگوریتم برای تشخیص زودهنگام ADHD استفاده کرده‌اند، نتایجی با صحت حدود ۸۵ تا ۹۰ درصد ارائه کرده‌اند [65].

۳-۳-۶- الگوریتم یادگیری تقویتی چندعامله (MARL)^۲

الگوریتم MARL در مسائل تشخیصی و درمانی بیماری‌های روانی کاربرد دارد. در زمینه تشخیص ADHD، MARL می‌تواند به‌عنوان یک سیستم چندعاملی عمل کند که هر عامل مسئول ارزیابی و تشخیص یک جنبه خاص از بیماری است. روند کار MARL به این صورت است که ابتدا چندین عامل با تخصص‌های مختلف (مانند پزشک، روان‌شناس، فیزیوتراپیست و...) تشکیل می‌شود. هر عامل با استفاده از داده‌های خاص خود (مانند اطلاعات بالینی، آزمایشگاهی، تصویربرداری و...) به ارزیابی و تشخیص جنبه‌های خاصی از ADHD می‌پردازد. سپس این عوامل با تعامل و مشارکت هم‌دیگر، به‌طور جمعی به یک تشخیص نهایی می‌رسند. این تعامل بین عوامل با استفاده از یادگیری تقویتی اتفاق می‌افتد. به این صورت که هر عامل با دریافت پاداش (صحت تشخیص)، استراتژی خود را بهبود می‌بخشد تا به بهترین تصمیم جمعی برسند.

مزیت اصلی MARL در این است که می‌تواند پیچیدگی‌های موجود در تشخیص ADHD را بهتر مدل‌سازی کند؛ زیرا هر عامل با تخصص خاص خود، جنبه‌های مختلف بیماری را ارزیابی می‌کند و نتیجه نهایی از تعامل این

² Multi-Agent Reinforcement Learning

عوامل حاصل می‌شود. همچنین MARL با ارائه توضیحات از جانب هر عامل، قابلیت تفسیرپذیری بالایی را فراهم می‌کند. به این معنا که پزشکان می‌توانند مسیر استدلال هر عامل را درک کرده و تصمیمات نهایی را بهتر تفسیر کنند. در مجموع MARL با استفاده از یادگیری تقویتی چند-عاملی، الگوریتمی قدرتمند و تفسیرپذیر را برای تشخیص ADHD ارائه می‌دهد که می‌تواند به پزشکان در تصمیم‌گیری کمک کند. پژوهش‌هایی که از این الگوریتم برای تشخیص زودهنگام ADHD استفاده کرده‌اند، نتایجی با صحت حدود ۸۵ تا ۹۰ درصد ارائه کرده‌اند [66].

۳-۴- پردازش زبان طبیعی

NLP یک حوزه پیشرفته در هوش مصنوعی است که می‌تواند نقش کلیدی در تشخیص ADHD ایفا کند. این روش‌ها قادر به استخراج و تحلیل ویژگی‌های زبانی و گفتاری هستند که می‌تواند اطلاعات ارزشمندی درباره نشانه‌های ADHD ارائه دهند.

یکی از کاربردهای مهم NLP در این حوزه، تحلیل گفتار و نوشتار بیماران مبتلا به ADHD است. الگوهای منحصر به فرد در ویژگی‌هایی مانند پیچیدگی نحوی، سرعت کلام، نظم و انسجام گفتار و میزان تکرار واژگان می‌تواند به شناسایی نشانه‌های بالینی این اختلال کمک کند. همچنین تحلیل محتوای پیام‌ها و متون تولیدشده توسط این افراد می‌تواند اطلاعاتی درباره نوسانات توجه، تمرکز و فراموش‌کاری آن‌ها ارائه دهد. فراتر از تحلیل گفتار و نوشتار، NLP امکان استخراج ظریف ویژگی‌های زبانی و رفتاری از داده‌های چندرسانه‌ای مانند گفت‌وگوهای صوتی، تعاملات چندرسانه‌ای و فعالیت‌های آنلاین افراد را فراهم می‌کند. این امر می‌تواند به تشخیص دقیق‌تر ADHD و تفکیک آن از اختلالات روانی دیگر کمک کند. علاوه بر این، NLP می‌تواند در پایش پیشرفت درمان و ارزیابی اثربخشی مداخلات نقش مهمی ایفا کند. تحلیل تغییرات الگوهای زبانی و گفتاری بیماران طی دوره درمان می‌تواند به پزشکان و متخصصان در تصمیم‌گیری‌های بالینی یاری رساند [10], [11].

در مجموع، استفاده از روش‌های NLP در حوزه ADHD پتانسیل بسیار بالایی برای بهبود فرایند تشخیص، پایش بالینی و طراحی مداخلات هدفمند دارد. با توسعه این رویکردها و همکاری نزدیک متخصصان حوزه‌های مختلف، می‌توان گام‌های مؤثری در راستای ارتقای کیفیت زندگی افراد مبتلا به ADHD برداشت.

۴- مرور پژوهش‌های گذشته در تشخیص ADHD

در [4] یک روش مبتنی بر یادگیری ماشین برای تحلیل داده‌های دینامیک به‌عنوان یک بایومارکر برای تشخیص ADHD ارائه شده است. روش آن‌ها از تجسم و مهندسی ویژگی مردمک چشم برای تشخیص و طبقه‌بندی ADHD استفاده می‌کند. نتایج آن‌ها نشان می‌دهد که با صحت $85/6$ درصد می‌تواند ADHD را تشخیص دهد.

در [2] یک الگوریتم ترکیبی هوش مصنوعی (ترکیبی از یادگیری ماشین و مدل مبتنی بر دانش) برای تشخیص افراد بالغ مبتلا به ADHD ارائه شده است. روش آن‌ها با آموزش مدل یادگیری ماشین با استفاده از اطلاعات مدل‌های مبتنی بر دانش کار می‌کند. نتایج آن‌ها نشان می‌دهد که می‌تواند با صحت $93/61$ درصد ADHD را شناسایی نماید. همچنین در [8] توانستند به صحت حدود 95 درصد در تشخیص ADHD دست یابند.

در [9] یک پلتفرم دوگانه برای ادغام داده‌های CNN سه‌بعدی برای تشخیص ADHD که یک شبکه عصبی مصنوعی هم‌افزایی مبتنی بر جمع است ارائه شده است. روش آن‌ها به‌اختصار SSANN نامیده می‌شود. روش آن‌ها در مرحله اول از تصاویر MRI ویژگی‌های عملکردی و در مرحله دوم از تصاویر MRI ویژگی‌های ساختاری استخراج می‌کند. در نهایت ماتریس‌های خروجی هر دو مرحله با یک فرآیند القای جمع پیشنهادی ترکیب می‌شوند که سپس به یک شبکه عصبی کاملاً متصل وارد می‌شوند و در نهایت پیش‌بینی طبقه‌بندی دودویی را تولید می‌کند. روش آن‌ها با صحت $72/89$ درصد می‌تواند ADHD را تشخیص دهد.

در [11] روشی مبتنی بر الگوریتم‌های هوش مصنوعی قابل توضیح ارائه شده است. روش آن‌ها از الگوریتم‌های مختلف یادگیری ماشین مانند جنگل تصادفی، درخت تصمیم، رگرسیون لجستیک و اشباع‌گردان در جهت تشخیص ADHD استفاده می‌کند. نتایج نشان می‌دهد که الگوریتم جنگل تصادفی با صحت بالای 90 درصد می‌تواند ADHD را شناسایی کند و به‌طور کلی بهتر از دیگر الگوریتم‌های یادگیری ماشین عمل می‌کند.

در [12] روشی مبتنی بر شبکه‌های عصبی مصنوعی برای تشخیص ADHD ارائه شده است. آن‌ها از پردازش سیگنال‌های EEG برای تشخیص استفاده نموده‌اند. بدین منظور ابتدا سیگنال‌های EEG تحت مراحل پیش‌پردازش قرار گرفتند و سپس برای تشخیص وارد شبکه عصبی مصنوعی شدند. نتایج آن‌ها نشان می‌دهد که با صحت $98/4$ درصد می‌تواند ADHD را شناسایی کند. در این شبکه هر لایه مخفی دارای 8 نورون است.

در [13] روشی مبتنی بر الگوریتم‌های هوش مصنوعی که از داده‌های حرکتی مردمک چشم برای تشخیص ADHD استفاده می‌کند، ارائه شده است. نتایج آن‌ها نشان می‌دهد که با صحت بالای 95 درصد می‌تواند ADHD را از TD تشخیص دهد.

در [67] ترکیبی از روش‌های یادگیری ماشین و یادگیری عمیق برای تشخیص خودکار ADHD با استفاده از پردازش سیگنال‌های EEG ارائه شده است. آن‌ها از روش انتخاب ویژگی LASSO¹ برای انتخاب ویژگی استفاده کردند. همچنین از ترکیب CNN و LSTM برای پیاده‌سازی بخش یادگیری عمیق استفاده شده است. نتایج آن‌ها نشان می‌دهد که مدل می‌تواند با صحت ۹۷/۷۵ درصد ADHD را تشخیص دهد.

در [68] رویکردی مبتنی بر استفاده از روش‌های هوش مصنوعی برای تحلیل عمیق اطلاعات حرکتی بیماران ارائه شده است. روش آن‌ها نیز از پردازش سیگنال‌های EEG برای تشخیص ADHD استفاده می‌کند. نتایج آن‌ها نشان می‌دهد که با صحت ۹۸/۲۱ درصد ADHD را تشخیص دهد.

در [47] روشی مبتنی بر شبکه‌های عمیق کانولوشنی سه‌بعدی چندوجهی که از تصاویر MRI برای تشخیص ADHD استفاده می‌کنند، ارائه شده است. هدف آن‌ها طبقه‌بندی تصاویر مغز با استفاده از روش‌های هوش مصنوعی بالینی مانند سیستم پشتیبانی تصمیم برای تشخیص ADHD است. آن‌ها از طبقه‌بندهای مختلف مانند SVM، KNN و LDA برای تشخیص ADHD استفاده کرده‌اند. روش آن‌ها با صحت ۷۴/۹۳ درصد قابلیت تشخیص ADHD را دارد.

جدول ۱: مقایسه صحت روش‌های بررسی شده

مرجع	روش	صحت (%)
[4]	روش مبتنی بر یادگیری ماشین (تجسم و مهندسی ویژگی مردمک چشم)	۸۵/۶
[2]	الگوریتم ترکیبی هوش مصنوعی (یادگیری ماشین + مدل مبتنی بر دانش)	۹۳/۶۱
[8]	الگوریتم ترکیبی هوش مصنوعی توسعه‌یافته	۹۵
[9]	شبکه عصبی مصنوعی هم‌افزایی مبتنی بر جمع	۷۲/۸۹
[11]	الگوریتم‌های هوش مصنوعی قابل توصیف	۹۰
[12]	شبکه‌های عصبی مصنوعی	۹۸/۴
[13]	روش مبتنی بر داده‌های حرکتی مردمک چشم	۹۵
[67]	یادگیری عمیق + یادگیری ماشین	۹۷/۷۵
[68]	یادگیری ماشین + تحلیل داده‌ها	۹۸/۲۱
[47]	شبکه‌های عمیق کانولوشنی سه‌بعدی چندوجهی	۷۴/۹۳

¹ Least Absolute Shrinkage and Selection Operator

در نهایت در [69] روشی مبتنی بر الگوریتم‌های یادگیری ماشین مانند درخت تصمیم، جنگل تصادفی، SVM و MLP ارائه شده است. روش آن‌ها با استفاده از MLP به صحت حدود ۸۹ درصد، با استفاده از جنگل تصادفی به صحت ۸۷ درصد، با استفاده از درخت تصمیم به صحت ۷۸ درصد و با استفاده از SVM به صحت ۹۱ درصد برای تشخیص ADHD دست‌یافته‌اند. در ادامه خلاصه‌ای از نتایج حاصل از مرور روش‌های مذکور در جدول ۱ آورده شده است.

۵- معیارهای ارزیابی و مجموعه داده‌ها

۵-۱- معیارهای ارزیابی

ارزیابی عملکرد رویکردهای هوش مصنوعی در تشخیص ADHD معمولاً با استفاده از معیارهای استاندارد ارزیابی طبقه‌بندی انجام می‌شود. این معیارها شامل صحت^۱، حساسیت (یادآوری-فراخوانی^۲)، دقت، خصوصیت (ویژگی^۳) و امتیاز F₁ هستند.

صحت نشان‌دهنده میزان درستی پیش‌بینی‌های کلی مدل است. در تشخیص ADHD، صحت نشان می‌دهد که مدل تا چه حد می‌تواند افراد مبتلا به ADHD را از افراد سالم تشخیص دهد. مطابق رابطه ۱ محاسبه می‌شود.

$$Accuracy = \frac{T_P + T_N}{T_P + T_N + F_P + F_N} \quad (1)$$

حساسیت یعنی از کل نمونه‌هایی که از یک دسته به‌خصوص در پایگاه داده موجود بوده، چند مورد توسط طبقه‌بند شناسایی شده است. این معیار نشان می‌دهد چه درصدی از افراد واقعاً مبتلا به ADHD، توسط مدل به‌درستی تشخیص داده می‌شوند. مطابق رابطه ۲ محاسبه می‌شود.

$$Recall = Sensitivity = \frac{T_P}{T_P + F_N} \quad (2)$$

دقت یعنی از کل پیش‌بینی‌هایی که طبقه‌بند در مورد یک دسته به‌خصوص انجام داده چند مورد درست بوده است. مطابق رابطه ۳ محاسبه می‌شود.

¹ Accuracy

² Sensitivity

³ Specificity

$$Precision = \frac{T_P}{T_P + F_P} \quad (۳)$$

خصوصیت به توانایی یک آزمایش برای رد وجود یک نوع بیماری در کسی که آن بیماری را ندارد، اشاره می‌کند. به عبارت دیگر در یک آزمایش با ویژگی بالا، نتیجه منفی واقعاً منفی است. مطابق رابطه ۴ محاسبه می‌شود.

$$Specificity = \frac{T_N}{T_N + F_P} \quad (۴)$$

امتیاز F_1 یک معیار ترکیبی است که تعادل بین حساسیت و دقت را در نظر می‌گیرد. معیار F_1 در بهترین حالت یک و در بدترین حالت صفر است. مطابق رابطه ۵ محاسبه می‌شود.

$$F_1 \text{ Score} = 2 \cdot \frac{Precision \cdot Recall}{Precision + Recall} \quad (۵)$$

در طول فرآیند آموزش و ارزیابی مدل‌های هوش مصنوعی، این معیارها بر روی مجموعه داده‌های آموزشی، اعتبارسنجی و آزمون محاسبه می‌شوند. این امر امکان مقایسه عملکرد مدل‌های مختلف و انتخاب مدل بهینه را فراهم می‌آورد. همچنین داده‌های تصویربرداری مغزی مرتبط با ADHD و افراد سالم، به‌طور جداگانه مورد تحلیل و مقایسه قرار می‌گیرند. این مقایسه می‌تواند الگوهای فعالیت مغزی مرتبط با ADHD را شناسایی کند و به بهبود صحت تشخیص کمک کند. در مجموع این معیارهای ارزیابی استاندارد و تحلیل مقایسه‌ای داده‌ها، امکان سنجش دقیق عملکرد مدل‌های هوش مصنوعی در تشخیص ADHD را فراهم می‌سازد و به توسعه و بهبود مداوم این رویکردها کمک می‌کند [2].

۵-۲- مجموعه داده‌های استاندارد

مهم‌ترین مجموعه داده‌های مورد استفاده در این حوزه به همراه تعداد نمونه‌های سالم و ADHD در جدول ۲ معرفی شده‌اند.

جدول ۲: توصیف ویژگی‌های مجموعه داده‌ها

مرجع	مجموعه داده	نوع داده‌ها	مجموع تعداد نمونه‌ها	تعداد نمونه‌های سالم	تعداد نمونه‌های ADHD
[11]	ADHD-200	fMRI/اطلاعات پایه	۹۷۳	۴۹۱	۴۸۲
[2]	ADHD-HCP	fMRI/اطلاعات پایه	۲۸۵	۱۵۴	۱۳۱
[14]	ADHD-ICA	fMRI/اطلاعات پایه	۱۲۰	۶۰	۶۰
[6]	ADHD-ENIGMA	MRI/اطلاعات پایه	۳۲۴۲	۱۷۱۳	۱۵۲۹
[9]	ADHD-Scores	آزمون‌های روان‌شناختی/اطلاعات پایه	۸۰۹	۴۰۳	۴۰۶
[12]	ADHD-BRAIN	EEG/MRI	۱۲۰	۶۰	۶۰
[13]	ADHD-Behavioral	آزمون‌های رفتاری/نظرسنجی‌های خودگزارشی	۵۰۰	۲۵۰	۲۵۰
[16]	ADHD-Genetics	داده‌های ژنتیکی/اطلاعات پایه	۸۰۰	۴۰۰	۴۰۰
[19]	ADHD-Multimodal	EEG/nMRI/داده‌های رفتاری/اطلاعات پایه	۱۵۰	۷۵	۷۵
[47]	ADHD-Longitudinal	داده‌های طولی از ارزیابی‌های بالینی/آزمون‌های عصب‌شناختی/fMRI	۱۰۰	۵۰	۵۰
[15]	ADHD-HNU	MRI/EEG	۳۷۸	۱۷۹	۱۹۹
[6]	ADHD-Vanderbilt	اطلاعات بالینی/EEG	۲۷۵	۱۳۶	۱۳۹
[13]	KKI Dataset	اطلاعات بالینی/fMRI	۱۷۲	۸۹	۸۳
[20]	CPAC Dataset	اطلاعات بالینی/fMRI	۱۰۰۰	۵۰۰	۵۰۰

۶- چالش‌ها و محدودیت‌ها

اولین چالش مربوط به پیچیدگی و ناهمگنی ADHD است. این اختلال طیف وسیعی از علائم را شامل می‌شود که می‌تواند در هر فرد به شکل متفاوتی بروز کند. همچنین عوامل متعددی از جمله عوامل ژنتیکی، عصبی-شیمیایی و محیطی در ایجاد و شدت آن نقش دارند. این پیچیدگی می‌تواند موجب چالش‌هایی در زمینه مدل‌سازی و تشخیص دقیق ADHD با استفاده از روش‌های هوش مصنوعی شود [68].

دوم اینکه اکثر مطالعه‌ها تا به امروز بر روی جمعیت‌های بالغ یا کودکان متمرکز بوده‌اند و مطالعه‌های کمتری در زمینه نوجوانان و سالمندان انجام شده است. این محدودیت می‌تواند باعث کاهش قابلیت تعمیم‌پذیری مدل‌های ایجادشده به سایر گروه‌های سنی شود.

چالش دیگر، دسترسی محدود به داده‌های استاندارد و بزرگ‌مقیاس است. برای آموزش مدل‌های دقیق هوش مصنوعی، نیاز به مجموعه داده‌های غنی و نماینده از جمعیت‌های مختلف است که متأسفانه در برخی مناطق به راحتی در دسترس نیست.

علاوه بر این، تفسیر و پذیرش مدل‌های هوش مصنوعی توسط پزشکان و متخصصان بالینی نیز می‌تواند چالش‌برانگیز باشد. ایجاد شفافیت و قابلیت توضیح‌پذیری در مدل‌های هوش مصنوعی از اهمیت بالایی برخوردار است تا اعتماد و پذیرش بالینی این فناوری‌ها تضمین شود.

در مجموع علی‌رغم پیشرفت‌های چشمگیر در استفاده از هوش مصنوعی برای تشخیص ADHD، همچنان چالش‌ها و محدودیت‌هایی وجود دارد که باید در نظر گرفته شوند تا بتوان از این فناوری‌ها به‌طور مؤثرتری در عرصه بالینی بهره برد [47].

۷- بحث، نتیجه‌گیری و پیشنهادها برای آینده

به‌طور کلی در این پژوهش به بررسی رویکردهای پرکاربرد هوش مصنوعی در جهت بهبود تشخیص ADHD پرداخته شد. مطالعات مختلف نشان دادند که استفاده از روش‌های هوش مصنوعی همچون یادگیری ماشین و NLP می‌تواند سرعت و کارایی تشخیص ADHD را به‌طور قابل‌توجهی افزایش دهند. این امر به‌نوبه خود می‌تواند هزینه‌های مراقبت‌های بهداشتی را کاهش و دسترسی به خدمات تشخیصی را بهبود بخشد. با وجود این پیشرفت‌ها،

همچنان محدودیت‌ها و چالش‌هایی در زمینه استفاده از هوش مصنوعی در این حوزه وجود دارد که نیازمند پژوهش‌های بیشتر است.

در مجموع نتایج پژوهش‌ها نشان می‌دهد که هوش مصنوعی پتانسیل قابل توجهی برای بهبود تشخیص ADHD دارد. با این حال برای تحقق کامل این پتانسیل، نیاز به توجه بیشتر به این موضوع و انجام پژوهش‌های بیشتر در آینده وجود دارد. با بهره‌گیری از این رویکردها، چشم‌انداز روشنی برای ارتقای صحت تشخیص، پیش‌بینی و مداخلات مبتنی بر هوش مصنوعی در حوزه ADHD متصور است که می‌تواند به بهبود زندگی بیماران و خانواده‌های آن‌ها کمک شایانی کند.

برای ادامه پژوهش مواردی به شرح زیر ارائه می‌شود:

اول و مهم‌ترین، استفاده از رویکردهای یکپارچه و چندوجهی است. این بدان معنی است که در کنار داده‌های عصب تصویربرداری و داده‌های عملکردی، سایر منابع داده مانند اطلاعات ژنتیکی، محیطی و رفتاری نیز در نظر گرفته شوند. با ترکیب این منابع داده گوناگون، می‌توان مدل‌های پیش‌بینی کننده و تشخیصی قدرتمندتری توسعه داد.

دوم، توسعه و به‌کارگیری روش‌های هوش مصنوعی پیشرفته‌تر مانند یادگیری عمیق و یادگیری تقویتی است. این رویکردها می‌توانند الگوهای پیچیده‌تر و ظریف‌تری را در داده‌های مرتبط با ADHD کشف کنند و در نتیجه صحت تشخیصی را افزایش دهند.

سوم، انجام مطالعات بیشتر بر روی گروه‌های سنی مختلف از جمله نوجوانان و سالمندان. این امر می‌تواند زمینه را برای توسعه مدل‌های جامع‌تر و قابل‌تعمیم‌پذیری بیشتر فراهم سازد.

چهارم، توجه به مسائل اخلاقی و حریم خصوصی در توسعه و استقرار این فناوری‌ها است. اطمینان از محافظت از داده‌های شخصی و کاربرد مسئولانه و شفاف آن‌ها از موارد مهم در این حوزه است.

پنجم، همکاری نزدیک‌تر میان متخصصان حوزه‌های مختلف از جمله پزشکان، روان‌شناسان، دانشمندان داده و متخصصان هوش مصنوعی. این همکاری‌ها می‌تواند منجر به درک بهتر چالش‌ها و نیازهای واقعی بالینی و توسعه راهکارهای کاربردی‌تر شود.

با فراهم شدن این مسیرهای پژوهشی، چشم‌انداز روشنی برای ارتقای صحت تشخیص، پیش‌بینی و مداخله‌های مبتنی بر هوش مصنوعی در حوزه ADHD متصور است.

- [1] J. Anuradha, Tisha, V. Ramachandran, K. V. Arulalan, and B. K. Tripathy, "Diagnosis of ADHD using SVM algorithm," in *Proceedings of the Third Annual ACM Bangalore Conference*, Bangalore India: ACM, Jan. 2010, pp. 1–4. doi: 10.1145/1754288.1754317.
- [2] T. Chen, I. Tachmazidis, S. Batsakis, M. Adamou, E. Papadakis, and G. Antoniou, "Diagnosing attention-deficit hyperactivity disorder (ADHD) using artificial intelligence: a clinical study in the UK," *Frontiers in Psychiatry*, vol. 14, p. 1164433, 2023, doi: 10.3389/fpsy.2023.1164433.
- [3] J. Hernández-Capistran, L. N. Sánchez-Morales, G. Alor-Hernández, M. Bustos-López, and J. L. Sánchez-Cervantes, "Machine and Deep Learning Algorithms for ADHD Detection: A Review," in *Innovations in Machine and Deep Learning*, vol. 134, G. Rivera, A. Rosete, B. Dorronsoro, and N. Rangel-Valdez, Eds., in *Studies in Big Data*, vol. 134. , Cham: Springer Nature Switzerland, 2023, pp. 163–191. doi: 10.1007/978-3-031-40688-1_8.
- [4] S. Khanna and W. Das, "A novel application for the efficient and accessible diagnosis of ADHD using machine learning," in *2020 IEEE/ITU International Conference on Artificial Intelligence for Good (AI4G)*, IEEE, 2020, pp. 51–54, doi: 10.1109/AI4G50087.2020.9311012.
- [5] S. Oh *et al.*, "Diagnosis of ADHD using virtual reality and artificial intelligence: an exploratory study of clinical applications," *Frontiers in Psychiatry*, vol. 15, p. 1383547, 2024, doi: 10.3389/fpsy.2024.1383547.
- [6] S. Tarnima, P. Sandhya, V. Vani, and A. Bhaumik, "Diagnosis and treatment of attention deficit hyperactivity disorder using artificial intelligence," in *AIP Conference Proceedings*, AIP Publishing, 2024.
- [7] D. A. R. Lopez, H. Pirim, and D. Grewell, "ADHD Prediction in Children Through Machine Learning Algorithms," in *Emerging Trends and Applications in Artificial Intelligence*, vol. 960, F. P. García Márquez, A. Jamil, A. A. Hameed, and I. Segovia Ramírez, Eds., in *Lecture Notes in Networks and Systems*, vol. 960. , Cham: Springer Nature Switzerland, 2024, pp. 89–100. doi: 10.1007/978-3-031-56728-5_8.
- [8] I. Tachmazidis, T. Chen, M. Adamou, and G. Antoniou, "A hybrid AI approach for supporting clinical diagnosis of attention deficit hyperactivity disorder (ADHD) in adults," *Health Inf Sci Syst*, vol. 9, no. 1, p. 1, Dec. 2021, doi: 10.1007/s13755-020-00123-7.
- [9] J. Peng, M. Debnath, and A. K. Biswas, "Efficacy of novel summation-based synergetic artificial neural network in ADHD diagnosis," *Machine Learning with Applications*, vol. 6, p. 100120, 2021, doi: 10.1016/j.mlwa.2021.100120.
- [10] T. Chen, G. Antoniou, M. Adamou, I. Tachmazidis, and P. Su, "Automatic Diagnosis of Attention Deficit Hyperactivity Disorder Using Machine Learning," *Applied Artificial Intelligence*, vol. 35, no. 9, pp. 657–669, Jul. 2021, doi: 10.1080/08839514.2021.1933761.

- [11] I. Navarro-Soria, J. R. Rico-Juan, R. Juárez-Ruiz De Mier, and R. Lavigne-Cervan, "Prediction of attention deficit hyperactivity disorder based on explainable artificial intelligence," *Applied Neuropsychology: Child*, pp. 1–14, Apr. 2024, doi: 10.1080/21622965.2024.2336019.
- [12] G. Güney, E. Kisacik, C. KALAYCIOĞLU, and G. Saygili, "Exploring the attention process differentiation of attention deficit hyperactivity disorder (ADHD) symptomatic adults using artificial intelligence onelectroencephalography (EEG) signals," *Turkish Journal of Electrical Engineering and Computer Sciences*, vol. 29, no. 5, pp. 2312–2325, 2021, doi: 10.3906/elk-2011-3.
- [13] X. Chen *et al.*, "Utilizing artificial intelligence-based eye tracking technology for screening ADHD symptoms in children," *Frontiers in Psychiatry*, vol. 14, p. 1260031, 2023, doi: 10.3389/fpsyt.2023.1260031.
- [14] D. C. Lohani and B. Rana, "ADHD diagnosis using structural brain MRI and personal characteristic data with machine learning framework," *Psychiatry Research: Neuroimaging*, vol. 334, p. 111689, 2023, doi: 10.1016/j.psychresns.2023.111689.
- [15] H. Christiansen *et al.*, "Use of machine learning to classify adult ADHD and other conditions based on the Conners' Adult ADHD Rating Scales," *Scientific reports*, vol. 10, no. 1, p. 18871, 2020, doi: 10.1038/s41598-020-75868-y.
- [16] G. Wang, W. Li, S. Huang, and Z. Chen, "A Prospective Study of an Early Prediction Model of Attention Deficit Hyperactivity Disorder Based on Artificial Intelligence," *J Atten Disord*, vol. 28, no. 3, pp. 302–309, Feb. 2024, doi: 10.1177/10870547231211360.
- [17] A. Parashar, N. Kalra, J. Singh, and R. K. Goyal, "Machine learning based framework for classification of children with ADHD and healthy controls," *Intell. Autom. Soft Comput*, vol. 28, no. 3, pp. 669–682, 2021, doi: 10.32604/iasc.2021.017478.
- [18] F. Amato, M. Di Gregorio, C. Monaco, M. Sebillio, G. Tortora, and G. Vitiello, "Socially assistive robotics combined with artificial intelligence for ADHD," in *2021 IEEE 18th Annual Consumer Communications & Networking Conference (CCNC)*, IEEE, 2021, pp. 1–6, doi: 10.1109/CCNC49032.2021.9369633.
- [19] M. Sheriff and R. Gayathri, "Retracted: An enhanced ensemble machine learning classification method to detect attention deficit hyperactivity for various artificial intelligence and telecommunication applications," *Computational Intelligence*, vol. 38, no. 4, pp. 1327–1337, Aug. 2022, doi: 10.1111/coin.12509.
- [20] M. S. NV and R. Surendran, "Prediction of Attention Deficit Hyperactivity Disorder (ADHD) in Adult using Novel Artificial Neural Network Algorithm," in *2022 International Conference on Augmented Intelligence and Sustainable Systems (ICAISS)*, IEEE, 2022, pp. 135–139, doi: 10.1109/ICAISS55157.2022.10010869.
- [21] A. Sharma, A. Jain, S. Sharma, A. Gupta, P. Jain, and S. P. Mohanty, "iPAL: A Machine Learning Based Smart Healthcare Framework for Automatic Diagnosis of Attention Deficit/Hyperactivity Disorder," *SN COMPUT. SCI.*, vol. 5, no. 4, p. 433, Apr. 2024, doi: 10.1007/s42979-024-02779-4.

- [22] C. Nash, R. Nair, and S. M. Naqvi, "Machine Learning in ADHD and Depression Mental Health Diagnosis: A Survey," *IEEE Access*, vol. 11, pp. 86297-86317, 2023, doi: 10.1109/ACCESS.2023.3304236.
- [23] E. Salah, M. Shokair and W. Shalaby, "Effective techniques for classifying ADHD based on artificial intelligence," 2023 doi: 10.21203/rs.3.rs-2828086/v1.
- [24] I.-C. Lin, S.-C. Chang, Y.-J. Huang, T. B. Kuo, and H.-W. Chiu, "Distinguishing different types of attention deficit hyperactivity disorder in children using artificial neural network with clinical intelligent test," *Frontiers in Psychology*, vol. 13, p. 1067771, 2023, doi: 10.3389/fpsyg.2022.1067771.
- [25] S. Walvekar, B. Thawkar, M. Chintamaneni, and G. Kaur, "Recent Advances of Artificial Intelligence Tools in Attention-Deficit Hyperactivity Disorder (ADHD)," *Current Psychopharmacology*, vol. 11, no. 1, pp. 18–29, 2022, doi: 10.2174/2211556011666220607112528.
- [26] R. Medina *et al.*, "Electrophysiological brain changes associated with cognitive improvement in a pediatric attention deficit hyperactivity disorder digital artificial intelligence-driven intervention: randomized controlled trial," *Journal of medical Internet research*, vol. 23, no. 11, p. e25466, 2021, doi: 10.2196/25466.
- [27] M. M. Misgar and M. P. S. Bhatia, "Advancing ADHD diagnosis: using machine learning for unveiling ADHD patterns through dimensionality reduction on IoMT actigraphy signals," *Int. j. inf. technol.*, May 2024, doi: 10.1007/s41870-024-01895-x.
- [28] M. Moghaddari, M. Z. Lighvan, and S. Danishvar, "Diagnose ADHD disorder in children using convolutional neural network based on continuous mental task EEG," *Computer Methods and Programs in Biomedicine*, vol. 197, p. 105738, 2020, doi: 10.1016/j.cmpb.2020.105738.
- [29] A. Ahmadi, M. Kashefi, H. Shahrokhi, and M. A. Nazari, "Computer aided diagnosis system using deep convolutional neural networks for ADHD subtypes," *Biomedical Signal Processing and Control*, vol. 63, p. 102227, 2021, doi: 10.1016/j.bspc.2020.102227.
- [30] P. Amado-Caballero *et al.*, "Objective ADHD diagnosis using convolutional neural networks over daily-life activity records," *IEEE journal of biomedical and health informatics*, vol. 24, no. 9, pp. 2690–2700, 2020, doi: 10.1109/JBHI.2020.2964072.
- [31] M. Chen, H. Li, J. Wang, J. R. Dillman, N. A. Parikh, and L. He, "A Multichannel Deep Neural Network Model Analyzing Multiscale Functional Brain Connectome Data for Attention Deficit Hyperactivity Disorder Detection," *Radiology: Artificial Intelligence*, vol. 2, no. 1, p. e190012, Dec. 2019, doi: 10.1148/ryai.2019190012.
- [32] 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," *Frontiers in neuroscience*, vol. 14, p. 251, 2020, doi: 10.3389/fnins.2020.00251.
- [33] H. Chen, Y. Song, and X. Li, "A deep learning framework for identifying children with ADHD using an EEG-based brain network," *Neurocomputing*, vol. 356, pp. 83–96, 2019, doi: 10.1016/j.neucom.2019.04.058.

- [34] M. Mafi and S. Radfar, "High dimensional convolutional neural network for EEG connectivity-based diagnosis of ADHD," *Journal of Biomedical Physics & Engineering*, vol. 12, no. 6, p. 645, 2022, doi: 10.31661/jbpe.v0i0.2108-1380.
- [35] S. A. Hosseini, Y. Modaresnia, and F. A. Torghabeh, "EEG-Based Effective Connectivity Analysis for Attention Deficit Hyperactivity Disorder Detection Using Color-Coded Granger-Causality Images and Custom Convolutional Neural Network," *International Clinical Neuroscience Journal*, vol. 10, no. 1, pp. e12–e12, 2023, doi:10.34172/icnj.2023.12.
- [36] T. Zhang *et al.*, "Separated channel attention convolutional neural network (SC-CNN-attention) to identify ADHD in multi-site rs-fMRI dataset," *Entropy*, vol. 22, no. 8, p. 893, 2020, doi: 10.3390/e22080893.
- [37] R. Liu, Z. Huang, M. Jiang, and K. C. Tan, "Multi-LSTM networks for accurate classification of attention deficit hyperactivity disorder from resting-state fMRI data," in *2020 2nd International Conference on Industrial Artificial Intelligence (IAI)*, IEEE, 2020, pp. 1–6, doi: 10.1109/IAI50351.2020.9262176.
- [38] M. Siniatchkin *et al.*, "Behavioural Treatment Increases Activity in the Cognitive Neuronal Networks in Children with Attention Deficit/Hyperactivity Disorder," *Brain Topogr*, vol. 25, no. 3, pp. 332–344, Jul. 2012, doi: 10.1007/s10548-012-0221-6.
- [39] M. de Oliveira Meira, A. M. de Paula Canuto, B. M. de Carvalho, and R. L. C. Jales, "Comparison of Machine Learning predictive methods to diagnose the Attention Deficit/Hyperactivity Disorder levels using SPECT," *Research, Society and Development*, vol. 11, no. 8, pp. e54811831258–e54811831258, 2022.
- [40] L. Zou, J. Zheng, C. Miao, M. J. Mckeown, and Z. J. Wang, "3D CNN based automatic diagnosis of attention deficit hyperactivity disorder using functional and structural MRI," *Ieee Access*, vol. 5, pp. 23626–23636, 2017, doi: 10.1109/ACCESS.2017.2762703.
- [41] Z. Wang, Y. Zhu, H. Shi, Y. Zhang, and C. Yan, "A 3D multiscale view convolutional neural network with attention for mental disease diagnosis on MRI images," *Math. Biosci. Eng*, vol. 18, pp. 6978–6994, 2021, doi: 10.3934/mbe.2021347.
- [42] T. W. P. Janssen *et al.*, "Neural network topology in ADHD; evidence for maturational delay and default-mode network alterations," *Clinical neurophysiology*, vol. 128, no. 11, pp. 2258–2267, 2017, doi: 10.1016/j.clinph.2017.09.004.
- [43] G. Deshpande, P. Wang, D. Rangaprakash, and B. Wilamowski, "Fully connected cascade artificial neural network architecture for attention deficit hyperactivity disorder classification from functional magnetic resonance imaging data," *IEEE transactions on cybernetics*, vol. 45, no. 12, pp. 2668–2679, 2015, doi: 10.1109/TCYB.2014.2379621.
- [44] M. R. Mohammadi, A. Khaleghi, A. M. Nasrabadi, S. Rafieivand, M. Begol, and H. Zarafshan, "EEG classification of ADHD and normal children using non-linear features and neural network," *Biomed. Eng. Lett.*, vol. 6, no. 2, pp. 66–73, May 2016, doi: 10.1007/s13534-016-0218-2.

- [45] R. H. Pruijm *et al.*, “An integrated analysis of neural network correlates of categorical and dimensional models of attention-deficit/hyperactivity disorder,” *Biological Psychiatry: Cognitive Neuroscience and Neuroimaging*, vol. 4, no. 5, pp. 472–483, 2019, doi: 10.1016/j.bpsc.2018.11.014.
- [46] M. Muñoz-Organero, L. Powell, B. Heller, V. Harpin, and J. Parker, “Automatic extraction and detection of characteristic movement patterns in children with ADHD based on a convolutional neural network (CNN) and acceleration images,” *Sensors*, vol. 18, no. 11, p. 3924, 2018, doi: 10.3390/s18113924.
- [47] S. Abdolmaleki and M. S. Abadeh, “Brain MR image classification for ADHD diagnosis using deep neural networks,” in *2020 international conference on machine vision and image processing (MVIP)*, IEEE, 2020, pp. 1–5, doi: 10.1109/MVIP49855.2020.9116877.
- [48] S. Motamed and E. Askari, “Recognition of Attention Deficit/Hyperactivity Disorder (ADHD) Based on Electroencephalographic Signals Using Convolutional Neural Networks (CNNs),” *Journal of Information Systems and Telecommunication (JIST)*, vol. 3, no. 39, p. 222, 2022, doi: 10.52547/jist.16399.10.39.222.
- [49] M. Delavarian, E. Nayebi, P. Dibajnia, G.-A. Afrooz, S. Gharibzadeh, and F. Towhidkhal, “Designing an accurate system for differentiating children with attention deficit-hyperactivity disorder from oppositional defiant disorder by using artificial neural network,” *The Scientific Journal of Rehabilitation Medicine*, vol. 4, no. 1, pp. 90–98, 2015.
- [50] A. Nouri and Z. Tabanfar, “Detection of ADHD Disorder in Children Using Layer-Wise Relevance Propagation and Convolutional Neural Network: An EEG Analysis,” *Frontiers in Biomedical Technologies*, vol. 11, no. 1, pp. 14–21, 2024, doi: 10.18502/fbt.v11i1.14507.
- [51] B. A. Rahadian, C. Dewi, and B. Rahayudi, “The performance of genetic algorithm learning vector quantization 2 neural network on identification of the types of attention deficit hyperactivity disorder,” in *2017 International Conference on Sustainable Information Engineering and Technology (SIET)*, IEEE, 2017, pp. 337–341, doi: 10.1109/SIET.2017.8304160.
- [52] S. Altun, A. Alkan, and H. Altun, “Automatic diagnosis of attention deficit hyperactivity disorder with continuous wavelet transform and convolutional neural network,” *Clinical Psychopharmacology and Neuroscience*, vol. 20, no. 4, p. 715, 2022, doi: 10.9758/cpn.2022.20.4.715.
- [53] G. Taşpınar and N. Özkurt, “fMRG Hacimlerini Kullanarak DEHB’nin 3B ESA Tabanlı Otomatik Teşhisi 3D CNN Based Automatic Diagnosis of ADHD Using fMRI Volumes”, vol. 25, no. 73, pp. 1-8, 2023, doi: 10.21205/deufmd.2023257301.
- [54] Y. Wang, H. Wang, H. Pirim, L.-W. Fan, and N. Ojeda, “Attention-Deficit/Hyperactivity Disorder Diagnosis with Temporal Diffusion Convolutional Recurrent Neural Networks”, *Biomedical Sciences Instrumentation*, vol. 58, no. 1, 2022, doi: 10.34107/MYQO345429.
- [55] G. Ariyaratne, S. De Silva, S. Dayarathna, D. Meedeniya, and S. Jayarathne, “ADHD Identification using Convolutional Neural Network with Seed-based Approach for fMRI Data,” in

Proceedings of the 2020 9th International Conference on Software and Computer Applications, Langkawi Malaysia: ACM, Feb. 2020, pp. 31–35. doi: 10.1145/3384544.3384552.

[56] E. Salah, M. Shokair and A. El-Samie, “Detection Attention Deficit Hyperactivity Disorder by using Convolution Neural Network,” *International Journal of Telecommunications*, vol. 3, no. 02, pp. 1–11, 2023, doi: 10.21608/ijt.2023.315782.

[57] H. Safari, S. Makvand Hosseini, P. Sabahi, and A. Maleki, “Diagnosis of Attention Deficit/Hyperactivity Disorder with Fourth Wechsler Tool and Integrated Version: Ranking of Effective sub Scale with Artificial Neural Network Analysis,” *Neuropsychology*, vol. 6, no. 23, pp. 99–122, 2021, doi: 10.30473/clpsy.2020.52924.1546.

[58] C. Uyulan and E. S. Gokten, “Prediction of Long-term Prognosis of Children with Attention-deficit/Hyperactivity Disorder in Conjunction with Deep Neural Network Regression,” *Psychiatry and Behavioral Sciences*, vol. 12, no. 4, p. 176, 2022, doi: 10.5455/PBS.20220602052257.

[59] N. Qiang, Q. Dong, Y. Sun, B. Ge, and T. Liu, “deep variational autoencoder for modeling functional brain networks and ADHD identification,” in *2020 IEEE 17th International Symposium on Biomedical Imaging (ISBI)*, IEEE, 2020, pp. 554–557, doi: 10.1109/ISBI45749.2020.9098480

[60] R. Rodriguez-Herrera *et al.*, “Contingency-based flexibility mechanisms through a reinforcement learning model in adults with Attention-Deficit/Hyperactivity Disorder and Obsessive-Compulsive Disorder,” *medRxiv*, pp. 2024–01, 2024, doi: 10.1101/2024.01.17.24301365.

[61] J. Zupan, “Introduction to artificial neural network (ANN) methods: what they are and how to use them,” *Acta Chimica Slovenica*, vol. 41, no. 3, p. 327, 1994.

[62] W. D. Fosco, L. W. Hawk, K. S. Rosch, and M. G. Bubnik, “Evaluating cognitive and motivational accounts of greater reinforcement effects among children with attention-deficit/hyperactivity disorder,” *Behav Brain Funct*, vol. 11, no. 1, p. 20, Dec. 2015, doi: 10.1186/s12993-015-0065-9.

[63] E. J. Sonuga-Barke, “ADHD as a reinforcement disorder—Moving from general effects to identifying (six) specific models to test.,” vol. 52, no. 9, pp. 917-8, 2011, doi: 10.1111/j.1469-7610.2011.02444.x.

[64] M. Luman, G. Tripp, and A. Scheres, “Identifying the neurobiology of altered reinforcement sensitivity in ADHD: a review and research agenda,” *Neuroscience & Biobehavioral Reviews*, vol. 34, no. 5, pp. 744–754, 2010, doi: 10.1016/j.neubiorev.2009.11.021.

[65] H. De Meyer, T. Beckers, G. Tripp, and S. Van Der Oord, “Reinforcement Contingency Learning in Children with ADHD: Back to the Basics of Behavior Therapy,” *J Abnorm Child Psychol*, vol. 47, no. 12, pp. 1889–1902, Dec. 2019, doi: 10.1007/s10802-019-00572-z.

[66] A. Sethi, V. Voon, H. D. Critchley, M. Cercignani, and N. A. Harrison, “A neurocomputational account of reward and novelty processing and effects of psychostimulants in attention deficit hyperactivity disorder,” *Brain*, vol. 141, no. 5, pp. 1545–1557, 2018, doi: 10.1093/brain/awy048.

- [67] H. Alkahtani, T. H. Aldhyani, Z. A. Ahmed, and A. A. Alqarni, “Developing System-Based Artificial Intelligence Models for Detecting the Attention Deficit Hyperactivity Disorder,” *Mathematics*, vol. 11, no. 22, p. 4698, 2023, doi: 10.3390/math11224698.
- [68] D. Yu and J. hui Fang, “Using artificial intelligence methods to study the effectiveness of exercise in patients with ADHD,” *Frontiers in Neuroscience*, vol. 18, p. 1380886, 2024, doi: 10.3389/fnins.2024.1380886.
- [69] N. Alsharif, M. H. Al-Adhaileh, and M. Al-Yaari, “Accurate Identification of Attention-deficit/Hyperactivity Disorder Using Machine Learning Approaches,” *Journal of Disability Research*, vol. 3, no. 1, p. 20230053, 2024, doi: 10.57197/JDR-2023-0053.