



## مروری بر روش‌های یادگیری عمیق در تشخیص اختلال نقص توجه بیش‌فعالی

اکرم فیضی<sup>(۱)</sup> سید عابد حسینی<sup>(۲)</sup> محبوبه هوشمند<sup>(۳)\*</sup>

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

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

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

تاریخ دریافت: ۱۴۰۳/۰۵/۱۳ تاریخ پذیرش: ۱۴۰۳/۰۷/۱۰

### چکیده

اختلال نقص توجه بیش‌فعالی (ADHD) یکی از شایع‌ترین اختلال‌های رفتاری در کودکان و نوجوانان است. تشخیص دقیق و به‌موقع آن برای آغاز درمان مناسب حائز اهمیت است. در سال‌های اخیر با پیشرفت در زمینه‌های یادگیری ماشین و یادگیری عمیق، پژوهشگران توجه ویژه‌ای به تشخیص بهتر ADHD داشته‌اند. این پژوهش به بررسی کاربردهای یادگیری عمیق در تشخیص ADHD از طریق تحلیل داده‌های مختلف از جمله سیگنال‌های الکتروانسفالوگرافی و تصاویر تشدید مغناطیسی می‌پردازد. همچنین چالش‌ها و محدودیت‌های موجود در این زمینه را مورد بررسی قرار می‌دهد. هدف این پژوهش ارائه یک دیدگاه کلی در مورد پتانسیل استفاده از یادگیری عمیق در تشخیص ADHD و مسیرهای آتی پژوهش در این حوزه است. امید است که این پژوهش بتواند به‌عنوان راهنمایی کارآمد، مسیر پژوهشگران این حوزه را هموار سازد.

کلمات کلیدی: اختلال نقص توجه بیش‌فعالی، سیگنال‌های مغزی، تصاویر تشدید مغناطیسی، یادگیری عمیق.

\*عهده‌دار مکاتبات:

محبوبه هوشمند

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

پست الکترونیکی: [houshmand@mshdiau.ac.ir](mailto:houshmand@mshdiau.ac.ir)



اختلال نقص توجه بیش‌فعالی (ADHD)<sup>1</sup> یکی از رایج‌ترین اختلال‌های روان‌شناختی است که در کودکان و نوجوانان شیوع بالایی دارد. این اختلال با علائمی مانند بی‌توجهی، فعالیت بیش‌ازحد و تکانش‌گری مشخص می‌شود و می‌تواند بر عملکرد تحصیلی، شغلی و اجتماعی فرد تأثیر منفی بگذارد. شواهد تجربی نشان می‌دهند که ADHD با اختلال در عملکرد برخی مناطق مختلف مغزی نظیر قشر پیش‌پیشانی، هسته‌های قاعده‌ای و مخچه مرتبط است. 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. همچنین نقص در سامانه‌های نوروشیمیایی مغز از جمله سامانه‌های دوپامینرژیک و نورآدرنرژیک نیز در پاتوژنز ADHD نقش دارند. این سامانه‌ها 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 [1]. تشخیص به‌موقع و صحیح ADHD اهمیت زیادی دارد، زیرا می‌تواند منجر به مداخله‌های درمانی مناسب و پیشگیری از پیامدهای منفی آن بر حوزه‌های مختلف زندگی فرد شود.

متأسفانه روش‌های سنتی تشخیص ADHD مانند مصاحبه‌های بالینی و پرسشنامه‌های خودگزارشی با محدودیت‌هایی روبرو هستند. این محدودیت‌ها شامل سوگیری در پاسخ‌دهی توسط مراجعان (مثلاً تمایل به ارائه تصویر مثبت از خود)، عدم امکان تشخیص زودهنگام و دقیق این اختلال و همچنین نیاز به منابع انسانی و زمانی زیاد برای اجرای این روش‌ها است [2]؛ بنابراین نیاز به رویکردهای نوآورانه‌تر برای ارتقای فرآیند تشخیص ADHD مانند رویکرد یادگیری عمیق (DL)<sup>2</sup> احساس می‌شود.

در دهه‌های اخیر، با پیشرفت‌های چشمگیر در زمینه علوم و فناوری‌های شناختی، درک ما از مکانیسم‌های عصبی زیستی در حوزه ADHD عمیق‌تر شده است. این امر به‌نوبه خود منجر به توسعه رویکردهای نوین تشخیصی مبتنی بر شواهد علمی شده است. در این میان، یکی از رویکردهای امیدبخش، استفاده از روش‌های یادگیری ماشین (ML)<sup>3</sup> و DL است. DL به‌عنوان زیرشاخه‌ای از ML، توانایی بالقوه‌ای در استخراج ویژگی‌های پیچیده و مرتبط از داده‌های تصویری، صوتی و متنی دارد. این رویکرد می‌تواند در تحلیل الگوهای پردازش عصبی مرتبط با ADHD و در نتیجه بهبود تشخیص نقش مهمی ایفا کند. با استفاده از داده‌های عصبی، تصویربرداری، سیگنال‌های الکتروفیزیولوژیکی و حتی داده‌های رفتاری، مدل‌های DL قادر به شناسایی نشانه‌های مختلف ADHD خواهند بود [3].

<sup>1</sup> Attention Deficit Hyperactivity Disorder

<sup>2</sup> Deep learning

<sup>3</sup> Machine learning

از نظر علت‌شناسی، ADHD به عوامل چندگانه‌ای از جمله عوامل ژنتیکی، نوروپاتولوژیکی و محیطی مرتبط است. پژوهش‌های مختلف نشان دادند که عوامل ژنتیکی نقش مهمی در ایجاد این اختلال دارند و احتمال ابتلا به ADHD در افراد دارای بستگان مبتلا بیشتر است. عوامل نوروپاتولوژیکی نیز در بروز ADHD نقش دارند. مطالعات تصویربرداری مغزی نشان داده‌اند که در افراد مبتلا به ADHD، ساختار و عملکرد برخی نواحی مغز از جمله قشر پیشانی و مناطق وابسته به سامانه دوپامینرژیک تفاوت‌هایی با افراد سالم دارد [1].

عوامل محیطی نیز می‌توانند در بروز و شدت علائم ADHD تأثیر بگذارند. مواردی مانند آسیب‌های مغزی ناشی از حوادث، مواجهه با سموم محیطی در دوران بارداری و کودکی و همچنین استرس‌های شدید در کودکی و نوجوانی می‌توانند زمینه‌ساز ابتلا به ADHD باشند. تشخیص ADHD معمولاً بر اساس ارزیابی‌های بالینی توسط متخصص‌های مربوطه و با استفاده از مصاحبه‌ها و پرسشنامه‌های استاندارد انجام می‌شود. در این فرآیند، علائم فرد، سابقه پزشکی و عملکرد در زندگی روزمره مورد بررسی قرار می‌گیرد [4]. درمان ADHD معمولاً شامل ترکیبی از روان‌درمانی و دارودرمانی است. روان‌درمانی‌های مؤثر در این زمینه شامل درمان‌های شناختی-رفتاری، آموزش مهارت‌های مدیریت زمان و سازمان‌دهی هستند. در مورد دارودرمانی نیز، داروهای محرک مانند متیل‌فنیدات و داروهای ضدافسردگی از جمله راهکارهای رایج درمانی هستند [5].

در مجموع ADHD یک اختلال پیچیده است که جنبه‌های مختلف زندگی فرد را تحت تأثیر قرار می‌دهد. تشخیص و درمان به موقع این اختلال می‌تواند به بهبود عملکرد و کیفیت زندگی فرد مبتلا کمک کند. همچنین توجه به عوامل علمی گوناگون و درمان‌های چندوجهی، نقش مهمی در مدیریت مؤثر ADHD ایفا می‌کنند.

برای تشخیص ADHD، متخصص‌ها به مجموعه‌ای از معیارهای خاص توجه می‌کنند. این معیارها کمک می‌کند تا این اختلال را از سایر اختلال‌های رفتاری متمایز کنند. نقص توجه یکی از ارکان اصلی ADHD است. افراد مبتلا به این اختلال اغلب در حفظ توجه و تمرکز دچار مشکل هستند. آن‌ها ممکن است به جزئیات توجه نکنند و در نتیجه دچار اشتباه‌های سهوی شوند. همچنین ممکن است در گوش دادن به حرف‌های دیگران دشواری داشته و دستورالعمل‌ها را به طور کامل دنبال نکنند. سازمان‌دهی و مدیریت زمان نیز از دیگر چالش‌های آن‌ها است [3].

علاوه بر نقص توجه، بیش‌فعالی و تکانش‌گری نیز از دیگر ویژگی‌های بارز ADHD هستند. افراد مبتلا به این اختلال اغلب با دست‌وپا بازی می‌کنند، در موقعیت‌هایی که باید ساکت بمانند بی‌قرار هستند و بیش‌از حد صحبت می‌کنند. آن‌ها همچنین معمولاً منتظر نمی‌مانند تا نوبتشان برسد و به سرعت پاسخ می‌دهند و مزاحم دیگران می‌شوند. لازم است این علائم قبل از ۱۲ سالگی شروع شده باشند و در دو یا چند حوزه از زندگی فرد مانند مدرسه، محل کار و خانه مشاهده شوند. همچنین علائم باید تا حدی شدید باشند که بر عملکرد روزمره فرد تأثیر منفی بگذارند. تشخیص

قطعی ADHD توسط متخصص‌ها با انجام ارزیابی‌های جامع شامل مصاحبه‌های بالینی، پرسشنامه‌ها و آزمون‌های روان‌شناختی صورت می‌گیرد. این فرآیند به افتراق علائم ADHD از سایر اختلال‌ها و تجویز درمان مناسب کمک می‌کند [6].

برای تشخیص ADHD، متخصص‌ها از مجموعه‌ای از ابزارهای استاندارد و متداول استفاده می‌کنند. این ابزارها کمک می‌کند تا علائم و نشانه‌های این اختلال را به‌طور جامع ارزیابی کنند. یکی از رایج‌ترین ابزارهای تشخیصی، مصاحبه‌های بالینی است. در این مصاحبه‌ها، متخصص با فرد مبتلا و اطرافیان او گفت‌وگو می‌کند تا درک کاملی از سیر تاریخیچه علائم، شدت آن‌ها و تأثیر آن‌ها بر زندگی روزمره به دست آورد. این مصاحبه‌ها همچنین به شناسایی نقاط قوت و ضعف فرد و عوامل محیطی مؤثر کمک می‌کند. علاوه بر مصاحبه‌ها، پرسشنامه‌های استاندارد نیز ابزار مهمی در تشخیص ADHD هستند. این پرسشنامه‌ها که توسط والدین، معلمان و خود فرد تکمیل می‌شوند، میزان بروز علائم را در زمینه‌های مختلف ارزیابی می‌کنند. نتایج این پرسشنامه‌ها به متخصص کمک می‌کند تا نقاط ضعف و قوت فرد را شناسایی و تشخیص دقیق‌تری ارائه دهد. همچنین انجام آزمون‌های روان‌شناختی بخش مهمی از فرآیند تشخیص ADHD است. این آزمون‌ها به ارزیابی توانایی‌های شناختی فرد مانند توجه، حافظه و کنترل تکانه می‌پردازند. نتایج این آزمون‌ها به متخصص کمک می‌کند تا الگوی منحصر به فرد علائم هر فرد را مشخص کند.

از سویی دیگر، تصویربرداری مغزی با استفاده از تصویربرداری تشدید مغناطیسی (MRI)<sup>1</sup> و همچنین ثبت سیگنال‌های الکتروانسفالوگرافی (EEG)<sup>2</sup> می‌توانند نقش مهمی در تشخیص ADHD داشته باشند. MRI مغز می‌تواند تفاوت‌های ساختاری و عملکردی مغز در افراد مبتلا به ADHD را نسبت به افراد سالم نشان دهد. در افراد مبتلا به ADHD، مطالعه‌ها نشان داده‌اند که برخی مناطق مغز مانند قشر پیش‌پیشانی، هسته‌های قاعده‌ای و مخچه کوچک‌تر یا کم‌تر فعال هستند. این تفاوت‌های ساختاری و عملکردی می‌توانند به‌عنوان نشانگرهای زیستی برای تشخیص ADHD مورد استفاده قرار گیرند. همچنین MRI می‌تواند به شناسایی علل زمینه‌ای احتمالی ADHD مانند آسیب‌های مغزی کمک کند [7].

در مقابل، ثبت سیگنال‌های EEG می‌تواند الگوهای غیرطبیعی فعالیت مغزی در افراد مبتلا به ADHD را نشان دهد. در افراد مبتلا به ADHD، مطالعه‌ها نشان داده‌اند که الگوهای موج مغزی آن‌ها می‌تواند تفاوت‌هایی با افراد سالم داشته باشد، مانند افزایش موج‌های کُند و کاهش موج‌های تند. این الگوهای خاص فعالیت مغزی می‌توانند به‌عنوان

<sup>1</sup> Magnetic Resonance Imaging

<sup>2</sup> Electroencephalogram

نشانگرهای زیستی برای تشخیص ADHD استفاده شوند. همچنین EEG می‌تواند کمک کند تا تفاوت‌های فردی در الگوهای فعالیت مغزی افراد مبتلا به ADHD شناسایی شود.

در مجموع ترکیب اطلاعات به‌دست‌آمده از MRI و سیگنال‌های EEG می‌تواند به متخصص‌ها در تشخیص دقیق‌تر ADHD و شناسایی زیرگروه‌های مختلف این اختلال کمک کند. این اطلاعات همچنین می‌توانند در طراحی درمان‌های مبتنی بر مکانیسم‌های عصب‌شناختی مؤثر باشند. در نتیجه استفاده از ابزارهای تصویربرداری و سیگنال مغزی نقش مهمی در فهم و تشخیص بهتر ADHD ایفا می‌کنند. در مجموع ترکیب این ابزارهای تشخیصی به متخصص‌ها اجازه می‌دهد تا تصویر کامل‌تری از وضعیت فرد به دست آورند و تشخیص صحیح‌تری ارائه دهند. این امر به نوبه خود به تجویز درمان مناسب و مدیریت مؤثرتر علائم کمک می‌کند [8].

این پژوهش با تمرکز بر مقاله‌های پژوهشی انگلیسی‌زبان منتشرشده در یک بازه زمانی ۴ ساله (۲۰۲۰-۲۰۲۴) به بررسی و تحلیل رویکردهای مبتنی بر DL برای تشخیص ADHD پرداخته است. این مطالعه مروری به‌طور جامع به بررسی آخرین دستاوردها و پیشرفت‌های حوزه تشخیص ADHD با استفاده از رویکردهای DL می‌پردازد. ضمن معرفی اصول کلیدی DL و کاربردهای آن در تحلیل داده‌های عصبی-شناختی، مطالعه‌های موردی متعددی در این زمینه مورد بررسی و ارزیابی قرار خواهد گرفت. همچنین چالش‌ها و محدودیت‌های موجود در این حوزه پژوهشی نیز مورد بحث و تحلیل قرار می‌گیرد تا مسیرهای آینده پژوهشی در این زمینه مشخص شود.

در این مقاله ابتدا به بررسی چگونگی استفاده از روش‌های DL برای شناسایی ویژگی‌های مرتبط با ADHD پرداخته خواهد شد. سپس به معرفی مدل‌های پیشرفته DL و کاربرد آن‌ها در تشخیص ADHD پرداخته می‌شود. در ادامه مزایای استفاده از DL در تشخیص ADHD مورد بحث و تحلیل قرار می‌گیرد. در نهایت به بررسی چالش‌ها و محدودیت‌های موجود در این زمینه و همچنین آینده پژوهش‌های مرتبط با آن پرداخته می‌شود.

## ۲- رویکرد DL

DL 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 به‌صورت خودکار ویژگی‌های مفید را از داده‌های خام استخراج کنند. در DL، 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 [5].

در مقایسه با رویکردهای سنتی ML که نیاز به استخراج ویژگی‌های دستی داشتند، DL امکان یادگیری خودکار این ویژگی‌ها را از طریق آموزش بر روی داده‌های خام فراهم می‌کند. این مزیت باعث شده است که DL در بسیاری از زمینه‌ها مانند بینایی ماشین، پردازش زبان طبیعی و تشخیص پزشکی کاربردهای گسترده‌ای پیدا کند [9]. در حوزه تشخیص ADHD رویکردهای مبتنی بر DL به‌طور فزاینده‌ای مورد توجه قرار گرفته‌اند. این مدل‌ها می‌توانند به صورت خودکار ویژگی‌های حرکتی، شناختی و رفتاری مرتبط با ADHD را از داده‌های ویدئویی، صوتی و متنی استخراج کرده و بر اساس آن‌ها تشخیص را انجام دهند. عملکرد این مدل‌ها در برخی مطالعه‌ها 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 باقی‌مانده‌اند که نیاز به پژوهش‌های بیشتری در این زمینه دارند [10].

در مجموع DL 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 [9], [5].

## ۲-۱- اهمیت DL در تشخیص ADHD

DL نقش بسیار مهمی در بهبود تشخیص ADHD ایفا می‌کند. این روش‌های پیشرفته تحلیل داده، قادر به شناسایی الگوهای پیچیده و نشانه‌های ظریف هستند که ممکن است توسط متخصص‌های بالینی معمولی نادیده گرفته شوند. با استفاده از DL، تشخیص ADHD قابل اعتمادتر خواهد بود. همچنین مدل‌های DL می‌توانند نشانه‌های زودرس این اختلال را شناسایی کنند و تشخیص را در مراحل اولیه ارائه دهند. این امر به مداخله به‌موقع و درمان مؤثر کمک می‌کند و از پیشرفت اختلال و ایجاد عوارض ثانویه جلوگیری می‌کند. بسیاری از افراد مبتلا به ADHD در سنین ۷ تا ۱۲ سال تشخیص داده می‌شوند، اما با استفاده از DL می‌توان این اختلال را در سنین پایین‌تر شناسایی کرد [11].

علاوه بر این، روش‌های DL قادر به تحلیل چندبُعدی داده‌های مختلف مانند اطلاعات عصب‌شناختی، ژنتیکی و رفتاری هستند. این امر به کشف الگوهای پیچیده و همبستگی‌های پنهان بین این داده‌ها کمک می‌کند و به متخصص‌ها در ایجاد تصویری جامع و دقیق‌تر از ADHD یاری می‌رساند. درنهایت با به‌کارگیری DL، می‌توان درمان‌های سفارشی‌شده‌ای برای هر فرد مبتلا به ADHD طراحی کرد که متناسب با نیازهای خاص او باشد. این امر به مدیریت

و درمان مؤثرتر این اختلال کمک می‌کند و کیفیت زندگی بیماران را بهبود می‌بخشد. در مجموع DL به‌طور چشمگیری به بهبود صحت تشخیص، تشخیص زودهنگام، تحلیل چندبُعدی و درمان سفارشی‌شده ADHD کمک می‌کند. این پیشرفت‌های فناورانه به متخصص‌های بالینی در مدیریت مؤثرتر این اختلال یاری می‌رساند [3].

### ۳- چهارچوب عمومی و رویکردهای پرکاربرد DL

#### ۳-۱- رویکرد شبکه‌های عصبی عمیق

در حوزه تشخیص ADHD، رویکردهای مبتنی بر شبکه‌های عصبی عمیق در سال‌های اخیر توجه زیادی را به خود جلب کرده‌اند. این روش‌ها با استفاده از قابلیت‌های DL و پردازش داده‌های پیچیده، می‌توانند به‌طور مؤثرتری الگوها و ویژگی‌های مرتبط با ADHD را در داده‌های تصویربرداری مغز و سیگنال‌های EEG شناسایی کنند. یکی از کاربردهای مهم شبکه‌های عصبی عمیق در تشخیص خودکار ADHD به کمک MRI مغز است. در این رویکرد، شبکه‌های عصبی عمیق با آموزش بر روی مجموعه داده‌های MRI افراد مبتلابه ADHD و افراد سالم، می‌توانند الگوهای ساختاری و عملکردی مغز مرتبط با این اختلال را شناسایی کنند. این الگوها می‌توانند شامل تفاوت‌های حجم، ضخامت و فعالیت نواحی مختلف مغز باشد. شبکه‌های عصبی عمیق با قابلیت تشخیص این الگوها در تصاویر جدید، می‌توانند به‌طور خودکار افراد مبتلابه ADHD را از افراد سالم تشخیص دهند [12].

همچنین شبکه‌های عصبی عمیق می‌توانند در تحلیل سیگنال‌های EEG نیز به کار گرفته شوند. شبکه‌های عصبی عمیق با آموزش بر روی الگوهای موج مغزی افراد مبتلابه ADHD و افراد سالم، می‌توانند ویژگی‌های خاص فعالیت مغزی مرتبط با این اختلال را استخراج کنند. این ویژگی‌ها می‌توانند شامل تفاوت‌های در توان طیفی موج‌های مغزی، ارتباطات بین نواحی مختلف مغز و الگوهای هم‌زمانی فعالیت مغزی باشد. با استفاده از این ویژگی‌ها، شبکه‌های عصبی عمیق می‌توانند به‌طور خودکار افراد مبتلابه ADHD را از افراد سالم تشخیص دهند [13].

فراتر از تشخیص خودکار، شبکه‌های عصبی عمیق می‌توانند در زمینه‌های دیگری نیز در حوزه ADHD کاربرد داشته باشند. برای مثال، این رویکردها می‌توانند در طبقه‌بندی زیرگروه‌های مختلف ADHD، پیش‌بینی پاسخ به درمان و حتی طراحی درمان‌های سفارشی‌شده برای هر فرد مبتلابه کار گرفته شوند. در مجموع استفاده از شبکه‌های عصبی عمیق در تحلیل داده‌های تصویربرداری و سیگنال مغزی، پتانسیل بالایی برای پیشرفت در تشخیص و درمان ADHD دارد [14].



### ۲-۳- رویکردهای یادگیری تقویتی عمیق

در سال‌های اخیر در حوزه تشخیص و درمان ADHD، رویکردهای یادگیری تقویتی عمیق موردتوجه قرار گرفته‌اند. این روش‌ها با ترکیب قابلیت‌های DL و یادگیری تقویتی، می‌توانند به‌طور مؤثری به مسائل پیچیده حوزه ADHD پاسخ دهند.

یکی از کاربردهای مهم یادگیری تقویتی عمیق، طراحی سامانه‌های تصمیم‌گیری هوشمند برای انتخاب بهترین درمان برای هر فرد مبتلا به ADHD است. در این رویکرد، سامانه‌های یادگیری تقویتی عمیق با مدل‌سازی پویای اثرات درمان‌های مختلف بر روی بیماران و به‌کارگیری راهبردهای بهینه‌سازی، می‌توانند درمان‌های سفارشی شده را برای هر بیمار پیشنهاد دهند. این سامانه‌ها با دریافت داده‌های بیمار مانند سوابق پزشکی، نتایج آزمایش‌ها و پاسخ به درمان‌های قبلی و همچنین با تعریف پاداش‌هایی برای بهبود علائم بیماری و کاهش عوارض جانبی درمان، می‌توانند به‌طور خودکار و سریع بهترین درمان را برای هر بیمار تشخیص دهند.

همچنین یادگیری تقویتی عمیق می‌تواند در طراحی سامانه‌های هوشمند برای پایش وضعیت روانی بیماران ADHD نیز به کار گرفته شود. در این رویکرد، سامانه‌های یادگیری تقویتی با دریافت داده‌های مختلف مانند فعالیت مغزی، رفتار و سایر اطلاعات بیمار در زندگی روزمره، می‌توانند به‌صورت پویا وضعیت تغییرات علائم بیماری را تحلیل کنند. این سامانه‌ها با استفاده از الگوریتم‌های بهینه‌سازی، می‌توانند به‌طور خودکار تصمیم‌گیری کرده و اقدام‌های درمانی مناسب را پیشنهاد دهند، به‌طوری‌که علائم بیماری در بهترین وضعیت ممکن کنترل شود.

فراتر از این کاربردها، یادگیری تقویتی عمیق می‌تواند در طبقه‌بندی زیرگروه‌های مختلف ADHD، پیش‌بینی پاسخ به درمان و حتی طراحی تمرین‌های شناختی سفارشی شده نیز به کار گرفته شود. در مجموع استفاده از این رویکردهای هوشمند مبتنی بر یادگیری تقویتی عمیق، پتانسیل بالایی برای بهبود تشخیص و درمان ADHD دارد [7].

### ۳-۳- رویکردهای DL ترکیبی

در حوزه تشخیص و درمان ADHD، رویکردهای DL ترکیبی نیز در سال‌های اخیر موردتوجه قرار گرفته‌اند. این روش‌ها با ترکیب مزایای چندین رویکرد DL، می‌توانند به‌طور مؤثرتری به مسائل پیچیده حوزه ADHD پاسخ دهند. یکی از مهم‌ترین کاربردهای DL ترکیبی در این حوزه، طراحی سامانه‌های تشخیصی پیشرفته است. در این رویکرد،

ترکیبی از شبکه‌های عصبی متنوع مانند شبکه‌های عصبی پیچشی (CNN<sup>۱</sup>)، شبکه‌های عصبی بازگشتی<sup>۲</sup> و شبکه‌های عصبی روبه‌جلو به کار گرفته می‌شوند تا جنبه‌های مختلف داده‌های بیمار مانند تصاویر مغزی، داده‌های زیست‌سنجی و داده‌های جمع‌آوری شده از رفتار روزمره را به‌طور هم‌زمان مدل‌سازی کنند. این سامانه‌های DL ترکیبی با بررسی الگوهای پیچیده در داده‌ها، می‌توانند صحت و قدرت تشخیص ADHD را به‌طور چشمگیری افزایش دهند [15].

همچنین DL ترکیبی می‌تواند در طراحی سامانه‌های پیش‌بینی پاسخ به درمان نیز مورداستفاده قرار گیرد. در این رویکرد، ترکیبی از مدل‌های DL باقابلیت‌های مختلف مانند بازشناسی الگو، تحلیل سری‌های زمانی و پردازش داده‌های چندوجهی به کار گرفته می‌شوند تا بتوانند با صحت بالا پاسخ بیماران به درمان‌های مختلف را پیش‌بینی کنند. این سامانه‌های هوشمند می‌توانند به پزشکان در انتخاب بهترین درمان برای هر بیمار کمک کنند [11].

فراتر از این کاربردها، DL ترکیبی می‌تواند در طراحی سامانه‌های کمکی هوشمند برای بهبود کیفیت زندگی بیماران ADHD نیز به کار گرفته شود. در این رویکرد، مدل‌های DL باقابلیت‌های متنوع مانند پردازش زبان طبیعی، تحلیل رفتار و تشخیص الگوهای مغزی ترکیب می‌شوند تا بتوانند به‌طور هوشمندانه‌تری نیازهای روزمره بیماران را شناسایی کرده و راهکارهای مناسب را ارائه دهند.

در مجموع، استفاده از رویکردهای DL ترکیبی پتانسیل بالایی برای بهبود تشخیص، درمان و کیفیت زندگی بیماران مبتلا به ADHD دارد [8].

### ۳-۴- رویکردهای DL چندوجهی

رویکرد DL چندوجهی یک روش پیشرفته در حوزه ML است که به درک و تحلیل اطلاعات از طریق ترکیب چندین منبع داده می‌پردازد. این رویکرد در مقابل رویکردهای سنتی ML که معمولاً بر روی یک نوع داده خاص متمرکز می‌شوند، قادر است اطلاعات مختلف را به‌صورت هم‌زمان پردازش و ادغام کند. اساس کار این رویکرد بر این اصل استوار است که ترکیب انواع مختلف اطلاعات (مانند تصاویر، متون، صداها و سایر داده‌های مرتبط) می‌تواند به درک عمیق‌تر و جامع‌تری از پدیده مورد مطالعه منجر شود. این امر به‌ویژه در حوزه‌های پیچیده مانند تشخیص اختلال‌های روانی، بسیار کاربردی است [16].

<sup>۱</sup> Convolutional neural network

<sup>۲</sup> Recurrent neural network

به‌طور مثال، در مورد ADHD، مدل‌های DL چندوجهی می‌توانند با استفاده از ترکیب داده‌هایی چون تصاویر مغزی، تحلیل رفتار و گفتار بیماران، اطلاعات بالینی و سوابق پزشکی، به تصویری جامع‌تر از این اختلال دست یابند. این امر به تشخیص دقیق‌تر و زود هنگام‌تر این اختلال کمک می‌کند. همچنین، این رویکرد با بهره‌گیری از پیشرفت‌های اخیر در حوزه‌های مختلف هوش مصنوعی مانند DL، پردازش زبان طبیعی و پردازش سیگنال‌های بیولوژیکی، توانایی تحلیل و استخراج الگوهای پیچیده را افزایش داده است [5].

در مجموع، رویکرد DL چندوجهی با ادغام اطلاعات چندگانه، امکان تحلیل عمیق‌تر و جامع‌تر پدیده‌های پیچیده را فراهم می‌آورد که در حوزه‌های مختلفی از جمله تشخیص اختلال‌های روانی کاربرد فراوانی دارد.

#### ۴- روش‌ها و مدل‌های DL ارائه شده برای تشخیص ADHD

در [10] روشی را برای تفسیر خروجی یک سامانه تشخیص ADHD مبتنی بر هوش مصنوعی در جمعیت‌های طبقه‌بندی شده بر اساس سن و جنسیت پیشنهاد کرده‌اند. سامانه آن‌ها بر اساس تحلیل رکوردهای فعالیت ۲۴ ساعته با استفاده از CNNها برای طبقه‌بندی طیف‌نگارهای پنجره‌های فعالیت است. این پنجره‌ها با استفاده از نقشه‌های انسداد تفسیر می‌شوند تا الگوهای زمان-فرکانس را توضیح دهند که نشان‌دهنده فعالیت ADHD هستند. نتایج این پژوهش تفاوت قابل توجهی در الگوهای فرکانس مغزی بین افراد دارای ADHD و افراد سالم در هر دو حالت روزانه و فعالیت شبانه نشان می‌دهد.

در [17] از DL برای طبقه‌بندی ADHD استفاده نمودند. روش آن‌ها شامل ۳ بخش است: (۱) کانال جداگانه CNN - RNN با توجه (ASCRNN)، (۲) کانال جداگانه CNN - RNN انتساع با توجه (ASDRNN)، (۳) کانال جداگانه CNN - RNN - برش با توجه (ASSRNN). نتایج حاصل نشان می‌دهد که روش آن‌ها با صحت ۷۰٫۴۶ درصد قابلیت تشخیص ADHD را دارد. همچنین در [18] رویکردی ترکیبی متشکل از روش‌های ML، شبکه‌های عصبی عمیق و یادگیری گروهی ارائه نمودند. روش آن‌ها از داده‌های بالینی برای تشخیص ADHD استفاده می‌کند. در نهایت نتایج نشان می‌دهد روش آن‌ها قادر است ADHD را با صحت ۹۵ درصد شناسایی نماید.

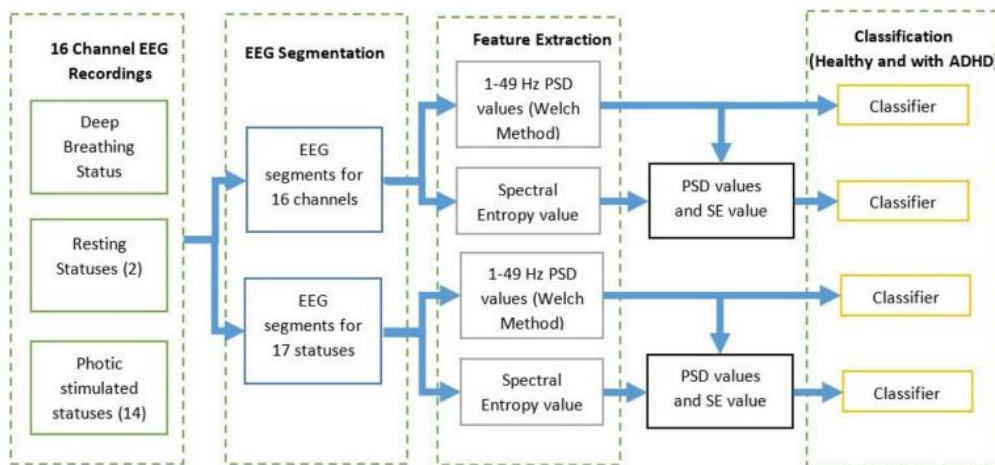
در [19] یک روش یادگیری عمیق با کمک CNNهای ۴ بُعدی ارائه شده است که بر اساس تغییرات مشتق در آنتروپی آموزش داده شده و می‌تواند دانه‌بندی را در سطح

درشت با روی هم قرار دادن لایه‌ها محاسبه کند. نتایج نشان می‌دهد که روش قادر است ADHD را با صحت ۷۱,۳ درصد تشخیص دهد.

در [20] یک ابزار تشخیص عینی برای ADHD با استفاده از سیگنال‌های EEG ارائه نمودند. در روش آن‌ها، سیگنال‌های EEG با تجزیه حالت محلی قوی و حالت متغیر به زیر باندها تجزیه می‌شوند. در نهایت این زیر باندها به‌عنوان ورودی به شبکه عصبی عمیق داده می‌شوند. نتایج نشان می‌دهد روش آن‌ها قادر است با صحت طبقه‌بندی بالای ۸۷ درصد و نیز صحت کلی بالای ۹۵ درصد در تشخیص مؤثر باشد.

در [4] یک رویکرد برای شناسایی مناطق مغزی که ADHD را با استفاده از EEG و DL به بهترین نحو طبقه‌بندی می‌کنند، ارائه شده است. روش آن‌ها در ابتدا مرحله پیش‌پردازش و حذف نویز را طی می‌کند، سپس زیرمجموعه‌های مختلفی از کانال‌های EEG تولید می‌کنند و به‌عنوان ورودی به شبکه عصبی عمیق می‌دهند. در نهایت از روش‌های مختلف انتخاب ویژگی برای تشخیص اختلال استفاده می‌شود. نتایج نشان می‌دهد روش آن‌ها قادر است ADHD را با صحت حدود ۸۲ درصد تشخیص دهد.

در [21] یک روش مبتنی بر LSTM ارائه شده است که می‌تواند ADHD را با صحت ۸۸,۸۸ درصد شناسایی نماید. اثرات محرک‌های نوری در فرکانس‌های مختلف و در کانال‌های مختلف در تشخیص ADHD مورد تحلیل قرار گرفته است. هدف اصلی پژوهش آن‌ها نشان دادن مؤثرترین کانال و وضعیت ثبت برای تشخیص ADHD است. به این ترتیب داده EEG را می‌توان از کانال‌های مؤثر و وضعیت‌های ثبت به دست آورد و طبقه‌بندی ADHD را می‌توان با کانال‌های کمتر و صحت بالاتر انجام داد. شکل ۱ نحوه عملکرد روش آن‌ها را نشان می‌دهد.



شکل ۱: چارچوب روش پژوهش در [21] برای تشخیص ADHD به کمک LSTM

در [8] یک الگوریتم مبتنی بر DL را برای شناسایی کودکان دارای دو اختلال اُتیسْم و ADHD ارائه شده است. روش آن‌ها یک رویکرد ترکیبی CNN و حافظه کوتاه‌مدت دو جهته برای تعیین کودکان مبتلابه ADHD که دارای اختلال اُتیسْم است. نتایج نشان می‌دهد که روش آن‌ها قادر است این اختلال‌ها را با صحت حدود ۹۴ درصد شناسایی نماید. در [16] روشی مبتنی بر CNN تک بُعدی برای تشخیص و طبقه‌بندی ADHD ارائه نمودند. روش آن‌ها از تابع نگاشت فعال‌سازی گرادیان برای برجسته‌سازی ویژگی‌های مهم ECG استفاده می‌کند. نتایج نشان می‌دهد که روش آن‌ها در تشخیص ADHD با صحت طبقه‌بندی ۹۶,۰۴ درصد مؤثر است.

در [9] مدل DL متشکل از لایه‌های پیچشی، pooling، حافظه کوتاه‌مدت دو جهته و لایه‌های تماماً متصل برای طبقه‌بندی ADHD ارائه شده است. روش آن‌ها از طبقه‌بندهای پرکاربرد ML نظیر ماشین بردار پشتیبان (SVM)<sup>1</sup> و تحلیل تفکیک خطی (LDA)<sup>2</sup> استفاده می‌کند. نتایج نشان می‌دهد که روش قادر است ADHD را با صحت ۹۵,۵۴ درصد طبقه‌بندی نماید. در [22] یک استراتژی برای ادغام داده‌های چندوجهی و یک مدل یادگیری گروهی برای تشخیص ADHD ارائه شده است. برای پیاده‌سازی بخش یادگیری گروهی از ترنسفورهای سه‌بُعدی استفاده شده است. نتایج نشان می‌دهد که روش آن‌ها قادر است این اختلال را با صحت ۷۴,۵ درصد تشخیص دهد.

در [23] یک معماری DL پایان به پایان برای تشخیص ADHD پیشنهاد شده است. هدف آن‌ها این بود که به‌طور خودکار شخص را به‌عنوان ADHD یا کنترل سالم طبقه‌بندی کنند و همچنین صحت طبقه‌بندی را افزایش دهند. روش آن‌ها که DeepFMRI نام دارد از سه شبکه متوالی تشکیل شده است، یعنی (۱) یک استخراج‌کننده ویژگی، (۲) یک شبکه اتصال عملکردی و (۳) یک شبکه طبقه‌بندی. این مدل سیگنال‌های سری زمانی از پیش پردازش شده MRI عملکردی (fMRI) را به‌عنوان ورودی و خروجی تشخیص می‌گیرد و با استفاده از انتشار برگشتی آموزش داده می‌شود. نتایج نشان می‌دهد که این روش قادر است ADHD را با صحت ۷۳,۱ درصد تشخیص دهد.

در [24] یک سیستم بازی برای غربالگری و تشخیص ADHD کودکان ابداع شده است. برای این منظور داده‌های اسکلت کودکان با استفاده از پنج واحد کینکت Azure مجهز به حسگرهای عمق در حین انجام بازی حاصل شده است. بازی تشخیص غربالگری شامل یک ربات است که ابتدا در یک مسیر خاص حرکت می‌کند، پس‌از آن کودک باید مسیری را که ربات طی کرده به خاطر بیاورد و سپس آن را دنبال کند. داده‌های اسکلت مورد استفاده در این مطالعه به دو دسته تقسیم می‌شوند: داده‌های آماده‌به‌کار، زمانی که کودک منتظر می‌ماند و ربات مسیر را نشان می‌دهد و داده‌های بازی، زمانی که کودک بازی می‌کند به دست می‌آید. داده‌های به‌دست‌آمده با استفاده از الگوریتم‌های

<sup>1</sup> Support Vector Machine

<sup>2</sup> Linear discriminant analysis

GRU, RNN و LSTM طبقه‌بندی شدند. در این میان، یک الگوریتم LSTM با استفاده از یک لایه دوطرفه و یک تابع هدر رفت متقابل آنتروپی وزنی، صحت طبقه‌بندی ۹۷٫۸۲ درصد را به دست آورد.

در [25] اظهار نمودند که ADHD یک اختلال ناهمگون است که تأثیر مخربی بر رشد عصبی مغز دارد. بیماران ADHD ترکیبی از بی‌توجهی، تکانش‌گری و بیش‌فعالی را نشان می‌دهند. با درمان و تشخیص زودهنگام، پتانسیل اصلاح اتصال‌های عصبی و بهبود علائم وجود دارد. باین‌حال، ماهیت ناهمگون ADHD، همراه با بیماری‌های همراه آن و کمبود پزشکان تشخیصی در جهان، به این معنی است که تشخیص ADHD اغلب به تأخیر می‌افتد. از این‌رو، در نظر گرفتن سایر مسیرها برای بهبود کارایی تشخیص زودهنگام از جمله نقش هوش مصنوعی مهم است. در این پژوهش انواع روش‌های ارائه‌شده برای تشخیص ADHD بر اساس ابزار تشخیصی آن‌ها به‌عنوان MRI، سیگنال‌های فیزیولوژیکی، پرسشنامه‌ها، شبیه‌سازی و آزمون عملکرد و داده‌های حرکتی دسته‌بندی شدند و شکاف‌های پژوهشی که شامل کمبود پایگاه داده در دسترس عموم برای همه روش‌های ارزیابی ADHD به‌غیر از MRI و همچنین عدم تمرکز بر استفاده از داده‌های دستگاه‌های پوشیدنی برای تشخیص ADHD، مانند الکتروکاریوگرافی (ECG)<sup>۱</sup>، فتوپلتیسموگراف (PPG)<sup>۲</sup> و داده‌های حرکتی است، برطرف شدند.

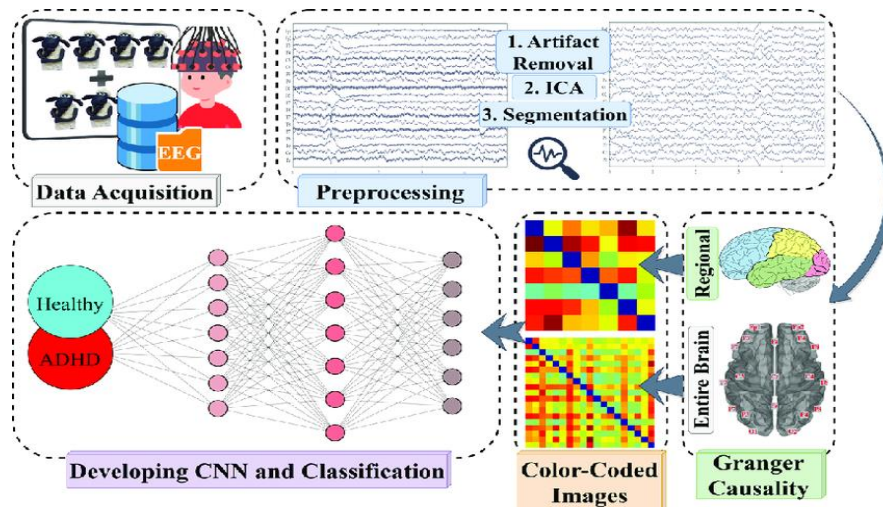
در [26] یک روش ابتکاری معرفی شده که از علیت گرنجر (GC)<sup>۳</sup> که یک روش تحلیل اتصال مغزی به‌خوبی تثبیت شده است برای کاهش الکترودهای EEG موردنیاز استفاده می‌کند. آن‌ها شاخص‌های GC (GCI)<sup>۴</sup> را برای کل مغز و مناطق خاص مغز، که به‌عنوان GCI منطقه‌ای شناخته می‌شوند، در باندهای فرکانسی مختلف محاسبه نمودند. متعاقباً این GCIها به تصاویر کد رنگی تبدیل شده و به یک CNN با ۱۱ لایه‌ای سفارشی داده‌شده‌اند. مدل آن‌ها از طریق اعتبارسنجی متقاطع پنج دسته‌ای ارزیابی شد و بالاترین صحت ۹۹٫۸۰ درصد در باند فرکانس گاما برای کل مغز و صحت ۹۸٫۵۰ درصد در تشخیص باند فرکانس تتا در نیمکره راست به دست آمد. شکل ۲ ساختار روش آن‌ها را نشان می‌دهد.

<sup>1</sup> Electrocardiogram

<sup>2</sup> Photoplethysmogram

<sup>3</sup> Granger causality

<sup>4</sup> Granger causality Index



شکل ۲: ساختار روش ارائه‌شده در [26] مبتنی بر GC و روش تحلیل اتصال مغزی

در [27] از دو اندازه‌گیری متمایز اتصال عملکردی مغز برای ارزیابی رویکرد تشخیص ADHD استفاده شده است. در این پژوهش از شش طبقه‌بندی‌کننده رایج برای تمایز بین کودکان مبتلابه ADHD و افراد سالم استفاده شده است. بر اساس تحلیل مبتنی بر فاز، این مطالعه دو نشانگر زیستی را پیشنهاد می‌کند که کودکان مبتلابه ADHD را از افراد سالم با صحت قابل توجه ۹۹,۱۷۴ درصد متمایز می‌کند. یافته‌های این پژوهش نشان می‌دهد که محوریت زیرگراف اتصال مغزی شاخص تأخیر فاز در باند فرکانس بتا و دلتا می‌تواند یک نشانگر زیستی امیدوارکننده برای تشخیص ADHD باشد.

همچنین در [14] رویکردی ترکیبی متشکل از استخراج ویژگی TFI و CNNها ارائه شده است. روش آنها از طبقه‌بند KNN برای تشخیص ADHD استفاده می‌کند. در این پژوهش داده‌های بعد از جمع‌آوری از پایگاه تحت مرحله پیش‌پردازش قرار می‌گیرند و برای مرحله استخراج ویژگی آماده می‌شوند. سپس در جهت تشخیص و طبقه‌بندی اختلال وارد CNN می‌شوند. نتایج صحت ۹۹,۷۵ درصد را گزارش می‌کند.


در [28] رویکردی ترکیبی متشکل از الگوریتم LRP و CNNها ارائه شده است. روش آنها متشکل از ۲ لایه پیچشی، ۲ لایه Maxpooling و ۲ لایه تماماً متصل است. نتایج صحت ۹۴,۵۲ درصد را گزارش می‌کند. در نهایت در [29] روشی مبتنی بر الگوریتم‌های DL که متشکل از CNNها و شبکه‌های عصبی مصنوعی می‌باشد، ارائه شده است که به تشخیص زودهنگام ADHD کمک می‌کند. در این روش از الگوریتم‌های ML مانند SVM، رگرسیون لجستیک، XGBoost، AdaBoost برای طبقه‌بندی ADHD استفاده می‌شود. نتایج صحت حدود ۹۹ درصد را

<sup>۱</sup> k-nearest neighbors

گزارش می‌کند. به طور خلاصه مقایسه صحت روش‌ها و مدل‌های ارائه‌شده مختلف برای تشخیص ADHD در جدول ۱ و شکل ۳ آورده شده است.

جدول ۱: مقایسه صحت روش‌ها و مدل‌های ارائه‌شده مختلف برای تشخیص ADHD

موجع	سال	روش	صحت (درصد)
[17]	۲۰۲۳	SCCNN-RNN	۷۰/۴۶
[18]	۲۰۲۳	ML+DNN+Ensamble learning	۹۵
[20]	۲۰۲۳	EEG + DL	۹۵
[4]	۲۰۲۴	EEG-MHCNet	۸۲
[8]	۲۰۲۳	CNN + Bi-LSTM	۹۴
[16]	۲۰۲۳	1-Dimensional CNN	۹۶/۰۴
[9]	۲۰۲۳	CNN+Pooling+ Bi-LSTM+Fully connected layers	۹۵/۵۴
[14]	۲۰۲۳	TFI Feature Extraction + CNN	۹۹/۷۵
[28]	۲۰۲۴	LRP + CNN	۹۴/۵۲
[29]	۲۰۲۳	CNN + ANN + ML Classifiers	۹۹
[19]	۲۰۱۹	4D CNN	۷۱/۳
[21]	۲۰۲۱	LSTM	۸۸/۸۸
[22]	۲۰۲۲	3D Transformer	۷۴/۵
[23]	۲۰۲۰	DeepFMRI	۷۳/۱
[24]	۲۰۲۲	RNN+LSTM	۹۷/۸۲
[26]	۲۰۲۳	11 Layers CNN + GCI	۹۹/۸
[27]	۲۰۲۳	Local graph features + Biomarkers	۹۹/۱۷۴



شکل ۳: مقایسه صحت روش‌ها و مدل‌های ارائه‌شده مختلف برای تشخیص ADHD



## ۵- چالش‌ها و محدودیت‌های رویکرد DL

رویکرد DL در حوزه تشخیص ADHD با چالش‌ها و محدودیت‌های مهمی روبرو است که باید مورد توجه قرار گیرند. یکی از مهم‌ترین چالش‌ها، دسترسی محدود به داده‌های کافی و جامع در این زمینه است. تشخیص ADHD نیازمند دسترسی به داده‌های گسترده و ثبت شده از بیماران است، اما به دلیل حساسیت موضوع و محرمانگی اطلاعات پزشکی، این امر دشوار است [11]. همچنین تغییرپذیری علائم ADHD در طول زمان و بین افراد مختلف یک محدودیت دیگر در این حوزه است. این تغییرپذیری می‌تواند بر آموزش و عملکرد مدل‌های DL تأثیر منفی بگذارد. عدم درک مکانیسم‌های زیربنایی و بیولوژیکی تشخیص ADHD توسط مدل‌های DL نیز چالشی دیگر است. این مدل‌ها اغلب به عنوان A جعبه سیاه عمل می‌کنند و علل زیربنایی تشخیص را به خوبی توضیح نمی‌دهند [11].

همبودی ADHD با سایر اختلال‌های روانی مانند اضطراب و افسردگی نیز یکی دیگر از محدودیت‌های استفاده از رویکرد DL در این حوزه است. این همبودی می‌تواند بر تشخیص صحیح ADHD توسط مدل‌ها تأثیر بگذارد. علاوه بر این در موضوع‌های حساس پزشکی مانند ADHD، پذیرش و اعتماد به تشخیص‌های ارائه شده توسط سامانه‌های هوش مصنوعی چالش برانگیز است. لزوم شفافیت و تفسیرپذیری تصمیم‌گیری مدل‌ها برای افزایش اعتماد و پذیرش نیز یک محدودیت مهم است [3].

در مجموع، هرچند رویکرد DL چندوجهی دارای پتانسیل بالایی برای تشخیص ADHD است، اما باید با در نظر گرفتن این چالش‌ها و محدودیت‌ها به صورت مسئولانه و جامع مورد استفاده قرار گیرد.

## ۶- بحث و نتیجه‌گیری و پیشنهادها برای آینده

نتایج حاصل از مرور مقاله‌ها در حوزه تشخیص ADHD با استفاده از رویکرد DL نشان می‌دهد که تشخیص این اختلال همواره چالش برانگیز بوده است. در این مقاله مروری به بررسی کاربرد روش‌های DL در تشخیص ADHD پرداخته شد. مطالعه‌ها نشان می‌دهند که روش‌های DL قادر به استخراج ویژگی‌های پیچیده از داده‌های تصویری، صوتی و سایر منابع داده می‌باشند و می‌توانند صحت تشخیصی بالاتری نسبت به روش‌های سنتی ارائه دهند.

نتایج این مطالعه حاکی از آن است که با استفاده از روش‌های DL، می‌توان الگوهای پیچیده در داده‌های مربوط به ADHD را شناسایی کرده و به تشخیص بهتر این اختلال کمک کرد. همچنین این روش‌ها قادر به شناسایی ویژگی‌های پنهانی هستند که ممکن است از طریق روش‌های سنتی قابل تشخیص نباشند. در مجموع به کارگیری DL در تشخیص ADHD می‌تواند به بهبود صحت تشخیص و در نتیجه ارائه درمان مناسب‌تر کمک کند.

همچنین نتایج حاصل از مرور مطالعه‌ها در حوزه تشخیص ADHD با استفاده از رویکرد DL نشان می‌دهد که چشم‌انداز آینده پژوهش در زمینه استفاده از DL برای تشخیص ADHD بسیار امیدوارکننده است و پتانسیل ایجاد پیشرفت‌های چشمگیر را در این حوزه دارد. دسترسی به مجموعه داده‌های غنی و جامع از بیماران مبتلابه ADHD یکی از عوامل کلیدی است که می‌تواند به درک بهتر مکانیسم‌های زیربنایی این اختلال کمک کند. همچنین، توسعه مدل‌های DL پیشرفته که قادر به شناسایی الگوهای متغیر و پیچیده علائم در طول زمان باشند، از اهمیت فوق‌العاده‌ای برخوردار است. به‌کارگیری این رویکردهای نوآورانه می‌تواند به تشخیص بهتر و به‌هنگام‌تر ADHD، کشف زیرگروه‌های مختلف بیماری و بهبود درمان این اختلال در آینده نزدیک کمک شایانی کند. این پیشرفت‌ها می‌توانند به بهبود کیفیت زندگی افراد مبتلابه ADHD و کاهش بار اجتماعی-اقتصادی ناشی از این اختلال منجر شوند. امیدوار است این مطالعه مروری، چشم‌اندازی جدید در زمینه تشخیص ADHD با استفاده از DL ارائه دهد و زمینه‌ساز پژوهش‌های بیشتر در این حوزه باشد.

آینده پژوهش در حوزه استفاده از DL برای تشخیص ADHD بسیار امیدوارکننده است و راهکارهای مهمی را در پیش رو دارد. اولین گام مهم، تلاش برای دسترسی به مجموعه داده‌های گسترده و جامع از بیماران مبتلابه ADHD خواهد بود. این مجموعه داده‌ها باید شامل اطلاعات پزشکی دقیق، علائم بالینی، سوابق درمانی و داده‌های طبی مرتبط باشد. با داشتن چنین پایگاه داده‌ای غنی، پژوهشگران قادر خواهند بود مدل‌های DL پیشرفته‌تری را توسعه دهند.

همچنین تمرکز بر درک بهتر مکانیسم‌های زیربنایی ADHD و ارتباط آن با نتایج تصویربرداری مغزی و داده‌های بیوشیمیایی، می‌تواند به ایجاد مدل‌های تفسیرپذیرتر و شفاف‌تر در تشخیص کمک کند. این امر نه تنها به درک بهتر بیماری کمک می‌کند، بلکه به افزایش اعتماد پزشکان و بیماران به تشخیص‌های ارائه‌شده توسط سامانه‌های هوش مصنوعی نیز منجر خواهد شد.

همچنین توسعه روش‌های DL که قادر به شناسایی الگوهای متغیر و پیچیده علائم ADHD در طول زمان باشند، یکی دیگر از مسیرهای آینده پژوهش در این حوزه است. این امر می‌تواند به تشخیص بهتر و به‌هنگام‌تر ADHD منجر شود. مدل‌های DL می‌توانند همچنین در زمینه تشخیص افتراقی ADHD از سایر اختلال‌های همراه کاربرد داشته باشند.

علاوه بر این، ادغام داده‌های چندگانه مانند داده‌های بالینی، تصویربرداری مغز، فعالیت الکتریکی مغز و داده‌های ژنتیکی در مدل‌های DL می‌تواند به تشخیص جامع‌تر و قدرتمندتر ADHD کمک کند. این رویکرد چندوجهی ممکن است به کشف زیرگروه‌های مختلف ADHD و بهبود صحت تشخیص منجر شود. در نهایت توسعه مدل‌های

DL با قابلیت تفسیرپذیری و توضیح‌دهندگی بالا، به‌منظور افزایش پذیرش و اعتماد پزشکان و بیماران به نتایج تشخیصی، از دیگر مسیرهای مهم آینده پژوهش در این حوزه خواهد بود.

## مراجع

- [1] S. Agarwal, A. Raj, A. Chowdhury, G. Aich, R. Chatterjee, and K. Ghosh, "Investigating the impact of standard brain atlases and connectivity measures on the accuracy of ADHD detection from fMRI data using deep learning," *Multimed Tools Appl*, vol. 83, no. 25, pp. 67023–67057, Jan. 2024, doi: 10.1007/s11042-023-17962-7.
- [2] E. Salah, M. Shokair, F. E. Abd El-Samie, and W. A. Shalaby, "Utilization of Deep Learning to Overcome the Effect of ADHD on Children," in *2023 3rd International Conference on Electronic Engineering (ICEEM)*, IEEE, 2023, pp. 1–5.
- [3] N. K. Iyortsuun, S.-H. Kim, M. Jhon, H.-J. Yang, and S. Pant, "A review of machine learning and deep learning approaches on mental health diagnosis," in *Healthcare*, MDPI, 2023, p. 285.
- [4] J. Sanchis, S. García-Ponsoda, M. A. Teruel, J. Trujillo, and I.-Y. Song, "A novel approach to identify the brain regions that best classify ADHD by means of EEG and deep learning," *Heliyon*, vol. 10, no. 4, 2024.
- [5] S. Aggarwal, N. Chugh, and A. Balyan, "Identification of ADHD Disorder in Children Using EEG Based on Visual Attention Task by Ensemble Deep Learning," in *Proceedings of International Conference on Data Science and Applications*, vol. 552, M. Saraswat, C. Chowdhury, C. Kumar Mandal, and A. H. Gandomi, Eds., in *Lecture Notes in Networks and Systems*, vol. 552, Singapore: Springer Nature Singapore, 2023, pp. 243–259, doi: 10.1007/978-981-19-6634-7\_18.
- [6] S. Abedian, G. S. Bajestani, H. Saeedi, and F. Makhlooghi, "Diagnosis of Adult ADHD Using EEG Signals Based on the Spectrogram and Convolutional Neural Networks," *Int. J. Comp. Intel. Appl.*, vol. 23, no. 01, p. 2350034, Mar. 2024, doi: 10.1142/S1469026823500347.
- [7] N. Chen and Y. Jiao, "Deep Learning of Automatic Encoder Based on Attention for ADHD Classification of Brain MRI," in *2023 7th International Conference on Biomedical Engineering and Applications (ICBEA)*, IEEE, 2023, pp. 11–14.
- [8] J. Shin *et al.*, "Identifying ADHD for children with coexisting ASD from fNIRs signals using deep learning approach," *IEEE Access*, 2023.

- [9] Ö. Kasim, "Identification of attention deficit hyperactivity disorder with deep learning model," *Phys Eng Sci Med*, vol. 46, no. 3, pp. 1081–1090, Sep. 2023, doi: 10.1007/s13246-023-01275-y.
- [10] P. Amado-Caballero, P. Casaseca-de-la-Higuera, S. Alberola-López, J. M. Andrés-de-Llano, J. A. López-Villalobos, and C. Alberola-López, "Insight into ADHD diagnosis with deep learning on Actimetry: Quantitative interpretation of occlusion maps in age and gender subgroups," *Artificial Intelligence in Medicine*, vol. 143, p. 102630, 2023.
- [11] X. Liu, "Detection and Classification of ADHD Using Deep Learning Based on EEG Signals," *Highlights in Science, Engineering and Technology*, vol. 91, pp. 191–199, 2024.
- [12] N. Chugh, S. Aggarwal, and A. Balyan, "The Hybrid Deep Learning Model for Identification of Attention-Deficit/Hyperactivity Disorder Using EEG," *Clin EEG Neurosci*, vol. 55, no. 1, pp. 22–33, Jan. 2024, doi: 10.1177/15500594231193511.
- [13] 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.
- [14] L. A. Jacob, K. S. Biju, U. Sangeetha, and S. Ramachandran, "ADHD detection based on time frequency image and deep-learning CNN from event-related EEG," 2023.
- [15] J. Sanchis, M. A. Teruel, and J. Trujillo, "Hyperparameter Tuning of a Deep Learning EEG-based Neural Network for the Diagnosis of ADHD," in *2023 IEEE International Conference on Big Data (BigData)*, IEEE, 2023, pp. 2719–2725.
- [16] H. W. Loh *et al.*, "Deep neural network technique for automated detection of ADHD and CD using ECG signal," *Computer methods and programs in biomedicine*, vol. 241, p. 107775, 2023.
- [17] B. Kim, J. Park, T. Kim, and Y. Kwon, "Finding essential parts of the brain in rs-fMRI can improve ADHD diagnosis using deep learning," *IEEE Access*, 2023.
- [18] M. Garcia-Argibay, Y. Zhang-James, S. Cortese, P. Lichtenstein, H. Larsson, and S. V. Faraone, "Predicting childhood and adolescent attention-deficit/hyperactivity disorder onset: a nationwide deep learning approach," *Molecular Psychiatry*, vol. 28, no. 3, pp. 1232–1239, 2023.
- [19] Z. Mao *et al.*, "Spatio-temporal deep learning method for adhd fmri classification," *Information Sciences*, vol. 499, pp. 1–11, 2019.

- [20] M. Y. Esas and F. Latifoğlu, "Detection of ADHD from EEG signals using new hybrid decomposition and deep learning techniques," *Journal of Neural Engineering*, vol. 20, no. 3, p. 036028, 2023.
- [21] M. Tosun, "Effects of spectral features of EEG signals recorded with different channels and recording statuses on ADHD classification with deep learning," *Phys Eng Sci Med*, vol. 44, no. 3, pp. 693–702, Sep. 2021, doi: 10.1007/s13246-021-01018-x.
- [22] Y. Qin, Y. Lou, Y. Huang, R. Chen, and W. Yue, "An Ensemble Deep Learning Approach Combining Phenotypic Data and fMRI for ADHD Diagnosis," *J Sign Process Syst*, vol. 94, no. 11, pp. 1269–1281, Nov. 2022, doi: 10.1007/s11265-022-01812-0.
- [23] A. Riaz, M. Asad, E. Alonso, and G. Slabaugh, "DeepFMRI: End-to-end deep learning for functional connectivity and classification of ADHD using fMRI," *Journal of neuroscience methods*, vol. 335, p. 108506, 2020.
- [24] W. Lee, D. Lee, S. Lee, K. Jun, and M. S. Kim, "Deep-learning-based ADHD classification using children's skeleton data acquired through the ADHD screening game," *Sensors*, vol. 23, no. 1, p. 246, 2022.
- [25] V. Khullar, K. Salgotra, H. P. Singh, and D. P. Sharma, "Deep Learning-Based Binary Classification of ADHD Using Resting State MR Images," *Augment Hum Res*, vol. 6, no. 1, p. 5, Dec. 2021, doi: 10.1007/s41133-020-00042-y.
- [26] 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.
- [27] F. Abedinzadeh Torghabeh, S. A. Hosseini, and Y. Modaresnia, "Potential biomarker for early detection of ADHD using phase-based brain connectivity and graph theory," *Phys Eng Sci Med*, vol. 46, no. 4, pp. 1447–1465, Dec. 2023, doi: 10.1007/s13246-023-01310-y.
- [28] 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.
- [29] M. A. Hamim, F. M. Tanmoy, O. Tasfia, and F. A. Juthi, "Attention deficit hyperactivity disorder detection using deep learning approach," in *2023 14th International Conference on Computing Communication and Networking Technologies (ICCCNT)*, IEEE, 2023, pp. 1–7.