



An Artificial Intelligence-Based Approach for Diagnosing ADHD in Children

F. Kabudvand^{*1}

¹ Computer Engineering Department, Islamic Azad University, Zanjan Branch, Zanjan, Iran.

ABSTRACT

Research PAPER

Received: 28 December 2024

Accepted: 24 March 2025

KEYWORDS:

ADHD,
deep learning,
self-encoding networks,
functional image segmentation,

In this paper, a method for diagnosing children with ADHD using the concept of deep learning and correlation analysis between divided regions of functional brain images is presented. The proposed method includes preprocessing medical images to remove distorted and noisy images, generating new functional brain images using autoencoders 2 to help better analyze medical images and solve the problem of medical image limitations; The proposed method uses image segmentation and creating separate networks to increase the accuracy of diagnosing the disease by calculating the total functional connections of the regions in each of the networks, and children with weaker functional connections, which leads to hyperactivity, can be detected.

¹ Corresponding author:

✉ kabudvand@iau.ir

نشریه تخصصی آرمان پردازش، دوره ۶، شماره ۱، بهار ۱۴۰۴



فصلنامه تخصصی آرمان پردازش
(APJ)

Homepage: www.armanprocessjournal.ir



ارائه راه کار مبتنی بر هوش مصنوعی جهت تشخیص بیماری ADHD در کودکان

فرزانه کبودوند^۱*

^۱ دانشکده مهندسی کامپیوتر، دانشگاه آزاد اسلامی، واحد زنجان، زنجان، ایران.

چکیده

در این مقاله، روشی جهت تشخیص بیماری کودکان مبتلا به بیش فعالی (ADHD) با استفاده از مفهوم یادگیری عمیق و تحلیل همبستگی بین نواحی تقسیم شده تصاویر عملکردی مغز ارائه می شود. روش پیشنهادی شامل پیش پردازش تصاویر پزشکی جهت حذف تصاویر مخدوش و نویز دار، تولید تصاویر جدید عملکردی مغز با استفاده از خودرمنگارها برای کمک به تحلیل بهتر تصاویر پزشکی و حل مشکل محدودیت تصاویر پزشکی می باشد؛ روش پیشنهادی با استفاده از قطعه بندی تصاویر و ایجاد شبکه هایی مجزا برای افزایش دقت تشخیص بیماری از طریق محاسبه مجموع اتصالات عملکردی مناطقی که در هر کدام از شبکه ها هستند می توان کودکانی را که اتصالات عملکردی ضعیف تری دارند و این منجر به بیش فعالی می شود را تشخیص داد.

مقاله پژوهشی

واژگان کلیدی:
بیماری ADHD،
یادگیری عمیق،
شبکه های خودرمنگار،
قطعه بندی عملکردی تصاویر،

۱. مقدمه

عنوان نمونه برای تشخیص دقیق تومورهای مغزی از قطعه‌بندی تصاویر پزشکی استفاده می‌شود. عمل قطعه‌بندی تومور تاثیر زیادی روی کیفیت تشخیص، روند پیشروی بیماری و رشد تومور دارد.

۲. پیشینه پژوهش

تاکنون شماری از گروه‌های تحقیقاتی به بررسی این بیماری با استفاده از روش‌های یادگیری عمیق همچنین گروهی دیگر از پژوهشگران به بررسی استفاده از مفهوم قطعه‌بندی تصاویر پزشکی در تشخیص بیماری‌های مختلف از جمله دیابت و سرطان پرداخته‌اند. در ادامه به بررسی مختصر برخی از این تحقیقات می‌پردازیم.

گروهی از پژوهشگران توانستند با تحلیل نواحی مغزی و ویژگی‌های یکنواختی نواحی مغز مناطقی که در افراد سالم و افراد مبتلا به ADHD متفاوت است را تا حدودی شناسایی کنند و از این طریق به جداسازی افراد سالم و بیمار پردازند [3]. گروهی دیگر از محققان با اندازه‌گیری شدت اتصالات عملکردی میان واکسل‌های موجود در هر ناحیه و نیز شدت اتصالات عملکردی میان نواحی مختلف مغز نشان داده شده است که کودکان مبتلا به بیماری ADHD در مناطق مربوط به مخچه، قشر آهیانه فوقانی مغز و نیز شبکه حالت پیش فرض مغز اتصالات عملکردی ضعیف تری دارند و در مناطق مربوط به عواطف و شور و شوق آنها اتصالات قوی تری وجود دارد [4]. شائوگوکوی و همکاران از داده‌های MRI مربوط به سال ۲۰۱۵ از مجموعه داده BarTs استفاده کرده‌اند آنها یک شبکه عصبی عمیق ایشاری را برای قطعه‌بندی تصاویر MRI مغزی را پیشنهاد دادند و به نتایج خوبی در تشخیص تومور مغزی دست یافتند [5]. گروهی از پژوهشگران نیز با استفاده از FMRI، الگوهای فعال سازی عصبی در نوجوانان مبتلا به ADHD، خواهر و برادران غیر مبتلا و افراد سالم را در طول انجام یک تکلیف بازداری پاسخ مقایسه کرده‌اند [6]. تحقیق دیگری نیز از شبکه‌های عصبی مصنوعی و داده‌های تست هوش بالینی برای تمایز بین انواع مختلف ADHD در کودکان و همچنین تمایز آنها از گروه کنترل استفاده کرده است [7].

در پژوهش انجام شده دیگری، از سیستم‌های دسته‌بندی یادگیر با استفاده از هوش مصنوعی با تکنیک‌های یادگیری مبتنی بر قواعد برای شناسایی بیماران قلبی استفاده شده است. این تکنیک‌ها بر پایه دو اصل اساسی یادگیری تقویتی و الگوریتم‌های تکاملی ژنتیک ساخته شده‌اند. پس از آموزش سیستم، تعدادی قانون باارزش تولید شده که در مرحله آزمون برای پیش‌بینی بیماران قلبی مورد استفاده قرار گرفته است. نتایج آزمایش‌ها نشان می‌دهد که با استفاده از سیستم دسته‌بندی یادگیر بر مبنای سبک می‌شینگان، شناسایی بیماران قلبی بهبود یافته و دقت پیش‌بینی به ۸۸ درصد افزایش یافته است؛ که این روش قادر

مغز انسان یکی از حساس‌ترین اعضای بدن است. فعالیت‌های مغز فقط به رفتارهای ساده حرکتی مثل راه رفتن یا خوردن محدود نمی‌شود. روش‌های مختلفی برای تشخیص بیماری‌های مغز از جمله FMRI¹ و EEG² استفاده می‌شود. ابزارهای متعددی برای مشاهده آناتومی و فیزیولوژی مغز وجود دارد؛ به طور کلی دو نوع ارتباط مغزی وجود دارد: ارتباطات ساختاری و ارتباطات عملکردی. ارتباطات ساختاری به مجموعه‌ای از ارتباطات فیزیکی بین مولفه‌های عصبی مثل ارتباطات سیناپسی یا مسیرهای متوالی فیبری اشاره دارد؛ در واقع شبکه‌ای است که از حدود یکصد میلیارد سلول عصبی تشکیل شده است. آگاهی‌ها، اطلاعات و تجربه‌ها باعث ایجاد اتصالات نورونی^۳ می‌شوند که هر نورون با تحریک شدن، احساسات مربوط به خود را ایجاد می‌کند. بعضی از اتصالات نورونی قوی و کارآمد هستند در حالی که برخی دیگر چندان اثربخش نیستند. در حالی که ارتباطات عملکردی در واقع وابستگی‌های زمانی بین الگوی فعالیت نورون‌های مناطق مختلف مغز است که به کمک تحلیل داده‌ای روش‌هایی چون FMRI، EEG و ... سنجیده می‌شود. این شبکه‌ها به شدت به زمان وابسته‌اند و در مقیاس‌های زمانی مختلفی از چند میلی ثانیه تا چند ثانیه تغییر می‌کنند [1].

بیماری ADHD اختلالی عصبی رشدی است که با اختلال عملکرد اجرایی سبب می‌شود کودکان مبتلا به آن پرتحرکی، بی‌توجهی و رفتارهای ناگهانی بیشتر و شدیدتری نسبت به کودکان دیگر داشته باشند [2]. ۳ تا ۵ درصد کودکان به این اختلال مبتلا هستند. علائم این بیماری قبل از ۷ سالگی نمایان می‌شود، ولی اغلب مشکلات جدی در دوران تحصیل ایجاد می‌شود. در مورد علل و عوامل ایجاد این اختلال به نظر می‌رسد مهمترین علل آن، نقص در تکامل سیستم اعصاب می‌باشد که ترکیبی از دلایل ژنتیکی و محیطی در بروز آن موثر هستند. کودکان مبتلا به این بیماری احتمالاً در قسمت‌هایی از مغز که مسئول توجه و تمرکز و تنظیم فعالیت‌های حرکتی می‌باشد دچار نقص جزئی هستند. بیماران مبتلا به ADHD را بر حسب علائم به سه گروه نوع: الف: بی‌دقت و بدون توجه، ب: نوع تکانشی - بیش‌فعالی ج: و نوع ترکیبی تقسیم بندی می‌کنیم.

در راهکار پیشنهادی ارائه شده در این مقاله پس از تولید تصاویر جدید با استفاده از مفهوم یادگیری عمیق و خود رمزنگارها تصاویر عملکردی مغز قطعه‌بندی می‌شوند. قطعه‌بندی یکی از مهمترین موضوعات در حوزه پزشکی است که در تشخیص بیماری‌های مختلف کاربرد دارد. به

³ neuron

¹Function magnetic resource imaging

²Electroncephalogram

امروزه علم داده کاوی باعث شده تا داده ها به سرمایه های باارزش تبدیل شوند زمانیکه تعداد داده ها زیاد باشد فرایند داده کاوی می تواند منجر به کشف الگوها و همبستگی از میان حجم زیادی از داده های خام گردد. داده های بدست آمده از داده کاوی را می توان در تجزیه و تحلیل پیشرفته استفاده نمود افزایش ظرفیت، یافتن الگوها، روندها و همبستگی های پنهان در مجموعه داده ها، یکی از اصلی ترین مزیت های ابزارهای داده کاوی است [13].

شبکه خودرمنگار (Autoencoder) نوع خاصی از شبکه عصبی است که عمدتاً برای رمزگذاری ورودی به یک نمایش فشرده و معنادار طراحی شده است و سپس آن را به گونه ای رمزگشایی می کند که ورودی بازسازی شده تا حد امکان شبیه ورودی اصلی است. کاربردهای رمزگذارها به سه بخش تقسیم می شود: الف: کاهش حجم و فشرده سازی؛ ب: استخراج ویژگی؛ ج: و حذف نویز. خودرمنگارها به عنوان یک تکنیک که قابلیت ترجمه تصاویر به یکدیگر را دارند کاربرد دارند. در واقع با این کار می توان تصاویر جدید تولید کرد. برای این عمل، آن دسته از ویژگی هایی که پنهان بودند استخراج می شوند و با توجه به ابعاد کم لایه پنهان^۲ نسبت به ورودی و امکان بازسازی اطلاعات از روی latent در قسمت دیگر اطلاعات را فشرده می کند. از این رو مدل ما به عنوان مولد^۳ می تواند از یک شبکه خودرمنگار استفاده نماید.

پیش پردازش تصاویر

معمولاً در آزمایش ها از تعداد کمی تصویر استفاده می شود. عمدتاً تصاویر استفاده شده مربوط به یک ملیت می باشد و مسائل ژنتیکی قومیت های متفاوت در نظر گرفته نمی شود. برای رسیدن به یک نتیجه بهتر تعداد تصاویر باید زیاد باشد. مشکل استفاده از تصاویر زیاد وجود تصاویر نویز دار و مخدوش و غیر نرمال و همچنین حجم بالای دیتابیس ها می باشد که قبل از هر عملی ابتدا باید تصاویر پیش پردازش شوند سپس حجم تصاویر کاهش یابد.

جهت پیش پردازش تصاویر موارد زیر پیشنهاد می گردد:

- از گزینه motion correction در نرم افزارها برای از بین بردن اثرات ناشی از حرکت شخص در اسکنر استفاده می - شود. تا حد امکان سعی می شود حرکتی اتفاق نیفتد ولی از آنجایی که ممکن است حرکت های جزئی اتفاق بیفتند و این حرکت ها موجب می شود واکنش های مورد نظر در سری های

به انجام شناسایی کامل تری از بیماران قلبی است [8]. پیشرفت های اخیر در هوش مصنوعی (AI) نویدبخش ارائه تشخیص های عینی از طریق تحلیل تصاویر پزشکی یا ضبط فعالیت ها هستند. این تکنیک های مبتنی بر هوش مصنوعی در تشخیص دقیق ADHD موفق بوده اند؛ اما پیچیدگی فزاینده مدل های یادگیری عمیق باعث شده است که قابلیت تفسیر این مدل ها کاهش یابد. این مدل ها معمولاً به عنوان جعبه های سیاه عمل می کنند و نمی توانند بینش های معناداری درباره الگوهای داده ای که ویژگی های ADHD را توصیف می کنند، ارائه دهند [9]. در پژوهش انجام شده دیگری شامل داده های ECG جمع آوری شده از تعدادی بیمار بود که داده های ECG به دوره های ۲ ثانیه ای تقسیم شده بطور مستقیم برای آموزش مدل شبکه عصبی کانوولوشنی یک بعدی CNN استفاده شد؛ مدل پیشنهادی ۹۶٫۰۴٪ دقت شناسایی، ۹۶٫۲۶٪ دقت، ۹۵٫۹۹٪ حساسیت و ۹۶٫۱۱٪ نمره F1 را ارائه داد. همچنین، از تابع نقشه برداری فعال سازی کلاس وزنی گرادین (Grad-CAM) برای بیان ویژگی های مهم ECG در نقاط زمانی خاص که بیشترین تأثیر را بر نمره طبقه بندی دارند، استفاده شد. [10]

یادگیری عمیق

یادگیری عمیق به شبکه های عصبی با تعداد زیادی لایه مخفی گفته می شود که یک سلسله از ویژگی ها را از داده خام ورودی استخراج می - کند. در یادگیری عمیق بر خلاف یادگیری ماشین ویژگی هایی توسط خود شبکه یافته می شوند و برای شناسایی آنها نیازی به مهندسی ویژگی و دخالت عامل انسانی نیست [11,12]. الگوریتم های یادگیری عمیق زیر مجموعه ای از الگوریتم های یادگیری ماشین هستند و هدف آنها بدست آوردن چندین سطح توزیع شده از داده ورودی است. اخیراً الگوریتم های یادگیری عمیق زیادی برای حل مسائل هوش مصنوعی ارائه شده اند.

الگوریتم این شبکه ها به این صورت است که شبکه های عصبی یک ورودی دریافت می کنند، سپس آنها را از تعدادی لایه مخفی عبور داده و در نهایت یک خروجی که نتیجه پردازش لایه های مخفی است در لایه خروجی شبکه ظاهر می شود. هر لایه مخفی از تعدادی نورون تشکیل شده که این نورون ها به تمام نورون های لایه قبل از خود متصل می شوند. نورون های هر لایه به صورت مستقل عمل کرده و هیچ ارتباطی با یکدیگر ندارند. آخرین لایه تماماً متصل^۱ به لایه خروجی معروف است و معمولاً نقش نمایش دهنده امتیاز هر دسته را ایفا می کند. (دنگ و همکاران ۲۰۱۴)

³ generator

¹ Fully connected

² Latent

• تولید تصاویر جدید

از خودرمننگارها برای تولید تصاویر مصنوعی جدید و افزایش تعداد تصاویر و کمک به تحلیل بهتر استفاده می‌شود. به این منظور ابتدا در لایه ورودی تصویر اصلی را به خودرمننگار می‌دهیم. در واقع در این لایه هر نورون متناظر با یک پیکسل از تصویر است. در لایه دوم که لایه نهان یا کد نام دارد و مهم‌ترین بخش در فرآیند تولید تصویر است فقط مهم‌ترین ویژگی‌های تصویر استخراج می‌شوند که معمولاً شامل الگوها، اشکال و بافت‌ها هستند. در واقع در این لایه هر تصویر به صورت بردار نمایش داده می‌شود که این بردار نشان‌دهنده ویژگی‌های اصلی تصویر است بنابراین تعداد نورون‌ها در این لایه کمتر از لایه ورودی است. در نهایت در لایه سوم که لایه خروجی نام دارد تلاش می‌شود تا تصویر اصلی از روی نمایش فشرده بازسازی شود. اگر خود رمننگار خوب آموزش دیده باشد تصویر خروجی بسیار شبیه به تصویر اصلی خواهد بود.

• قطعه‌بندی تصاویر عملکردی

در فاز سوم از یک segmentor که تصاویر ایجاد شده توسط خودرمننگار را به عنوان ورودی دریافت می‌کند و شروع به قطعه‌بندی تصاویر می‌کند، استفاده می‌شود. به این منظور تصاویر عملکردی مغز به ۲۶۴ ناحیه تقسیم می‌شوند؛ یعنی ۲۶۴ گره در مغز در نظر گرفته می‌شود و یک ماتریس ۲۶۴*۲۶۴ برای هر نفر بدست می‌آید.

• محاسبه همبستگی

در نهایت همبستگی دو به دوی این مناطق محاسبه می‌شود. ضریب همبستگی معیاری از رابطه خطی بین دو متغیر است که توان آن را هم بصورت دستی و هم توسط نرم افزار محاسبه نمود. در زبان برنامه نویسی پایتون در کتابخانه Numpy با استفاده از (correcoef) می‌توان آن را محاسبه نمود. اگر متغیرها دارای ارتباط خطی بالایی باشند ضریب همبستگی آنها نزدیک به ۱ یا -۱ است. از سویی متغیرهای مستقل آماری دارای ضرایب همبستگی نزدیک به صفر هستند.

از آزمون t-student و سایر روش‌های آماری برای مقایسه همبستگی‌ها بین گروه سالم و بیمار استفاده می‌شود. پاور و همکارانش در سال ۲۰۱۱ با استفاده از تصاویر عملکردی مغز افراد ۲۶۴ ناحیه و شبکه‌هایی که به آن تعلق دارند را پیدا کرده‌اند. بخشی از این جدول ۱-۴ در تصویر ارائه شده است [15].

زمانی پشت سر هم قرار نگیرند، بنابراین می‌توان اصلاح حرکت را با نرم افزار انجام داد.

• عملیات تصحیح زمانبندی تصاویر معمولاً با توجه به مشخصات تصویر انجام می‌شود چرا که زمان ثبت برش‌ها در حدود دهم ثانیه با هم اختلاف دارند. با عمل اصلاح زمان-بندی می‌توان شیفت زمانی داخل یک volume را حذف نمود. این عمل در نرم‌افزارها توسط slice timing correction انجام می‌شود.

• فیلترینگ زمانی عمل دیگری است که باید انجام شود. از آنجایی که عوامل زیادی می‌تواند باعث تغییر سیگنال شود؛ مثلاً با تغییر ضربان قلب حجم خون تغییر می‌کند و این تغییرات به عنوان نویز روی سیگنال ظاهر می‌شوند و با اعمال فیلترینگ زمانی این نویزها از بین می‌روند.

قطعه‌بندی تصاویر عملکردی مغز

قطعه‌بندی تصویر یک مشکل کلاسیک در تحقیقات بینایی کامپیوتری است و به کانونی در زمینه درک تصویر تبدیل شده است. قطعه‌بندی تصویر به اصطلاح به تقسیم یک تصویر به چندین ناحیه از هم گسسته بر اساس ویژگی‌هایی مانند مقیاس خاکستری، رنگ، بافت فضایی و اشکال هندسی اشاره دارد. قطعه‌بندی تصویر در واقع همان کلاس بندی^۱ در ابعاد پیکسل می‌باشد. در قطعه بندی، کلاس هر پیکسل مشخص می‌شود، به طوری که این ویژگی‌ها در یک حوزه شباهت را نشان می‌دهد، اما بین مناطق مختلف تفاوت آشکاری را نشان می‌دهد. قطعه‌بندی تصاویر پزشکی به عنوان یک کار قطعه‌بندی معنایی در نظر گرفته می‌شود. در متد پیشنهادی جهت انجام قطعه‌بندی تصاویر به نواحی کوچکتر تقسیم می‌شوند و تصاویر عملکردی به ۲۶۴ ناحیه تقسیم شدند و ۱۲ شبکه که این نواحی متعلق به آن بودند بدست آمد [۱۴]. شبکه‌های مهم شامل hand somato-motor و visual و auditory و default و ventral attention و dorsal attention و frontal-parietal control می‌باشند. به طوری که یک ماتریس ۲۶۴*۲۶۴ برای هر تصویر بدست می‌آید.

۳. الگوریتم پیشنهادی

در این پژوهش یک شبکه سلسله مراتبی معرفی شده است که طی چهار فاز به قطعه‌بندی عملکردی قسمت‌های مختلف مغز می‌پردازد.

• پیش پردازش تصاویر

تصاویر FMRI جهت حذف نویز و اثرات حرکتی پیش پردازش می‌شوند.

جدول ۱. بخشی از برچسب گذاری عملکردی نواحی مختلف مغزی ۱-۴

نواحی	مختصات			شبکه
	x	y	z	
1	66	-8	25	Sensory/somatomotor
2	65	-13	20	auditory
3	-41	-75	26	Default mode
4	-10	11	67	Ventral attention
5	-47	-76	-10	visual
6	29	-5	54	Dorsal attention
7	-29	-8	57	Sensory/somatomotor
8	10	-43	61	Sensory/somatomotor
9	-2	-37	44	Default mode
10	8	-72	11	visual

جدول ۲. بخشی از جدول مقایسه روش های مختلف تشخیص بیماری بیش فعالی در دو سال اخیر

سال	مدل	نوع تصویر	قطعه بندی	تولید تصاویر مصنوعی
۲۰۲۴	ViT+U-NeT	MRI	U-NeT	GAN
۲۰۲۳	3D RESNET + FSL	FMRI+DTI	FSL	Diffusion models
۲۰۲۴	GNN+Tractography	DTI	Tractography based	VAE
۲۰۲۳	CNN+Attention	FMRI	ICA	GAN
۲۰۲۴	Self supervised	FMRI	nnU-Net	Data Augmentation

فرضیه صفر می توان مقدار p-value را برای مقایسه استفاده نمود. معمولاً اگر مقدار p-value کمتر از ۰,۰۵ باشد دلیل کافی برای رد فرضیه وجود دارد. یعنی نتیجه می گیریم میانگین دو جامعه برابر نیستند. در غیر اینصورت فرضیه تایید می شود.

۴. نتیجه گیری:

مدل پیشنهادی ما از ترکیب دو رویکرد با ارائه یک مدل نوین جهت تشخیص بیماری ADHD ارائه شد که در ابتدا پس از پیش پردازش تصاویر با استفاده از یک خودرمننگار تصاویر جدید را تولید نموده نوآوری اصلی این مدل در استفاده از خودرمننگار برای تولید تصاویر جدید می باشد. این امر بخصوص در حوزه پزشکی که با محدودیت دسترسی به داده های کافی مواجه است اهمیت دارد. سپس از یک segmentor استفاده می شود که تصاویر را قطعه بندی نموده تا بتواند با محاسبه همبستگی بین نواحی و محاسبه مجموع اتصالات عملکردی به تشخیص وجود بیماری ADHD بپردازد.

همچنین نتایج بررسی ها در جدول ۲ برای مقایسه روش های مختلف بررسی تصاویر پزشکی در دو سال اخیر که از قطعه بندی تصاویر استفاده کرده اند؛ نشان داده شده است. لازم به ذکر است، بهترین روش از نظر دقت روش ViT+U-Net می باشد که به تشخیص ۹۴,۲ منجر شده و بهترین روش برای داده های کم، روش self supervised learning می باشد.

در نهایت مجموع اتصال عملکردی مناطقی که در هر کدام از شبکه ها هستند به صورت جداگانه برای هر شبکه محاسبه می شود و تقسیم بر بیشینه اتصالات عملکردی ما بین تعداد نواحی (گره ها) در آن شبکه می شود و با استناد به این مطلب که کودکان مبتلا به بیماری ADHD در مناطق مربوط به مخچه، قشر آهیانه فوقانی مغز و نیز شبکه حالت پیش فرض مغز اتصالات عملکردی ضعیف تری دارند، مجموع اتصالات عملکردی محاسبه می شوند. برای قضاوت در مورد نتایج خروجی می توان از آزمون t-student برای مقایسه میانگین دو جامعه سالم و بیمار استفاده نمود. همچنین می توان از آزمون مکانی دو نمونه مستقل استفاده نمود که از فرضیه صفر برای مقایسه استفاده می کند؛ در مورد

7. Differentiating Boys with ADHD from Those with Typical Development Based on Whole-Brain Functional Connections Using a Machine Learning Approach: (<https://pmc.ncbi.nlm.nih.gov/articles/PMC707187>)
 محمدی، پیام. داده کاوی، کاربردها، نیازمندی ها، فرایند و ابزارها. ۴(۳): ۵۹-۵۱. فصلنامه تخصصی آرمان پردازش، ۱۴۰۲؛
9. Amado-Caballero P, Casaseca-de-la-Higuera P, Alberola-López S, Andrés-de-Llano JM, López-Villalobos JA, Alberola-López C. Insight into ADHD diagnosis with deep learning on Actimetry: Quantitative interpretation of occlusion maps in age and gender subgroups. *Artificial Intelligence in Medicine*. 2023;143:102630.
10. Loh HW, Ooi CP, Oh SL, Barua PD, Tan YR, Molinari F, et al. Deep neural network technique for automated detection of ADHD and CD using ECG signal. *Computer Methods and Programs in Biomedicine*. 2023;241:107775.
۱۱. 3. Singh, N.K. and K. Raza, Medical image generation using generative adversarial networks: A review. *Health informatics: A computational perspective in healthcare*, 2021: p. 77-96.
12. Suganyadevi S, Seethalakshmi V, Balasamy K. A review on deep learning in medical image analysis. *International Journal of Multimedia Information Retrieval*. 2022;11(1):19-38.
- 13 دهقانی محمودآبادی، محمدرضا. بررسی کارایی سیستم دسته‌بند یادگیر برای شناسایی بیماران قلبی. فصلنامه تخصصی آرمان پردازش، ۱۴۰۲؛ ۴(۴): ۱۹-۲۹.
14. functional network organization of the human brain ,Jonathan D Power et al .*Neuron* .2011
15. Power JD, Cohen AL, Nelson SM, Wig GS, Barnes KA, Church JA, et al. Functional network organization of the human brain. *Neuron*. 2011;72(4):665-78.

برای پیاده سازی اهداف مذکور می‌توان از زبان برنامه‌نویسی پایتون و کتابخانه‌های tensorflow و keras در بستر google colab استفاده نمود. البته دقت داده‌ها و صحت نام‌گذاری شبکه‌ها بسیار مهم است و هر نوع خطایی می‌تواند نتایج نادرستی ایجاد نماید. همچنین تعداد نواحی مغزی در هر شبکه باید به اندازه کافی بزرگ باشد تا تحلیل‌های آماری معنا داری انجام شود.

منابع

1. Lang EW, Tomé AM, Keck IR, Górriz-Sáez JM, Puntinet CG. Brain connectivity analysis: a short survey. *Comput Intell Neurosci*. 2012;2012:412512.
2. Foreman DM. Attention deficit hyperactivity disorder: legal and ethical aspects. *Arch Dis Child*. 2006;91(2):192-4.
3. Zhu C-Z, Zang Y-F, Cao Q-J, Yan C-G, He Y, Jiang T-Z, et al. Fisher discriminative analysis of resting-state brain function for attention-deficit/hyperactivity disorder. *NeuroImage*. 2008;40(1):110-20.
4. Tomasi D, Volkow ND. Abnormal functional connectivity in children with attention-deficit/hyperactivity disorder. *Biol Psychiatry*. 2012;71(5):443-50.
5. Cui, S., et al., Automatic semantic segmentation of brain gliomas from MRI images using a deep cascaded neural network. *Journal of healthcare engineering*, 2018.
6. Distinguishing Adolescents With ADHD From Their Unaffected Siblings and Healthy Comparison Subjects by Neural Activation Patterns During Response Inhibition:

COPYRIGHTS

©2025 by the authors. Published by the Islamic Azad University, Khodabandeh Branch, Zanjan. This article is an open-access article distributed under the terms and conditions of the Creative Commons Attribution 4.0 International (CC BY 4.0) <https://creativecommons.org/licenses/by/4.0>

