



تشخیص بهره هوشی از روی تصاویر fMRI با استفاده از ترکیب شبکه حافظه کوتاه مدت بلند و منطق فازی

سارا معتمد^{۱*}، مجید اقدامی عربانی^۲

استادیار گروه کامپیوتر، واحد فومن و شفت، دانشگاه آزاد اسلامی، فومن، ایران^{۱*}

دانش آموخته کارشناسی ارشد، گروه کامپیوتر، واحد فومن و شفت، دانشگاه آزاد اسلامی، فومن، ایران^۲

چکیده

بهره هوشی^۱ از دیرباز موضوعی جذاب و مهم در روان شناسی و علوم شناختی بوده است. این مسئله یک معیار اساسی برای توانایی های شناختی یک فرد در نظر گرفته می شود و شامل جنبه های مختلف استدلال، حل مسئله، حافظه و توانایی کلی فکری است. با توجه به اهمیت این موضوع، در این پژوهش، به تحلیل و توسعه یک مدل ترکیبی از شبکه های LSTM و منطق استنتاج فازی به منظور تشخیص بهره هوشی با استفاده از تصاویر fMRI مغزی پرداخته شده است. مدل پیشنهادی پژوهش حاضر با ترکیب قدرت یادگیری عمیق LSTM در درک الگوهای زمانی و قابلیت های استنتاج فازی در مدیریت عدم قطعیت، موفق به افزایش دقت در شناسایی سطح بهره هوشی نسبت به روش های پایه شده است. نتایج آزمایش ها نشان داد که دقت مدل به طور معناداری بهتر از روش های سنتی بوده و با نرخ تشخیص بهره هوشی ۸۳ درصد بهتر از سایر روش ها جواب داده است. این نرخ نشان دهنده هم بستگی مثبت و درستی بین اندازه و نواحی انتخاب شده مغز انسان و ضریب هوشی است.

واژگان کلیدی: بهره هوشی، یادگیری عمیق، تصاویر fMRI مغزی، شبکه LSTM، موتور استنتاج فازی.

Detection of intelligence from fMRI images using a combination of long short-term memory network (LSTM) and fuzzy logic (FL)

Sara Motamed^{1*}, Majid Eghdami Arabani²

Assistant Professor, Department of Computer Engineering, FSh.C., Islamic Azad University, Fouman, Iran¹

Master graduate, Department of Computer Engineering, FSh.C., Islamic Azad University, Fouman, Iran^{2*}

Abstract

Intelligence Quotient (IQ) is a widely used indicator of cognitive ability and is commonly assessed through standardized psychometric tests. However, questionnaire-based IQ assessments may be impractical for certain populations (e.g., very young children) and can be influenced by non-neural factors. In recent years, neuroimaging has enabled the investigation of the relationship between brain structure/function and intelligence. Functional Magnetic Resonance Imaging (fMRI), due to its ability to capture brain activity patterns, provides an opportunity for building automated IQ estimation or IQ-level classification systems. Nevertheless, fMRI data are high-dimensional, noisy, and temporally complex, which motivates the use of deep learning models that can learn sequential dependencies. This study proposes a hybrid framework that combines Long Short-Term Memory (LSTM) networks with a fuzzy inference engine to improve robustness under uncertainty and noise. This research uses the ABIDE dataset, which provides resting-state fMRI data

¹ Intelligence Quotient(IQ)

* Corresponding author

* نویسنده عهده دار مکاتبات

along with phenotypic information. The Full-Scale IQ (FIQ) is considered as the main intelligence criterion. Since FIQ is missing for a subset of subjects, it is computed from Verbal IQ (VIQ) and Performance IQ (PIQ) using the linear relation reported in the manuscript (Relation (1)).

The pipeline consists of three main stages:

1. Preprocessing: Skull stripping and preparation of brain data, followed by standard fMRI preprocessing steps including noise removal, normalization, realignment, smoothing, ROI selection using the AAL atlas, and extraction of ROI-wise temporal BOLD signals.
2. Temporal Feature Learning (LSTM): The extracted ROI time-series are fed to a multi-layer LSTM to capture temporal dynamics and long-range dependencies. The learned latent representation is mapped to a normalized score $qLSTMq_{\{LSTM\}}qLSTM$ that summarizes the temporal evidence.
3. Fuzzy Inference (TSK): To manage uncertainty in brain signals and improve decision stability, a first-order Takagi-Sugeno-Kang (TSK) fuzzy inference system is employed. The fuzzy system uses $qLSTMq_{\{LSTM\}}qLSTM$ along with additional normalized indices (e.g., connectivity and structural indicators defined in the manuscript) to infer the final IQ estimate/class. The rule-base (Table (2)) is used to combine evidence through weighted aggregation of membership degrees. For evaluation, the data are split into training and test sets, and K-fold cross-validation is used. Performance is reported using accuracy and class-wise F1-score (as illustrated in the corresponding figures), and the proposed method is compared against baseline architectures.

The experimental results indicate that the proposed hybrid LSTM-Fuzzy model achieves higher performance than the baseline methods implemented under the same experimental setting on ABIDE. In particular, the proposed approach reaches an accuracy of 83%, demonstrating a noticeable improvement over conventional deep models and hybrid baselines. The learning curves show a decreasing trend of training and testing errors across boosting/training rounds, suggesting stable convergence. In addition, the class-wise F1-score analysis confirms that the proposed method improves classification consistency across IQ-level categories.

The improvements can be attributed to two complementary factors. First, LSTM effectively models the temporal variability of resting-state fMRI signals and captures sequential dependencies across ROI time-series. Second, fuzzy inference provides a principled mechanism to handle ambiguity and noise by translating numerical evidence into interpretable linguistic rules and aggregating them through membership degrees. This hybrid design increases robustness when the neuroimaging data contain uncertainty, which is common in multi-site resting-state datasets. A key practical aspect of this work is the consistent use of FIQ (reported or computed via Relation (1)), which ensures coherent labeling and evaluation across subjects. Limitations include dataset heterogeneity (scanner/site effects), computational complexity, and sensitivity to preprocessing choices. Future work may incorporate domain adaptation, transfer learning, or more advanced temporal encoders to improve generalization across acquisition sites.

This study presents a hybrid deep learning and fuzzy logic framework for IQ detection/estimation from resting-state fMRI. By combining LSTM-based temporal feature learning with a TSK fuzzy inference engine, the proposed approach improves performance and robustness on the ABIDE dataset. The results suggest that integrating deep sequential modeling with fuzzy reasoning is an effective strategy for fMRI-based cognitive score analysis.

Keywords: IQ, deep learning, brain fMRI images, LSTM network, fuzzy inference engine.

نزدیک یا در حد مقدار متوسط خواهد بود؛ همچنین نمره بهره هوشی بسیار اندکی از افراد بالای ۱۴۰ یا کمتر از هفتاد است [۱].

پژوهشگران در مطالعات اخیر خود به این نتیجه رسیدند که داشتن مغز بزرگتر به معنای بهره هوشی بالاتر نیست و حجم مغز تنها یک نقش جزئی در توضیح عملکرد انسان در آزمون ضریب هوشی ایفا می کند؛ در عوض، به نظر می رسد ساختار و یک پارچگی مغز به عنوان یک پایه و اساس زیستی بهره هوشی، اهمیت بیشتری داشته باشد؛ بنابراین آنچه سبب تمایز انسان هوشمند برای تفاوت در عملکرد شناختی می شود ساختار مغز است [۲]؛ درواقع، هوش با تغییرات در ساختارهای مختلف مغز و متغیرهای عصبی مرتبط است [۳]؛ با توجه به هم بستگی بین ساختار مغز و هوش، می توان بهره هوشی افراد را از روی تصاویر fMRI مغزی تشخیص داد. بررسی ها نشان داده است؛ در صورتی که

۱- مقدمه

بهره هوشی روشی برای سنجش هوش است و توانایی درک، یادگیری و تفکر انسان را نشان می دهد؛ به بیان دیگر، بهره هوشی شاخصی عددی از توانایی شناختی یک فرد است. میزان هوش انسان ها به عنوان یکی از مباحث بسیار مهم در طول چند دهه اخیر مورد بحث بوده و جنجال بر سر میزان بهره هوشی افراد بخشی از چالش های بشری به حساب آمده است؛ در این راستا، دانشمندان همواره به دنبال این بوده اند که بتوانند با استفاده از انجام آزمون های بهره هوشی در مؤسسات و مدارس به کارگیری تکالیف شناختی، ضریب هوشی افراد را به صورت دقیق اندازه گیری کنند. به طور معمول، در سراسر جهان آزمون ها و خرده آزمون های استاندارد برای ارزیابی بهره هوشی مورد استفاده قرار می گیرند و امتیاز بهره هوشی با توزیع بهنجار (به جای نرمال) مطابقت دارد که در آن بیشتر مقادیر بهره هوشی

بتوان به کمک روش‌های تصویربرداری میزان هوش را تعیین کرد، می‌توان از نتایج کسب‌شده از این ساختار برای ارائه قابلیت‌هایی بیشتر به سامانه‌های هوش مصنوعی استفاده کرد؛ همچنین به کمک این روش می‌توان به سراغ درک بهتر و درمان نارسایی‌هایی مانند افسردگی یا روان‌گسیختگی (شیزوفرنی) رفت [۳، ۴]. در سال‌های اخیر مطالعات مختلفی در راستای تشخیص بهره‌هوشی از روی تصاویر fMRI صورت گرفته است. در کنار استفاده از این روش‌ها و با توسعه روش‌های یادگیری، مسیر حرکت پژوهش در این حوزه به سمت استفاده از شبکه‌های عصبی عمیق سوق پیدا کرده‌است؛ یادگیری عمیق درواقع یادگیری به‌وسیله شبکه‌های عصبی است که دارای لایه‌های پنهانی زیاد هستند. شبکه‌های عصبی پیچشی یکی از این شبکه‌ها است که در کاربردهای مختلفی مانند بازشناسی حروف، اشیاء و غیره مورد استفاده قرار گرفته است؛ با اینکه استفاده از روش‌های یادگیری عمیق باعث بهبود قابل توجهی در حوزه بینایی ماشین شده‌است، پژوهش‌های انجام‌شده هنوز در ابتدای مسیر پیشرفت قرار دارند و نیاز به پیشرفت در این حوزه به شدت احساس می‌شود؛ با توجه به موارد یادشده، پیشنهاد می‌شود از ظرفیت بالای شبکه‌های عصبی عمیق در تشخیص بهره‌هوشی از روی تصاویر مغزی استفاده شود [۵]. پیش‌بینی میزان بهره‌هوشی از طریق تصاویر fMRI مغز یک زمینه پژوهشی پیچیده و در حال تکامل است و هدف آن درک رابطه بین ساختار مغز و توانایی‌های شناختی است. این موضوع یک حوزه پژوهشی با پیامدهای نهفته برای درک پایه عصبی هوش و کاربردهای بالینی است؛ با این حال، این مسئله یک زمینه پیچیده و در حال تحول با چالش‌های اخلاقی و روش‌شناختی است که نیاز به بررسی دقیق دارد. توجه به این نکته مهم است که پیش‌بینی میزان بهره‌هوشی از طریق تصاویر fMRI مغز یک کار چالش‌برانگیز است و هنوز یک حوزه فعال پژوهشی است. بهره‌هوشی یک ویژگی پیچیده است که تحت تأثیر ترکیبی از عوامل ژنتیکی، محیطی و عصبی است؛ از آنجاکه بین ساختار مغز و ضریب هوشی هم‌بستگی‌هایی وجود دارد، این رابطه باید به‌طور کامل مورد بررسی و مطالعه قرار گیرد و جزئیات ارتباط آن درک شود؛ همچنین ملاحظات اخلاقی و نگرانی‌های حفظ حریم خصوصی هنگام کار با داده‌های پزشکی حساس مانند پایش‌های fMRI مهم‌اند. پژوهش‌گران باید اطمینان حاصل کنند که داده‌ها ناشناس‌اند و نهایت دقت و تدابیر لازم برای محافظت از حقوق حریم خصوصی افراد انجام می‌گیرد. در

۲- بهره‌هوشی

کشف هوش انسانی همواره مورد توجه عمده علوم اعصاب شناختی بوده است [۶]؛ با این حال، آزمون‌های استاندارد هوشی فعلی به دلیل مجموعه آزمون‌های مبتنی بر پرسش‌نامه برای نوزادان یا کودکان خردسال قابل اجرا نیستند. اگر برای تخمین ضریب هوشی فعلی یا پیش‌بینی ضریب هوشی آینده، روش‌های نظام‌مندتری توسعه داده شود، نویدهای بزرگی برای شناسایی نوزادان یا کودکان خردسالی خواهد بود که ممکن است دچار رشد فکری غیرعادی باشند. با ظهور تصویربرداری مغز، تلاش‌هایی برای بررسی رابطه بین کالبدشناسی مغز و هوش صورت گرفته است [۷، ۸]؛ برای مثال، سوپکار و همکاران [۹]، نشان دادند که اندازه و مدار بخش‌های خاصی از مغز کودکان می‌تواند پیش‌بینی‌کننده نهفته‌ای برای پاسخ‌گویی آن‌ها به تدریس خصوصی فشرده ریاضی باشد. مک دانیل و همکاران بر اساس آزمایش‌های مبتنی بر fMRI دریافتند که حجم مغز با بهره‌هوشی هم‌بستگی مثبت دارد [۸]. فرانکو و همکاران، هم‌بستگی مثبتی بین نمره بهره‌هوشی و تراکم بخش خاکستری قشر مداری-پیشانی (اوربیتوفرونتال)، شکنج کمربندی^۱، مخچه و نهنج (تالاموس) را گزارش کردند؛ آن‌ها در چهارچوب پیشنهادی خود، از روش یادگیری ماشینی به‌ویژه برای تخمین بهتر نمره بهره‌هوشی استفاده کرده‌اند و در پژوهش خود، با در نظر گرفتن ویژگی‌های ماده خاکستری و ماده سفید مشتق‌شده از تصاویر fMRI، به‌عنوان پیش‌بینی‌کننده، بهره‌هوشی را اندازه‌گیری کرده‌اند؛ با این حال، در زمینه تجزیه و تحلیل داده‌های تصویربرداری عصبی، یکی از مهم‌ترین و چالش‌برانگیزترین مسائل، ساختن یک مدل تعمیم‌یافته برای مواردی با ابعاد ویژگی بالا و حجم نمونه کوچک است [۱۰].

تصویربرداری با پرتو یا تشدید مغناطیسی یک روش تصویربرداری در علم پزشکی به حساب می‌آید که در رادیولوژی برای تشکیل تصاویر کالبدشناسی و فرآیندهای فیزیولوژیکی بدن انسان مورد استفاده قرار می‌گیرد. برای تهیه عکس‌های fMRI، پویش‌گرها با استفاده از میدان مغناطیسی قوی، شیب‌های میدان مغناطیسی و امواج رادیویی اقدام به تهیه عکس از اندام‌های بدن انسان

¹ Cingulate gyrus

می‌کنند. تصویربرداری fMRI روشی غیرتهاجمی است که برخلاف حالت‌های دیگر تصویربرداری مانند سی‌تی‌اسکن، پرتوشناسی، پزشکی هسته‌ای و غیره از پرتوهای غیر یونیزه‌شده برای تشکیل تصویر استفاده می‌کند. fMRI به دلیل ایجاد تضاد بالا در بافت‌های نرم بدن یکی از حالت‌های مهم در تصویربرداری پزشکی محسوب می‌شود. این روش تصویربرداری کاربردهایی نظیر تجزیه و تحلیل ساختاری کوچک‌ترین مولکول‌های آلی، ماکرومولکول‌های بیوشیمیایی، بافت‌های استخراجی از بدن، اعضای سالم قرنطینه و مطالعات درون‌تنی را شامل می‌شود. ایجاد تصاویر تشدید مغناطیسی در طی چندین فرآیند صورت می‌گیرد و شامل هم‌راستاشدن ممان مغناطیسی هسته‌ای، تحریک به وسیله امواج رادیو فرکانسی، کدگذاری فضایی و در نهایت تشکیل تصویر است. در این روند سخت‌افزار و نرم‌افزارهای متفاوتی دخیل‌اند که سخت‌افزارها شامل آهن‌ربا، سیم‌پیچ‌ها، پردازنده تصویر و دستگاه رایانه‌ای برای ذخیره داده‌ها هستند؛ اگرچه امروزه در بیشتر شاخه‌ها و زمینه‌های پزشکی خطرات تابش یونیزه به‌خوبی کنترل می‌شود، اما بازهم این امکان وجود دارد که fMRI هنوز هم گزینه‌ای بهتر از سی‌تی‌اسکن تلقی شود. برای اینکه بیماران در معرض اشعه قرار نگیرند fMRI به‌طور گسترده در بیمارستان‌ها و مراکز پزشکی برای تشخیص پزشکی و پیگیری بیماری مورد استفاده قرار می‌گیرد. fMRI در مقایسه با سی‌تی‌اسکن دارای اطلاعات متفاوت و دارای مدت زمان بیشتری است. افراد برای ورود به محدوده موردنظر برای عکس‌برداری fMRI که محفظه باریکی است باید در حالت خوابیده قرار گیرند. افرادی که دارای فلزات غیر جاشدنی در بدن خود هستند، نمی‌توانند به آسودگی تحت عکس‌برداری fMRI قرار گیرند [۱۱]؛ از آنجاکه تصاویر fMRI مربوط به مغز حاوی نوفه، ناهمگنی و گاهی انحراف‌اند، امروزه تقسیم‌بندی تصویر مغز یکی از مهم‌ترین بخش‌های ابزار تشخیص بالینی است؛ از آنجاکه فرآیند تقسیم‌بندی دقیق این تصاویر برای تشخیص صحیح به‌وسیله ابزارهای بالینی بسیار مهم و حیاتی است، پژوهش‌های زیادی در مورد روش‌های تصویربرداری، تصویربرداری تشدید مغناطیسی و روش‌های کاهش نوفه، تصحیح ناهمگنی و تقسیم‌بندی انجام گرفته است [۱۲].

۳- کارهای مرتبط

شبکه‌های عصبی عمیق، به‌ویژه شبکه‌های عصبی پیچشی، به‌طور گسترده در نقش طبقه‌بندی تصویر استفاده می‌شوند.

جمع‌آوری تصاویر پزشکی و برچسب‌گذاری روی داده‌ها امری دشوار است؛ با توجه به اهمیت طبقه‌بندی تصاویر پزشکی و چالش‌های خاص از مجموعه داده‌های کوچک تصاویر پزشکی، سمیر و همکاران نحوه اعمال طبقه‌بندی را مبتنی بر شبکه عصبی پیچشی انتخاب کردند؛ آن‌ها مجموعه داده‌های کوچک اشعه ایکس قفسه سینه را بررسی و به ارزیابی عملکرد آن‌ها پرداختند و طبق بررسی‌ها به این نتیجه رسیدند که یادگیری انتقال مبتنی بر شبکه عصبی پیچشی بهترین روش برای تشخیص بهره هوشی است؛ همچنین در آزمایش‌هایی که انجام دادند، اعلام کردند که شبکه کپسولی بهتر از طبقه‌بندی‌کننده باینری سریع و چرخشی جهت‌دار^۲ و ماشین بردار پشتیبان عمل می‌کند [۱۴]. با الهام از هم‌بستگی بین ساختار مغز و هوش، مانوئل و همکاران پیشنهاد کردند که ضریب هوشی افراد را به یکی از چهار طبقه با استفاده از شبکه عصبی پیچشی با استخراج ویژگی‌های مربوط به بهره هوشی از تصاویر fMRI مغز انسان طبقه‌بندی کنند. طبقه‌بندی‌کننده‌ای که استفاده کردند بر اساس مقیاس هوش وکسلر بود؛ همچنین آن‌ها اعلام کردند که متغیرهای کنترلی مختلف عصبی بر سطح هوش انسان تأثیر می‌گذارد و تصاویر مغزی با نمای میان‌بر^۳ و تاجی^۴ بهترین گزینه برای طبقه‌بندی بهره هوشی هستند. با استقرار شبکه عصبی پیچشی سه‌بعدی، ضریب هوش را می‌توان از روی تصاویر سه‌بعدی مغز خود اندازه‌گیری کرد و در نتیجه فرآیند استخراج برش را کاهش داد [۵]. در [۱۵]، الگوریتم‌های یادگیری عمیق دوبعدی و سه‌بعدی مختلف، با کانال‌های ورودی مختلف تصویربرداری تشدید مغناطیسی ساختاری استفاده شد. در طی این آزمایش‌ها تنظیمات متغیرهای کنترلی مختلف و حالت‌های پیش‌بینی متفاوت، روی تصویربرداری تشدید مغناطیسی ساختاری بیشتر از هشتصد نفر با افراد ۶-۶۴ ساله، استفاده شد و نتایج خوبی به‌دست آمد. در پژوهش‌ش، یک فرآیند دقیق از ایجاد یک سیستم طبقه‌بندی سن مغز با استفاده از تصاویر fMRI و شبکه عصبی کانولوشن سه‌بعدی به‌عنوان چهارچوب مدل ارائه شده است. پس از واکشی داده‌ها و پاک‌سازی اولیه، چهار مرحله پیش‌پردازش روی تصاویر اعمال شد. چهار مرحله شامل تغییر اندازه، استخراج مغز، تصحیح میدان بایاس N4 و ثبت الگو بود [۱۶].

وانگ و همکاران یک مدل یادگیری عمیق همراه با چهارچوب ماشینی تقویت‌کننده گرادیان را پیشنهاد کردند. آن‌ها یک شبکه عصبی پیچشی را به‌وسیله داده‌های fMRI با ابعاد بالا آزمایش کرده و ویژگی‌های مهم تصاویر را استخراج کردند. سپس از این ویژگی‌های استخراج‌شده برای آموزش یک ماشین تقویت‌کننده گرادیان استفاده و امتیاز

³ Sagittal
⁴ Coronal

² Oriented Fast and
Rotated Binary

هوش سیال باقی‌مانده را پیش‌بینی کردند [۱۷]. هدف از پژوهش باچاری و همکاران ساخت یک سامانه خودکار برای استخراج و طبقه‌بندی تومور مغزی در تصاویر پزشکی بود. این سامانه قادر بود تصاویر مغناطیسی تشدید را با سرعت تشخیص بالا پردازش کند [۱۸]. پولستر و همکاران پیش‌بینی هوش سیال را از تصاویر تشدید مغناطیسی با وزن T1 بر اساس ویژگی‌های مشتق‌شده از اطلس SRI24 و FreeSurfer مطالعه کردند. آن‌ها یک مدل رگرسیون خطی را با چهار حجم و چهار اندازه‌گیری ضخامت مغز پیشنهاد کردند و آن را با مدل‌های تقویت‌گرایان با استفاده از اندازه‌گیری‌های ۱۲۲ (SRI24) و ۱۳۶ (FreeSurfer) مغز مقایسه کردند [۱۹].

ریترو و همکاران، چالش پیش‌بینی عصبی رشد شناختی مغز نوجوانان را مورد بررسی قرار دادند. آن‌ها مجموعه داده‌های بزرگ تصویربرداری تشدید مغناطیسی با وزن T1 و نمرات هوش سیال کودکان (تصحیح‌شده برای حجم مغز، مکان جمع‌آوری داده‌ها و متغیرهای جمعیت‌شناختی) بین نه تا یازده سال را ارائه کردند (N=۳۷۳۹ برای آموزش، N=۴۱۵ برای اعتبارسنجی و N=۴۵۱۶ برای آزمایش). در این بررسی، روش جست‌وجوی گروه Caruana را برای انتخاب بهترین مدل‌ها از میان مجموعه بزرگ و متنوعی از مدل‌های داوطلب پیشنهاد کردند. مدل‌های داوطلب شامل شبکه‌های عصبی پیچشی روی مجموعه داده‌ها و در نواحی مغز مرتبط با هوش سیال (برای مثال نواحی پیشانی و جداری) و روش‌های یادگیری ماشین استاندارد با کارایی بالا (پشتیبان رگرسیون برداری، جنگل‌های تصادفی، تقویت‌گرایان و تقویت‌گرایان فوق‌العاده) بودند. آن‌ها از نمرات منطقه‌ای حجم و میانگین گرایش ماده استفاده کردند؛ برای ایجاد تنوع بیشتر و افزایش استحکام، مجموعه وسیعی از پیکربندی‌های ابرپارامتر برای هر یک از مدل‌ها استفاده شد. در اعتبارسنجی و داده‌های آزمون نگه‌داری، میانگین مربعات خطا به ترتیب ۷۱.۱۵ و ۹۳.۶۸ به دست آمد [۲۰].

جدول (۱)، مقایسه‌ای از کارهای انجام‌شده را در سال‌های اخیر، در تشخیص ضریب هوشی افراد نمایش می‌دهد. در این جدول به خلاصه‌ای از مزایا و معایب روش‌های ارائه شده اشاره شده است.

۴- مدل پیشنهادی

مطالعات تصویربرداری عصبی چندین نظریه را در مورد نقشه‌برداری بین ساختار و عملکرد مغز ارائه کرده است که

^۶ Long Short Term Memory (LSTM)

^۵ Parieto-frontal Integration Theory (P-FIT)


علاوه بر این، سامانه‌های استنتاج فازی را می‌توان در کنار مدل‌های یادگیری عمیق برای ارائه تفسیرپذیری و توضیح‌پذیری آموزش داد. با ترکیب شبکه LSTM و منطق فازی، مدل‌های به دست آمده می‌توانند داده‌های نامطمئن یا غیردقیق را بهتر مدیریت کنند، تفسیرپذیری را بهبود بخشند و تصمیمات دقیق بگیرند. طرح‌واره کلی مراحل مدل پیشنهادی در شکل (۱) نشان داده شده است.

در مدل پیشنهادی و به منظور نرخ تشخیص بهره هوشی از ترکیب شبکه LSTM و منطق فازی استفاده شده است؛ به طور معمول منطق فازی را می‌توان با شبکه‌های عصبی عمیق در سطوح ورودی و استنتاج ادغام کرد. ورودی‌ها به طور معمول مقادیر قطعی یا علائم دودویی هستند؛ با این حال، با استفاده از مجموعه‌های فازی، ورودی‌ها را می‌توان به عنوان درجات عضویت در چندین دسته نمایش داد. این روش به مدل اجازه می‌دهد تا داده‌های ورودی نامشخص یا مبهم را مدیریت کند؛

(جدول-۱): روش‌های انجام شده روی تشخیص بهره هوشی

(Table-1): Methods used to diagnose IQ

معایب	مزایا	نتایج کلیدی	مدل	عنوان پژوهش و مرجع	مرجع
نیاز به داده‌های با کیفیت و حجم زیاد داده	استفاده از ساختار سری زمانی و ارتباطات پویا	دقت ۷۵ درصد ~ در پیش‌بینی IQ	Bi-directional LSTM	Accounting for Temporal Variability in fMRI Improves IQ Prediction	[۲۱]
پیچیدگی محاسباتی بالا	ترکیب چند منبع داده مغزی برای بهبود عملکرد	دقت ۷۰ درصد ~	Diffusion Map Fusion	Alternating Diffusion Map Based Fusion	[۲۲]
نیازمند تنظیم دقیق ابرپارامترها	یادگیری هم‌زمان چند وظیفه و حفظ ساختار هندسی داده	دقت ۷۲ درصد ~	Multi-task Learning	Multi-Task Learning Model for IQ Prediction (Chen et al., 2019)	[۲۳]
فقط روی داده ساختاری MRI	قابلیت استخراج ویژگی‌های پیچیده بدون مهندسی دستی	دقت ۷۸ درصد ~	CNN, Deep Learning	Deep Learning on Structural MRI (Cao et al., 2022)	[۲۴]
محدود به داده استراحتی، تفسیر سخت‌تر	مدل مبتن بر شبکه‌های مغزی (connectome)	دقت ۷۳ درصد ~	Connectome-based Predictive Modeling (CPM)	Connectome Signatures from Resting-state fMRI (Sui et al., 2022)	[۲۵]
دقت بالا، تعمیم‌پذیری	پیش‌بینی دقیق وضعیت‌های مغزی	کاهش زمان اسکن fMRI و در وضوح بالا یاد گرفته شده	Swin Transformer + CNN	Voxel-Level Brain States Prediction Using Swin Transformer (2025)	[۲۶]
مناسب برای کودکان، استراحتی	پیش‌بینی دقیق IQ عملکردی	ضریب هم‌بستگی $R=0.71$	یادگیری ماشین سنتی	Prediction of IQ from Resting-state fMRI (2024)	[۲۷]
شفافیت در تحلیل مغز	دقت متوسط با تفسیر بالا	نمرات IQ (gC) و سیال (gF)، با ضریب هم‌بستگی پیرسون به ترتیب ۰.۶۳ و ۰.۷۱	Explainable ML + Connectome	Choosing Explanation Over Performance (2024)	[۲۸]



شبکه LSTM

(شکل-۱): ساختار مدل پیشنهادی

(Figure-1): Structure of the proposed model

متوسط - بالا	بالا	متوسط	بالا	VR
متوسط - بالا	بالا	متوسط	متوسط	۸R
متوسط	بالا	بالا	کم	۹R

جدول (۲)، طرح‌واره مقدمات قواعد را نشان می‌دهد؛ در مدل TSK، پیامد هر قاعده تابعی خطی از q_LSTM (نمره به‌هنگار شده استخراج شده از LSTM که پویایی زمانی BOLD را خلاصه می‌کند)، شاخص به‌هنگار شده اتصال عملکردی بین شبکه جبهه-جداری و هیپوکامپ^۴ و شاخص ساختاری به‌هنگار شده برپایه Z-score حجم ماده خاکستری در ROI های کلیدی^۵ است و خروجی نهایی برپایه وزن دهی متناسب با درجات عضویت ترکیب می‌شود. برچسب متوسط - بالا بیان‌کننده پیامد خطی میانی بین متوسط و بالا است. دلیل استفاده از شبکه‌های LSTM این است که این شبکه نوعی از شبکه‌های عصبی بازگشتی^۶ هستند که به‌طور خاص برای پردازش داده‌های دنباله‌ای طراحی شده‌اند. شبکه‌های عصبی بازگشتی به‌دلیل مشکل «کاهش گرادین» در یادگیری وابستگی‌های طولانی‌مدت در دنباله‌ها با محدودیت‌هایی روبه‌رو هستند؛ شبکه‌های LSTM این مشکل را با استفاده از واحدهای حافظه و دریچه‌های مختلف حل کرده و به آن‌ها این امکان را می‌دهند که اطلاعات مهم را برای مدت طولانی حفظ کنند و اطلاعات غیرضروری را فراموش کنند. LSTM‌ها از سه نوع دریچه اصلی تشکیل شده‌اند: دریچه ورودی، دریچه فراموشی و دریچه خروجی. دریچه ورودی تعیین می‌کند که چه اطلاعاتی باید به حالت جدید اضافه شود؛ در حالی که دریچه فراموشی مشخص می‌کند که کدام اطلاعات قدیمی باید از حافظه حذف شود. دریچه خروجی نیز تعیین می‌کند که چه اطلاعاتی باید به‌عنوان خروجی تولید شود. این سازوکارهای بازرسی به LSTM اجازه می‌دهد تا در پردازش دنباله‌ها به‌صورت مؤثرتری عمل کند و وابستگی‌های طولانی‌مدت را یاد بگیرد؛ همچنین شبکه‌های استنتاج منطق فازی نیز برای مدل‌سازی و پردازش سامانه‌های غیرخطی و پیچیده طراحی شده‌اند. این شبکه‌ها با استفاده از اصول منطق فازی، به کاربر اجازه می‌دهند تا دانش و تجربیات خود را به‌صورت قواعد اگر-آنگاه^۷ بیان کند. این قواعد به سامانه کمک می‌کنند تا تصمیم‌گیری بهتری در شرایط فقدان قطعیت و ابهام انجام دهد. ساختار اساسی یک سامانه استنتاج منطق فازی شامل سه بخش اصلی است: (۱) بخش فازی‌سازی، (۲) بخش استنتاج و (۳) بخش غیرفازی‌سازی.

همان‌طور که در شکل (۱) نشان داده شد، مدل پیشنهادی شامل سه مرحله اصلی است. در ادامه جزئیات هر سه مرحله به تفکیک توضیح داده شده‌است.

مرحله ۱: پیش‌پردازش داده‌های fMRI

تصاویر سه بعدی مغز را می‌توان به‌عنوان ورودی مدل پیشنهادی برای استخراج ویژگی‌های مرتبط با ضریب هوشی استفاده کرد؛ اما این امر پیچیدگی‌های پردازش را افزایش می‌دهد؛ بنابراین در این مرحله برداشتن مجسمه و ایجاد برش‌های دوبعدی از تصاویر سه‌بعدی دو کار اصلی می‌است. برداشتن مجسمه فرآیند تقسیم بافت مغز از ناحیه اطراف سر است. در این پژوهش، برای انتخاب بخش‌های صحیح مغز از نرم‌افزار MRIcro استفاده شده‌است. در ادامه پیش‌پردازش حذف نوفه، به‌هنگار کردن، هم‌ترازی^۱، هموارسازی^۲، انتخاب نواحی مغزی AAL atlas و استخراج علائم زمانی از هر ROI انجام می‌شود.

مرحله ۲: مدل LSTM

برای آموزش یک شبکه LSTM و پیش‌بینی داده‌های جدید، تصاویر مغز باید اندازه مورد نیاز شبکه عصبی را برآورده کنند؛ در این راستا در این مرحله، اندازه تصاویر تغییر می‌یابد. در این مرحله گام‌های زیر انجام می‌گیرد:

- ورودی LSTM: دنباله‌هایی از بردارهای BOLD از چندین ROI

- خروجی LSTM: ویژگی‌های سطح بالا یا پیش‌بینی اولیه بهره هوشی

مرحله ۳: منطق فازی^۳

در این مرحله ورودی منطق فازی به‌این‌صورت است:

- ورودی: خروجی LSTM با ویژگی‌های مهم یا پیش‌بینی IQ خام

- قوانین فازی: با در نظر گرفتن نواحی فعال و غیر فعال

- خروجی: تخمین نهایی IQ

(جدول - ۲): جدول قواعد فازی (TSK) با نه قاعده منتخب

(Table-2): TSK Fuzzy Rule Table with 9 Selected Rules

ID	q_LSTM	conn_score	gm_z	خروجی (IQ)
۱R	کم	کم	کم	کم
۲R	کم	متوسط	کم	کم
۳R	متوسط	متوسط	متوسط	متوسط
۴R	بالا	متوسط	متوسط	متوسط - بالا
۵R	متوسط	بالا	متوسط	متوسط - بالا
۶R	بالا	بالا	متوسط	متوسط - بالا

^۵ gm_z
^۶ RNN
^۷ If-Then

^۱ realignment
^۲ smooth
^۳ Fuzzy Inference System - FIS
^۴ conn_score

اعتبارسنجی با استفاده از روش K-Fold و K=10 استفاده شده است. در ادامه جزئیات پیاده سازی مورد بحث و بررسی قرار گرفته است.


۵-۱- مجموعه داده ABIDE

در این پژوهش از تصاویر مغزی fMRI در مجموعه داده ABIDE استفاده شده است. این مجموعه شامل داده هایی از ۱۱۱۴ فرد است که ۵۲۱ نفر از آن ها مبتلا به اوتیسم و ۵۹۳ نفر از آن ها در گروه بررسی قرار دارند. ۴۷۴ مرد و ۶۵ زن مبتلا به اوتیسم، ۴۷۴ مرد و ۹۹ زن در گروه بررسی هستند. مجموعه داده شامل تصاویر مغز سه بعدی و قالب فایل تصویری NIFTI (ابتکار فناوری اطلاعات داده ورزی عصبی) است. اطلاعات رخ نمودی (فنوتیپی) نیز شامل سن، جنسیت و نمرات IQ افراد مختلف است. فایل رخ مانده ای سه شکل از نمرات IQ را فهرست کرده است که عبارتند از: IQ کامل، FIQ، ضریب هوشی عملکرد PIQ و هوش کلامی VIQ. در این پژوهش FIQ به عنوان معیار هوش در نظر گرفته شده است. امتیازات FIQ برای بسیاری از موضوعات در مجموعه داده فهرست نشده است و بنابراین FIQ برای آن افراد از مقادیر PIQ و VIQ با استفاده از رابطه (۱) محاسبه می شود [۳۰]:

$$FIQ = -11.611 + 0.551VIQ + 0.566PIQ \quad (1)$$

۵-۲- بررسی نتایج و آزمایش ها

شبکه های LSTM بیشتر به تصاویر ورودی نیاز دارند تا اندازه ثابتی داشته باشند. این یک نواختی ضروری است؛ زیرا معماری شبکه، به ویژه لایه های به طور کامل متصل، انتظار ورودی با اندازه ثابت را دارد. در مدل پیشنهادی، ابعاد تمامی تصاویر (۲۵۵، ۲۶۱) تغییر یافته است؛ همچنین برای ارزیابی مدل پیشنهادی، از معیارهای دقت، F1-Score برای هر کلاس و میانگین میزان خطا در مجموعه های آموزش و آزمون استفاده شده است. شکل (۲) نرخ تشخیص IQ را با استفاده از مدل پیشنهادی و معیار F1-Score برای مجموعه های آموزش و آزمون نمایش می دهد.



(شکل ۲): میزان خطای آموزش و خطای آزمون در تشخیص

IQ روی مدل پیشنهادی

(Figure- 2): The amount of training error and test error in IQ detection on the proposed model

در بخش فازی سازی، مقادیر دقیق ورودی به مقادیر فازی تبدیل می شوند. این کار با استفاده از توابع عضویت انجام می شود که تعیین می کنند یک ورودی تا چه حد به یک مجموعه فازی خاص تعلق دارد. در مرحله استنتاج، قواعد تعریف شده بررسی شده و نتیجه ها محاسبه می شوند؛ در نهایت، در بخش غیرفازی سازی، نتایج فازی به مقادیر دقیق و محسوب شده تبدیل می شوند تا تصمیم نهایی گرفته شود.

ادغام این دو فناوری می تواند منجر به یک مدل جامع و دقیق برای تشخیص بهره هوشی باشد. این سامانه می تواند به پزشکان و متخصصان کمک کند تا اطلاعات بهتری از وضعیت مغز بیماران به دست آورند و به تشخیص های پیشرفته تری نائل آیند؛ همچنین، قابلیت پاسخ گویی به تغییرات پیچیده در داده های مغزی کمک می کند تا نتایج قابل اعتمادتر و در نتیجه درک بهتری از رابطه بین ساختار مغز و بهره هوشی به دست آید. ترکیب LSTM با منطق فازی دارای مزایایی به شرح زیر است:

- مدیریت فقدان قطعیت: منطق فازی برای مدیریت فقدان قطعیت و ابهام طراحی شده است. با ترکیب LSTM، با منطق فازی، می توان از نقاط قوت هر دو رویکرد برای مدیریت فقدان قطعیت در داده های متوالی استفاده کرد.

- استحکام در برابر داده های نوفه ای: ترکیب LSTM با منطق فازی می تواند استحکام در برابر نوفه را با اجازه دادن به عملکردهای عضویت انعطاف پذیرتر و سازوکارهای استدلال افزایش دهد.

به اختصار دنباله زمانی ROI های AAL-116 با یک LSTM دولایه پردازش و بردار نهفته نهایی با یک MLP کوچک به نمره به هنجار شده q_LSTM تبدیل می شود؛ هم زمان دو شاخص؛ یعنی شاخص به هنجار شده اتصال عملکردی بین شبکه جبهه جداری و هیپوکامپ و شاخص ساختاری به هنجار شده بر پایه Z-score حجم ماده خاکستری در ROI های کلیدی استخراج و هر سه ورودی به بازه [۰، ۱] مقیاس می شوند. این سه مقدار به سامانه فازی TSK درجه یک داده می شود؛ در این سامانه پیامد هر قانون تابعی خطی از ورودی هاست و خروجی نهایی به صورت ترکیب وزن دار قوانین محاسبه و سپس به مقیاس استاندارد IQ بازنگاشت می شود. همه به هنجار سازی ها تنها بر اساس آمار مجموعه آموزش انجام می شود تا از سرریز اطلاعات جلوگیری شود.

۵- تشریح و بحث نتایج

تمامی پیاده سازی های این پژوهش با نرم افزار پایتون صورت گرفته است. در آزمایش های انجام شده، هشتاد درصد داده ها به مجموعه آزمون و بیست درصد به مجموعه آزمون اختصاص داده شده و در تمام آزمایش ها از آزمون


استفاده از داده‌های MRI و fMRI اختصاص دارد و نشان‌دهنده عملکرد روش‌های مختلف در پژوهش‌های گذشته است؛ در مقابل، جدول (۳) نتایج حاصل از پیاده‌سازی مدل پیشنهادی و مقایسه آن با روش‌های پایه بر روی مجموعه داده ABIDE را ارائه می‌دهد؛ بنابراین، رابطه (۱) مبنای محاسبه برچسب‌های مورد استفاده در این پژوهش را فراهم کرده و نتایج ارائه شده در جدول (۳) بر اساس همین مقادیر محاسبه شده یا گزارش شده FIQ ارزیابی شده‌اند؛ در حالی که جدول (۱) تنها برای مقایسه با مطالعات پیشین ارائه شده است.

۶- نتیجه گیری

در این پژوهش و به منظور تشخیص بهره‌ هوشی از روی تصاویر fMRI و از ترکیب شبکه LSTM و منطق فازی استفاده شد. برای ترکیب شبکه LSTM و منطق فازی به منظور تشخیص بهره‌ هوشی از روی تصاویر fMRI مغزی، ابتدا نیاز است که ویژگی‌های کلیدی از تصاویر استخراج شوند. رسانه‌های مغزی به شکل پیچیده‌ای اطلاعاتی را درباره ساختار و فعالیت مغز ارائه می‌دهند. روش‌های پردازش تصویر مانند پالایه‌گذاری و استخراج ویژگی‌ها می‌توانند به شناسایی الگوهای مرتبط با هوش کمک کنند. شبکه LSTM توانایی پردازش داده‌های متوالی را دارد و می‌تواند رابطه‌های پیچیده درون زمان را شناسایی کند، که این امر در تشخیص تغییرات ناشی از بهره‌ هوشی حائز اهمیت است؛ پس از استخراج ویژگی‌ها، مرحله بعدی استفاده از شبکه استنتاج منطق فازی است. منطق فازی به پژوهش‌گر اجازه می‌دهد تا تصمیم‌گیری‌های نامشخص و نیود قطعیت‌ها را در ورودی‌ها لحاظ کنند. در این مرحله، بر اساس ویژگی‌های استخراج شده، قاعده‌های فازی برای تعیین سطح بهره‌ هوشی طراحی می‌شوند. این قاعده‌ها می‌توانند ورودی‌های مختلف را به سطوح مختلف هوش مرتبط کنند و به دستگاه کمک می‌کنند تا نتایج دقیقی ارائه دهد.

در انتها باید به این نکته اشاره کرد، در شرایطی که بتوان مدل‌های یادگیری عمیق را با حجم بزرگی از داده‌ها آموزش داد این مدل‌ها از کارایی خوبی برخوردار خواهند بود؛ اما همواره در کاربردهای مختلف با مجموعه داده‌های عظیم هنوز چالش‌هایی وجود دارد؛ به همین دلیل در کارهای آینده پیشنهاد می‌شود تا از روش‌های انطباق دامنه و انتقال یادگیری در این کاربرد استفاده شود؛ همچنین در سطح مدل یادگیری و در همین مدل پیشنهادی نیز می‌توان تعداد لایه‌های شبکه را افزایش داد و میزان تأثیر آن را مشاهده کرد

همان‌طور که از شکل (۲) مشاهده می‌شود نرخ خطا در مرحله آزمون و آموزش در سی بار تکرار به شدت پایین آمده است. شکل (۳) میزان خطای آموزش و خطای تست تشخیص IQ را روی مدل پیشنهادی و تصاویر fMRI مغزی نمایش می‌دهد. نتایج به دست آمده به ازای هر پنج کلاس بسیار برتر، برتر، متوسط بالا و متوسط و متوسط پایین دسته بندی می‌شود. جدول (۳) نتایج دقت مدل‌های رقیب را با مدل پیشنهادی نمایش می‌دهد.



(شکل-۳): تشخیص IQ با استفاده از معیار F1-Score به ازای

هر کلاس روی مدل پیشنهادی

(Figure-3): IQ detection using the F1-Score criterion for each class on the proposed model

(جدول-۳): مقایسه معیار دقت برای مدل‌های اجرا شده روی

مجموعه داده ABIDE

(Table-3): Comparison of the accuracy criteria for the models implemented on the ABIDE dataset

میزان دقت	نام مدل
دقت	روش
۵۳ درصد	ResNet-50 [5]
۷۳ درصد	VGG16 [5]
۶۰ درصد	ResNet-50+XGboost [5]
۶۳ درصد	LSTM [21]
۸۳ درصد	LSTM+Fuzzy

در جدول (۳)، عملکرد روش پیشنهادی با چندین روش پایه مقایسه شده است. به منظور انجام مقایسه‌ای منصفانه، مدل‌های پایه شامل ResNet-50 و VGG16 و LSTM بر اساس مطالعات پیشین [۵] و [۲۱] پیاده‌سازی شده و تمامی روش‌ها تحت شرایط یکسان و با استفاده از مجموعه داده ABIDE مورد ارزیابی قرار گرفته‌اند. در این پژوهش، معیار اصلی ارزیابی سطح هوش، نمره بهره‌ هوشی کلی (FIQ) در نظر گرفته شده است؛ از آنجا که در برخی از نمونه‌های مجموعه داده ABIDE مقدار FIQ به صورت مستقیم گزارش نشده است، مقدار آن با استفاده از رابطه (۱) و بر اساس مقادیر VIQ و PIQ محاسبه شد. جدول (۱) به مرور نتایج مطالعات پیشین در زمینه تخمین بهره‌ هوشی با

- [19] S. Pölsterl et al., "Prediction of fluid intelligence from MRI," in *MICCAI Workshop*, 2019.
- [20] S. Srivastava et al., "Predicting fluid intelligence using ensemble methods," *Springer*, 2019.
- [21] Y. Li et al., "Accounting for temporal variability in fMRI improves IQ prediction," *Human Brain Mapping*, vol. 44, no. 13, pp. 4772–4791, 2023.
- [22] L. Xiao et al., "Alternating diffusion map-based fusion," *IEEE Trans. Biomedical Engineering*, vol. 66, no. 8, pp. 2140–2151, 2018.
- [23] S. Zhang et al., "Multi-task learning model for IQ prediction," *Environmental Research*, 2024.
- [24] M. A. Hussain et al., "Deep learning on structural MRI," *Scientific Reports*, vol. 14, 2024.
- [25] X. Tong et al., "Connectome signatures from resting-state fMRI," *Translational Psychiatry*, vol. 12, no. 1, 2022.
- [26] Y. Sun et al., "Voxel-level brain state prediction using Swin Transformer," *arXiv preprint*, 2025.
- [27] N. He, C. Kou, "Prediction of IQ from resting-state fMRI," *Int. J. Developmental Neuroscience*, vol. 84, no. 7, pp. 779–790, 2024.
- [28] J. A. Thiele et al., "Choosing explanation over performance," *PNAS Nexus*, vol. 3, no. 12, 2024.

[۲۹] معتمد، سارا؛ عسکری، احسان، «تشخیص اسلحه کمری با استفاده از شبکه عصبی کانولوشنی سه بعدی»، فصلنامه پردازش علائم و داده‌ها، دوره ۲، شماره ۵۶، صفحات ۷۹–۱۴۰۲، ۶۹.

- [29] Motamed, S., Askari, E., "Detection of handgun using 3D convolutional neural network (3DCNNs)," *Signal and Data Processing*, vol. 2, no. 56, pp. 69–79, 2023.
- [30] M. Hanik et al., "Predicting cognitive scores with graph neural networks," *Brain Imaging and Behavior*, 2021.



سارا معتمد دکترای خود را در رشته مهندسی رایانه گرایش هوش مصنوعی در سال ۱۳۹۶ دریافت کرده‌است. وی هم‌اکنون استادیار گروه مهندسی کامپیوتر دانشگاه آزاد اسلامی واحد فومن و شفت است. زمینه‌های پژوهشی ایشان هوش مصنوعی، پردازش تصاویر، بینایی ماشین و علم داده است. نشانی رایانامه ایشان عبارت است از:

sara.motamed@iau.ac.ir



مجید اقدامی عربانی دانش‌آموخته کارشناسی ارشد مهندسی کامپیوتر است. وی مدرک کارشناسی خود را از دانشگاه آزاد اسلامی واحد لاهیجان دریافت کرده‌است. زمینه‌های پژوهشی وی پردازش تصاویر و شناسایی آماری الگو است.

نشانی رایانامه ایشان عبارت است از:

eghdami61@gmail.com

7-References

۷-مراجع

- [1] G. O. Adebayo, R. V. Yampolskiy, "Estimating intelligence quotient using stylometry and machine learning techniques: A review," *Big Data Mining and Analytics*, vol. 5, no. 3, pp. 163–191, 2022.
- [2] P. Thilakavathy, B. Diwan, "Semi-automatic framework for estimating intelligence quotient (IQ) using MRI," *Archives of Clinical and Biomedical Research*, pp. 2087–2101, 2021.
- [3] F. Liu, Y. Shi, Z. Chen, "Intelligence quotient test for smart cities in the United States," *Journal of Urban Planning and Development*, vol. 147, no. 1, p. 04020053, 2021.
- [4] F. Ke, H. Liu, M. Zhou, R. Yang, H.-M. Cao, "Diagnostic biomarker exploration of autistic patients with different ages and verbal intelligence quotients using random forest," *IEEE Access*, vol. 9, pp. 123861–123872, 2021.
- [5] A. Arya, M. Manuel, "Intelligence quotient classification from human MRI brain images using convolutional neural network," in *Proc. 12th Int. Conf. Computational Intelligence and Communication Networks (CICN)*, IEEE, 2020, pp. 75–80.
- [6] L. Wang, C. Y. Wee, H. I. Suk, X. Tang, D. Shen, "MRI-based intelligence quotient estimation with sparse learning," *PLoS One*, vol. 10, no. 3, p. e0117295, 2015.
- [7] Y. Li et al., "Brain anatomical network and intelligence," *PLoS Computational Biology*, vol. 5, no. 5, p. e1000395, 2009.
- [8] M. McDaniel, "Big-brained people are smarter: A meta-analysis of brain volume and intelligence," *Intelligence*, vol. 33, no. 4, pp. 337–346, 2005.
- [9] K. Supekar et al., "Neural predictors of individual differences in response to math tutoring," *Proc. Natl. Acad. Sci. USA*, vol. 110, no. 20, pp. 8230–8235, 2013.
- [10] S. Frangou, X. Chitins, S. C. Williams, "Mapping IQ and gray matter density in healthy young people," *NeuroImage*, vol. 23, no. 3, pp. 800–805, 2004.
- [11] "MRI from picture to proton," *American Journal of Neuroradiology*, vol. 29, no. 6, p. e50, 2008.
- [12] M. A. Balafar et al., "Review of brain MRI image segmentation methods," *Artificial Intelligence Review*, vol. 33, no. 3, pp. 261–274, 2010.
- [13] Y. Roy et al., "Deep learning-based EEG analysis: A systematic review," *Journal of Neural Engineering*, vol. 16, no. 5, 2019.
- [14] S. S. Yadav, S. Jadhav, "Deep CNN-based medical image classification," *Journal of Big Data*, vol. 6, no. 1, pp. 1–18, 2019.
- [15] M. A. Hussain et al., "Can deep learning predict human intelligence from structural MRI?," *bioRxiv*, 2023.
- [16] T. Shen, "Classifying brain using convolutional neural networks," *M.Sc. Thesis*, University of Manchester, 2020.
- [17] Y. S. Vang, Y. Cao, X. Xie, "Deep learning and gradient boosting for intelligence prediction," in *ABCD-NP Challenge*, MICCAI, 2019.
- [18] A. El Boustani et al., "MRI brain classification using CNN," in *AI2SD*, Springer, 2020.