



## **IQ Estimation from MRI Images using a Combination of Convolutional Neural Network and XGBoost Algorithm**

**Rostami, Shayan<sup>1</sup> / Sadr, Hossein<sup>2\*</sup> / Edalatpanah, Seyed Ahmad<sup>3</sup> / Nazari, Mojdeh<sup>4</sup>**

<sup>1</sup> - M.Sc., Department of Computer Engineering, Ayandegan Institute of Higher Education, Tonekabon, Iran

<sup>2</sup> - Assistant Professor, Department of Health Informatics, Guilan Road Trauma Research Center, Trauma Institute, Guilan University of Medical Sciences, Rasht, Iran

<sup>3</sup> - Associate Professor, Department of Computer Engineering, Ayandegan Institute of Higher Education, Tonekabon, Iran

<sup>4</sup> - Assistant Professor, Department of Health Information Technology and Management, School of Allied Medical Sciences, Shahid Beheshti University of Medical Sciences, Tehran, Iran

### **ARTICLE INFO**

DOI: 10.22041/ijbme.2024.2031836.1906

Received: 10 June 2024

Revised: 28/10/2024 – 13/11/2024

Accepted: 27 November 2024

### **KEYWORDS**

*IQ*  
*Deep Learning*  
*Convolutional Neural Network*  
*XGBoost Algorithm*  
*MRI Images*

### **ABSTRACT**

IQ test is a common solution to detect and measure people's intelligence, but studies show that the brain activity of intelligent people is significantly different compared to people with normal and low IQ, and this difference can be detected from advanced magnetic resonance imaging or MRI. In this regard, the aim of this paper is to present a model based on artificial intelligence to estimate people's IQ from brain MRI images. To achieve this goal, the combination of Convolutional Neural Network (CNN) and eXtreme Gradient Boosting (XGBoost) is used in this paper. Convolutional neural networks excel in extracting features from images and make them effective for processing visual stimuli related to IQ tests. On the other hand, the XGBoost algorithm is a powerful ensemble algorithm that can effectively combine the predictions of multiple models to improve overall accuracy. In the proposed model, ResNet-50 and VGG16 were used as a feature extractor and the XGBoost algorithm was used as an identifier at the top level of the network to generate results. The proposed model was tested on the Autism Brain Imaging Information Exchange (ABIDE) brain image dataset. Based on the results of the experiments, the use of the pre-trained convolutional neural network VGG16 showed a better performance than the pre-trained convolutional neural network ResNet-50 in the feature extraction section, and its combination with XGBoost algorithm obtained an accuracy of 83% achieved against 60% accuracy of ResNet-50.

### **\*Corresponding Author**


**Address:** Department of Health Informatics, Guilan Road Trauma Research Center, Trauma Institute, Guilan University of Medical Sciences, Rasht, Iran

**Postal Code:** 41937-13111

**E-Mail:** [hosein.sadr@gums.ac.ir](mailto:hosein.sadr@gums.ac.ir)

**Tel:** +98-13-33335823





## تخمین بهره‌ی هوشی از روی تصاویر ام آر آی با استفاده از ترکیب شبکه‌ی عصبی کانولوشنی و الگوریتم تقویت گرادیان فوق‌العاده

رستمی، شایان<sup>۱</sup> / صدر، حسین<sup>۲\*</sup> / عدالت‌پناه، سیداحمد<sup>۳</sup> / نظری، مژده<sup>۴</sup>

- ۱- کارشناسی ارشد، گروه مهندسی کامپیوتر، موسسه‌ی آموزش عالی آیندگان، تنکابن، ایران
- ۲- استادیار، گروه انفورماتیک سلامت، پژوهشکده‌ی تروما، دانشگاه علوم پزشکی گیلان، رشت، ایران
- ۳- دانشیار، گروه مهندسی کامپیوتر، موسسه‌ی آموزش عالی آیندگان، تنکابن، ایران
- ۴- استادیار، گروه انفورماتیک پزشکی، دانشکده‌ی پیراپزشکی، دانشگاه علوم پزشکی شهید بهشتی، تهران، ایران

### مشخصات مقاله

شناسه‌ی دیجیتال: 10.22041/ijbme.2024.2031836.1906

پذیرش: ۷ آذر ۱۴۰۳

بازنگری: ۱۴۰۳/۸/۱۷ - ۱۴۰۳/۸/۲۳

ثبت در سامانه: ۲۱ خرداد ۱۴۰۳

### چکیده

تست آی کیو یک راه حل متداول برای تشخیص و اندازه‌گیری میزان هوش افراد است اما بررسی‌ها نشان داده که ساختار مغزی افراد باهوش در مقایسه با افراد معمولی و با ضریب هوش پایین تفاوت چشم‌گیری دارد که این اختلاف را می‌توان به کمک آشکارسازهای پیش‌رفته‌ی مغناطیسی یا تصاویر ام آر آی مغزی تشخیص داد. در این راستا هدف این مقاله ارائه‌ی مدلی مبتنی بر هوش مصنوعی برای تخمین بهره‌ی هوشی افراد از روی تصاویر ام آر آی مغزی است. برای رسیدن به این هدف در این مقاله از ترکیب شبکه‌ی عصبی کانولوشنی و الگوریتم تقویت گرادیان فوق‌العاده استفاده شده است. شبکه‌های عصبی کانولوشنی در استخراج ویژگی‌های محلی از تصاویر برتری دارند که آن‌ها را برای پردازش محرک‌های بصری مرتبط با تست بهره‌ی هوشی موثر می‌سازد. از سوی دیگر الگوریتم تقویت گرادیان فوق‌العاده یک الگوریتم گروهی قدرتمند است که می‌تواند به طور موثر پیش‌بینی‌های چندین مدل را برای بهبود دقت کلی ترکیب کند. در این راستا در مدل پیشنهادی از شبکه‌های عصبی کانولوشنی ResNet-50 و VGG16 به عنوان استخراج‌کننده‌ی ویژگی و از الگوریتم تقویت گرادیان فوق‌العاده به عنوان یک شناسایی‌کننده در سطح بالای شبکه برای دسته‌بندی استفاده شده است. مدل پیشنهادی روی مجموعه‌ی داده‌ی تصاویر مغز تبادل اطلاعات تصویربرداری مغز اوتیسم (ABIDE) مورد آزمایش قرار گرفته است. بر اساس نتایج حاصل از آزمایشات، استفاده از شبکه‌ی عصبی کانولوشنی از پیش آموزش داده شده‌ی VGG16 به نسبت شبکه‌ی عصبی کانولوشنی از پیش آموزش داده شده‌ی ResNet-50 در بخش استخراج ویژگی عمل کرد بهتری نشان داده و ترکیب آن با الگوریتم تقویت گرادیان فوق‌العاده به دقت ۸۳٪ در برابر دقت ۶۰٪ شبکه‌ی عصبی کانولوشنی ResNet-50 دست یافته است.

### واژه‌های کلیدی

بهره‌ی هوشی  
یادگیری عمیق  
شبکه‌ی عصبی کانولوشنی  
الگوریتم تقویت گرادیان فوق‌العاده  
تصاویر ام آر آی

### \*نویسنده‌ی مسئول

نشانی: گروه انفورماتیک سلامت، پژوهشکده‌ی تروما، دانشگاه علوم پزشکی گیلان، رشت، ایران

تلفن: ۰۹۸-۱۳-۳۳۳۳۵۸۲۳


پست الکترونیکی: hosein.sadr@gums.ac.ir

کد پستی: ۴۱۹۳۷-۱۳۱۱۱



## ۱- مقدمه

شناختی خفیف و غیره شده است [۱۲-۱۴]. از آنجا که در مطالعات، ارتباط عمیقی بین هوش و آناتومی مغز انسان مشاهده شده است، می‌توان بهره‌ی هوشی را از روی تصاویر ام‌آر‌آی مغزی<sup>۲</sup> نیز تشخیص داد. آناتومی مغز انسان در یک نیم‌کره در شکل (۱) ارائه شده که شامل چهار لوب مجزای پیشانی<sup>۳</sup>، گیج‌گاهی<sup>۴</sup>، پس‌سری<sup>۵</sup> و جداری<sup>۶</sup> است. به نظر می‌رسد لوب‌های گیج‌گاهی در ارتباط با لوب‌های پیشانی کم‌تر با سطوح بالاتر بهره‌ی هوش در کودکان و بزرگسالان جوان مرتبط است. با این حال در میان‌سال، لوب‌های جداری در قیاس با لوب‌های پیشانی نقش محوری‌تری در توانایی‌های شناختی ایفا می‌کنند.



شکل (۱) - آناتومی مغز انسان

با توجه به ارتباط آشکار بین ساختار مغز و سطوح هوش، هدف این مقاله نیز ارائه‌ی مدلی مبتنی بر ترکیب شبکه‌های یادگیری عمیق برای تشخیص میزان بهره‌ی هوشی از روی تصاویر ام‌آر‌آی مغزی است. در این راستا در این مقاله از ترکیب شبکه‌ی عصبی کانولوشنی<sup>۷</sup> و الگوریتم تقویت گرادیان فوق‌العاده<sup>۸</sup> (XGBoost) برای رسیدن به این هدف استفاده شده است. شبکه‌های عصبی کانولوشنی با توجه به ساختار خود توانایی استخراج خودکار ویژگی‌های محلی از تصاویر را دارند. از سوی دیگر الگوریتم تقویت گرادیان فوق‌العاده یک الگوریتم گروهی قدرتمند است که می‌تواند به طور موثر پیش‌بینی‌های چندین مدل را برای بهبود دقت کلی ترکیب کند. در این راستا از شبکه‌های عصبی کانولوشنی ResNet-50 و VGG16 به عنوان استخراج‌کننده‌ی ویژگی و از الگوریتم تقویت گرادیان فوق‌العاده به عنوان یک شناسایی‌کننده در سطح بالای شبکه برای تولید نتایج استفاده شده است. مدل پیشنهادی این مقاله روی مجموعه‌ی داده‌ی تصویر مغز تبادل اطلاعات تصویربرداری مغز اوتیسم<sup>۹</sup> (ABIDE)

هوش به معنای توانایی فراگیر انسان برای فهمیدن، یادگیری، اندیشیدن، حل مسائل، اتخاذ تصمیمات و قدرت برقراری ارتباط با دیگران و محیط اطراف است [۱]. بهره‌ی هوشی<sup>۱</sup> (IQ) راهی برای سنجش هوش انسان است که قدرت ذهنی یا هوش یک فرد را نسبت به سایر افراد در یک جامعه مشخص می‌کند. در واقع بهره‌ی هوشی امتیازی است که از آزمون‌های مختلف به دست آمده و توسط روان‌شناسان بالینی به عنوان یک معیار آماری معتبر برای اهداف بالینی مورد استفاده قرار می‌گیرد [۲، ۳].

تعیین هوش انسانی همواره مورد توجه پژوهشگران علوم اعصاب شناختی بوده [۴، ۵] و تحقیقات نشان داده است که در صورت امکان تعیین سطح بهره‌ی هوشی، نتایج به دست آمده می‌تواند منجر به درک و درمان بهتر مشکلات و اختلالات روانی از جمله اختلالات طیف اوتیسم، اسکیزوفرنی یا افسردگی شود [۶، ۷]. با این حال بهره‌ی هوشی یک مفهوم پیچیده است و اندازه‌گیری آن توسط یک روش تک نظر نمی‌تواند به صورت دقیق و کامل انجام شود. همچنین برخی از افراد ممکن است پاسخ‌های صادقانه‌ای را در پاسخ به سوالات پرسش‌نامه‌های هوشی ارائه ندهند و بررسی‌های تکراری، خستگی مخفی و ترجیح برخی فعالیت‌های هوشی را برای یک شخص به دنبال داشته باشد. همچنین آزمون‌های استاندارد تعیین بهره‌ی هوشی به دلیل مجموعه‌های آزمایشی مبتنی بر پرسش‌نامه برای نوزادان یا کودکان قابل اجرا نیستند. در نتیجه چنانچه روش سیستماتیک‌تری برای تخمین بهره‌ی هوشی ایجاد شود، نه تنها نویدهای بزرگی برای شناسایی نوزادان یا کودکانی که ممکن است دچار رشد فکری غیرعادی شوند خواهد داشت بلکه فرصتی برای انجام مداخلات اولیه مانند آموزش‌های تخصصی و مناسب را فراهم خواهد کرد [۸، ۹].

در سال‌های اخیر و با ظهور روش‌های مختلف تصویربرداری مغز، تلاش‌هایی برای بررسی رابطه‌ی بین آناتومی مغز و هوش صورت گرفته است. تصویربرداری مغز کمک می‌کند تا فعالیت‌های طبیعی و غیرطبیعی مرتبط با مغز مانند پیش‌بینی بیماری، نارسایی ناحیه، پیش‌بینی هوش و سایر عمل‌کردهای حیاتی مختلف یافته شود [۵، ۱۰، ۱۱]. به طور کلی توسعه‌ی سریع فناوری تصویربرداری مغزی در سال‌های اخیر باعث دستیابی به موفقیت قابل توجهی در تشخیص بیماری‌های عصبی مختلف مانند آلزایمر، پارکینسون، اسکیزوفرنی، افسردگی و اختلال

<sup>۶</sup> Parietal Lobe<sup>۷</sup> Convolutional Neural Network<sup>۸</sup> Extreme Gradient Boosting<sup>۹</sup> Autism Brain Imaging Data Exchange<sup>۱</sup> Intelligence Quotient<sup>۲</sup> Magnetic Resonance Imaging<sup>۳</sup> Frontal Lobe<sup>۴</sup> Temporal Lobe<sup>۵</sup> Occipital Lobe

سوسا و هم‌کارانش به پیش‌بینی هوش سیال از روی تصاویر ام‌آر‌آی با وزن T1 پرداخته‌اند. در این راستا آن‌ها از ترکیب سه مدل ماشین بردار پشتیبان، جنگل تصادفی و الگوریتم انتخاب مدل مرحله‌ی عاقلانه‌ی بوت استرپ<sup>۱</sup> استفاده کرده‌اند. بر اساس نتایج به دست آمده، ویژگی‌های برتر حجم ماده‌ی سفید و حجم شکنج پراهیپوکامپ با هوش سیال مرتبط بوده و تایید شده است که می‌توان از روش‌های یادگیری ماشین برای کشف ویژگی‌های مرتبط با هوش سیال استفاده کرد [۱۸].

وانگ و هم‌کارانش یک چارچوب برای تخمین بهره‌ی هوشی از روی تصاویر ام‌آر‌آی ارائه کرده‌اند. آن‌ها دو مجموعه آزمایش روی داده‌های ام‌آر‌آی جمع‌آوری شده از ۱۶۴ کودک در بازه‌ی سنی ۶ تا ۱۵ سال انجام داده‌اند. در آزمایش اول، آن‌ها از یک رگرسیون بردار پشتیبان چندهسته‌ای<sup>۲</sup> برای تخمین مقادیر بهره‌ی هوشی استفاده کرده و ضریب همبستگی متوسط ۰/۷۱۸ و میانگین ریشه‌ی میانگین مربع خطای ۸/۶۹۵ بین بهره‌ی هوش واقعی و بهره‌ی هوشی برآورد شده را به دست آورده‌اند. در آزمایش دوم، آن‌ها از SVR تک‌هسته‌ای برای تخمین ضریب هوشی استفاده کرده و ضریب همبستگی متوسط ۰/۶۸۴ و میانگین ریشه‌ی میانگین مربعات خطای ۹/۱۶۶ را به دست آورده‌اند. نتایج به دست آمده اثربخشی استفاده از داده‌های تصویربرداری برای پیش‌بینی بهره‌ی هوشی را نشان داده است [۱۹].

با توجه به اهمیت طبقه‌بندی تصاویر پزشکی و چالش مجموعه‌ی داده‌های کوچک تصاویر پزشکی، سمیر و هم‌کارانش تاثیر اعمال طبقه‌بندی مبتنی بر شبکه‌ی عصبی کانولوشنی را روی مجموعه‌ی داده‌های کوچک اشعه‌ی ایکس از قفسه‌ی سینه مورد بررسی قرار داده‌اند. بر اساس نتایج آزمایشات، یادگیری انتقالی مبتنی بر شبکه‌ی عصبی کانولوشنی بهترین روش در مواجهه با مجموعه‌ی داده‌های کوچک است [۲۰].

پیش‌بینی امتیازات هوش سیال مستقیماً از اسکن‌های ام‌آر‌آی مغز، بدون استخراج معیارهای ثانویه مانند حجم یا ضخامت، به دلیل ساختار پیچیده‌ی داده‌ها، کار دشواری است. مطالعه‌ی ساها و هم‌کارانش نشان داده که مدل‌های شبکه‌ی عصبی کانولوشنی پتانسیل پیش‌بینی نمرات هوش سیال اصلاح نشده و باقی‌مانده از ام‌آر‌آی‌های ساختاری با وزن T1 مغز را با عمل کرد بهتر در مقایسه با موارد قبلی دارند. آن‌ها توانسته‌اند بالاترین عمل کرد را برای پیش‌بینی امتیاز واقعی با معماری معمولی و برای پیش‌بینی امتیاز باقی‌مانده با معماری معکوس به دست آورند. افزودن معیارهای حجمی ناحیه‌ای مغز انتخاب شده با تصاویر برش شده، عمل کرد مدل را اندکی بهبود بخشیده است [۲۱].

مورد آزمایشی قرار گرفته است. بر اساس نتایج حاصل از آزمایشات، مدل پیشنهادی این مقاله از دقت بالاتری نسبت به مدل‌های پایه برای تشخیص بهره‌ی هوشی برخوردار است. در ادامه در بخش ۲ تعاریف پایه و جزئیات کارهای پیشین بیان شده است. جزئیات مدل پیشنهادی در بخش ۳ ارائه شده و بخش ۴ شامل جزئیات پیاده‌سازی و نتایج حاصل از آزمایشات است. بخش ۵ نیز حاوی نتیجه‌گیری و مسیر تحقیقات آینده است.

## ۲- پیشینه‌ی پژوهش

مطالعات مختلف نشان داده است که مناطق متعددی در ساختار پیچیده‌ی مغز با قدرت تفکر و بهره‌ی هوشی فرد ارتباط دارند. توسعه‌ی روش‌های مختلف تصویربرداری مغز در سال‌های اخیر و تولید حجم زیادی از داده‌ها از نماهای مختلف از مغز نیز منجر به انجام مطالعات مختلفی برای تعیین میزان بهره‌ی هوشی از روی این تصاویر شده است. در این راستا مانوئل و هم‌کارانش با الهام از همبستگی بین ساختار مغز و هوش، از شبکه‌ی عصبی کانولوشنی برای استخراج ویژگی و طبقه‌بندی بهره‌ی هوشی از تصاویر ام‌آر‌آی مغز بر اساس مقیاس هوش وکسلر استفاده کرده‌اند. نتایج آن‌ها نشان داده که تصاویر مغزی با نمای سائیتال و کروئال بهترین کاندید برای تعیین بهره‌ی هوشی هستند. آن‌ها همچنین نشان داده‌اند که با استفاده از شبکه‌ی عصبی کانولوشنی سه‌بعدی می‌توان بهره‌ی هوشی را از تصاویر سه‌بعدی مغز اندازه‌گیری کرد که نه تنها فرایند استخراج ویژگی را ساده‌تر می‌کند بلکه دقت دسته‌بندی را نیز افزایش می‌دهد [۱۵].

گران و هم‌کارانش نیز در مطالعه‌ی خود ارتباط تصاویر ام‌آر‌آی مغزی با وزن T1 را با بهره‌ی هوشی افراد مورد بررسی قرار داده‌اند. آن‌ها مجموعه‌ای جامع از ۴۳۲ آزمایش را با استفاده از تصاویر ورودی مختلف و ۶ مدل یادگیری عمیق روی ۸۵۰ فرد سالم و اوتیستیک در بازه‌ی سنی ۶-۶۴ سال انجام داده‌اند. بررسی‌های آن‌ها نشان دهنده‌ی ارتباط معنا دار بین بخش‌های مختلف مغز و میزان بهره‌ی هوشی افراد در سنین مختلف است [۱۶].

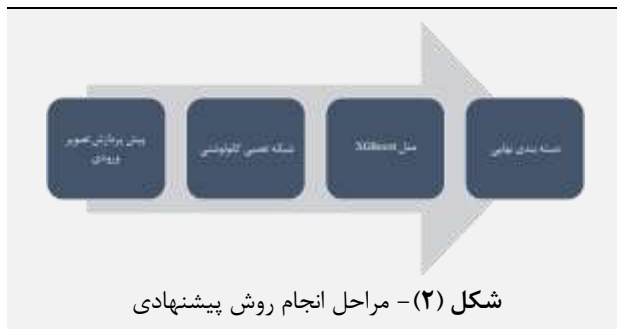
شن و هم‌کارانش یک سیستم طبقه‌بندی سن مغز با استفاده از تصاویر ام‌آر‌آی و شبکه‌ی عصبی کانولوشن سه‌بعدی را معرفی کرده‌اند. در این مطالعه چهار مرحله پیش‌پردازش شامل تغییر اندازه، استخراج مغز، تصحیح میدان سوگیری N4 و ثبت الگو انجام شده است. سپس شبکه‌ی عصبی کانولوشنی سه‌بعدی روی مجموعه‌ی داده‌ی پیش‌پردازش شده اعمال گردیده است. نتایج نشان داده که شبکه‌ی عصبی کانولوشن عمل کرد بهتری نسبت به روش‌های سنتی برای طبقه‌بندی سن مغز انسان دارد [۱۷].

<sup>۱</sup> Multi-Kernel Support Vector Regression (SVR)

<sup>۲</sup> Bootstrap Stage Wise Model Selection Algorithm (BSWMS)

### ۳- مدل پیشنهادی

نشان داده شده و جزئیات آن در ادامه بیان شده است. به طور کلی در ابتدا به کمک شبکه‌ی عصبی کانولوشنی ویژگی‌های مهم از داده‌های تصویری ام‌آرآی استخراج شده است. این ویژگی‌ها شامل الگوهای فضایی و ارتباطات بین بخش‌های مختلف مغز بوده که ممکن است با بهره‌ی هوشی مرتبط باشد. پس از استخراج ویژگی‌ها، از XGBoost برای ساخت مدل پیش‌بینی نهایی استفاده شده است. این الگوریتم به دلیل قابلیت‌های خود در مدیریت داده‌های پیچیده و جلوگیری از بیش‌برازش، انتخاب بسیار مناسبی برای مرحله‌ی نهایی طبقه‌بندی است.



### ۳-۱- پیش‌پردازش

مرحله‌ی اول اجرای مدل پیشنهادی، پیش‌پردازش تصاویر ورودی بوده که شامل حذف داده‌های نامربوط، تبدیل تصاویر به فرمت استاندارد و انجام تغییرات مورد نیاز برای آموزش شبکه‌های عصبی مانند تغییر اندازه‌ی تصاویر و نرمال‌سازی داده‌ها است. با توجه به مجموعه‌ی داده‌ی مورد استفاده در این مقاله، مدل پیشنهادی تصاویر را در فرمت <sup>۱</sup>Gif و <sup>۲</sup>NIFTI به عنوان ورودی دریافت می‌کند. فرمت NIFTI یک فرمت استاندارد برای ذخیره‌ی داده‌های تصویربرداری عصبی به ویژه ام‌آرآی است که به دلیل انعطاف‌پذیری و سهولت استفاده در مقایسه با فرمت‌های دیگر معمولاً در تحقیقات تصویربرداری عصبی و ابزارهای نرم‌افزاری به کار می‌رود. فایل‌های NIFTI دارای پسوند‌های .nii. برای حجم‌های تک‌فایل و .nii.gz. برای حجم‌های فشرده است. فایل‌های NIFTI حاوی یک هدر هستند که اطلاعات فراداده‌ی مربوط به تصویر از جمله ابعاد، نوع داده، اندازه‌ی وکسل، جهت‌گیری و سایر جزئیات ضروری را ذخیره می‌کند. فایل‌های NIFTI داده‌های تصویربرداری حجمی را در قالب آرایه‌ای چندبعدی ذخیره کرده که می‌تواند برش‌های دوبعدی، حجم‌های سه‌بعدی یا حجم‌های چهاربعدی را برای داده‌های سری زمانی نشان دهد. نمونه‌ای از تصاویر در قالب NIFTI سه‌بعدی در شکل (۳) ارائه شده که از چپ به راست از نماهای عرضی، سائیتال و کرونال استخراج شده است. فرمت Gif

هدف این مقاله ارائه‌ی مدلی مبتنی بر یادگیری عمیق برای استخراج خودکار ویژگی‌های پیچیده از تصاویر ام‌آرآی مغزی و پیرو آن طبقه‌بندی تصاویر برای تعیین بهره‌ی هوشی افراد است. مدل پیشنهادی تصاویر ام‌آرآی مغز را به عنوان ورودی دریافت کرده و پس از اعمال پیش‌پردازش و آماده‌سازی تصاویر، از شبکه‌های عصبی کانولوشنی VGG16 و ResNet-50 برای استخراج ویژگی‌ها بهره می‌برد. علت انتخاب شبکه‌ی عصبی کانولوشنی در لایه‌ی اول مدل پیشنهادی را می‌توان منوط به توانایی‌های این شبکه در تحلیل داده‌های فضایی و تصویری دانست که آن را به گزینه‌ی مناسبی برای تحلیل داده‌های ام‌آرآی سه‌بعدی تبدیل می‌کند. در واقع شبکه‌های عصبی کانولوشنی به طور خاص برای تحلیل داده‌های تصویری طراحی شده و توانایی استخراج ویژگی‌های فضایی و موضعی را از داده‌های تصویری دارند. یکی دیگر از مزایای این شبکه‌ها عدم نیاز به استخراج دستی ویژگی‌ها از تصاویر است، زیرا لایه‌های کانولوشنی موجود در این شبکه‌ها می‌توانند ویژگی‌های مهم و نمایشی را به صورت خودکار از داده‌های ام‌آرآی استخراج کنند. این امر در مورد داده‌های حجیم و پیچیده مانند تصاویر ام‌آرآی بسیار مفید است، زیرا استخراج دستی ویژگی‌ها می‌تواند چالش‌برانگیز و مستلزم دانش تخصصی عمیق باشد. همچنین در شبکه‌های عصبی کانولوشنی وزن‌های یکسان در سراسر تصویر برای فیلترهای کانولوشن اعمال شده که باعث کاهش تعداد پارامترهای آموزش‌پذیر می‌شود. این ویژگی به مدل کمک می‌کند تا با داده‌های تصویری حجیم ام‌آرآی به صورت موثرتری کار کند. پس از استخراج ویژگی‌ها، از الگوریتم تقویت گرادیان فوق‌العاده (XGBoost) به عنوان یک الگوریتم یادگیری ترکیبی<sup>۱</sup> برای طبقه‌بندی نهایی تصاویر استفاده شده است که بهره‌ی هوشی فرد را بر اساس مقیاس هوش بزرگسالان و کسلر به یکی از پنج کلاس بسیار برتر، برتر، متوسط بالاتر، متوسط و متوسط پایین‌تر طبقه‌بندی می‌کند. این الگوریتم یکی از بهترین الگوریتم‌ها برای مدیریت داده‌ها با ابعاد بالا و پیچیدگی‌های غیرخطی است. این ویژگی برای تحلیل داده‌های ام‌آرآی که شامل هزاران وکسل<sup>۲</sup> و ویژگی‌های فضایی پیچیده هستند، بسیار مفید است. همچنین XGBoost از پارامترهای منظم‌سازی و درخت‌های تصمیم برای کنترل بیش‌برازش بهره می‌برد که کمک می‌کند تا مدل در تحلیل داده‌های ام‌آرآی که ممکن است نویز زیادی داشته باشند، به درستی تعمیم یابد. مراحل کلی مدل پیشنهادی در شکل (۲)

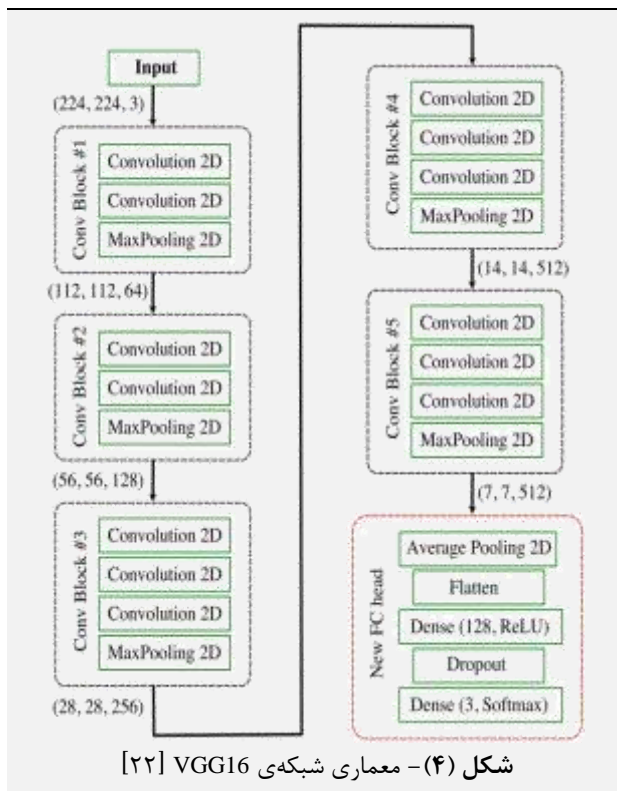
<sup>۱</sup> Graphics Interchange Format

<sup>۲</sup> Neuroimaging Informatics Technology Initiative

<sup>۱</sup> Ensemble Learning


<sup>۲</sup> Voxel

تمرکز کرده و الگوها و جزئیات را در مقیاس‌های مختلف ثبت کند. هم‌چنین شبکه‌های عصبی کانولوشنی معمولاً از چندین لایه با افزایش سطوح انتزاع تشکیل می‌شوند. لایه‌های پایین‌تر، ویژگی‌های ساده‌ای مانند لبه‌ها و بافت‌ها را ثبت می‌کنند در حالی که لایه‌های عمیق‌تر الگوهای پیچیده و نمایش‌های سطح بالاتر را می‌آموزند. این ساختار سلسله‌مراتبی به استخراج ویژگی‌های معنادار کمک می‌کند. در مدل پیشنهادی از شبکه‌های عصبی کانولوشنی ResNet-50 و VGG16 به عنوان استخراج‌کننده‌ی ویژگی استفاده شده که جزئیات آن‌ها در ادامه بیان شده است. شبکه‌ی VGG16<sup>۱</sup> یک معماری شبکه‌ی عصبی کانولوشنی بوده که دارای ۱۶ لایه (۱۳ لایه کانولوشن و ۳ لایه کاملاً متصل) است. در این شبکه هر لایه کانولوشن با یک تابع فعال‌سازی ReLU و لایه ادغام بیشینه<sup>۲</sup> دنبال می‌شود. تمام لایه‌های کانولوشن در این معماری از فیلترهای ۳×۳ استفاده می‌کنند و لایه‌های ادغام بیشینه در برخی از لایه‌های کانولوشن برای کاهش ابعاد فضایی نقشه‌های ویژگی استفاده می‌شود. شبکه‌ی VGG16 دارای ۳ لایه کاملاً متصل در انتها است که به دنبال آن یک لایه softmax برای طبقه‌بندی قرار دارد. این شبکه حدود ۱۳۸ میلیون پارامتر دارد و یک مدل نسبتاً بزرگ و پیچیده است. لذا از این شبکه به عنوان یک مدل پایه برای یادگیری انتقال استفاده می‌شود، زیرا کارایی آن در تشخیص تصویر در مقیاس بزرگ است. ساختار مدل VGG16 در شکل (۴) نشان داده شده است.



شکل (۴) - معماری شبکه‌ی VGG16 [۲۲]

نیز یک فرمت تصویری پرکاربرد است که تا ۲۵۶ رنگ را پشتیبانی کرده و امکان ایجاد انیمیشن در یک سری فریم را فراهم می‌کند. فرمت Gif را می‌توان به مجموعه‌ای از تصاویر (برش‌های ام‌آرآی) با فریم‌های جداگانه تبدیل کرده و با ترکیب آن‌ها یک دنباله‌ی متحرک ایجاد کرد که می‌تواند برای ارائه‌ی جذاب‌تر جنبه‌های پویا اسکن، مانند جریان خون یا حرکت در بدن مفید باشد.



شکل (۳) - یک فایل NIFTI سه‌بعدی [۱۸]

اولین مرحله‌ی پیش‌پردازش شامل تقویت مناطق یا ساختارهای روشن و تقویت مناطق یا ساختارهای تاریک در یک تصویر و در عین حال سرکوب پس‌زمینه است. مرحله‌ی دوم، نرمال‌سازی تصویر ورودی بوده که مقادیر پیکسل به یک مقیاس مشترک بین صفر و ۱ تبدیل شده است. این کار با تقسیم هر پیکسل بر حداکثر مقدار ممکن (۲۵۵) برای یک تصویر ۸ بیتی انجام شده است. نرمال‌سازی تصاویر تضمین می‌کند که مقادیر پیکسل در یک محدوده‌ی ثابت نگاشت شوند که به ثبات عددی در طول فرایند آموزش مدل کمک می‌کند. مرحله‌ی بعدی تغییر سایز تصویر بوده که به فرایند تغییر ابعاد (عرض و ارتفاع) یک تصویر اشاره دارد که یک مرحله‌ی پیش‌پردازش متداول در هنگام کار با شبکه‌های عصبی کانولوشنی برای کارهایی مانند طبقه‌بندی تصویر، تشخیص اشیا و تقسیم‌بندی تصویر است. در این مرحله و برای یکسان‌سازی ابعاد تصاویر ورودی، میانگین تصاویر محاسبه شده و مقدار (۲۶۱، ۲۵۵) به عنوان ابعاد میانگین روی تمام عکس‌ها اعمال شده است.

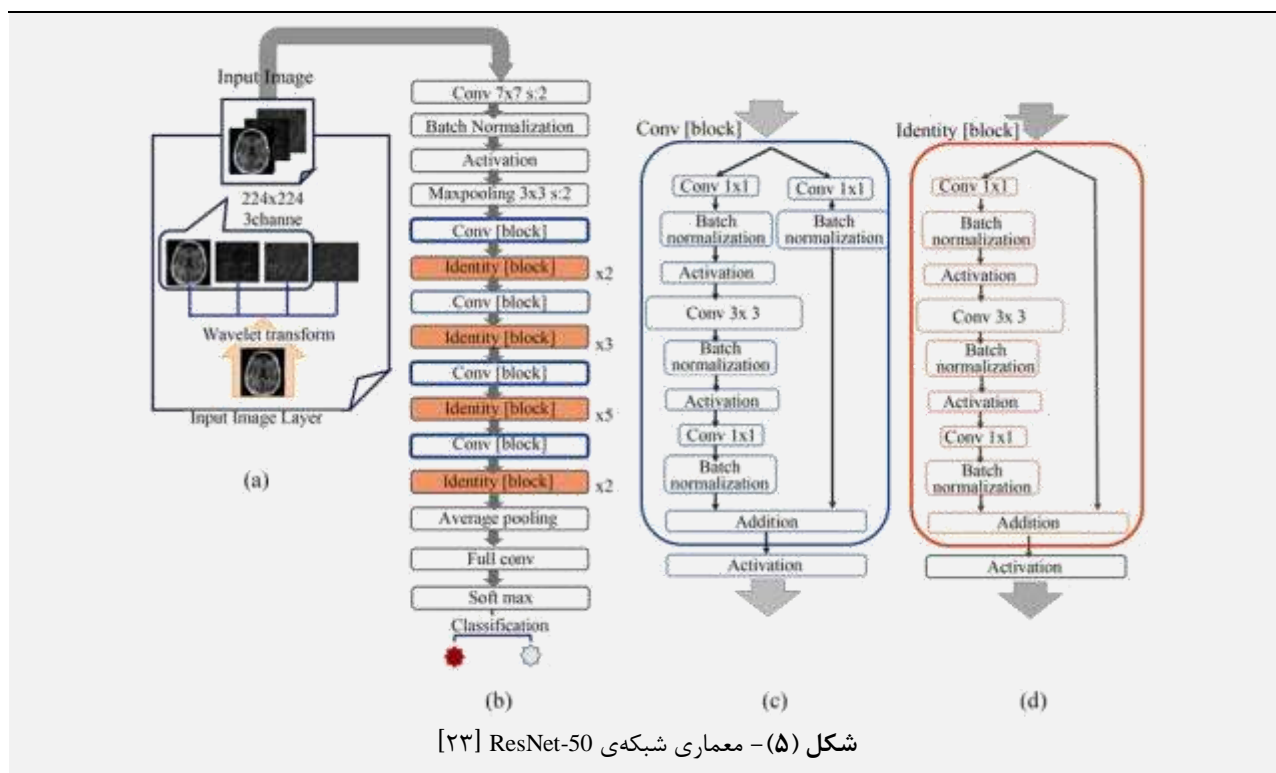
### ۳-۲- شبکه‌ی عصبی کانولوشنی

پس از پیش‌پردازش تصاویر ورودی باید ویژگی‌های مناسب از تصاویر استخراج شود. در این راستا در لایه‌ی دوم از شبکه‌ی عصبی کانولوشنی برای استخراج ویژگی‌های محلی از تصاویر ورودی استفاده شده است. شبکه‌های عصبی کانولوشنی از لایه‌های کانولوشن با فیلترهای کوچک استفاده کرده که در سراسر تصویر ورودی به طور کشویی اعمال می‌شوند. این فیلترها به شبکه اجازه می‌دهد تا روی ویژگی‌های محلی شده در تصویر

<sup>۲</sup> Max-Pooling<sup>۱</sup> Visual Geometry Group

یابد و مشکل ناپدید شدن گرادیان را کاهش دهد. شبکه‌ی ResNet-50 از طرح گلوگاه در بلوک‌های باقی‌مانده‌ی خود استفاده می‌کند. طرح گلوگاه از به ترتیب ۳ لایه‌ی کانولوشنال مختلف با اندازه‌های  $1 \times 1$ ،  $3 \times 3$  و  $1 \times 1$  استفاده می‌کند تا پیچیدگی محاسباتی را کاهش دهد. این شبکه پس از آخرین لایه‌ی کانولوشن، از ادغام میانگین جهانی برای کاهش ابعاد فضایی نقشه‌های ویژگی به بردار بهره می‌برد. یک لایه‌ی کاملاً متصل و به دنبال آن یک تابع فعال‌سازی softmax در انتهای شبکه برای طبقه‌بندی نهایی تعبیه شده است. ساختار مدل ResNet-50 در شکل (۵) نشان داده شده است.

شبکه‌ی ResNet-50 معماری دیگری از شبکه‌ی عصبی کانولوشنی می‌باشد که به خانواده‌ی ResNet (شبکه‌ی باقی‌مانده<sup>۱</sup>) تعلق دارد. لایه‌های اولیه‌ی این شبکه از لایه‌های کانولوشنال سنتی به منظور استخراج ویژگی‌های سطح پایین از تصویر ورودی تشکیل شده است. ویژگی کلیدی معماری‌های ResNet استفاده از بلوک‌های باقی‌مانده است که امکان آموزش آسان‌تر شبکه‌های عصبی بسیار عمیق را فراهم می‌کند. شبکه‌ی ResNet-50 دارای ۱۶ بلوک باقی‌مانده است که روی هم چیده شده‌اند. در هر بلوک باقی‌مانده، اتصالات پرش (یا اتصالات میان‌بر) وجود دارد که به گرادیان اجازه می‌دهد راحت‌تر به عقب انتشار



### ۳-۳- الگوریتم تقویت گرادیان فوق‌العاده و دسته‌بندی

در ادامه پس از استخراج ویژگی توسط شبکه‌های ResNet-50 و VGG16 از الگوریتم تقویت گرادیان فوق‌العاده (XGBoost) برای دسته‌بندی نهایی تصاویر استفاده شده است. این الگوریتم یک الگوریتم یادگیری ماشینی قدرتمند و کارآمد است که به کلاسی از الگوریتم‌های یادگیری گروهی<sup>۲</sup> معروف به تقویت گرادیان تعلق دارد که با ترکیب چندین مدل ضعیف، یک مدل پیش‌بینی قوی ایجاد می‌کند. الگوریتم تقویت گرادیان فوق‌العاده یک الگوریتم یادگیری ماشینی محبوب بوده که با ساخت مجموعه‌ای از درختان تصمیم ضعیف<sup>۲</sup> به صورت متوالی

شبکه‌ی VGG16 با معماری یک‌نواخت خود که دارای فیلترهای کانولوشنال نسبتاً کوچک با ابعاد  $3 \times 3$  و لایه‌های ساده است، تعادل بسیار خوبی بین پیچیدگی و عمل‌کرد مدل ایجاد می‌کند. در نتیجه این شبکه می‌تواند به راحتی ویژگی‌ها را از تصویر ورودی استخراج کند و برای کارهایی که نیاز به نمایش ویژگی‌های دقیق دارند مناسب است. از سوی دیگر ResNet50 با معماری عمیق‌تر خود که از بلوک‌های باقی‌مانده استفاده می‌کند، یادگیری بهتر ویژگی‌های انتزاعی را با پرداختن به مشکل گرادیان محو می‌کند. این طراحی به ResNet50 اجازه می‌دهد تا ویژگی‌های سطح پایین و سطح بالا را به طور موثری از تصویر ورودی استخراج کند.

<sup>۱</sup> Weak

<sup>۱</sup> Residual Network

<sup>۲</sup> Ensemble Learning

مجموعه‌ی داده‌های تشریحی و فنوتیپی را با هدف به اشتراک‌گذاری داده با جامعه‌ی علمی گسترده‌تر در دسترس قرار داده است. حاصل این تلاش، ایجاد یک مجموعه‌ی داده با ۱۱۱۲ نمونه شامل ۵۳۹ فرد مبتلا به اختلال طیف اوتیسم و ۵۷۳ فرد کنترل معمولی (سنین ۷-۶۴ سال، میانگین ۱۴/۷ سال در گروه‌ها) بوده که در آگوست ۲۰۱۲ منتشر شده است [۲۶]. تصاویر این مجموعه‌ی داده به صورت تصاویر Nifti (فرمت nii) و SNAPSHOTs (فرمت Gif) موجود بوده که این تصاویر از نماهای سائیتال، عرضی و تاجی مغز تصویربرداری شده است. به همراه تصاویر ارائه شده، یک فایل با اطلاعات فنوتیپی از افرادی که عکس‌برداری از مغز آن‌ها انجام شده ارائه گردیده که شامل اطلاعات مفیدی بوده که بخش‌های مهم آن در جدول (۱) نمایش داده شده است.

فایل فنوتیپی حاوی سه نوع امتیاز بهره‌ی هوشی شامل بهره‌ی هوشی کامل<sup>۱</sup> (FIQ)، بهره‌ی هوشی عمل‌کردی<sup>۲</sup> (PIQ) و بهره‌ی هوشی کلامی<sup>۳</sup> (VIQ) است. بهره‌ی هوشی کامل به عنوان معیاری برای نشان دادن بهره‌ی هوشی افراد است. از آن‌جا که نمرات بهره‌ی هوشی کامل برای برخی افراد در مجموعه‌ی داده ذکر نشده، بهره‌ی هوشی کامل برای آن افراد از مقادیر بهره‌ی هوشی عمل‌کردی و هوش کلامی با استفاده از رابطه‌ی (۱) محاسبه شده است.

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

#### ۴-۲- معیارهای ارزیابی

به منظور ارزیابی مدل پیشنهادی از معیارهای ارزیابی دقت، صحت، فراخوانی و امتیاز F استفاده شده است که به ترتیب مطابق روابط زیر محاسبه می‌شوند.

$$Accuracy = \frac{TP + TN}{N} \quad (2)$$

$$Precision = \frac{TP}{TP + FP} \quad (3)$$

$$Recall = \frac{TP}{TP + FN} \quad (4)$$

$$F - \text{measure} = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (5)$$

در این روابط TP و TN به ترتیب نشان دهنده‌ی نمونه‌های مثبت و منفی که درست طبقه‌بندی شده‌اند، FP و FN به ترتیب نشان دهنده‌ی نمونه‌های مثبت و منفی که نادرست طبقه‌بندی شده‌اند و N نشان دهنده‌ی تعداد کل نمونه‌ها می‌باشد.

کار می‌کند و هدف آن بهبود قدرت پیش‌بینی مدل با ترکیب پیش‌بینی‌های چند دسته‌بند ضعیف است. ابتدای کار این الگوریتم با یک گره برگ شروع شده و برای هر درخت بعدی سعی می‌شود تا خطاهای درخت‌های قبلی اصلاح شود. این کار با بهینه‌سازی یک تابع هدف خاص بر اساس گرادیان‌ها انجام شده که به آن تقویت گرادیان می‌گویند. این فرایند تکراری همان چیزی است که این الگوریتم را منحصر به فرد می‌سازد تا با یادگیری مکرر از خطاهای درختان قبلی و ایجاد درخت‌های جدید و اصلاح آن‌ها روابط پیچیده‌ی درون داده‌ها را مدیریت کرده و پیش‌بینی‌های بسیار دقیقی ایجاد کند.

یکی از جنبه‌های مهم این الگوریتم، تکنیک‌های منظم‌سازی آن است که با جریمه کردن مدل‌های بیش از حد پیچیده به جلوگیری از برازش بیش از حد کمک می‌کند. این الگوریتم هم‌چنین امکان محاسبات موازی را فراهم می‌کند و برای مدیریت مجموعه‌ی داده‌های بزرگ کارآمد است [۲۴، ۲۵]. به طور کلی و با توجه به مزایای این الگوریتم، انتظار می‌رود که ترکیب شبکه‌ی عصبی کانولوشنی و الگوریتم تقویت گرادیان فوق‌العاده منجر به ایجاد یک طبقه‌بند قدرتمند شود که از توانایی شبکه‌ی عصبی کانولوشنی برای استخراج ویژگی‌های معنادار تصویر و توانایی تقویت گرادیان فوق‌العاده برای اصلاح مرزهای تصمیم‌گیری بهره می‌برد. شبه کد الگوریتم تقویت گرادیان فوق‌العاده برای طبقه‌بندی و مشخص کردن خلاص خروجی در الگوریتم (۱) ارائه شده است.

#### الگوریتم (۱) - تقویت گرادیان فوق‌العاده [۲۱]

```

Initialize  $f_0(x)$ ;
for  $k = 1, 2, \dots, M$  do
  Calculate  $g_k = \frac{\partial L(y, f)}{\partial f}$ ;
  Calculate  $h_k = \frac{\partial^2 L(y, f)}{\partial f^2}$ ;
  Determine the structure by choosing splits with maximized gain;
   $A = \frac{1}{2} \left[ \frac{G_L^2}{N_L} + \frac{G_R^2}{N_R} - \frac{G^2}{N} \right]$ ;
  Determine the leaf weights  $w^* = -\frac{G}{N}$ ;
  Determine the base learner  $\hat{f}_k(x) = \sum_{j=1}^T w_j^* I_j(x)$ ;
  Add tree  $f_k(x) = f_{k-1}(x) + \hat{f}_k(x)$ ;
end
Result:  $f(x) = \sum_{k=0}^M f_k(x)$ 

```

#### ۴-۳- پیاده‌سازی و نتایج آزمایشات

##### ۴-۱- مجموعه‌ی داده

برای آموزش مدل پیشنهادی از مجموعه‌ی داده‌ی تصاویر تبادل اطلاعات تصویربرداری مغز اوتیسم (ABIDE) استفاده شده که در آن داده‌ها به پنج گروه تقسیم شده است. این مجموعه‌ی داده، تصاویر ام‌آر‌آی عمل‌کردی حالت استراحت و

<sup>۱</sup> Verbal IQ

<sup>۱</sup> Functional IQ

<sup>۲</sup> Performance IQ

جدول (۱) - توضیحات بخش‌های مهم فایل فنوتیپی

فیلد	توضیحات
SUB_ID	شماره‌ی شناسه‌ی منحصر به فرد ABIDE
DX_GROUP	گروه تشخیصی / عدد ۱ نشانه‌ی مبتلا به اوتیسم
AGE_AT_ACAN	سن در زمان اسکن در سال
SEX	جنسیت / عدد ۱ نشان‌گر مرد و عدد ۲ نشان‌گر زن بودن
HANDEDNESS_CATEGORY	R- راست‌دست / L- چپ‌دست / Ambidextrous- دوسویه
HANDEDNESS_SCORES	اعداد مثبت نشانه‌ی راست‌دست بودن، اعداد منفی نشانه‌ی چپ‌دست بودن و عدد ۰ نشانه‌ی دوسویه بودن
FIQ	میزان بهره‌ی هوشی کامل که بر اساس یکی از تست‌هایی که اطلاعات آن در پایین جدول آمده محاسبه شده است
VIQ	میزان هوش کلامی که با استفاده از یکی از روش‌هایی که اطلاعات آن در پایین جدول آمده محاسبه شده است
PIQ	میزان هوش عمل‌کردی که با استفاده از یکی از روش‌هایی که اطلاعات آن در پایین جدول آمده محاسبه شده است
FIQ_TEST_TYPE	مشخص‌کننده‌ی روش و مدل استفاده شده برای عدد به دست آمده برای این آیتم
VIQ_TEST_TYPE	مشخص‌کننده‌ی روش و مدل استفاده شده برای عدد به دست آمده برای این آیتم
PIQ_TEST_TYPE	مشخص‌کننده‌ی روش و مدل استفاده شده برای عدد به دست آمده برای این آیتم

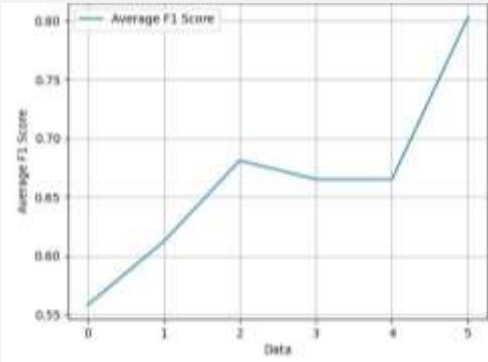
### ۳-۴- جزئیات پیاده‌سازی و نتایج

ابتدا مدلی برای داده‌های دوبعدی با فرمت Gif ساخته شده است. پس از وارد کردن ۱۱۰۰ تصویر ام‌آر‌آی مغز دوبعدی به عنوان ورودی و اعمال پیش‌پردازش‌های مورد نظر، بهره‌ی هوشی کامل مطابق هر عکس به آن نسبت داده شده است. سپس از ۳۰ درصد کل داده‌ها برای داده‌های تست و از ۱۰ درصد برای داده‌ی اعتبارسنجی استفاده شده است. اگر چه با اجرای مراحل و آموزش هر چه بیش‌تر داده‌های ورودی در مراحل پایانی میزان خطا روی داده‌های آموزشی و داده‌های اعتبارسنجی رو به کاهش بوده اما نتایج به دست آمده بر اساس معیارها و هم‌چنین میزان دقت نهایی ۳۷٪ نشان دهنده‌ی این است که پیش‌بینی با دقت خوبی انجام نشده و حتی با تغییر در شبکه‌ی عصبی کانولوشنی و عمیق‌تر کردن آن و استفاده از مدل‌های معروف شبکه‌ی عصبی کانولوشنی نیز نتایج بهبود نیافته است. علت این موضوع را می‌توان به کیفیت پایین تصاویر Gif و تعداد کم مجموعه‌ی داده نسبت داد. از این رو برای کسب نتایج بهتر از تصاویر سه‌بعدی با فرمت Nifti استفاده شده و این تصاویر با شبکه‌های عصبی عمیق متفاوت مورد ارزیابی قرار گرفته است.

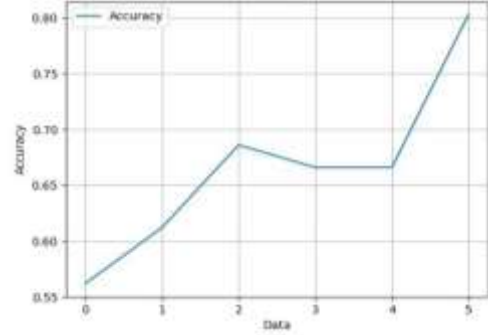
در ادامه عملیات استخراج برش‌های دوبعدی از تصاویر سه‌بعدی انجام شده است. سپس اندازه‌ی آن‌ها مطابق بخش ۳-۱ برای اعمال یک ورودی با اندازه‌ی مناسب در شبکه‌های VGG16 و ResNet-50 تغییر داده شده و اندازه‌ی تصویر بارگذاری شده به ۲۲۴×۲۲۴ پیکسل تغییر یافته است. سپس داده‌های تصویری پیش‌پردازش شده برای پیش‌بینی به مدل VGG16 و ResNet-50 از پیش آموزش دیده، داده شده است. از آن‌جا که ویژگی‌های محاسبه شده توسط مدل‌های VGG16

و ResNet-50 آرایه‌های چندبعدی هستند، با استفاده از روش مسطح، ویژگی‌ها به یک آرایه‌ی یک‌بعدی مسطح تبدیل شده است. پس از عملیات استخراج ویژگی، ویژگی‌های استخراج شده‌ی تصاویر با توجه به برجسب‌های بهره‌ی هوشی آن‌ها ذخیره شده است. از آن‌جا که در شبکه‌ی ResNet-50 آرایه‌ی تک‌بعدی کدگذاری شده عناصر زیادی دارد، حدود ۵۰۰۰ عکس با مدل آموزش داده شده و در ادامه به دلیل محدودیت حافظه‌ی موقت و محدودیت سخت‌افزاری و نرم‌افزاری، تصاویر از هم جدا شده است. در ادامه ۵۰۰ تصویر بعدی و مشخصات آن‌ها استخراج شده است. برای ۵۰۰ تصویر بعدی روی مدلی که وزن آن‌ها ایجاد شده، تصاویر جدید اجرا گردیده که ویژگی‌های آن با مدل قبلی استخراج شده بوده تا وزن‌های مدل به روز شود و این روند تا پایان ورود تمام تصاویر ادامه داشته است. به همین دلیل این مدل با شبکه‌ی ResNet-50 نزدیک به ۳۶ بار آموزش داده شده است.


در شبکه‌ی VGG16 روش کار به این صورت بوده که با وارد کردن ۵۰۰ تصویر، ویژگی‌های آن تصاویر استخراج و ذخیره شده و سپس ۵۰۰ تصویر بعدی وارد شده است. برای هر مرحله که ۵۰۰ تصویر خوانده شده و ویژگی‌ها استخراج گردیده، مدل نه تنها با آن تعداد ویژگی اجرا شده، بلکه ویژگی‌های تمام تصاویر استخراج شده به یک‌باره به مدل داده شده که دلیل به دست آوردن نتیجه‌ی بهتر در این مدل نیز همین عامل است. هم‌چنین مدل VGG16 برای هر مرحله‌ای که تصاویر خوانده شده و ویژگی‌های آن‌ها استخراج گردیده، اجرا شده و نتایج مربوط به مدل نهایی با ویژگی‌های استخراج شده از تمام عکس‌ها به دست آمده است. در پایان معیارهای در نظر گرفته شده برای ارزیابی و متریک‌های مورد نظر یعنی دقت، میانگین




شکل (۱۰) - میزان امتیاز F1 میانگین برای مدل VGG16



شکل (۱۱) - میانگین میزان دقت برای مدل VGG16




شکل (۱۲) - میانگین میزان خطا برای مدل VGG16




شکل (۱۳) - خطای آموزش و خطای تست برای مدل VGG16

مقایسه‌ی میزان صحت به دست آمده از انواع مختلف پیاده‌سازی‌های انجام شده در جدول (۲) نشان داده شده است. مشاهده می‌شود که مدل VGG16+XGboost توانسته است بالاترین میزان معیار صحت را در مقایسه با سایر مدل‌ها به دست آورد. استفاده از الگوریتم تقویت گرادیان فوق‌العاده همراه با الگوریتم VGG16 باعث شده است تا صحت دسته‌بندی نزدیک به ۱۰ درصد افزایش یابد.

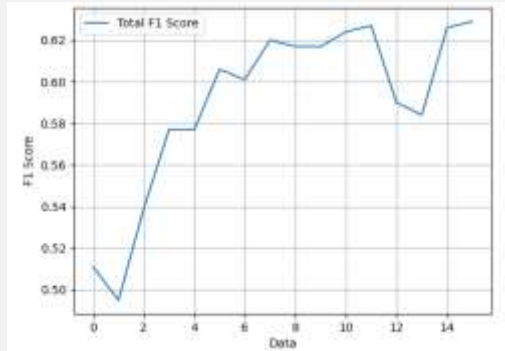
امتیاز F1، امتیاز F1 برای هر کلاس، میانگین میزان خطا برای این دو مدل شبکه‌ی عصبی کانولوشنی و همچنین میزان خطای آموزش و خطای تست برای مدل VGG16 مطابق شکل‌های (۶) تا (۱۳) محاسبه و نمایش داده شده است.




شکل (۶) - میانگین میزان خطا برای مدل ResNet-50



شکل (۷) - امتیاز F1 به ازای هر کلاس برای مدل ResNet-50



شکل (۸) - میزان امتیاز F1 میانگین برای مدل ResNet-50



شکل (۹) - امتیاز F1 به ازای هر کلاس برای مدل VGG16

استخراج دستی ویژگی‌ها از تصاویر بوده، در حالی که مدل پیشنهادی مهندسی ویژگی‌ها را کاملا به صورت خودکار انجام داده و نیازی به دخالت دستی برای استخراج ویژگی‌ها یا انتخاب نواحی خاص از مغز وجود ندارد که باعث افزایش دقت و بهره‌وری مدل پیشنهادی و حذف خطاهای انسانی می‌شود.

تامز و هم‌کارانش [۱۸] از ترکیب مدل‌های یادگیری ماشین SVM، جنگل تصادفی و BSWiMS برای پیش‌بینی نمرات هوش سیال از روی تصاویر ام‌آرآی استفاده کرده‌اند. شباهت این دو پژوهش، استخراج ویژگی‌های ساختاری از مغز و یافتن ارتباط بین ساختار مغزی و بهره‌ی هوشی است. با این حال مشخص است که مدل پیشنهادی به دلیل استفاده از شبکه‌ی عصبی کانولوشنی توانایی بیشتری در استخراج ویژگی‌های پیچیده دارد و روش‌های یادگیری ماشین در تحلیل داده‌های تصویری بزرگ‌تر یا پیچیده‌تر با چالش مواجه خواهند بود.

آریا و هم‌کارانش [۱۵] از شبکه‌ی عصبی کانولوشنی برای استخراج ویژگی و تخمین بهره‌ی هوشی از روی تصاویر ام‌آرآی بهره برده‌اند. برتری مطالعه‌ی حاضر نسبت به کار آن‌ها استفاده از ترکیب شبکه‌ی عصبی کانولوشنی و الگوریتم تقویت گرادیان فوق‌العاده است. در واقع در مدل پیشنهادی شبکه‌ی عصبی کانولوشنی به عنوان ابزاری برای استخراج ویژگی‌ها از تصاویر عمل کرده و پیش‌بینی نهایی توسط الگوریتم تقویت گرادیان فوق‌العاده انجام می‌شود. این تفاوت کلیدی باعث شده است که مدل پیشنهادی بتواند به دقت و کارایی بالاتری دست یابد.

حسین و هم‌کارانش [۱۶] نیز از شبکه‌های عصبی کانولوشنی دوبعدی و سه‌بعدی برای پیش‌بینی نمرات بهره‌ی هوشی بر اساس تصاویر ام‌آرآی وزن T1 استفاده کرده‌اند. این مطالعه سعی دارد ارتباط بین ویژگی‌های ساختاری مغز و نمرات بهره‌ی هوشی را بررسی کند و در این راستا از مدل‌های مختلف شبکه‌های عصبی کانولوشنی مانند ResNet و VGG برای انجام این کار استفاده شده است. برخلاف این مقاله که از داده‌های دوبعدی و سه‌بعدی و استفاده کرده، در مطالعه‌ی حاضر از داده‌های NIFTI استفاده شده که دارای جزئیات مکانی بیشتری است و می‌تواند به دقت بالاتری در تخمین بهره‌ی هوشی منجر شود. مزیت دیگر مدل پیشنهادی استفاده از الگوریتم تقویت گرادیان فوق‌العاده بوده که به دلیل توانایی در مقابله با بیش‌برازش و مدیریت داده‌های پیچیده منجر به افزایش صحت مدل پیشنهادی شده است.

سها و هم‌کارانش [۲۱] نیز از داده‌های ام‌آرآی بدون استخراج ویژگی‌های از پیش تعیین شده برای تخمین هوش سیال در

## جدول (۲) - مقایسه‌ی معیار دقت برای مدل‌های اجرا شده

روی مجموعه‌ی داده‌ی ABIDE

مدل	صحت (%)
ResNet-50	۵۳
VGG16	۷۳
ResNet-50+XGboost	۶۰
VGG16+XGboost	۸۳

## ۴-۴- بحث و تحلیل نتایج

در این مطالعه مدلی برای تخمین بهره‌ی هوشی از روی تصاویر ام‌آرآی با استفاده از ترکیب شبکه‌ی عصبی کانولوشنی و الگوریتم تقویت گرادیان فوق‌العاده توسعه داده شده است. بر اساس نتایج به دست آمده، مدل ترکیبی پیشنهادی در مقایسه با سایر مدل‌های پایه از صحت بالاتری در تخمین بهره‌ی هوشی برخوردار است. در ادامه‌ی این بخش به تجزیه و تحلیل و مقایسه‌ی نتایج به دست آمده با مطالعات گذشته پرداخته شده است. با توجه به این که مجموعه‌ی داده‌ی مورد استفاده در مطالعات مختلف مشابه نیست، مقایسه‌ی صحت الگوریتم‌ها معیار مناسبی برای مقایسه نخواهد بود. در این راستا در ادامه مقایسه‌ی بین جزئیات مطالعات موجود با مدل پیشنهادی این مقاله با تکیه بر توانایی آن‌ها برای ارائه‌ی پیش‌بینی‌های دقیق و معتبر صورت گرفته است.

در مطالعه‌ی ونگ و هم‌کارانش [۱۹] از تکنیک‌های یادگیری پراکنده<sup>۱</sup> برای پیدا کردن ویژگی‌های مرتبط با بهره‌ی هوشی، کاهش ابعاد ویژگی‌ها و پیرو آن تخمین بهره‌ی هوشی روی تصاویر استفاده شده است. شباهت کار آن‌ها با این پژوهش، تخمین بهره‌ی هوشی از روی تصاویر ام‌آرآی است. با این حال آن‌ها روی استخراج دستی ویژگی‌ها از روی تصاویر تاکید داشته‌اند در حالی که در مدل پیشنهادی این مقاله از شبکه‌ی عصبی کانولوشنی برای استخراج خودکار ویژگی‌ها از تصویر استفاده شده که باعث می‌شود مدل پیشنهادی بتواند الگوهای پیچیده‌تری را که ممکن است با چشم انسان یا روش‌های آماری ساده قابل شناسایی نباشند، به صورت خودکار استخراج کند. تیلاکاواتی و هم‌کارانش [۲۷] یک چارچوب نیمه‌خودکار برای تخمین بهره‌ی هوشی از روی تصاویر ام‌آرآی مغزی ارائه کرده‌اند. هدف آن‌ها توسعه‌ی یک سیستم ترکیبی بوده که با تکنیک‌های یادگیری ماشین و برخی فرایندهای دستی پردازش تصویر، بهره‌ی هوشی را تخمین بزند. آن‌ها روی تکنیک‌های سنتی یادگیری ماشین و پردازش تصویر تمرکز داشته‌اند که نیازمند

<sup>۱</sup> Sparse Learning

داده‌های بدون ساختار یاد بگیرند و به علت پیچیده بودن ساختار مغز، می‌توانند برای استخراج ویژگی‌های پیچیده مرتبط با بهره‌ی هوشی از تصاویر مغز مناسب باشند. در این راستا در این مقاله مدلی مبتنی بر ترکیب شبکه‌ی عصبی کانولوشنی و الگوریتم تقویت گرادیان فوق‌العاده برای تخمین بهره‌ی هوشی از روی تصاویر ام‌آر‌آی مغزی معرفی شده است. شبکه‌های عصبی کانولوشنی با توجه به ساختار آن‌ها گزینه‌ی مناسبی برای استخراج ویژگی محلی از تصاویر هستند. از سوی دیگر الگوریتم تقویت گرادیان فوق‌العاده یک الگوریتم گروهی قدرتمند است که می‌تواند به طور موثر پیش‌بینی‌های چندین مدل را برای بهبود دقت کلی ترکیب کند. در مدل پیشنهادی از شبکه‌های عصبی کانولوشنی ResNet-50 و VGG16 به عنوان استخراج کننده‌ی ویژگی و از الگوریتم تقویت گرادیان فوق‌العاده به عنوان یک شناسایی کننده در سطح بالای شبکه برای تولید نتایج استفاده شده است. به منظور اجرای مدل پیشنهادی، مجموعه‌ی داده‌ی تصاویر مغزی ام‌آر‌آی ABIDE مورد استفاده قرار گرفته و تصاویر بر اساس مقیاس هوش بزرگسالان و کسلر به یکی از پنج کلاس بسیار برتر، برتر، متوسط بالا، متوسط و متوسط پایین طبقه‌بندی شده است. نتایج نشان داده که ترکیب شبکه‌ی عصبی کانولوشنی و الگوریتم تقویت گرادیان فوق‌العاده که در آن شبکه‌های عصبی کانولوشنی ویژگی‌های سلسله‌مراتبی را یاد می‌گیرند و تقویت گرادیان فوق‌العاده مرزهای طبقه‌بندی را بر اساس این ویژگی‌ها بهینه می‌کند باعث بهبود دقت و عمل کرد کلی در مقایسه با استفاده از هر یک از این تکنیک‌ها به صورت مجزا شده و نتایج بهتری نسبت به استفاده از هر یک از روش‌ها به تنهایی به دست آمده است. هم‌چنین نتایج به دست آمده نشان داده که استفاده از تصاویر Nifti برای این پژوهش بسیار مناسب‌تر و ایده‌آل‌تر از تصاویر دوبعدی بوده و از بین شبکه‌های عصبی کانولوشنی مورد استفاده، شبکه‌ی VGG16 منجر به دست‌یابی به نتایج بهتری نسبت به سایر روش‌های پایه شده است. این نتایج می‌تواند به عنوان یک نقطه‌ی عطف در زمینه‌ی تحقیقات روان‌شناسی و علوم اعصاب باشد و نشان دهد که چگونه فناوری‌های نوین می‌توانند باعث ایجاد درک بهتر از ارتباط بین ساختار مغز و توانایی‌های شناختی شوند. در این راستا بررسی‌های بیشتر برای اعتبارسنجی این تکنیک‌ها در جمعیت‌های مختلف و زیرگروه‌های سنی مختلف ضروری است.

با این حال محدودیت‌های مطالعه‌ی حاضر شامل اندازه‌ی نمونه‌ی نسبتاً کوچک و عدم تنوع بالا در داده‌ها است که می‌تواند بر قابلیت تعمیم یافته‌ها تاثیر بگذارد. برای تحقیقات

نوجوانان استفاده کرده‌اند. هدف اصلی آن‌ها بررسی قابلیت شبکه‌ی عصبی کانولوشنی برای تخمین بهره‌ی هوشی سیال بوده است. نتایج این مطالعه نشان داده که تخمین هوش سیال از تصاویر ام‌آر‌آی بدون ویژگی‌های از پیش تعریف شده، یک چالش بزرگ است. در حالی که شبکه‌ی عصبی کانولوشنی توانسته همبستگی ضعیفی بین تصاویر ام‌آر‌آی و نمرات هوش سیال برقرار کند، عمل کرد آن در پیش‌بینی نمرات واقعی ضعیف بوده است. برخلاف این مطالعه که از تصاویر دوبعدی استفاده کرده، در مطالعه‌ی حاضر از تصاویر سه‌بعدی به عنوان ورودی استفاده شده است که اطلاعات ساختاری بیشتری از مغز را فراهم می‌کند. هم‌چنین در مطالعه‌ی حاضر به جای پیش‌بینی هوش سیال، به پیش‌بینی هوش کلی پرداخته شده است که از لحاظ عملی اهمیت بیشتری خواهد داشت.

مجموعه‌ی داده‌ی تصاویر تبادل اطلاعات تصویربرداری مغز اوتیسم که در این مقاله مورد استفاده قرار گرفته، در اصل برای تشخیص اوتیسم از روی تصاویر مغزی جمع‌آوری شده و در مطالعات اندکی از این مجموعه‌ی داده برای محاسبه‌ی بهره‌ی هوشی استفاده شده است. در این میان مطالعات [۱۵، ۱۶، ۲۱] برای محاسبه‌ی بهره‌ی هوشی از همین مجموعه‌ی داده استفاده کرده‌اند، اما تفاوت‌های کلیدی در روش‌شناسی آن‌ها با پژوهش حاضر وجود دارد. مطالعه‌ی [۱۵] تنها نمای ساژیتال را در نظر گرفته و دقت‌های ۰/۵۱۶۲، ۰/۴۵۵ و ۰/۶۶۱۸ را به ترتیب برای مدل‌های SVG، VGG16 و ResNet50 گزارش کرده که به وضوح پایین‌تر از نتایج مقاله‌ی حاضر است. مطالعه‌ی [۱۶] از معیار میانگین مربع خطا استفاده کرده که با میانگین خطای ۱۱/۶۷ توسط شبکه‌ی ResNet50 در مقایسه با مدل پیشنهادی دارای میانگین خطای بالاتری است. هم‌چنین مطالعه‌ی [۲۱] به محاسبه‌ی دقت میزان بهره‌ی هوشی در اسلایس‌های مختلف پرداخته و به مساله‌ی دسته‌بندی توجهی نداشته است. بنابراین با توجه به تفاوت‌های ذکر شده در تنظیمات و معیارهای ارزیابی، به نظر می‌رسد که مقایسه‌ی نتایج مقاله‌ی حاضر با مقالات فوق نمی‌تواند به عنوان مرجعی معتبر برای ارزیابی عمل کرد مدل پیشنهادی تلقی شود. با این حال در این مطالعه به بررسی دقیق‌تر و کاربردی‌تر معیارهای مرتبط با تشخیص اوتیسم و بهره‌ی هوشی پرداخته شده است که می‌تواند ارزش افزوده‌ای برای ادبیات موجود ایجاد کند.

## ۵- نتیجه‌گیری

یادگیری عمیق زیرمجموعه‌ای از هوش مصنوعی بوده و از شبکه‌هایی تشکیل شده است که می‌توانند بدون نظارت از

- Journal of Supercomputing, 2023. 79(3): p. 2431-2450.
- [10] Thilakavathy, P. and B. Diwan, Semi-automatic framework for estimating intelligence quotient (IQ) using MRI. Annals of the Romanian Society for Cell Biology, 2021: p. 2087-2101.
- [11] Saberi, Z.A., H. Sadr, and M.R. Yamaghani. An Intelligent Diagnosis System for Predicting Coronary Heart Disease. in 2024 10th International Conference on Artificial Intelligence and Robotics (QICAR). 2024. IEEE.
- [12] Zahmatkesh Zakariaee, A., H. Sadr, and M.R. Yamaghani, A New Hybrid Method to Detect Risk of Gastric Cancer Using Machine Learning Techniques. Journal of AI and Data Mining, 2023: p. -.
- [13] Nazari, M., et al., Detection of Cardiovascular Diseases Using Data Mining Approaches: Application of an Ensemble-Based Model. Cognitive Computation, 2024: p. 1-15.
- [14] Dehghan, S., et al., Comparative study of machine learning approaches integrated with genetic algorithm for IVF success prediction. Plos one, 2024. 19(10): p. e0310829.
- [15] Arya, A. and M. Manuel. Intelligence quotient classification from human MRI brain images using convolutional neural network. in 2020 12th International Conference on Computational Intelligence and Communication Networks (CICN). 2020. IEEE.
- [16] Hussain, M.A., et al., Can deep learning predict human intelligence from structural brain MRI? bioRxiv, 2023: p. 2023.02. 24.529924.
- [17] SHEN, T., CLASSIFYING BRAIN AGE FROM MRI IMAGES USING CONVOLUTIONAL NEURAL NETWORK. 2020.
- [18] Tamez-Pena, J., et al. Ensemble of SVM, random-forest and the BSWiMS method to predict and describe structural associations with fluid intelligence scores from T1-weighted MRI. in Adolescent Brain Cognitive Development Neurocognitive Prediction: First Challenge, ABCD-NP 2019, Held in Conjunction with MICCAI 2019, Shenzhen, China, October 13, 2019, Proceedings 1. 2019. Springer.
- [19] Wang, L., et al., MRI-based intelligence quotient (IQ) estimation with sparse learning. 2015. 10(3): p. e0117295.
- [20] Yadav, S.S. and S.M.J.J.o.B.d. Jadhav, Deep convolutional neural network based medical image classification for disease diagnosis. 2019. 6(1): p. 1-18.
- [21] Saha, S., et al., Predicting fluid intelligence in adolescence from structural MRI with deep learning methods. 2021. 88: p. 101568.
- [22] Dash, A.K. and P. Mohapatra, A Fine-tuned deep convolutional neural network for chest radiography image classification on COVID-19 cases. Multimedia Tools and Applications, 2022: p. 1-21.

آینده، ارائه‌ی یک پایگاه داده‌ی بزرگ‌تر و متنوع‌تر می‌تواند به اعتبارسنجی بیش‌تر این نتایج کمک کند و مسیرهای جدیدی برای پیش‌بینی‌های دقیق‌تر فراهم سازد. تکنیک‌های تقویت داده‌ها را نیز می‌توان برای افزایش تنوع داده‌های آموزشی و بهبود تعمیم مدل مورد بررسی قرار داد. استفاده‌ی ترکیبی از سایر مدل‌های یادگیری عمیق و مدل‌های سنتی یادگیری ماشین را نیز می‌توان برای کارهای آینده در نظر گرفت تا دقت پیش‌بینی بهبود یابد. نتایج این تحقیق می‌تواند به توسعه‌ی ابزارهای تشخیصی در حوزه‌های بالینی، به ویژه در تشخیص سریع‌تر و دقیق‌تر اختلالات شناختی کمک نماید و زمینه‌ساز پژوهش‌های بیش‌تر در حوزه‌ی مغز و اعصاب و هوش باشد.

## ۶- مراجع

- [1] Adebayo, G.O. and R.V. Yampolskiy, Estimating intelligence quotient using stylometry and machine learning techniques: A review. Big Data Mining and Analytics, 2022. 5(3): p. 163-191.
- [2] Shuttleworth-Edwards, A.B., et al., Cross-cultural effects on IQ test performance: A review and preliminary normative indications on WAIS-III test performance. Journal of clinical and experimental neuropsychology, 2004. 26(7): p. 903-920.
- [3] Woodberry, K.A., A.J. Giuliano, and L.J. Seidman, Premorbid IQ in schizophrenia: a meta-analytic review. American journal of psychiatry, 2008. 165(5): p. 579-587.
- [4] Kalashami, M.P., M.M. Pedram, and H. Sadr, EEG feature extraction and data augmentation in emotion recognition. Computational Intelligence and Neuroscience, 2022. 2022.
- [5] Khodaverdian, Z., et al., An energy aware resource allocation based on combination of CNN and GRU for virtual machine selection. Multimedia Tools and Applications, 2023: p. 1-28.
- [6] Oommen, A., Factors influencing intelligence quotient. Journal of Neurology & Stroke, 2014. 1(4): p. 1-5.
- [7] Khodaverdian, Z., H. Sadr, and S.A. Edalatpanah. A shallow deep neural network for selection of migration candidate virtual machines to reduce energy consumption. in 2021 7th International conference on web research (ICWR). 2021. IEEE.
- [8] Sadr, H., et al., Cardiovascular disease diagnosis: a holistic approach using the integration of machine learning and deep learning models. European Journal of Medical Research, 2024. 29(1): p. 455.
- [9] Thilakavathy, P. and B. Diwan, Intelligent quotient estimation from MRI images using optimal light gradient boosting machine. The

- Workshop, IWDW 2017, Magdeburg, Germany, August 23-25, 2017, Proceedings 16. 2017. Springer.
- [26] Ingalhalikar, M., et al., Functional connectivity-based prediction of Autism on site harmonized ABIDE dataset. *IEEE Transactions on Biomedical Engineering*, 2021. 68(12): p. 3628-3637.
- [27] Thilakavathy, P. and B.J.A.o.t.R.S.f.C.B. Diwan, Semi-automatic framework for estimating Intelligence Quotient (IQ) Using MRI. 2021: p. 2087-2101.
- [23] Matsuyama, E., A deep learning interpretable model for novel coronavirus disease (COVID-19) screening with chest CT images. *Journal of Biomedical Science and Engineering*, 2020. 13(07): p. 140.
- [24] Chen, T. and C. Guestrin. Xgboost: A scalable tree boosting system. in *Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining*. 2016.
- [25] Ren, X., et al. A novel image classification method with CNN-XGBoost model. in *Digital Forensics and Watermarking: 16th International*