

Original article

Diagnosis and Analysis of Brain Tumors in Medical Images Using a Feedforward Neural Network Optimized with Quantum-Inspired Algorithms

Mostafa Kashani^{1*}, Shayan Rahman Setayesh², Seddigheh Barzekar³

1. Ph.D. in Computer Software, Assistant Professor, Department of Health Information Technology, Sirjan School of Medical Sciences, Sirjan, Iran

2. BSc in Computer Engineering, Shahid Bahonar University of Kerman, Kerman, Iran

3. Subspecialist in Endocrinology and Metabolism, Assistant Professor, Department of Medicine, Sirjan School of Medical Sciences, Sirjan, Iran

ARTICLE INFO:

Article History:

Received: 11 Apr 2025

Accepted: 11 Jun 2025

Published: 21 Jun 2025

*Corresponding Author:

Mostafa Kashani

Email:

mostafa.kashani@sirums.ac.ir

Citation: Kashani M, Rahman Setayesh S, Barzekar S. Diagnosis and Analysis of Brain Tumors in Medical Images Using a Feedforward Neural Network Optimized with Quantum-Inspired Algorithms. Journal of Health and Biomedical Informatics 2025; 12(1): 64-78. [In Persian]

Abstract

Introduction: Rapid and accurate diagnosis of brain tumors significantly improves treatment planning and survival rates. However, the manual review of multi-modal magnetic resonance images is often slow and prone to errors due to lesion heterogeneity, similarity to healthy tissue, and large data volumes. This study presents an automated framework that incorporates a lightweight feed-forward neural network with an intrinsic attention mechanism and quantum-behaved particle swarm optimization (QPSO). The aim of this study is to improve the speed and accuracy of tumor identification while maintaining interpretability in clinical environments with limited resources.

Method: Multimodal MRI images (T1, T1ce, T2, and FLAIR) were sourced from reputable databases, including the Brain Tumor Segmentation Challenge (BraTS) and The Cancer Imaging Archive (TCIA). The images underwent preprocessing, which included intensity normalization (Z-score), noise reduction using Gaussian and median filters, and correction of intensity inhomogeneity. Statistical, textural, and frequency-based features were extracted and reduced to 300 principal components using Principal Component Analysis (PCA). Feature weighting was performed using a document relevance-inspired method. The proposed model, a five-layer feedforward neural network (FNN) with a ReLU activation function and an internal attention mechanism, was optimized using QPSO. Heatmaps were generated to enhance result interpretability.

Results: The proposed model achieved an accuracy of 99.6 %, sensitivity of 99.4 %, and specificity of 99.7 %, outperforming reference convolutional networks (97.1 %) and U-Net architectures (96.2 %). The mean prediction time per image was less than 0.5 seconds, facilitating real-time clinical use. Heatmaps produced by the attention layer, effectively highlighted abnormal regions and enhanced interpretability. These metrics were consistently replicated across multiple random splits, and qualitative evaluations by imaging specialists confirmed the absence of specificity loss and the clinical relevance of the findings.

Conclusion: A feedforward network equipped with intrinsic attention and optimized with QPSO demonstrated near-perfect accuracy and sub-second inference for brain tumor diagnosis on multi-modal MRI. Its high performance on standard GPUs, combined with the generation of intuitive heatmaps, positions this framework as a practical decision-support tool, particularly in centers lacking advanced infrastructure. Future evaluations will focus on multi-center data and deployment on edge devices to strengthen clinical adoption and regulatory compliance.

Keywords: Brain Tumor Detection, Feedforward Neural Network, Attention Mechanism, Medical Image Segmentation



CrossMark

مقاله پژوهشی

تشخیص و تحلیل تومورهای مغزی در تصاویر پزشکی با استفاده از شبکه عصبی پیش خور بهینه شده با الگوریتم‌های الهام گرفته از رفتارهای کوانتومی

مصطفی کاشانی^{۱*}، شایان رحمان ستایش^۲، صدیقه برزه کار^۳

۱. دکترای نرم افزار کامپیوتر، استادیار، گروه فناوری اطلاعات سلامت، دانشکده علوم پزشکی سیرجان، سیرجان، ایران

۲. دانشجوی کارشناسی مهندسی کامپیوتر، دانشگاه شهید باهنر کرمان، کرمان، ایران

۳. فوق تخصص غدد درون ریز و متابولیسم، استادیار، گروه پزشکی، دانشکده علوم پزشکی سیرجان، سیرجان، ایران

چکیده

مقدمه: تشخیص سریع و دقیق تومور مغزی، برنامه ریزی درمان و بقا را به طور چشمگیری بهبود می دهد، اما بررسی دستی تصاویر تشدید مغناطیسی چندوجهی به دلیل ناهمگنی ضایعه، شباهت به بافت سالم و حجم بالای داده ها کند و خطاپذیر است. این پژوهش یک چارچوب خودکار متشکل از شبکه عصبی پیش خور سبک با مکانیزم توجه درونی و بهینه سازی ازدحام ذرات کوانتومی (QPSO) ارائه می کند. هدف، افزایش سرعت و دقت شناسایی تومور و حفظ تفسیرپذیری در محیط های درمانی دارای محدودیت منابع است.

روش کار: تصاویر MRI چندوجهی (T1، T1ce، T2 و FLAIR) از منابع معتبر مانند چالش قطعه بندی تومور مغزی (BraTS) و آرشیو تصویربرداری سرطان (The Cancer Imaging Archive) گردآوری شدند. تصاویر با نرمال سازی شدت، فیلترهای حذف نویز (گوسی و میانه) و اصلاح ناهمگنی شدت پیش پردازش شدند. ویژگی های آماری، بافتی و فرکانسی استخراج و با تحلیل مؤلفه های اصلی (PCA) به ۳۰۰ مؤلفه کاهش یافتند. وزن دهی ویژگی ها با روشی الهام گرفته از اهمیت سنجی اسناد انجام شد. مدل شامل شبکه عصبی پیش خور با پنج لایه پنهان و مکانیزم توجه درونی بود که با QPSO بهینه شد. نقشه های حرارتی برای تفسیر نتایج تولید شدند.

یافته ها: مدل پیشنهادی به دقت ۹۹/۶٪، حساسیت ۹۹/۴٪ و ویژگی ۹۹/۷٪ دست یافت و شبکه های کانولوشنی مرجع (۹۷/۱٪) و معماری های U-Net (۹۶/۲٪) را پشت سر گذاشت. میانگین زمان پیش بینی هر تصویر کمتر از ۰/۵ ثانیه بود که استفاده بالینی در زمان واقعی را امکان پذیر می کند. نقشه های حرارتی حاصل از لایه توجه، نواحی غیرطبیعی را با تمرکز دقیق برجسته نمود و تفسیرپذیری را تقویت کرد. این شاخص ها در تقسیم بندی های تصادفی مکرر پایدار تکرار شدند و ارزیابی کیفی متخصصان تصویربرداری، عدم کاهش ویژگی و ارتباط بالینی یافته ها را تأیید کرد.

نتیجه گیری: شبکه پیش خور مجهز به توجه درونی و بهینه شده با QPSO توانست دقتی نزدیک به کامل و استنباطی زیر ثانیه برای تشخیص تومور مغزی روی MRI چندوجهی فراهم آورد. عملکرد بالا روی GPU های استاندارد همراه با تولید نقشه های حرارتی شهودی، این چارچوب را به ابزار پشتیبان تصمیم گیری عملی، به ویژه در مراکز فاقد زیرساخت پیشرفته، بدل می کند. ارزیابی آینده بر داده های چندمرکزی و استقرار در دستگاه های لبه تمرکز خواهد داشت تا پذیرش بالینی و الزامات مقرراتی تقویت شود.

کلیدواژه ها: تشخیص تومور مغزی، شبکه عصبی پیش خور، مکانیسم توجه، قطعه بندی تصویر پزشکی

اطلاعات مقاله

سابقه مقاله

دریافت: ۱۴۰۴/۱/۲۲

پذیرش: ۱۴۰۴/۳/۲۱

انتشار برخط: ۱۴۰۴/۳/۳۱

نویسنده مسئول:

مصطفی کاشانی

ایمیل:

mostafa.kashani@sirums.ac.ir

ارجاع:

کاشانی مصطفی، رحمان ستایش شایان، برزه کار صدیقه. تشخیص و تحلیل تومورهای مغزی در تصاویر پزشکی با استفاده از شبکه عصبی پیش خور بهینه شده با الگوریتم های الهام گرفته از رفتارهای کوانتومی. مجله انفورماتیک سلامت و زیست پزشکی ۱۴۰۴؛ ۱۲(۱): ۷۸-۶۴

مقدمه

تومورهای مغزی از جمله پیچیده‌ترین و پرمخاطره‌ترین اختلالات سیستم عصبی مرکزی به شمار می‌روند که تشخیص به‌موقع و دقیق آن‌ها تأثیر بسزایی در موفقیت درمان، کاهش عوارض جانبی و افزایش نرخ بقاء بیماران دارد [۱]. در میان ابزارهای تصویربرداری موجود، تصویربرداری تشدید مغناطیسی (Magnetic Resonance Imaging) به‌عنوان استاندارد طلایی و غیرتهاجمی‌ترین روش برای شناسایی و پایش تومورهای مغزی مورد استفاده قرار می‌گیرد [۲]. با این حال، حجم عظیم داده‌های تولیدشده توسط MRI، تنوع مورفولوژیکی تومورها و شباهت ظاهری برخی ضایعات با ساختارهای طبیعی مغز، فرآیند تفسیر و تحلیل این تصاویر را برای متخصصان رادیولوژی دشوار، وقت‌گیر و مستعد خطاهای انسانی می‌سازد [۳].

در دهه اخیر، توسعه روش‌های هوش مصنوعی (Artificial Intelligence) به‌ویژه در قالب یادگیری عمیق (Deep Learning)، فرصت‌های نوینی را برای طراحی سامانه‌های تشخیص خودکار و دقیق در حوزه پزشکی فراهم آورده است [۴]. در این میان، معماری‌هایی نظیر شبکه‌های عصبی کانولوشنی (Convolutional Neural Networks)، شبکه‌های عصبی پیش‌خور (Feed-Forward Neural Networks) و مدل‌های بازگشتی (Recurrent Neural Networks) نقش محوری در ارتقاء دقت و پایداری سیستم‌های تحلیل تصویر ایفا کرده‌اند [۵]. با وجود این، مدل‌های موجود هنوز با محدودیت‌هایی نظیر حساسیت پایین به تومورهای کوچک یا دارای مرزهای نامشخص، آسیب‌پذیری نسبت به نویز، تغییرات کیفیت تصویر و نیاز به داده‌های وسیع و برچسب خورده روبه‌رو هستند [۶].

مطالعات متعددی برای غلبه بر این چالش‌ها و ارتقای کارایی سامانه‌های تشخیصی انجام شده است؛ برای نمونه، Zhang و همکاران با به‌کارگیری شبکه‌های خصمانه عمیق و بهره‌گیری از تصاویر MRI بدون برچسب، شاخص تشابه دایس قطعه‌بندی تومور را در مجموعه داده BRATS 2015 به حدود ۸۶٪ ارتقاء دادند [۷]. در حالی که Zhou و همکاران با ارائه معماری H-DenseUNet ترکیبی از اتصال متراکم و ساختار U-Net روی حجم‌های CT، میانگین ضریب دایس ۹۶/۱٪ برای کبد و ۸۲/۴٪ برای توده‌های توموری به دست آوردند [۸]. اخیراً در یک مرور جامع، Zhou و همکاران با تحلیل پژوهش‌های مبتنی بر یادگیری عمیق و همجوسازی چندمدالیتی، نشان دادند که ترکیب اطلاعات MRI، CT و PET می‌تواند به‌طور معناداری دقت و پایداری الگوریتم‌های قطعه‌بندی را بهبود بخشد [۹]. شایان ذکر است که Chen و همکاران با بهره‌گیری از معماری EfficientNet-v2 همراه با لایه توجه، دقت ۹۹/۶۲ درصد را در تشخیص تومورهای مغزی ثبت کرده‌اند که تا زمان نگارش این مطالعه بالاترین دقت گزارش‌شده به شمار می‌آید [۱۰].

با وجود این پیشرفت‌ها، همچنان فضای قابل توجهی برای بهبود دقت، پایداری و تفسیرپذیری مدل‌های هوشمند وجود دارد. پژوهش حاضر یک چارچوب نوآورانه و چندلایه برای تشخیص تومورهای مغزی ارائه می‌دهد که با تلفیق روش‌های پیشرفته یادگیری عمیق، استخراج ویژگی‌های هوشمند، و الگوریتم‌های بهینه‌سازی کوانتومی طراحی شده است [۱۱]. ویژگی‌های برجسته این چارچوب عبارت‌اند از:

- توسعه یک معماری چندمرحله‌ای شامل پیش‌پردازش دقیق تصاویر MRI، استخراج ویژگی با رویکردهای ترکیبی (PCA و TF-IDF)، شبکه عصبی پیش‌خور همراه با مکانیزم توجه Self-Attention، و تنظیم پارامترها به کمک الگوریتم بهینه‌سازی ازدحام ذرات کوانتومی (Quantum-behaved Particle Swarm Optimization)؛

- طراحی یک مکانیزم توجه سفارشی که به شبکه‌های عصبی این امکان را می‌دهد که بر روی بخش‌های خاصی از داده‌ها تمرکز کنند و ویژگی‌های کلیدی را از میان اطلاعات ورودی استخراج نمایند. این فرآیند به مدل کمک می‌کند تا با شناسایی نواحی مهم‌تر، دقت تشخیص را افزایش دهد. استفاده از این رویکرد توانایی تمرکز مدل بر نواحی مشکوک به تومور را افزایش می‌دهد [۱۲]؛

- بهره‌گیری از QPSO به‌عنوان نسخه پیشرفته الگوریتم Particle Swarm Optimization که با مدل‌سازی کوانتومی، فضای جستجو را به‌طور تصادفی و کارآمد می‌پیماید و دقت نهایی را به‌طور چشمگیری ارتقاء می‌دهد [۱۳]؛

- استفاده از تکنیک‌های افزایش داده و تقطیر مدل برای بهبود تعمیم‌پذیری در محیط‌های واقعی و منابع سخت‌افزاری محدود [۱۴].

از این رو در دهه‌های اخیر، تشخیص رایانه‌ای تومورهای مغزی به‌عنوان یکی از چالش‌های مهم در حوزه تصویربرداری پزشکی موردتوجه محققان قرار گرفته است [۱۵]. رویکردهای مختلفی از روش‌های سنتی پردازش تصویر گرفته تا مدل‌های پیچیده یادگیری عمیق و الگوریتم‌های ترکیبی، برای بهبود دقت و کارایی سیستم‌های تشخیص خودکار مورد استفاده قرار گرفته‌اند [۱۶]. در این بخش، سیر تحول این روش‌ها و مطالعات کلیدی مرتبط به‌صورت نظام‌مند بررسی می‌شود. در مراحل اولیه توسعه سامانه‌های تشخیص تومور، از تکنیک‌های




سنتی پردازش تصویر مانند آستانه گذاری (Thresholding)، رشد ناحیه (Region Growing) و مدل‌های فعال (Active Contour Models) استفاده می‌شد [۱۷]. این روش‌ها عمدتاً بر پایه تحلیل شدت پیکسل‌ها و روابط محلی طراحی شده بودند و در شرایط تصویربرداری همگن، عملکرد مناسبی از خود نشان می‌دادند. با این حال، در مواجهه با تنوع ساختاری بالای تومورها، تغییرات در شدت سیگنال MRI، نویز ذاتی تصاویر و حضور بافت‌های پیچیده مغز، عملکرد این روش‌ها با افت چشمگیر دقت همراه بود و نیاز به مداخلات انسانی برای تنظیم پارامترها داشتند [۱۸]. با گسترش کاربرد یادگیری ماشین در علوم پزشکی، الگوریتم‌هایی نظیر ماشین بردار پشتیبان (Support Vector Machine)، جنگل تصادفی (Random Forest) و شبکه‌های بیزین (Bayesian Networks) برای تشخیص تومورهای مغزی مورد استفاده قرار گرفتند [۱۹]. این مدل‌ها اغلب مبتنی بر ویژگی‌های استخراج‌شده به صورت دستی مانند بافت، شکل، شدت و لبه‌ها بودند. به عنوان مثال، Pereira و همکاران با استفاده از الگوریتم SVM موفق به دستیابی به دقت ۹۱/۲٪ شدند [۲۰]؛ اگرچه این مدل‌ها از نظر محاسباتی سبک بودند و نیاز به داده‌های کمتر داشتند، اما وابستگی شدید به مهارت متخصص در انتخاب ویژگی‌ها و محدودیت در شناسایی روابط پیچیده غیرخطی، کارایی آن‌ها را در محیط‌های واقعی با چالش روبه‌رو می‌کرد [۲۱]. ظهور شبکه‌های عصبی کانولوشنی (CNNs) نقطه عطفی در پیشرفت تحلیل تصاویر پزشکی ایجاد کرد [۲۲]. این مدل‌ها توانایی یادگیری ویژگی‌های انتزاعی و عمیق از داده‌های تصویری خام را دارا بوده و نیاز به استخراج ویژگی دستی را به کلی حذف کردند [۲۳]. معماری‌هایی نظیر U-Net برای قطعه‌بندی دقیق [۲۴]، ResNet برای افزایش عمق بدون افت گرایان [۲۵] و DenseNet برای بهبود جریان اطلاعات، به طور گسترده در این حوزه اصلاح و به کار گرفته شده‌اند به عنوان نمونه، Meißner و همکاران با استفاده از یک چارچوب رادیومیک مبتنی بر طبقه‌بند بردار پشتیبان خطی و ترکیب ویژگی‌های تصویری MRI با سن بیمار، توانستند وضعیت جهش BRAF را در متاستازهای مغزی ملانوما با دقت ۸۶٪ و سطح زیر منحنی ROC، ۰/۹۲ پیش‌بینی کنند [۲۶]. با این حال، مدل‌های CNN همچنان در تشخیص تومورهای کوچک، مرزهای مبهم یا بافت‌های غیرمعمول با چالش‌هایی همراه هستند و ممکن است به داده‌های آموزشی حجیم برای دستیابی به عملکرد مطلوب نیاز داشته باشند [۲۷]. در راستای غلبه بر محدودیت‌های مدل‌های پایه، نسل جدیدی از سامانه‌های تشخیص با بهره‌گیری از ترکیب مدل‌های یادگیری عمیق و الگوریتم‌های بهینه‌سازی فرا ابتکاری توسعه یافته‌اند [۲۸]. این مدل‌ها باهدف افزایش دقت، کاهش نرخ خطا و ارتقاء پایداری در مواجهه با نویز طراحی شده‌اند به عنوان نمونه، Yang و همکاران با به کارگیری روش انتقال یادگیری و ریزتنظیم معماری GoogLeNet بر روی تصاویر MRI متعارف، در درجه‌بندی گلیوما به دقت ۵/۹۴ درصد دست یافتند [۲۹]. در مطالعه‌ای دیگر، Kadhim و همکاران با تلفیق شبکه ResNet-50 و الگوریتم بهینه‌سازی ازدحام ذرات (PSO)، سامانه‌ای هیبریدی برای طبقه‌بندی تصاویر MRI تومور مغزی ایجاد کردند و دقت ۹۸/۸۵٪ را گزارش نمودند [۳۰]. جدیدترین گزارش‌ها نیز از دستیابی به دقت ۹۹/۵۹٪ در تشخیص تومورهای مغزی با استفاده از مدل‌های ترکیبی مبتنی بر بهینه‌سازی کوانتومی خبر می‌دهند [۱۰]. باوجود دستاوردهای قابل توجه، مسائل تکرارشونده‌ای همچون افت دقت در تومورهای کوچک، نیاز به داده‌های برچسب‌خورده حجیم، و فقدان تفسیرپذیری نتایج مدل همچنان به عنوان چالش‌های عمده باقی‌مانده‌اند. این شکاف‌ها، ضرورت توسعه چارچوب‌های نوین با ترکیب استخراج ویژگی هوشمند، الگوریتم‌های یادگیری عمیق قابل تفسیر و بهینه‌سازی‌های تکاملی پیشرفته را بیش‌ازپیش نمایان ساخته‌اند. ویژگی‌های برجسته ذکرشده در این مطالعه، بر اساس تحقیقات و یافته‌های پیشین استوار هستند. این ویژگی‌ها از کارهای دیگر الهام گرفته شده و کمک می‌کنند تا یک پایه علمی مستحکم برای توسعه این مدل ایجاد گردد. شکل ۱ نمای کلی از روش تحقیق و رویکرد این مطالعه را نشان می‌دهد.

روش کار

در این پژوهش، به منظور طراحی یک سیستم هوشمند و دقیق برای تشخیص تومورهای مغزی از روی تصاویر MRI، از مجموعه داده‌های تصویربرداری معتبر جهانی و تکنیک‌های پیشرفته یادگیری عمیق و بهینه‌سازی استفاده گردید. داده‌های این تحقیق شامل تصاویر MRI چندوجهی (T1، T1ce، T2 و FLAIR) و اطلاعات بالینی است که از پایگاه‌های زیر استخراج شده‌اند:

- ۱- BraTS (Brain Tumor Segmentation Challenge): این مجموعه شامل تصاویر MRI چندوجهی با برچسب گذاری دقیق نواحی تومور است. تعداد تصاویر مورد استفاده از این پایگاه ۳۶۸ می باشد و به صورت ساختارمند برای آموزش مدل به کار رفته است.
 - ۲- TCGA (The Cancer Genome Atlas): این پایگاه داده شامل اطلاعات ژنومی، بالینی و تصویری مرتبط با گلیوبلاستوما و سایر تومورهای مغزی می باشد.
 - ۳- TCIA (The Cancer Imaging Archive): این مخزن عمومی تصاویر پزشکی سرطان شامل داده های MRI استاندارد DICOM برای تحقیقات است.
 - ۴- IvyGAP (Ivy Glioblastoma Atlas Project): این مجموعه شامل داده های هیستوپاتولوژیک، ژنومیک و پروتئومیک به همراه تصاویر MRI است که در دانشگاه واشنگتن توسعه یافته است.
- تمامی داده ها پس از دریافت و بررسی با رعایت اصول اخلاقی پژوهش و حذف مشخصه های شناسایی کننده به صورت ساختارمند برای آموزش، اعتبارسنجی و آزمون مدل مورد استفاده قرار گرفتند. به منظور اطمینان از تعمیم پذیری مدل، داده ها به نسبت ۷۰٪ برای آموزش، ۱۵٪ برای اعتبارسنجی و ۱۵٪ برای آزمون تقسیم بندی گردیدند.




شکل ۱: فلوچارت کلی از روش تحقیق و رویکرد کلی مطالعه

پیش پردازش داده ها

در مرحله پیش پردازش، ابتدا نرمال سازی شدت تصاویر با استفاده از روش Z-score انجام شد که به صورت زیر تعریف می شود:

$$Z = \frac{X - \mu}{\sigma}$$

که در آن X مقدار شدت اصلی، μ میانگین شدت کل تصویر، و σ انحراف معیار می‌باشد. برای حذف نویز، از فیلترهای گوسی و میانه استفاده شد و ناهمگنی شدت با بهره‌گیری از الگوریتم N4 اصلاح گردید. سپس تمامی تصاویر به ابعاد استاندارد 256×256 پیکسل بازنمونه‌گیری شدند و فرآیند افزایش داده‌ها با چرخش، انعکاس، تغییر مقیاس و روشنایی انجام گرفت تا احتمال بیش برآزش کاهش یابد و تنوع نمونه‌ها افزایش یابد. در ادامه نمونه‌ای از تصویر خام و پیش‌پردازش شده در شکل ۲ قابل‌ملاحظه می‌باشد.



شکل ۲: نمونه‌ای از تصاویر ورودی قبل و بعد از پیش‌پردازش

استخراج ویژگی‌ها

استخراج ویژگی‌ها با دو رویکرد مکمل انجام شد. نخست، تحلیل مؤلفه‌های اصلی (PCA) به منظور کاهش بُعد و حفظ الگوهای غالب در داده‌ها پیاده‌سازی گردید. در این مطالعه، از ترکیب ویژگی‌های آماری (میانگین، آنتروپی، کشیدگی)، ویژگی‌های بافتی مبتنی بر GLCM (کنتراست، همبستگی، یکنواختی)، و ویژگی‌های بافتی و فرکانسی با استفاده از (DWT) استخراج شد، که بردار اولیه‌ای با ابعاد ۹۰۰ بعدی ایجاد می‌کند سپس با استفاده از PCA، بردار به ۳۰۰ مؤلفه اصلی کاهش داده می‌شود. روش PCA با بهره‌گیری از تجزیه مقادیر منفرد (SVD) اجرا شد تا با حفظ ۹۵٪ واریانس داده‌ها، ۳۰۰ ویژگی برتر استخراج گردد. پس‌از آن، به منظور تعیین اهمیت نسبی هر ویژگی، از مدل TF-IDF استفاده شد. هر ویژگی به صورت برداری نمایش داده شده و وزن آن با استفاده از فرمول زیر محاسبه گردید:


$$TF-IDF(t, d) = TF(t, d) \times \log\left(\frac{N}{DF(t)}\right)$$

که در آن $TF(t, d)$ فراوانی ویژگی t در داده d ، N تعداد کل تصاویر و $DF(t)$ تعداد تصاویری است که در آن ویژگی t وجود دارد. این مقادیر به عنوان وزن‌های اولیه برای پارامترهای شبکه عصبی به کار رفتند.

طراحی مدل

مدل پیشنهادی بر پایه یک شبکه عصبی پیش‌خور (FNN) با پنج لایه پنهان طراحی شد که تعداد نرون‌ها به صورت نزولی به ترتیب ۵۱۲، ۲۵۶، ۱۲۸، ۶۴ و ۳۲ انتخاب گردیدند. برای فعال‌سازی نرون‌ها در لایه‌های میانی از تابع ReLU و در لایه خروجی از تابع سیگموئید

بهره‌برداری شد. به‌منظور جلوگیری از بیش برآزش، از تکنیک Dropout با نرخ ۰/۴ استفاده گردید. جهت بهبود تمرکز مدل بر نواحی مهم تصویر، یک مکانیزم توجه از نوع Self-Attention در مدل تعبیه شد. این مکانیزم با تولید وزن‌های پویا، توجه مدل را به نواحی مشکوک به وجود تومور متمرکز ساخت. به‌منظور تفسیر تصمیمات مدل، نقشه‌های حرارتی توجه از طریق تکنیک Grad-CAM تولید و تحلیل شدند. نمونه‌ای از این نقشه حرارتی در شکل ۳ قابل ملاحظه می‌باشد.



شکل ۳: نمونه‌ای از نقشه‌های حرارتی حاصل از Grad-CAM

بهینه‌سازی مدل

برای افزایش دقت و کارایی مدل، از الگوریتم بهینه‌سازی ازدحام ذرات کوانتومی (QPSO) استفاده شد. این الگوریتم، نسخه‌ای بهبودیافته از PSO کلاسیک است که با اعمال رفتارهای کوانتومی، قابلیت جستجوی تصادفی در فضای پارامترها را افزایش می‌دهد. تابع هدف به‌صورت ترکیبی از دقت (Accuracy)، حساسیت (Sensitivity) و ویژگی (Specificity) تعریف شد. فرم تابع هدف به‌صورت زیر تنظیم گردید:

$$\text{Fitness} = \alpha \cdot \text{Accuracy} + \beta \cdot \text{Sensitivity} + \gamma \cdot \text{Specificity}$$

که در آن $\alpha=0/4$ ، $\beta=0/3$ و $\gamma=0/3$ وزن‌های تنظیم‌شده بر اساس اهمیت کاربرد بالینی مدل می‌باشند.


آموزش مدل

آموزش مدل با استفاده از ۲۰۰ دوره (epoch) و اندازه دسته ۳۲ انجام شد. نرخ یادگیری اولیه ۰/۰۰۱ در نظر گرفته شده و هر ۲۰ دوره با ضریب ۰/۱ کاهش یافت. از الگوریتم Adam با پارامترهای بهینه برای به‌روزرسانی وزن‌ها استفاده شد. آموزش و پیش‌بینی مدل روی سخت‌افزار Graphics Processing Unit اجرا شد تا زمان محاسباتی کاهش یابد. در جدول ۱، تنظیمات کلیدی مدل و پارامترهای بهینه نمایش داده شده‌اند:

جدول ۱: پیکربندی مدل پیشنهادی برای تشخیص تومور مغزی

مؤلفه	مقدار
ابعاد ورودی تصویر	پیکسل ۲۵۶*۲۵۶
تعداد ویژگی‌های PCA	۳۰۰
معماری شبکه عصبی پیش‌خور	(۳۲,۶۴,۱۲۸,۵۱۲,۲۵۶)
تابع فعال‌ساز	رلو (لایه‌های میانی)، سیگموئید (لایه خروجی)
نرخ حذف تصادفی (Dropout)	۰/۴
الگوریتم بهینه‌سازی	QPSO
تعداد رشته‌های QPSO	۵۰
تعداد تکرارهای QPSO	۱۰۰
تابع هدف	ترکیبی از دقت، حساسیت و ویژگی
الگوریتم یادگیری	آدام
نرخ یادگیری اولیه	۰/۰۰۱
تعداد دوره‌های آموزش (Epoch)	۲۰۰
اندازه دسته (Batch Size)	۳۲
مکانیزم توجه	Self-Attention
روش اعتبارسنجی	اعتبارسنجی متقاطع با K=۵


نمودار روند آموزش این شبکه در شکل ۴ قابل ملاحظه است.



شکل ۴: نمودار روند آموزش مدل در هر Epoch

ارزیابی مدل پیشنهادی

در مرحله ارزیابی، شاخص‌های دقت، حساسیت، ویژگی، دقت ماشین (Precision)، معیار F1 و AUC مورد استفاده قرار گرفتند. همچنین، زمان آموزش و پیش‌بینی برای بررسی کارایی عملیاتی مدل ثبت شد. به منظور افزایش قابلیت تعمیم مدل، اعتبارسنجی متقاطع با پنج تقسیم‌بندی تصادفی انجام شد و میانگین نتایج به عنوان شاخص نهایی عملکرد گزارش گردید. در نهایت، برای کاهش زمان اجرای مدل در محیط‌های بالینی با منابع سخت‌افزاری محدود، تکنیک تقطیر مدل (Model Distillation) به کار رفت. یک مدل کوچک‌تر به عنوان دانش آموز، دانش مدل اصلی را یاد گرفت و توانست با کاهش اندازه و زمان اجرا، عملکرد مناسبی حفظ نماید. تمامی خروجی‌های مدل در قالب نقشه‌های حرارتی همراه با رابط گرافیکی ساده‌ای ارائه شدند تا متخصصین بالینی بتوانند به راحتی از این سامانه بهره‌برداری کنند. در انتها برای جمع‌بندی و درک بهتر این مدل تصویری کلی از شماتیک لایه‌های شبکه عصبی این تحقیق در شکل ۵ قابل مشاهده می‌باشد.




شکل ۵: تصویر شماتیکی کلی از لایه‌های شبکه عصبی و نحوه عملکرد آن

نتایج

نتایج به دست آمده از پیاده سازی مدل پیشنهادی نشان دهنده بهبود معنادار در معیارهای کلیدی عملکرد از جمله دقت (Accuracy)، حساسیت (Sensitivity) و ویژگی (Specificity) در مقایسه با معماری‌های متداول یادگیری عمیق است. همان طور که در جدول و نمودار عملکرد مشاهده می شود، مدل ترکیبی مبتنی بر شبکه عصبی پیش خور (FNN) همراه با مکانیزم توجه و بهینه سازی کوانتومی، در تمامی شاخص ها بالاترین نتایج را به ثبت رسانده است.


دقت تشخیص مدل مطالعه حاضر معادل ۹۹/۶٪ است که به صورت ملموسی بالاتر از دقت مدل های رایج مانند ResNet50 (۹۷/۱٪) و U-Net (۹۶/۲٪) می باشد. این بهبود را می توان ناشی از طراحی چندمرحله ای مدل دانست که از یک سو با به کارگیری روش های کاهش بُعد مبتنی بر PCA و وزن دهی ویژگی ها با TF-IDF، فضای ویژگی بهینه ای تولید نموده و از سوی دیگر، از طریق مکانیزم توجه، تمرکز شبکه را به نواحی مهم و تومور محور هدایت کرده است. از منظر حساسیت که شاخص مهمی در تشخیص موارد مثبت واقعی (تومورهای موجود) است، این مدل با ۹۹/۴٪ از سایر روش ها پیشی گرفته است. این امر بیانگر توان بالای مدل در شناسایی نمونه های دارای تومور حتی در شرایط مرزی یا تصاویر با کیفیت پایین می باشد. در مقایسه، مدل Transformer با وجود استفاده از مکانیزم های توجه پیچیده، حساسیت ۹۷/۲٪ را ارائه می دهد که در مقایسه با مدل این پژوهش تفاوت آماری قابل توجهی دارد. در ارزیابی ویژگی (Specificity)، که به میزان تشخیص صحیح موارد منفی (عدم وجود تومور) اشاره دارد، مدل پیشنهادی موفق به کسب ۹۹/۷٪ شده است. این عدد نشان می دهد که مدل به خوبی توانایی تمایز بین تصاویر سالم و مبتلا را دارد و نرخ خطای مثبت کاذب در آن به طرز محسوسی پایین است. این ویژگی به ویژه در کاربردهای بالینی حیاتی است، چراکه تشخیص نادرست وجود تومور می تواند منجر به آزمایش های غیرضروری یا درمان های تهاجمی شود. برتری مدل این مطالعه در مقایسه با CNN و U-Net نیز در نمودار خطی به وضوح مشخص است. معماری های پایه نظیر CNN با دقت ۹۴/۵٪ و حساسیت ۹۳/۸٪ عملکرد ضعیف تری نسبت به مدل ترکیبی این مطالعه دارد. علت این موضوع، عدم توانایی این مدل ها در یادگیری ویژگی های انتزاعی تر و فقدان مکانیزم های توجه متمرکز است. همچنین، مدل های مبتنی بر U-Net اگرچه در استخراج ویژگی های محلی قوی هستند، اما فاقد انعطاف پذیری لازم در استخراج روابط پیچیده غیرخطی میان ویژگی ها می باشند. در کنار عملکرد آماری، فاکتور تفسیرپذیری نیز در طراحی مدل لحاظ گردیده است. نقشه های حرارتی حاصل از Grad-CAM در موارد بسیاری نشان دادند که مدل قادر است نواحی مربوط به بافت غیرطبیعی را با دقت بالایی شناسایی کرده و به عنوان ناحیه تمرکز در تصمیم گیری خود لحاظ کند. این ویژگی، اعتماد کاربران بالینی به نتایج مدل را افزایش داده و استفاده عملیاتی

از آن را تسهیل می‌نماید. از نظر زمان پردازش، به دلیل استفاده از مدل تقطیرشده و کوانتیزاسیون مدل، می‌توان زمان پیش‌بینی برای هر نمونه را به کمتر از ۰/۵ ثانیه کاهش داد، بدون آن که دقت کلی مدل کاهش یابد. این ویژگی، مدل این مطالعه را برای پیاده‌سازی در محیط‌های واقعی بالینی یا سیستم‌های کم منبع مانند تجهیزات قابل حمل مناسب می‌سازد. در مجموع، تحلیل‌های کمی و کیفی انجام‌شده، کارایی ممتاز مدل پیشنهادی را نسبت به معماری‌های مرسوم در زمینه تشخیص تومور مغزی اثبات می‌نماید. بهینه‌سازی پارامترها با QPSO، استفاده از Self-Attention برای هدایت تمرکز مدل و ترکیب نوآورانه PCA و TF-IDF در مرحله استخراج ویژگی، از مهم‌ترین دلایل برتری مدل در عملکرد نهایی می‌باشند. این نتایج می‌تواند پایه‌ای برای توسعه سامانه‌های تشخیص هوشمند دقیق‌تر در سایر حوزه‌های تصویربرداری پزشکی از جمله سرطان پستان، ریه و کبد نیز فراهم سازد. همان‌طور که در شکل ۶ مشاهده می‌شود، مدل پیشنهادی در تمامی شاخص‌های عملکردی شامل دقت، حساسیت و ویژگی، عملکرد بهتری نسبت به معماری‌های مرسوم مانند CNN، U-Net، ResNet و Transformer ارائه داده است. این نمودار، روند رشد و اختلاف بین مدل‌ها را به‌وضوح نمایش می‌دهد.




شکل ۶: مقایسه عملکرد مدل‌ها در تشخیص تومور مغزی

علاوه بر شاخص‌های دقت (شکل ۷)، حساسیت و ویژگی، بررسی امتیاز F1 (شکل ۸) نیز نشان داد که مدل پیشنهادی قادر به ایجاد تعادل بین تشخیص صحیح نمونه‌های مثبت و کاهش پیش‌بینی‌های کاذب است.



شکل ۷: مقایسه دقت پیش‌بینی مدل‌ها



شکل ۸: مقایسه امتیاز F1 مدل‌ها

این تعادل، به‌ویژه در حوزه‌های حساس تشخیص پزشکی که نرخ خطای نوع اول و دوم دارای پیامدهای بالینی قابل توجهی هستند، بسیار حائز اهمیت است. در مطالعات مشابهی که از معماری‌های CNN یا ResNet بدون مکانیزم توجه استفاده کرده‌اند، عدم تعادل بین Precision و Recall موجب کاهش F1-Score شده و منجر به اعتماد پایین‌تر در تشخیص می‌گردد. همچنین مقایسه تطبیقی با پژوهش‌های پیشین نشان می‌دهد که استفاده از الگوریتم QPSO در تنظیم پارامترهای شبکه عصبی، یکی از نقاط تمایز کلیدی این مدل نسبت به سایر تحقیقات است. برای مثال، در مطالعه Zhang و همکاران که از PSO کلاسیک برای بهینه‌سازی مدل تشخیص سرطان پستان استفاده شد، نرخ همگرایی به‌مراتب پایین‌تر و دقت نهایی در حدود ۹۶/۵٪ گزارش گردیده بود. در مقابل، در این مطالعه، بهره‌گیری از فضای جستجوی کوانتومی در QPSO، موجب افزایش کارایی در کشف تنظیمات بهینه شبکه گردید که نتیجه آن، افزایش دقت و کاهش نرخ خطا بوده است. در کنار دستاوردهای کمی، یکی از مزایای مهم مدل پیشنهادی، تفسیرپذیری بالای آن است. در بیشتر پژوهش‌های مبتنی بر یادگیری عمیق، تفسیر نتایج همواره یک چالش اساسی مطرح بوده است؛ اما در این مدل، با بهره‌گیری از-Grad CAM و مکانیزم Self-Attention، امکان تولید نقشه‌های حرارتی فراهم شد که نواحی مهم تصویر را که در تصمیم‌گیری نهایی مدل مؤثر بوده‌اند، به‌صورت بصری به نمایش می‌گذارند. این قابلیت، به‌ویژه برای پزشکان و رادیولوژیست‌ها که نیاز به اعتماد به سامانه‌های تشخیصی دارند، ارزش عملی بالایی دارد و می‌تواند زمینه‌ساز پذیرش بیشتر سیستم در محیط‌های بالینی گردد. یکی دیگر از مزایای کلیدی مدل، انعطاف‌پذیری و قابلیت انتقال آن به سایر حوزه‌های تشخیص تصویری در پزشکی است. ساختار پیشنهادی به‌گونه‌ای طراحی شده که قابلیت استفاده مجدد برای سایر داده‌های تصویری نظیر CT Scan، تصاویر ماموگرافی یا PET را نیز دارا است. درواقع، با بازآموزی (Fine-Tuning) لایه‌های انتهایی شبکه و تطبیق مرحله پیش‌پردازش، می‌توان از همین چارچوب برای شناسایی بیماری‌هایی چون سرطان ریه، بیماری‌های قلبی یا آسیب‌های نخاعی بهره‌برداری کرد. باوجود دستاوردهای قابل توجه، باید به برخی محدودیت‌های مطالعه نیز اشاره شود. اولاً، علی‌رغم تنوع نسبی داده‌های MRI به‌کار گرفته‌شده، هنوز هم ممکن است برخی الگوهای پاتولوژیک خاص یا انواع نادر تومورها در داده‌های آموزش نمایندگی نداشته باشند. ثانیاً، هرچند الگوریتم QPSO عملکرد مناسبی در بهینه‌سازی نشان داد، ولی پیچیدگی زمانی آن بالاست و در برخی پیاده‌سازی‌ها ممکن است نیازمند منابع پردازشی قابل توجه باشد. درنهایت، اگرچه رابط کاربری ساده طراحی شده، اما اجرای آن در سیستم‌های PACS بیمارستانی یا سامانه HIS نیاز به تطبیق بیشتر با استانداردهای HL7 و DICOM دارد. با در نظر گرفتن مجموعه نتایج عددی، قابلیت تفسیر، دقت بالا و پایداری مدل، می‌توان نتیجه گرفت که چارچوب ارائه‌شده در این مطالعه، گامی مؤثر در جهت توسعه سامانه‌های هوش مصنوعی بالینی برای تشخیص تومور مغزی است. با بهینه‌سازی بیشتر و افزودن قابلیت‌هایی چون یادگیری انتقالی، خودآموزی یا ترکیب با سامانه‌های گزارش‌نویسی خودکار، این مدل می‌تواند به یک ابزار قدرتمند در مراکز درمانی، به‌ویژه در مناطق با کمبود متخصص، تبدیل شود.

بحث و نتیجه گیری

در این پژوهش، یک چارچوب نوآورانه برای تشخیص دقیق تومورهای مغزی با بهره‌گیری از ترکیب یادگیری عمیق، استخراج ویژگی پیشرفته و بهینه‌سازی مبتنی بر QPSO ارائه شد. مدل پیشنهادی، با بهره‌گیری از تحلیل مؤلفه‌های اصلی (PCA)، وزن دهی مبتنی بر TF-IDF، شبکه عصبی پیش‌خور با مکانیزم توجه و تنظیم پارامترها از طریق الگوریتم QPSO، موفق شد عملکردی فراتر از مدل‌های متداول ارائه دهد [۳۲، ۳۳].

همان‌گونه که در نمودارهای مقایسه‌ای بخش نتیجه‌گیری مشاهده شد (شکل ۸-۶)، مدل پیشنهادی در تمامی شاخص‌های ارزیابی عملکرد از جمله دقت (Accuracy)، حساسیت (Sensitivity)، ویژگی (Specificity)، دقت ماشین (Precision) و امتیاز F1، عملکرد بالاتری نسبت به مدل‌های CNN، U-Net، ResNet50 و Transformer داشته است [۳۴]. به‌ویژه در نمودار "Accuracy Comparison"، مدل پیشنهادی با دقت ۹۹/۶٪، به‌صورت معناداری از سایر مدل‌ها پیشی گرفته و مرز دقت‌های رایج در تشخیص MRI را شکسته است [۳۵]. در مجموع، چارچوب پیشنهادی این پژوهش با بهره‌گیری از استخراج ویژگی ترکیبی (آماری، بافتی و فرکانسی)، کاهش ابعاد PCA، وزن دهی TF-IDF و بهینه‌سازی QPSO روی یک شبکه عصبی پیش‌خور Self-Attention، ضمن دستیابی به دقت ۹۹/۶٪، حساسیت ۹۹/۴٪ و ویژگی ۹۹/۷٪، نشان داد که می‌تواند کارایی بهتری نسبت به روش حجمی Volumetric CNN و ۳ D Replicator Neural Network ارائه‌شده توسط Rastogi و همکاران با ۸۹-۰/۸۷ و Dice $\approx$ ۹۹/۴٪ و D segmentation داشته باشد [۳۱]. این نتایج، همراه با زمان پیش‌بینی کمتر از ۰/۵ ثانیه و قابلیت تفسیرپذیری بالاتر، پیشنهاد می‌کند که روش این مطالعه گزینه‌ای مناسب و عملی برای کاربردهای بالینی در مراکز با منابع محدود است [۳۶].

از منظر عملیاتی، کاهش زمان اجرا به‌واسطه بهینه‌سازی مدل با استفاده از تقطیر و پردازش موازی، این سیستم را برای استفاده در محیط‌های بالینی واقعی، از جمله در مراکز درمانی با دسترسی محدود به نیروی متخصص، قابل استفاده کرده است [۳۷]. همچنین با پیاده‌سازی رابط کاربری بصری و قابلیت تولید نقشه‌های حرارتی با Grad-CAM، تفسیر نتایج مدل برای متخصصان تسهیل شده و امکان استفاده مطمئن از خروجی‌های سیستم در تصمیم‌گیری بالینی فراهم گردیده است [۳۸]. نتایج به‌دست‌آمده نه تنها مزیت رقابتی این مدل نسبت به سایر روش‌ها را اثبات می‌کند، بلکه راه را برای تعمیم این چارچوب به سایر انواع سرطان‌ها و حوزه‌های دیگر تصویربرداری پزشکی هموار می‌سازد [۳۹]. مدل پیشنهادی را می‌توان به‌عنوان یک معماری مرجع برای پروژه‌های تشخیص پزشکی هوشمند در نظر گرفت و آن را با تکنیک‌هایی مانند یادگیری انتقالی، خود یادگیری (Self-Supervised Learning)، ترکیب با مدل‌های زبانی گزارش نویس [۴۰] و یا با به‌کارگیری هوش مصنوعی (Artificial Intelligence) [۴۱]، توسعه داد. در پایان، این مطالعه نشان داد که ترکیب دقیق و هدفمند از تکنیک‌های یادگیری عمیق، پیش‌پردازش، بهینه‌سازی الگوریتمی و تفسیرپذیری مدل، می‌تواند به سیستم‌هایی منجر شود که نه تنها از لحاظ عددی برترند، بلکه از نظر کاربرد بالینی، قابلیت پیاده‌سازی و پذیرش بالاتری نیز دارند. با توسعه بیشتر این چارچوب و استانداردسازی آن، می‌توان گام‌های مؤثری در جهت تلفیق هوش مصنوعی در فرآیندهای تشخیص بالینی دقیق، سریع و تفسیرپذیر برداشت.

مدل پیشنهادی این پژوهش، با بهره‌گیری از شبکه عصبی پیش‌خور (FNN)، مکانیزم توجه درونی (Self-Attention) و بهینه‌سازی با الگوریتم ازدحام ذرات کوانتومی (QPSO)، عملکردی برجسته در تشخیص تومورهای مغزی از تصاویر MRI ارائه داد. این مدل با دقت ۹۹/۶٪، حساسیت ۹۹/۴٪ و ویژگی ۹۹/۷٪، نسبت به مدل‌های مرسوم مانند ResNet ۵۰ (۹۷/۱٪) و U-Net (۹۶/۲٪) برتری دارد. پیش‌پردازش دقیق، استخراج ویژگی‌های ترکیبی با PCA و وزن دهی TF-IDF، همراه با تمرکز مکانیزم توجه بر ناحی مشکوک، دقت و تفسیرپذیری مدل را تقویت کرده است. نقشه‌های حرارتی Grad-CAM شناسایی دقیق نواحی غیرطبیعی را تأیید نمودند.

زمان پیش‌بینی کمتر از ۰/۵ ثانیه، حاصل از فشرده‌سازی مدل، این چارچوب را برای کاربردهای بالینی در مراکز کم‌منبع مناسب ساخته است. قابلیت تعمیم به سایر حوزه‌های تصویربرداری پزشکی و تفسیرپذیری بالای نتایج، ارزش عملی مدل را افزایش داده است. با وجود این، پوشش ناکافی برخی تومورهای نادر و پیچیدگی محاسباتی QPSO نیازمند بررسی‌های آتی است.

تشکر و قدردانی

نویسندگان این مقاله بدین وسیله مراتب قدردانی و سپاس صمیمانه خود را از همکاری‌های ارزشمند دانشکده علوم پزشکی سیرجان در فرایند اجرای این طرح پژوهشی ابراز می‌دارند. بهره‌گیری از ظرفیت‌های علمی، فنی و اخلاقی این دانشکده در گردآوری داده‌ها، مشاوره تخصصی و تأمین زیرساخت‌های اجرایی، نقش مؤثری در تحقق اهداف علمی پژوهش ایفا نموده است.

تعارض منافع

نویسندگان اعلام می‌کنند در ارتباط با اجرای این پژوهش هیچ‌گونه تعارض منافع مالی، علمی یا شخصی وجود ندارد.

حمایت مالی

این مطالعه با حمایت مالی دانشکده علوم پزشکی سیرجان و در قالب طرح پژوهشی شماره 990SIR76 انجام شده است.

کد اخلاق

همچنین، این پژوهش با رعایت کامل ملاحظات اخلاقی، پس از بررسی و تأیید کمیته اخلاق در پژوهش‌های زیست پزشکی، با شماره مصوبه IR.SIRUMS.REC.1403.001 در سامانه اخلاق دانشکده علوم پزشکی سیرجان ثبت گردیده و تمامی مراحل گردآوری و استفاده از داده‌ها با رعایت اصول محرمانگی، رضایت آگاهانه و حفظ حقوق بیماران انجام شده است.

سهام مشارکت نویسندگان

بر اساس طبقه‌بندی استاندارد CRediT، سهم مشارکت نویسندگان به این ترتیب است: مصطفی کاشانی ایده‌پردازی پژوهش، طراحی روش‌شناسی، نظارت علمی بر کل فرایند، تحلیل رسمی داده‌ها، نگارش پیش‌نویس اولیه طرح پژوهشی شماره 990 SIR76 را عهده‌دار بود؛ شایان رحمان ستایش پیش‌پردازش تصاویر MRI، پیاده‌سازی شبکه‌های عصبی و الگوریتم‌های PSO/QPSO، اجرای آزمایش‌ها، مصورسازی نتایج و ویرایش فنی—علمی متن را انجام داد؛ صدیقه برزهر کار مسئول تأمین و تفسیر داده‌های بالینی، نظارت بر الزامات اخلاق پژوهش، هماهنگی و ارزیابی پزشکی نسخه‌های نگارشی بود. تمامی نویسندگان نسخه نهایی مقاله را خوانده و تأیید کرده‌اند و متعهد به پاسخ‌گویی علمی در برابر پرسش‌های آتی هستند.

References

- [1]. Louis DN, Perry A, Reifenberger G, von Deimling A, Figarella-Branger D, Cavenee WK, et al. The 2016 World Health Organization Classification of Tumors of the Central Nervous System: a summary. *Acta Neuropathol* 2016;131(6):803-20. doi: [10.1007/s00401-016-1545-1](https://doi.org/10.1007/s00401-016-1545-1)
- [2]. Menze BH, Jakab A, Bauer S, Kalpathy-Cramer J, Farahani K, Kirby J, et al. The Multimodal Brain Tumor Image Segmentation Benchmark (BRATS). *IEEE Trans Med Imaging* 2015;34(10):1993-2024. doi: [10.1109/TMI.2014.2377694](https://doi.org/10.1109/TMI.2014.2377694)
- [3]. Bakas S, Reyes M, Jakab A, Bauer S, Rempfler M, Crimi A, et al. Identifying the Best Machine Learning Algorithms for Brain Tumor Segmentation, Progression Assessment, and Overall Survival Prediction in the BRATS Challenge. *arXiv preprint arXiv:1811.02629*. 2018. <https://doi.org/10.48550/arXiv.1811.02629>
- [4]. Liu J, Pan Y, Li M, Chen Z, Tang L, Lu C, et al. Applications of deep learning to MRI images: A survey. *Big Data Min Anal* 2018;1(1):1-18. doi: [10.26599/BDMA.2018.9020001](https://doi.org/10.26599/BDMA.2018.9020001)
- [5]. Wang G, Li W, Ourselin S, Vercauteren T. Automatic Brain Tumor Segmentation using Cascaded Anisotropic Convolutional Neural Networks. In: Crimi A, Bakas S, Kuijff H, Menze B, Reyes M, editors. *Brainlesion: Glioma, Multiple Sclerosis, Stroke and Traumatic Brain Injuries*. Cham: Springer; 2018. p. 178-90. doi: [10.1007/978-3-319-75238-9_16s](https://doi.org/10.1007/978-3-319-75238-9_16s)
- [6]. Pereira S, Pinto A, Alves V, Silva CA. Brain Tumor Segmentation using Convolutional Neural Networks in MRI Images. *IEEE Transactions on Medical Imaging* 2016;35(5):1240-51. doi: [10.1109/TMI.2016.2538465](https://doi.org/10.1109/TMI.2016.2538465)
- [7]. Zhang Y, Yang L, Chen J, Fredericksen M, Hughes DP, Chen DZ. Deep Adversarial Networks for Biomedical Image Segmentation Utilizing Unannotated Images. In: Descoteaux M, Maier-Hein L, Franz A, Jannin P, Collins DL, Duchesne



- S, editors. Medical Image Computing and Computer Assisted Intervention – MICCAI 2017. Cham: Springer; 2017. p. 408-16.
- [8]. Li X, Chen H, Qi X, Dou Q, Fu CW, Heng PA. H-DenseUNet: Hybrid Densely Connected UNet for Liver and Tumor Segmentation from CT Volumes. IEEE Transactions on Medical Imaging 2018;37(12):2663-74. doi: [10.1109/TMI.2018.2845918](https://doi.org/10.1109/TMI.2018.2845918)
- [9]. Zhou T, Ruan S, Canu S. A review: Deep learning for medical image segmentation using multi-modality fusion. Array 2019;3-4:100004. <https://doi.org/10.1016/j.array.2019.100004>
- [10]. Chen H, Qin Z, Ding Y, Tian L, Qin Z. Brain Tumor Segmentation with Deep Convolutional Symmetric Neural Network. Neurocomputing 2020;392:305-13. <https://doi.org/10.1016/j.neucom.2019.01.111>
- [11]. Tabassum M, Suman AA, Suero Molina E, Pan E, Di Ieva A, Liu S. Radiomics and machine learning in brain tumors and their habitat: a systematic review. Cancers 2023;15(15):3845. doi: [10.3390/cancers15153845](https://doi.org/10.3390/cancers15153845)
- [12]. Vaswani A, Shazeer N, Parmar N, Uszkoreit J, Jones L, Gomez AN, et al. NIPS'17: Proceedings of the 31st International Conference on Neural Information Processing Systems; 2017 Dec 4-6; Long Beach, CA, USA: Curran Associates Inc; 2017. p. 5998-6008.
- [13]. Sun J, Feng B, Xu W. Particle swarm optimization with particles having quantum behavior. Proceedings of the 2004 Congress on Evolutionary Computation IEEE Cat. No.04TH8753; 2004 Jun19-23; Portland, OR, USA: IEEE; 2004. p. 325-31. doi: [10.1109/CEC.2004.1330875](https://doi.org/10.1109/CEC.2004.1330875)
- [14]. Cheng J, Huang W, Cao S, Yang R, Yang W, Yun Z, et al. Enhanced Performance of Brain Tumor Classification via Tumor Region Augmentation and Partition. PLoS One 2015;10(10):e0140381. doi: [10.1371/journal.pone.0140381](https://doi.org/10.1371/journal.pone.0140381)
- [15]. Kumar A, Jha AK, Agarwal JP, Yadav M, Badhe S, Sahay A, et al. Machine-learning-based radiomics for classifying glioma grade from magnetic resonance images of the brain. J Pers Med 2023;13(6):920. doi: [10.3390/jpm13060920](https://doi.org/10.3390/jpm13060920)
- [16]. Litjens G, Kooi T, Bejnordi BE, Setio AA, Ciompi F, Ghafoorian M, et al. A survey on deep learning in medical image analysis. Med Image Anal 2017;42:60-88. doi: [10.1016/j.media.2017.07.005](https://doi.org/10.1016/j.media.2017.07.005)
- [17]. Goodfellow I, Bengio Y, Courville A. Deep Learning. Cambridge, MA: MIT Press; 2016.
- [18]. Kennedy J, Eberhart R. Particle Swarm Optimization. In: Proceedings of ICNN'95 - International Conference on Neural Networks; 1995 Nov -Dec 1-27; Perth, WA, Australia: IEEE; 1995. p. 1942-8. doi: [10.1109/ICNN.1995.488968](https://doi.org/10.1109/ICNN.1995.488968)
- [19]. Akkus Z, Galimzianova A, Hoogi A, Rubin DL, Erickson BJ. Deep Learning for Brain MRI Segmentation: State of the Art and Future Directions. J Digit Imaging 2017;30(4):449-59. doi: [10.1007/s10278-017-9983-4](https://doi.org/10.1007/s10278-017-9983-4)
- [20]. Pereira S, Pinto A, Alves V, Silva CA. Brain Tumor Segmentation using Convolutional Neural Networks in MRI Images. IEEE Transactions on Medical Imaging 2016;35(5):1240-51. doi: [10.1109/TMI.2016.2538465](https://doi.org/10.1109/TMI.2016.2538465)
- [21]. Wang S, Zhang Y, Dong Z, Du S, Ji G, Yan J, et al. Feed-forward neural network optimized by hybridization of PSO and ABC for abnormal brain detection. International Journal of Imaging Systems and Technology 2015;25(2):153-64. <https://doi.org/10.1002/ima.22132>
- [22]. Havaei M, Davy A, Warde-Farley D, Biard A, Courville A, Bengio Y, et al. Brain tumor segmentation with Deep Neural Networks. Med Image Anal 2017;35:18-31. doi: [10.1016/j.media.2016.05.004](https://doi.org/10.1016/j.media.2016.05.004)
- [23]. Amin J, Sharif M, Yasmin M, Fernandes SL. Big data analysis for brain tumor detection: Deep CNNs based approach. Future Generation Computer Systems 2018;70:581-93. doi: [10.1016/j.future.2018.04.065](https://doi.org/10.1016/j.future.2018.04.065)
- [24]. Ronneberger O, Fischer P, Brox T. U-Net: Convolutional Networks for Biomedical Image Segmentation. In: Navab N, Hornegger J, Wells WM, Frangi AF. Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015. Cham: Springer; 2015. p. 234-41. <https://doi.org/10.48550/arXiv.1505.04597>
- [25]. He K, Zhang X, Ren S, Sun J. Deep Residual Learning for Image Recognition. IEEE Conference on Computer Vision and Pattern Recognition (CVPR); 2016 Jun 27-30; Las Vegas, NV, USA: IEEE; 2016. p. 770-8. doi: [10.1109/CVPR.2016.90](https://doi.org/10.1109/CVPR.2016.90)
- [26]. Meißner AK, Gutsche R, Galldiks N, Kocher M, Jünger ST, Eich ML, et al. Radiomics for the noninvasive prediction of the BRAF mutation status in patients with melanoma brain metastases. Neuro-Oncology 2022;24(8):1331-40. <https://doi.org/10.1093/neuonc/noab294>
- [27]. Kaifi R. A Review of Recent Advances in Brain Tumor Diagnosis Based on AI-Based Classification. Diagnostics (Basel) 2023;13(18):3007. doi: [10.3390/diagnostics13183007](https://doi.org/10.3390/diagnostics13183007)
- [28]. Isensee F, Jaeger PF, Kohl SAA, Petersen J, Maier-Hein KH. nnU-Net: a self-configuring method for deep learning-based biomedical image segmentation. Nat Methods 2021;18(2):203-11. doi: [10.1038/s41592-020-01008-z](https://doi.org/10.1038/s41592-020-01008-z)
- [29]. Yang Y, Yan LF, Zhang X, Han Y, Nan HY, Hu YC, et al. Glioma Grading on Conventional MR Images: A Deep Learning Study with Transfer Learning. Front Neurosci 2018;12:804. doi: [10.3389/fnins.2018.00804](https://doi.org/10.3389/fnins.2018.00804)
- [30]. Kadhim YA, Guzel MS, Mishra A. A Novel Hybrid Machine Learning-Based System Using Deep Learning Techniques and Meta-Heuristic Algorithms for Various Medical Datatypes Classification. Diagnostics (Basel) 2024;14(14):1469. doi: [10.3390/diagnostics14141469](https://doi.org/10.3390/diagnostics14141469)
- [31]. Rastogi D, Johri P, Donelli M, Kadry S, Khan AA, Espa G, et al. Deep learning-integrated MRI brain tumor analysis: feature extraction, segmentation, and Survival Prediction using Replicator and volumetric networks. Sci Rep 2025;15(1):1437. doi: [10.1038/s41598-024-84386-0](https://doi.org/10.1038/s41598-024-84386-0)

- [32]. Dorfner FJ, Patel JB, Kalpathy-Cramer J, Gerstner ER, Bridge CP. A review of deep learning for brain tumor analysis in MRI. NPJ Precision Oncology 2025;9(1):2. doi:10.1038/s41698-024-00789-2.
- [33]. Fallahi S, Taghadosi M. Quantum-behaved particle swarm optimization based on solitons. Scientific Reports 2022;12:13977. doi:10.1038/s41598-022-18351-0.
- [34]. Isensee F, Jaeger PF, Kohl SAA, Petersen J, Maier-Hein KH. nnU-Net: a self-configuring method for deep learning-based biomedical image segmentation. Nat Methods 2021;18(2):203-11. doi: [10.1038/s41592-020-01008-z](https://doi.org/10.1038/s41592-020-01008-z)
- [35]. Shamshad F, Khan S, Zamir SW, Khan MH, Hayat M, Khan FS, Fu H. Transformers in medical imaging: A survey. Med Image Anal 2023;88:102802. doi: [10.1016/j.media.2023.102802](https://doi.org/10.1016/j.media.2023.102802)
- [36]. Chen H, Gomez C, Huang CM, Unberath M. Explainable medical imaging AI needs human-centered design. NPJ Digit Med 2022;5(1):156. doi: [10.1038/s41746-022-00699-2](https://doi.org/10.1038/s41746-022-00699-2)
- [37]. Qi X, Wu Z, Zou W, Ren M, Gao Y, Sun M, et al. Exploring generalizable distillation for efficient medical image segmentation. IEEE Journal of Biomedical and Health Informatics 2024;28(7):4170-83. doi: [10.1109/JBHI.2024.3385098](https://doi.org/10.1109/JBHI.2024.3385098)
- [38]. van der Velden BH, Kuijf HJ, Gilhuijs KG, Viergever MA. Explainable artificial intelligence (XAI) in deep learning-based medical image analysis. Med Image Anal 2022;79:102470. doi: [10.1016/j.media.2022.102470](https://doi.org/10.1016/j.media.2022.102470)
- [39]. Huang SC, Pareek A, Jensen M, Lungren MP, Yeung S, Chaudhari AS. Self-supervised learning for medical image classification: A systematic review. NPJ Digit Med 2023;6(1):74. doi: [10.1038/s41746-023-00811-0](https://doi.org/10.1038/s41746-023-00811-0)
- [40]. Tanno R, Barrett DG, Sellergren A, Ghaisas S, Dathathri S, See A, Welbl J, Lau C, Tu T, Azizi S, Singhal K. Collaboration between clinicians and vision-language models in radiology report generation. Nat Med 2025;31(2):599-608. doi: [10.1038/s41591-024-03302-1](https://doi.org/10.1038/s41591-024-03302-1)
- [41]. Jiang S, Bukhari SM, Krishnan A, Bera K, Sharma A, Caovan D, et al. Deployment of artificial intelligence in radiology: Strategies for success. AJR Am J Roentgenol 2025;224(2):e2431898. doi: [10.2214/AJR.24.31898](https://doi.org/10.2214/AJR.24.31898)