

Intelligent Brain Tumor Detection in Medical Images using Unsupervised Learning and Optimization Techniques

Mohammad Salemifar¹, M. R. Mohammadrezaei^{2*}

1. MSc, Department of Computer Engineering, bardsir Branch, Islamic Azad University, bardsir, Iran.
Sf.mohammad1986@gmail.com
2. Assistant Professor, Department of Computer Engineering, Ramhormoz Branch, Islamic Azad University,
Ramhormoz, Iran. * Corresponding Author, Mohammadrezaei.m.reza@gmail.com

Abstract

Introduction: Early and accurate diagnosis of brain tumors, including precise location and size determination on MRI scans, is crucial for successful treatment planning. However, manual tumor detection is time-consuming. Recent advancements in machine learning and optimization algorithms have opened doors for automated medical image analysis. Neural networks, particularly deep networks with a large number of input images, have achieved high accuracy in image processing tasks.

Methodology: This paper proposes a novel approach for brain tumor diagnosis using a Self-Organizing Map (SOM) neural network and the Walrus Optimizer (WO) algorithm. The proposed method consists of four key steps: (1) Preprocessing: Input MRI images undergo preprocessing to enhance their quality. (2) Segmentation: SOM performs image segmentation, dividing the image into distinct regions. (3) Feature Extraction: Features are extracted from the segmented brain tissue to differentiate between healthy and tumorous regions. These features are then used to create a feature vector. (4) Feature Selection: Due to the high computational cost of evaluating all possible feature combinations, the WO algorithm is employed to select an optimal subset of the most discriminative features extracted in the previous step (e.g., using convolutional layers, wavelet transforms, or Gabor filters).

Results: The proposed method is implemented and evaluated using MATLAB software. Performance is measured using standard metrics like precision, accuracy, recall, and F1-score. The proposed approach utilizing SOM and WO achieves an accuracy of 92%, demonstrating a significant improvement of 16% compared to the baseline method with 76% accuracy. Additionally, it surpasses the accuracy of a method employing the Reptile Search Algorithm by 10%.

Discussion: The superior accuracy of the proposed method can be attributed to the combined strengths of the SOM neural network's ability to learn complex relationships in the data and the WO algorithm's effectiveness in selecting the most informative features for brain tumor classification.

Keywords: brain tumor detection, feature selection, som neural network, walrus optimizer algorithm.

تشخیص هوشمند تومور مغزی در تصاویر پزشکی با استفاده از روش‌های بهینه‌سازی و یادگیری بدون نظارت

دوره پنجم، تابستان ۱۴۰۳
شماره دوم، صص: ۱۶۳-۱۷۶

تاریخ دریافت: ۱۴۰۳/۰۲/۱۱
تاریخ پذیرش: ۱۴۰۳/۰۳/۲۲

محمد سالمی فر^۱، محمدرضا محمدرضائی^{۲*}

۱. کارشناسی ارشد، گروه مهندسی کامپیوتر، واحد بردسیر، دانشگاه آزاد اسلامی، بردسیر، ایران.
۲. استادیار، گروه مهندسی کامپیوتر، واحد رامهرمز، دانشگاه آزاد اسلامی، رامهرمز، ایران. (نویسنده مسئول)
Mohammadrezaei.m.reza@gmail.com

چکیده: تشخیص زود هنگام و مشخص کردن محل دقیق تومور در MRI و اندازه آن برای گروه‌های پزشکی، بسیار مهم است. از طرف دیگر، تشخیص دستی بافت‌های مغز و تومور، زمان‌بر است. پیشرفت‌های اخیر در یادگیری ماشین و روش‌های فراابتکاری، باعث تشخیص و دسته‌بندی الگوهای تصویربرداری پزشکی شده‌اند. در پردازش تصویر، شبکه عصبی از موفق‌ترین روش‌هایی است که امروزه به کار می‌رود، چون اگر تعداد تصاویر ورودی زیاد باشد، دارای لایه‌های زیادی هستند و دقت تشخیص بالایی خواهند داشت. در این مقاله یک رویکرد جدید برای تشخیص تومور مغزی با استفاده از شبکه عصبی SOM و الگوریتم بهینه‌سازی فیل دریایی (WO) ارائه می‌شود. مرحله اول، پیش‌پردازش تصاویر ورودی را دربرمی‌گیرد. در مرحله دوم، قطعه‌بندی تصویر بر مبنای شبکه عصبی SOM صورت می‌گیرد. قطعه‌بندی تصویر به معنای تقسیم‌بندی تصویر به نواحی تشکیل‌دهنده آن، است. در مرحله سوم طرح پیشنهادی، استخراج ویژگی صورت می‌گیرد. در این مرحله، ویژگی‌ها به منظور قیاس نمونه‌های سالم از بیمار از بافت مغز استخراج می‌گردند و ویژگی‌های استخراج شده به منظور ایجاد یک نمونه به کار می‌روند. در مرحله چهارم، انتخاب ویژگی صورت می‌پذیرد. به منظور انتخاب زیرمجموعه بهینه‌ای از ویژگی‌های متمایزکننده بافت‌های مغزی، از میان تعداد بالای ویژگی‌های ایجاد شده در لایه کانولوشن، تبدیلات موجک و فیلتر گابور، با توجه به سربار محاسباتی بالا در تولید راه‌حل‌های متعدد، از الگوریتم بهینه‌سازی فیل دریایی استفاده می‌گردد. نرم‌افزار متلب جهت شبیه‌سازی به کار گرفته شده است. پارامترهای ارزیابی طرح حاوی دقت، صحت، فراخوانی و F-Measure می‌باشد. دقت روش پیشنهادی مبتنی بر شبکه عصبی SOM و الگوریتم بهینه‌سازی فیل دریایی که ۹۲ درصد بوده است نسبت به طرح پایه که دقت ۷۶ درصد بوده است، ۱۶ درصد بهبود داشته است. همچنین روش پیشنهادی نسبت به روش مبتنی بر الگوریتم جست‌وجوی خزنده معیار دقت را به میزان ۱۰ درصد بهبود داده است. علت بهبود معیار دقت در روش پیشنهادی، قدرت شبکه عصبی و ادغام آن با الگوریتم بهینه‌سازی فیل دریایی جهت انتخاب ویژگی می‌باشد.

واژه‌های کلیدی: تشخیص تومور مغزی، انتخاب ویژگی، شبکه عصبی SOM، الگوریتم بهینه‌سازی فیل دریایی.

۱. مقدمه.

از شبکه‌های عصبی می‌توان در حوزه‌های مختلف استفاده نمود [۱] [۲]. یکی از کاربردهای آن در تشخیص تومور مغزی است. مغز، واحد کنترل مرکزی بدن انسان به‌شمار می‌رود. تشخیص تومور در مراحل اولیه، امکان‌پذیر نیست و بر مغز تأثیرگذار است؛ یعنی به مرگ بیمار منجر می‌گردد [۳]. تومور مغزی با وجود سلول‌های غیرطبیعی در بافت‌های مغز تشريح می‌گردد. تومورهای مغزی، خوش‌خیم (غیرسرطانی) یا بدخیم (سرطانی) هستند. از سرطان‌های شایع و پیشرو در جهان می‌توان به تومور بدخیم مغزی اشاره کرد. دو نوع تومور نظیر تومورهای اولیه و تومورهای ثانویه وجود دارد، تومورهای اولیه که در مغز به وجود می‌آیند و تومورهای ثانویه که از ناحیه دیگری از بدن آغاز می‌شود و به مغز بسط پیدامی‌کنند. در تشخیص تومور مغزی، تشخیص دقیق اندازه و محل تومور مغزی حائز اهمیت می‌باشد و تشخیص آن با تصویربرداری پرتو مغناطیسی (MRI) امکان‌پذیر است [۴]. MRI، از راه‌های تصویربرداری ترجیحی جهت تشخیص تومور مغزی و دریافت اطلاعات دقیق در خصوص اندازه، مکان، نوع و تشخیص تومور می‌باشد [۵]. به‌کارگیری اطلاعات چندوجهی، نقش کلیدی در تقسیم‌بندی تومور مغز دارند. با این وجود، بیشتر روش‌هایی که وجود دارند بر استخراج و انتخاب ویژگی‌های معنایی عمیق متمرکز هستند، در صورتی که بعضی دیگر ممکن است ویژگی‌های با معنا و اهمیت خاص برای مسئله تقسیم‌بندی را نادیده بگیرند [۶]. می‌توان بیان نمود که تشخیص تومور مغزی از اهمیت به‌سزایی برخوردار است و یک کار بسیار چالش‌برانگیز می‌باشد [۷]. تشخیص زودهنگام و درمان تومور مغزی، ضروری است و شایع‌ترین نوع سرطانی می‌باشد که در کودکان و بزرگسالان بروز می‌یابد. پیدا کردن نوع مناسب تومور در مراحل اولیه، بخش اساسی جهت ایجاد یک درمان خاص و تشخیص پاسخ بیمار بر مبنای درمان است [۸]. تشخیص زودهنگام و مشخص کردن محل دقیق تومور در MRI و اندازه آن برای گروه‌های پزشکی، بسیار مهم است. تقسیم‌بندی تصویر، یک مرحله مقدماتی در آنالیز تصویر پزشکی است [۹]. از طرف دیگر، تشخیص دستی تومور مغزی، یک فرآیند تهاجمی محسوب می‌شود و بدین جهت، خطرناک می‌باشد [۱۰]. از سوی دیگر، تشخیص دستی بافت‌های مغز و تومور، زمان‌بر است و به خاطر پیچیدگی زیاد بافت‌های مغز وابسته به وضعیت اپراتور است. کارشناسان نیز باید تصاویر را مطالعه کنند تا این مسائل را تشخیص دهند و رویکردهای سنتی و قدیمی را در غیاب آن‌ها، بی‌اثر نمایند. در نتیجه، به‌منظور معاینه دقیق تومور، به‌کارگیری روش‌های خودکار، مفید است [۱۱]. برای این منظور می‌توان از الگوریتم‌های فراابتکاری استفاده نمود. الگوریتم‌های فراابتکاری معمولاً برای حل مسائل بهینه‌سازی پیچیده مانند مسائل زمان‌بندی و برنامه‌ریزی مسیر یا حتی مسائل بهینه‌سازی چندهدفه استفاده می‌شوند. الگوریتم‌های فراابتکاری مجموعه‌ای از استراتژی‌ها و روش‌های ابتکاری هوشمند را برای بهبود کارایی از طریق حل مسائل پیچیده و کاهش هزینه‌های محاسباتی معرفی می‌کنند.

الگوریتم‌های فراابتکاری جدید از ترکیبی از جستجوی محلی و جهانی استفاده می‌کنند که تعادل بین همگرایی سریع و اجتناب از قرار گرفتن در راه‌حل‌های بهینه محلی را متعادل می‌کند. از طرف دیگر، با ظهور عصر داده‌های بزرگ، بسیاری از مسائل مستلزم پرداختن به مجموعه داده‌های مقیاس بزرگ است. برای تسريع در تجزیه و تحلیل و پردازش این داده‌ها می‌توان از الگوریتم‌های فراابتکاری استفاده کرد. می‌تواند به تصمیم‌گیرندگان کمک کند تا اطلاعات مفید را سریع‌تر دریافت کنند و امکان‌سنجی حل مسئله را بهبود بخشد [۱۲]. در این مقاله یک رویکرد جدید برای تشخیص تومور مغزی با استفاده از شبکه عصبی SOM و الگوریتم بهینه‌ساز فیل دریایی (WO)^۱ ارائه می‌شود. دلیل انتخاب الگوریتم بهینه‌ساز فیل دریایی از بین الگوریتم‌های فراابتکاری دیگر این است که با ساختار ساده، ویژگی‌های پایداری خاص و عملکرد بسیار رقابتی برای تحقق بخشیدن به راه‌حل‌های مسائل محدود و غیرمحدود به‌طور مؤثرتر پیشنهاد شده است. نوآوری این است که "رهبران"^۲ در گله فیل دریایی عامل تعیین‌کننده‌ای هستند که جهت گله را تحت تأثیر قرار می‌دهند. گله فیل دریایی می‌تواند از دستگیری یا مرگ توسط شکارچیان جلوگیری کند (افتادن در بهینه محلی) و به رشد جمعیت (جستجو برای بهینه جهانی) در یک محیط منظم دست یابد.

در ادامه ساختار مقاله به این شرح است که در بخش دوم، روش‌های پیشین در زمینه تشخیص و دسته‌بندی تومورهای مغزی مرور می‌شوند. در بخش سوم، روش پیشنهادی بیان می‌شود. در بخش چهارم، نتایج شبیه‌سازی روش پیشنهادی با استفاده از نرم‌افزار متلب تحلیل و مقایسه می‌شوند. در بخش پنجم، نتیجه‌گیری و پیشنهادها بیان می‌شوند.

۲. پیشینه تحقیق

در [۱۳]، یک رویکرد گویا برای دسته‌بندی تومورهای مغزی، با استفاده از یادگیری انتقالی و شبکه‌های عصبی کانولوشن ارائه کرده‌اند. چندین معماری CNN از جمله MobileNet-V2، ResNet و Xception را بررسی نموده‌اند. قابل ذکر است، MobileNet-V2 به‌عنوان مؤثرترین مدل ظاهر شد و به امتیاز FI چشمگیر ۹۸.۴۵٪ رسید.

در [۱۴]، ارزیابی عملکرد یک مدل چندوجهی برای دسته‌بندی اسکن‌های MRI پردازش شده به‌عنوان تصاویر خاکستری انجام شده است. نتایج امیدوارکننده هستند و مطابق با کارهای مشابه هستند، زیرا دقت مدل به حدود ۹۸٪ می‌رسد. همچنین بر نیاز به توضیح و شفافیت برای تضمین کنترل و ایمنی انسانی تأکید کرده‌اند.

در [۱۵]، یک روش یادگیری ماشین جدید را پیشنهاد کرده‌اند که مزایای شبکه‌های GRU^۳ و الگوریتم بهینه‌سازی EHDMO^۴ را برای تشخیص تومور مغزی ترکیب می‌کند. شبکه‌های GRU نوعی شبکه عصبی بازگشتی (RNN)^۵ هستند که می‌توانند داده‌های متوالی مانند زبان طبیعی یا سری‌های زمانی را پردازش کنند. نتایج نشان می‌دهد که روش پیشنهادی می‌تواند به‌طور دقیق و قوی تومورهای مغزی را از تصاویر MRI تشخیص دهد.

در [۱۶]، الگوریتم fCm^۲ را برای تصاویر MRI پیشنهاد کرده‌اند. برای کاهش پیچیدگی، مرتبط‌ترین شکل، بافت و ویژگی‌های رنگ انتخاب شده‌اند. دسته‌بندی پیشنهادی به‌طور مداوم دقت بالاتری را در تمام کلاس‌های تومور در مقایسه با مدل‌های موجود نشان می‌دهد. این افزایش مداوم در دقت بر عملکرد قوی دسته‌بندی پیشنهادی تأکید می‌کند و پتانسیل آن را برای دسته‌بندی دقیق‌تر و قابل‌اعتمادتر تومور مغزی نشان می‌دهد. داده‌های Kaggle استفاده شده‌است.

در [۱۷]، به چالش حیاتی دسته‌بندی دقیق تومورهای مغزی با استفاده از هوش مصنوعی پرداخته‌اند. یک رویکرد بهینه‌سازی جدید به نام PSCS همراه با یادگیری عمیق برای دسته‌بندی تومور مغزی پیشنهاد نموده‌اند. PSCS فرآیند دسته‌بندی را با بهبود بهره‌برداری از بهینه‌سازی ازدحام ذرات با استفاده از الگوریتم جستجوی فاخته بهینه می‌کند. سپس، داده‌های تومور مغزی را با استفاده از یادگیری عمیق برای شناسایی گروه‌ها یا کلاس‌های مختلف مرتبط با یک تومور خاص همراه با روش بهینه‌سازی PSCS دسته‌بندی کرده‌اند.

در [۱۸]، یک مدل مبتنی بر یادگیری عمیق بهبود یافته را برای تشخیص کارآمد تومورهای مغزی پیشنهاد کرده‌اند. پیش‌پردازش، تقسیم‌بندی، استخراج ویژگی، انتخاب ویژگی و دسته‌بندی برخی از فرآیندهایی هستند که مدل پیشنهادی را تشکیل می‌دهند. برای بهبود کیفیت تصاویر مغز، مراحل پیش‌پردازش با استفاده از فیلتر ترکیبی ساخته شده از فیلترهای گاوسی، میانگین و میانه استفاده می‌شود. علاوه بر این، تقسیم‌بندی مورفولوژیکی و مبتنی بر آستانه برای جداسازی تومور از بافت سالم مغز استفاده می‌شود. از روش مبتنی بر GLCM^۳ برای استخراج الگوهای بافت و شدت برای شناسایی مناطق تومور استفاده می‌شود. انتخاب ویژگی بهینه با استفاده از فراابتکاری WSSOA^۴ انجام می‌شود. در نهایت، شبکه عصبی عمیق DCNN^۵ برای تشخیص دقیق تومورها استفاده می‌شود.

در [۱۹]، بهینه‌سازی AMRFO^۱ را برای انجام یک انتخاب ویژگی مؤثر برای جلوگیری از مسئله بیش از حد برازش در حین انجام دسته‌بندی پیشنهاد کرده‌اند. استراتژی پارامتر کنترل تطبیقی در AMRFO برای بهبود فرآیند جستجو در حین انتخاب زیرمجموعه ویژگی گنجانده شده‌است. الگوریتم fCm یعنی LRIFCM^{۱۱} برای انجام تقسیم‌بندی نواحی تومور استفاده شده‌است. روش ALSTM^{۱۲} برای دسته‌بندی انواع تومور مغزی با توجه به ویژگی‌های انتخاب شده توسط AMRFO استفاده شده‌است. مجموعه داده‌های مورد استفاده در این مطالعه تحقیقاتی برای ارزیابی روش AMRFO-ALSTM عبارت‌اند از BRATS 2017، BRATS 2018 و مجموعه داده‌های مغز Figshare. اندازه‌گیری شاخص دقت برای روش پیشنهادی با پژوهش‌های پیشین مقایسه شده‌است.

در [۲۰]، تشخیص زود هنگام سرطان مغز حسگر زیست پزشکی با تلفات کم و حساسیت بالا در رژیم ترانز بر مبنای فناوری فیبر کریستال فوتونی را بررسی کرده‌اند. سلول‌های مغزی غیرعادی حاوی تومورها،

صدمات و سلول‌های بدخیم می‌باشند. حسگر ارائه شده قادر به شناسایی این انواع متفاوت با حساسیت نسبی بالا و تلفات ناچیز در قیاس با دیگر حسگرهای زیست پزشکی مبتنی بر فیبر کریستال فوتونی است. به علاوه، یک قیاس دقیق میان حسگر ارائه شده و ادبیات فیبر بلور فوتونی مرتبط جهت تأیید صحت اثربخشی و ساختار ارائه شده صورت گرفته‌است.

در [۲۱]، تشخیص و دسته‌بندی تومور مغزی چندوجهی با به کارگیری یادگیری عمیق و الگوریتم بهبود یافته بهینه‌سازی سنجاقک را بررسی کرده‌اند. چارچوب ارائه شده در ۵ مرحله اجرا شده‌است. در مرحله اولیه چارچوب ارائه شده، یک روش تقویت کنتراست مبتنی بر فیوژن پیشنهاد شده‌است. در مرحله بعد، یک روش تقسیم‌بندی تومور بر مبنای یادگیری عمیق پیشنهاد کرده‌اند و سپس روی تصاویر اصلی بر مبنای کانتور فعال نگاشت شده‌است. به دنبال آن، یک مدل CNN از قبل آموزش دیده شده به نام EfficientNetB0 به دو روش روی تصاویر بهبود یافته و تصاویر محلی سازی تومور به خوبی تنظیم و آموزش داده شد. بهترین ویژگی‌ها در مرحله نهایی با به کارگیری یک الگوریتم بهبود یافته بهینه‌سازی سنجاقک انتخاب شده‌اند.

در [۲۲]، یک رویکرد جدید جهت تشخیص تومور مغزی با به کارگیری روش یادگیری عمیق پیشنهاد نموده‌اند. در این تحقیق، یک ساختار U-Net اصلاح شده مبتنی بر شبکه‌های باقی‌مانده پیشنهاد کرده‌اند که به صورت دوره‌ای در بخش رمزگذار U-Net اصلی و پیچیدگی زیر پیکسل در بخش رمزگشا استفاده می‌شود. مدل U-Net ارائه شده روی دو مجموعه داده معیار نظیر چالش تقسیم‌بندی تومور مغزی با دقت تقسیم‌بندی به ترتیب ۹۳٫۴۰٪ و ۹۲٫۲۰٪ مورد ارزیابی قرار گرفته‌است. به علاوه، زیر نواحی تومور به سه دسته هسته تومور (TC^{۱۳})، تومور کامل (WT^{۱۴}) و هسته تقویت کننده (EC^{۱۵}) دسته‌بندی شده‌اند.

در [۲۳]، تشخیص نوآورانه تومور مغز را با به کارگیری روش‌های یادگیری عمیق پیشنهاد نموده‌اند. روش شبکه عصبی به کار گرفته شده است که از بهینه‌سازی کلونی زنبور عسل، بهینه‌سازی کلونی مورچگان و بهینه‌سازی ازدحام ذرات، بهینه‌سازی گرگ خاکستری، الگوریتم بهینه‌سازی نهنگ و الگوریتم ژنتیک برای انتخاب بهترین ویژگی استفاده کرده‌اند. شناسایی تومورهای مغزی توسط دسته‌بند CNN حاصل شده‌است. این سیستم با به کارگیری پارامترهای دقت، صحت و فراخوانی، عملکرد خود را با یکی دیگر از روش‌های مدرن بهینه‌سازی مقایسه نموده‌است. پیاده‌سازی این سیستم در زبان برنامه‌نویسی پایتون انجام شد.

در [۲۴]، تحلیل رویکردهای یادگیری عمیق را جهت تشخیص و تقسیم‌بندی تومور مغزی انجام داده‌اند. الگوریتم شبکه عصبی و پنج مدل یادگیری عمیق را به منظور به کارگیری آموزش انتقال (TL^{۱۶}) جهت دسته‌بندی تومورهای مغزی مورد استفاده قرار داده‌اند. دقت مدل، ResNet50 و DenseNet121 93.23 درصد بوده‌است.

در [۲۵]، تشخیص تومور مغزی با به کارگیری یادگیری عمیق هوشمند را پیشنهاد نموده‌اند. این پژوهش درباره شبکه‌های عصبی بوده- است؛ به علاوه نحوه تشخیص تومورهای مغزی با به کارگیری اشعه ایکس و MRI را تشریح کرده‌است که به تسریع و افزایش یکنواختی درمان منجر شده‌است. این پژوهش با کمک پایتون و نوت بوک Jupyter صورت- گرفته‌است. در اینجا، استخراج ویژگی‌های عمیق با به کارگیری مدل‌های عمیق CNN که از قبل آموزش داده شده‌بودند، حاصل شد.

در [۲۶]، شبکه عصبی عمیق را جهت شناسایی خودکار تومور مغز از MRI پیشنهاد نموده‌اند. هدف، بررسی قابلیت مدل‌های متعدد DCNN از قبل آموزش دیده با به کارگیری یادگیری انتقال جهت تشخیص و شناسایی تصاویر مغز بیمار بوده‌است. از مدل مفهومی با آموزش انتقال (TL) جهت تأیید آن استفاده نموده‌اند و به دقت ۹۸٫۲۸٪، بازخوانی ۹۷٫۵۱٪ و صحت ۹۷٫۴۳٪ رسیده‌اند. الگوریتم تشخیص تومور مغزی مبتنی بر TL از مدل‌های موجود، عملکرد بهتری داشته‌است.

در [۲۷]، به تشخیص و دسته‌بندی تومور مغزی با به کارگیری یادگیری عمیق بر مبنای روش CNN-LSTM پرداخته‌اند. این تحقیق پیشنهاد نموده‌است که با یک LSTM ترکیب گردد، LSTM ها قادرند قابلیت شبکه عصبی جهت استخراج ویژگی‌ها را تکمیل نمایند. مجموعه داده به دو بخش، ۲۸۷۰ عکس از مجموعه‌های آموزشی و ۳۹۴ تصویر از مجموعه‌های آزمون تقسیم‌بندی شد.

در [۲۸]، تشخیص تومور مغزی MRI را با استفاده از مدل یادگیری ماشین مبتنی بر رگرسیون لجستیک انجام داده‌اند. مجموعه داده‌های ADNI-1 و ADNI-2 برای آموزش مدل TSLR استفاده می‌شوند و همچنین نمونه‌های مغز MRI بلادرنک برای آزمایش انتخاب می‌شوند. در نهایت، معیارهای عملکردی مانند دقت ۹۷ درصد، صحت ۹۷٫۹ درصد و فراخوانی ۹۷ درصد به دست آمد که با مدل‌های موجود مقایسه شده و متوجه عملکرد بهتر روش‌شناسی شده‌اند.

در [۲۹]، سیستم مبتنی بر منطق فازی را برای تشخیص و دسته‌بندی تومور مغزی ارائه کرده‌اند. این مطالعه از مجموعه داده‌ای از ۲۵۳ تصویر مغزی MRI استفاده کرد که شامل تصاویر تومور و سالم بود. سیستم فازی دو ویژگی را به عنوان ورودی دریافت کرده‌است. دقت، امتیاز F1، صحت و فراخوانی برای ارزیابی نتایج فازی استفاده می‌شود. با کاهش مداخلات انسانی و ارائه نتایج قابل اعتماد، این رویکرد می‌تواند به متخصصان پزشکی در تصمیم‌گیری به موقع و دقیق کمک کند که منجر به بهبود نتایج بیمار و بالقوه نجات جان افراد شود.

در [۳۰]، تشخیص تومور مغزی در تصاویر چندوجهی را با استفاده از ویژگی‌های ترکیبی انجام داده‌اند. روش CGBF برای از بین بردن نویزها در تصاویر چندوجهی معرفی شده است. تبدیل موجک پیچیده با تبدیل Hybrid DTCWT-WHT و فیلتر گابور به منظور استخراج مجموعه ترکیبی ضروری از ویژگی‌ها از تبدیل موجک مربوطه پیشنهاد شده‌است. رویکرد ترکیبی DTCWT-WHT برای شناسایی دقیق تومور مغزی در تصاویر مغزی Multi-Modality استفاده می‌شود. در این چارچوب، AMO

برای انتخاب ویژگی‌های حیاتی از بردارهای ویژگی پیشنهاد شده‌است و ویژگی‌های غیرضروری را از بین می‌برد.

در [۳۱]، تشخیص تومور مغزی MRI را با استفاده از رویکردهای یادگیری عمیق و یادگیری ماشین انجام داده‌اند. ویژگی‌هایی مانند انرژی، میانگین، آنتروپی و کنتراست با استفاده از ماتریس GLCM استخراج- می‌شوند. میزان دقت (۹۷٫۹۳٪)، حساسیت (۹۲٪) و ویژگی (۹۸٪) در تشخیص بافت ناهنجار و نرمال از تصاویر MRI مغز به دست آمده‌است.

در [۳۲]، بخش‌بندی تصاویر MRI برای تشخیص تومور مغز را با UNet مبتنی بر ShuffleNet انجام داده‌اند. از یک تابع تلفات ترکیبی برای تعادل بهتر بین اکتشاف و بهره‌برداری استفاده کرده‌اند. شبکه پیشنهادی در BraTS 2017 و ۲۰۱۸ آزمایش شد. نتایج آزمایش نشان داد که Shuffle-UNet از روش‌های موجود بهتر عمل می‌کند.

در [۳۳]، یک رویکرد مبتنی بر تک مدل منحصربه‌فرد برای دسته‌بندی تومورهای مغزی بر روی مجموعه داده‌های کوچک ارائه شده- است. یک DCNN اصلاح شده به نام RegNetY-3.2G استفاده می‌شود که با تنظیم DropOut و DropBlock یکپارچه شده‌است. روش RandAugment برای کاهش مشکل مجموعه داده‌های کوچک استفاده- می‌شود.

در [۳۴]، عملکردهای مختلف و روش‌های بهینه‌سازی برای تشخیص تومور مغزی MRI ارزیابی شده‌اند. هنگام آموزش مدل‌های یادگیری عمیق، از توابع مختلف زیان برای اندازه‌گیری عملکرد آن‌ها استفاده شد. بهینه‌ساز ADAM نسبت به بهینه‌ساز BINARY CROSSENTROPY دقیق‌تر و تلفات کمتری داشت. روش پیشنهادی سرطان مغز را در ۹۷ درصد اسکن‌های MRI نشان داد، بنابراین می‌توان از آن برای تشخیص اولیه استفاده کرد.

جدول (۱): مرور روش‌های پیشین

مرجع	نویسنده	سال	الگوریتم
[۱۳]	ارائه یک رویکرد گویا برای دسته‌بندی تومورهای مغزی، با استفاده از یادگیری انتقالی و شبکه‌های عصبی کانولوشن	۲۰۲۴	معماری شبکه‌های عصبی کانولوشن از جمله MobileNet-V2، ResNet و Xception
[۱۴]	انجام ارزیابی عملکرد یک مدل چندوجهی برای دسته‌بندی اسکن‌های MRI پردازش شده به عنوان تصاویر خاکستری	۲۰۲۴	یک مدل چندوجهی
[۱۵]	ترکیب مزایای شبکه‌های GRU و الگوریتم بهینه‌سازی EHDMO برای تشخیص تومور مغزی	۲۰۲۴	شبکه‌های GRU (شبکه عصبی بازگشتی) و الگوریتم بهینه‌سازی EHDMO
[۱۶]	پیشنهاد الگوریتم fCm برای تصاویر MRI	۲۰۲۴	fCm

[۲۶]	پیشنهاد شبکه عصبی عمیق جهت شناسایی خودکار تومور مغز از MRI	۲۰۲۲	شبکه عصبی عمیق
[۲۷]	تشخیص و دسته بندی تومور مغزی با به کارگیری یادگیری عمیق بر مبنای روش CNN-LSTM	۲۰۲۲	روش CNN-LSTM
مرجع	نویسنده	سال	الگوریتم
[۲۸]	انجام تشخیص تومور مغزی MRI با استفاده از مدل یادگیری ماشین مبتنی بر رگرسیون لجستیک	۲۰۲۴	یادگیری ماشین مبتنی بر رگرسیون لجستیک
[۲۹]	ارائه سیستم مبتنی بر منطق فازی برای تشخیص و دسته بندی تومور مغزی	۲۰۲۴	منطق فازی
[۳۰]	انجام تشخیص تومور مغزی در تصاویر چندوجهی با استفاده از ویژگی های ترکیبی	۲۰۲۴	روش CGBF، تبدیل موجک پیچیده با تبدیل Hybrid DTCWT-WHT و فیلتر گابور
[۳۱]	انجام تشخیص تومور مغزی MRI با استفاده از رویکردهای یادگیری عمیق و یادگیری ماشین	۲۰۲۴	یادگیری عمیق و یادگیری ماشین
[۳۲]	انجام بخش بندی تصاویر MRI برای تشخیص تومور مغز با UNet مبتنی بر ShuffleNet	۲۰۲۳	UNet مبتنی بر ShuffleNet
[۳۳]	ارائه یک رویکرد مبتنی بر تک مدل منحصربه فرد برای دسته بندی تومورهای مغزی بر روی مجموعه داده های کوچک	۲۰۲۳	DCNN
[۳۴]	ارزیابی عملکردهای مختلف و روش های بهینه سازی برای تشخیص تومور مغزی MRI	۲۰۲۳	یادگیری عمیق

۳. روش پیشنهادی

هدف طرح پیشنهادی این است تا یک سیستم تشخیص عارضه های مغزی بر مبنای تصاویر MRI حاوی پنج مرحله ارائه گردد که ترکیبی از دو روش نظارت شده (مبتنی بر الگو) و فاقد نظارت است. با بهره گیری از مزیت های هر دو گروه روش های یادگیری ماشین، معایب آن ها پوشش داده می شود. نوآوری اصلی روش پیشنهادی استفاده از الگوریتم بهینه ساز فیل دریایی برای مرحله انتخاب ویژگی است.

[۱۷]	چالش حیاتی دسته بندی دقیق تومورهای مغزی با استفاده از هوش مصنوعی	۲۰۲۴	PSCS، یادگیری عمیق، بهینه سازی ازدحام ذرات، جستجوی فاخته
مرجع	نویسنده	سال	الگوریتم
[۱۸]	پیشنهاد یک مدل مبتنی بر یادگیری عمیق بهبود یافته برای تشخیص کارآمد تومورهای مغزی	۲۰۲۴	یادگیری عمیق بهبود یافته، روش مبتنی بر GLCM، فراابتکاری WSSOA، شبکه عصبی عمیق
[۱۹]	پیشنهاد بهینه سازی AMRFO برای انجام یک انتخاب ویژگی مؤثر برای جلوگیری از مسئله بیش از حد برازش در حین انجام دسته بندی	۲۰۲۴	بهینه سازی AMRFO، الگوریتم fCm یعنی LRFICM، روش ALSTM
[۲۰]	بررسی تشخیص زودهنگام سرطان مغز حسگر زیست پزشکی با تلفات کم و حساسیت بالا در رژیم ترانزیت بر مبنای فناوری فیبر کریستال فوتونی	۲۰۲۳	فناوری فیبر کریستال فوتونی
[۲۱]	بررسی تشخیص و دسته بندی تومور مغزی چندوجهی با به کارگیری یادگیری عمیق و الگوریتم بهبود یافته بهینه سازی سنجاقک	۲۰۲۳	یادگیری عمیق، الگوریتم بهبود یافته بهینه سازی سنجاقک
[۲۲]	پیشنهاد یک رویکرد جدید جهت تشخیص تومور مغزی با به کارگیری روش یادگیری عمیق	۲۰۲۳	ساختار U-Net، یادگیری عمیق
[۲۳]	پیشنهاد تشخیص نوآورانه تومور مغز با به کارگیری روش های یادگیری عمیق	۲۰۲۳	یادگیری عمیق، کلونی زنبور عسل، کلونی مورچگان و ازدحام ذرات، گرگ خاکستری، نهنگ و ژنتیک
[۲۴]	انجام تحلیل رویکردهای یادگیری عمیق جهت تشخیص و تقسیم بندی تومور مغزی	۲۰۲۲	الگوریتم شبکه عصبی و پنج مدل یادگیری عمیق
[۲۵]	پیشنهاد تشخیص تومور مغزی با به کارگیری یادگیری عمیق هوشمند	۲۰۲۲	مدل های عمیق CNN

۱-۳. مرحله اول: پیش پردازش تصاویر ورودی

فاز اول، پیش پردازش تصاویر ورودی را در برمی گیرد. عملیات پیش پردازش در جهت بهبود استخراج اطلاعات و یکنواختی میزان داده ها طی مراحل مختلف انجام می شود. عملیات پیش پردازش در تصاویر دربرگیرنده کاهش نویز تصویر، نرمال سازی اندازه با مدنظر قراردادن حداقل و حداکثر طول و عرض تصاویر، اتصال پیوندهای ضعیف و نازک-سازی تصاویر با ضخامت یکسان (تک پیکسلی) است. از آنجاکه اندازه تصویر اخذ شده متناسب با فاصله تغییر می یابد، برای سهولت در محاسبات و استقلال از این تغییر اندازه، تصویر بافت مغز، نرمال سازی می گردد.

۲-۳. مرحله دوم روش پیشنهادی: قطعه بندی تصویر

در مرحله دوم، قطعه بندی تصویر بر مبنای شبکه عصبی SOM صورت می گیرد. قطعه بندی تصویر به معنای تقسیم بندی تصویر به نواحی تشکیل دهنده آن، است. قطعات تصویر، عناصر مختلف موجود در تصویر می باشند که از لحاظ بافت، شدت نور یا رنگ یکنواخت هستند. نواحی پیرامون یک قطعه بایستی دارای تفاوت قابل توجهی با آن قطعه باشند. در تصویربرداری پزشکی که خروجی آن برای مغز تحت عنوان MRI شناخته شده است، به منظور تشخیص و شناسایی بیماری ها و بررسی نحوه رشد تومورها بایستی تصویر، قطعه بندی شود. خوشه بندی، یک روش قطعه بندی محسوب می شود که یک تصویر را با ناحیه بندی آن به گروه های متعدد، تحلیل می نماید. شبکه عصبی SOM عمل خوشه بندی را بر روی داده ها انجام می دهد و با کمی تغییرات در شبکه از آن جهت خوشه بندی پیکسل های تصویر استفاده می گردد. این کار می تواند هم روی تصاویر رنگی و هم روی تصاویر سیاه و سفید صورت پذیرد. از آنجاکه تصاویر رنگی با یک بردار سه مؤلفه ای مشخص می گردند که هر یک از مؤلفه ها نشان دهنده یکی از رنگ های قرمز، سبز و آبی است در خوشه بندی بایستی هر سه مؤلفه را جهت بررسی معیار نزدیکی پیکسل ها مورد بررسی قرار داد؛ اما در تصاویر سیاه و سفید از آنجاکه تصویر تنها با یک ویژگی شدت رنگ نشان داده می شود، در محاسبات تنها همان یک مؤلفه مورد استفاده قرار می گیرد.


۳-۳. مرحله سوم روش پیشنهادی: استخراج ویژگی

در مرحله سوم، استخراج ویژگی صورت می گیرد. در این مرحله، ویژگی ها به منظور قیاس نمونه های سالم از بیمار از بافت مغز استخراج می گردند و ویژگی های استخراج شده به منظور ایجاد یک نمونه به کار می روند. چندین روش متداول برای استخراج ویژگی از تصویر نرمال شده موجود است. به منظور بهره گیری از ویژگی های تصویر در حوزه فرکانس، تبدیل موجک روی تصویر و فیلتر گابور به کار می رود. در بینایی کامپیوتری، روش تبدیل یک تصویر به طوری که بتوان خصیصه های اصلی و مدنظر آن همانند مرز پیرامون را استخراج نمود، بسیار مهم است. تبدیل گسسته موجک جهت استخراج مؤلفه های تصاویر مربوطه از سه فیلتر عمودی، افقی و قطری استفاده می نمایند، روش پیشنهادی، تبدیل موجک را جهت استخراج

ویژگی های حوزه فرکانس به کار می برد، چون این تبدیل، لبه های جهت دار را به خوبی می یابد. مجموعه ضرایب تبدیل موجک از تصویر اولیه به عنوان ورودی به دسته بند داده می شود.

۴-۳. مرحله چهارم روش پیشنهادی: انتخاب ویژگی

در مرحله چهارم، انتخاب ویژگی صورت می پذیرد. به منظور انتخاب زیرمجموعه بهینه ای از ویژگی های متمایز کننده بافت های مغزی، از میان تعداد بالای ویژگی های ایجاد شده در لایه کانولوشن، تبدیلات موجک و فیلتر گابور، با توجه به سر بار محاسباتی بالا در تولید راه حل های متعدد، از الگوریتم بهینه ساز فیل دریایی [۱۲] استفاده می گردد.



گام دوم: علائم خطر و علائم ایمنی

فیل های دریایی هم در جستجوی غذا و هم در تولیدمثل، بسیار هوشیار هستند. یک تا دو فیل دریایی به عنوان نگهبان در اطراف سیر می کنند و به محض یافتن موقعیت های غیرمنتظره، بلافاصله سیگنال های خطر ارسال می شود. سیگنال خطر و سیگنال ایمنی در الگوریتم بهینه سازی فیل دریایی به صورت رابطه (۴) تا رابطه (۷) تعریف می شود:

$$Danger_signal = A * R \quad (4)$$

$$\alpha = 1 - t/T \quad (5)$$

$$A = 2 * \alpha \quad (6)$$

$$R = 2 * r_1 - 1 \quad (7)$$

A و R عوامل خطر هستند، α از ۱ ابتدا به ۰ با تعداد تکرار t کاهش می یابد و T حداکثر تکرار است. سیگنال ایمنی مربوط به سیگنال خطر در الگوریتم بهینه سازی فیل دریایی به صورت رابطه (۸) تعریف می شود. جایی که، r_1 و r_2 اعداد تصادفی در محدوده (۰، ۱) قرار دارند.

$$Safety_signal = r_2 \quad (8)$$

گام سوم: مهاجرت (اکتشاف)

وقتی عامل خطر خیلی زیاد باشد، گله های فیل دریایی به مناطق مناسب تر برای بقای جمعیت مهاجرت می کنند. در این مرحله موقعیت فیل دریایی به صورت رابطه (۹) تا رابطه (۱۱) به روز می شود:

$$X_{i,j}^{t+1} = X_{i,j}^t + Migration_step \quad (9)$$

$$Migration_step = (X_m^t - X_n^t) * \beta * r_3^2 \quad (10)$$

$$\beta = 1 - \frac{1}{1 + \exp\left(-\frac{t - \frac{T}{2}}{T} \times 10\right)} \quad (11)$$

که در آن، $X_{i,j}^{t+1}$ موقعیت جدید برای i امین فیل دریایی در بعد j ام است، $X_{i,j}^t$ موقعیت فعلی i امین فیل دریایی در بعد j ام است، $Migration_step$ اندازه گام حرکت فیل دریایی است. دو نگهبان به طور تصادفی از جمعیت انتخاب می شوند، موقعیت های نگهبان ها مطابق با X_m^t و X_n^t است، β عامل کنترل $Migration_step$ است که با تکرار به عنوان یک منحنی ساده تغییر می کند و r_3 یک عدد تصادفی است که در محدوده (۰، ۱) قرار دارد.

گام چهارم: تولیدمثل (بهره برداری)

برخلاف مهاجرت، گله های فیل های دریایی تمایل دارند در جریان هایی که عوامل خطر کم هستند، تولیدمثل کنند. در طول تولیدمثل، عمدتاً دو رفتار وجود دارد، تولیدمثل در خشکی و جستجوی غذا. مدل ریاضی به شرح زیر است.

فاز ۱: رفتار گروه (گله)

فیل های دریایی نر، ماده و نوجوان دسته بندی این تحقیق از اعضای جمعیت هستند. آن ها راه های مختلفی برای تجدید موقعیت خود دارند.

مرحله ۱: توزیع مجدد فیل های دریایی نر

تنوع جمعیت به منظور جستجوی تکرار بعدی برای برتری بسیار مهم است. در روش شبیه سازی مونت کارلو^{۱۷}، دنباله هالتون^{۱۸} به طور

در الگوریتم بهینه سازی فیل دریایی، سیگنال خطر برای تعیین اینکه آیا الگوریتم بهینه سازی فیل دریایی مرحله اکتشاف را انجام می دهد یا مرحله بهره برداری استفاده می شود. وقتی قدر مطلق سیگنال خطر کمتر از ۱ نباشد، گله فیل دریایی به حوزه جدیدی در فضای راه حل مهاجرت می کند که مرحله اکتشاف در مرحله اولیه الگوریتم است. برعکس، گله فیل دریایی تولیدمثل می کند که در آخرین الگوریتم مرحله بهره برداری است. سیگنال امنیتی نقش کلیدی را در مرحله بهره برداری ایفا می کند که بر انتخاب رفتار فیل های دریایی یا رفتار جستجوی غذا تأثیر می گذارد. در این میان، رفتار جستجوی غذا شامل دو پدیده معمولی، جمع آوری و فرار است که توسط سیگنال های خطر کنترل می شوند. بلوک دیاگرام الگوریتم بهینه سازی فیل دریایی در شکل (۱) به تفصیل شرح داده شده است. حل تابع هدف از طریق مدل ریاضی الگوریتم بهینه سازی فیل دریایی انجام می شود که در آن، فضای جستجو محدوده ای است که الگوریتم سعی می کند بهترین راه حل را پیدا کند. معمولاً فضای چند بعدی متشکل از متغیرهای تصمیم مسئله است. فضای راه حل شامل تمام راه حل های بالقوه است. یک راه حل، موقعیت یک فیل دریایی در فضای جستجو است. این یک راه حل بالقوه برای مسئله است. راه حل می تواند یک بردار باشد که در آن هر جزء با مقدار یک متغیر تصمیم مطابقت دارد. متغیر تصمیم با مسئله تعیین می شود. الگوریتم بهینه سازی فیل دریایی سعی می کند بهترین راه حل را در فضای جستجو پیدا کند، یعنی راه حلی که تابع هدف مسئله را بهینه می کند.

گام اول: مقداردهی اولیه

در الگوریتم بهینه سازی فیل دریایی، فرآیند بهینه سازی با مجموعه ای از راه حل های کاندید تولید شده به طور تصادفی (X) شروع می شود (رابطه (۲)).

$$X = LB + rand(UB - LB) \quad (2)$$

جایی که LB و UB، حد پایین و بالای متغیرهای مسئله هستند، rand، یک بردار تصادفی یکنواخت در محدوده ۰ تا ۱ است. فیل های دریایی عواملی هستند که فرآیند بهینه سازی را انجام می دهند. موقعیت آن ها به طور مداوم با تکرار به روز می شود (رابطه (۲)). که در آن، n اندازه جمعیت، d بعد متغیرهای طراحی است. مقادیر تناسب مربوط به همه عوامل جستجو به صورت رابطه (۳) ذخیره می شوند. جمعیت فیل دریایی به دو گروه بالغ و نوجوان تقسیم می شود که به ترتیب ۹۰٪ و ۱۰٪ جمعیت را تشکیل می دهند. در میان فیل های دریایی بالغ نسبت نر به ماده ۱:۱ است.

$$X = \begin{bmatrix} X_{1,1}, X_{1,2} \dots X_{1,d} \\ X_{2,1}, X_{2,2} \dots X_{2,d} \\ \vdots \\ X_{n,1}, X_{n,2} \dots X_{n,d} \end{bmatrix}_{n \times d} \quad (2)$$

$$F = \begin{bmatrix} f_{1,1}, f_{1,2} \dots f_{1,d} \\ f_{2,1}, f_{2,2} \dots f_{2,d} \\ \vdots \\ f_{n,1}, f_{n,2} \dots f_{n,d} \end{bmatrix}_{n \times d} \quad (3)$$

گسترده‌ای از روشی برای تولید دنباله‌های توزیع شده به‌طور تصادفی استفاده می‌شود. اتخاذ توزیع دنباله هالتون برای به‌روزرسانی موقعیت فیل دریایی نر می‌تواند توزیع گسترده‌تری از جمعیت با فضای جستجو را امکان‌پذیر کند. مهم این است که فضای جستجو به‌طور مساوی به چندین قسمت، تقسیم‌شود و در هر قسمت یک نقطه تصادفی انتخاب شود. این امر، هم تصادفی و هم یکنواختی را تضمین می‌کند.

مرحله ۲: به‌روزرسانی موقعیت فیل‌های دریایی ماده

فیل دریایی ماده تحت تأثیر فیل دریایی نر ($Male_{i,j}^t$) و فیل دریایی رهبر (X_{best}^t) قرار دارد. با روند تکرار، فیل دریایی ماده به‌تدریج کمتر تحت تأثیر جفت و بیشتر تحت تأثیر رهبر قرار می‌گیرد (رابطه (۱۲)):

$$Female_{i,j}^{t+1} = Female_{i,j}^t + \alpha \cdot (Male_{i,j}^t - Female_{i,j}^t) + (1 - \alpha) \cdot (X_{best}^t - Female_{i,j}^t) \quad (12)$$

که در آن، $Female_{i,j}^{t+1}$ موقعیت جدید برای آمین فیل دریایی ماده در بعد z ام است، $Male_{i,j}^t$ و $Female_{i,j}^t$ موقعیت‌های آمین فیل دریایی نر و ماده در بعد z ام هستند.

مرحله ۳: به‌روزرسانی موقعیت فیل‌های دریایی نوجوان (بچه)

فیل‌های دریایی نوجوان در رأس جمعیت اغلب توسط نهنگ‌های قاتل و خرس‌های قطبی هدف قرار می‌گیرند. بنابراین، فیل‌های دریایی نوجوان باید موقعیت فعلی خود را به‌روز کنند تا از شکار شدن جلوگیری کنند (رابطه (۱۳) و رابطه (۱۴)).

$$Juvenile_{i,j}^{t+1} = (O - Juvenile_{i,j}^t) \cdot P \quad (13)$$

$$O = X_{best}^t + Juvenile_{i,j}^t \cdot LF \quad (14)$$

که در آن، $Juvenile_{i,j}^{t+1}$ موقعیت جدید برای آمین فیل دریایی نوجوان در بعد z ام است، $Juvenile_{i,j}^t$ موقعیت آمین فیل دریایی نوجوان در بعد z ام است، P ، ضریب دقت فیل دریایی نوجوان است و یک عدد تصادفی از (۰، ۱) است. O ، موقعیت ایمنی مرجع است؛ L ، بردار اعداد تصادفی بر اساس وزیع $L'evy$ است که حرکت $L'evy$ را نشان می‌دهد (رابطه (۱۵)). که در آن، x و y دو متغیر با توزیع نرمال هستند،

$$x \sim N(0, \sigma_x^2), y \sim N(0, \sigma_y^2)$$

$$L'evy(a) = 0.05 \times \frac{x}{|y|^{\frac{1}{a}}} \quad (15)$$

$$\sigma_x = \left[\frac{\Gamma(1 + \alpha) \sin\left(\frac{\pi\alpha}{2}\right)}{\Gamma\left(\frac{1 + \alpha}{2}\right) \alpha 2^{\frac{(\alpha-1)}{2}}} \right]^{\frac{1}{\alpha}}, \sigma_y = 1, \alpha = 1.5 \quad (16)$$

که در آن، σ_x و σ_y انحرافات استاندارد هستند، $\Gamma(x) = (x + 1)!$. جستجوی غذا شامل رفتارهای فرار و جمع‌آوری است.

الف) رفتار فرار

فیل‌های دریایی همچنین در طول جستجوی غذا در زیر آب توسط شکارچیان طبیعی مورد حمله قرار می‌گیرند و آن‌ها بر اساس سیگنال‌های خطر از همتایان خود از منطقه فعالیت فعلی خود فرار می‌کنند. این رفتار در اواخر تکرار الگوریتم بهینه‌ساز فیل دریایی رخ

می‌دهد و درجه خاصی از اختلال در جمعیت به فیل‌های دریایی کمک می‌کند تا اکتشافات جهانی را انجام دهند (رابطه (۱۷)).

$$X_{i,j}^{t+1} = X_{i,j}^t \cdot R - |X_{best}^t - X_{i,j}^t| \cdot r_4^2 \quad (17)$$

که در آن، $|X_{best}^t - X_{i,j}^t|$ نشان‌دهنده فاصله بین فیل دریایی فعلی و بهترین فیل دریایی است، r_4 ، یک عدد تصادفی است که در محدوده (۰، ۱) قرار دارد.

ب) رفتار جمع‌آوری

فیل‌های دریایی می‌توانند برای جست‌وجوی غذا و حرکت با توجه به موقعیت سایر فیل‌های دریایی در گروه همکاری کنند و به اشتراک گذاشتن اطلاعات مکان می‌تواند به کل گله فیل‌های دریایی کمک کند تا منطقه دریایی با فراوانی غذا را پیدا کنند (رابطه (۱۸) تا رابطه (۲۱)).

$$X_{i,j}^{t+1} = (X_1 + X_2) / 2 \quad (18)$$

$$\begin{cases} X_1 = X_{best}^t - a_1 \times b_1 \times |X_{best}^t - X_{i,j}^t| \\ X_2 = X_{second}^t - a_2 \times b_2 \times |X_{second}^t - X_{i,j}^t| \end{cases} \quad (19)$$

$$a_2 = \beta \times r_5 - \beta \quad (20)$$

$$b = \tan(\theta) \quad (21)$$

که در آن، X_1 و X_2 دو وزنی هستند که بر رفتار جمع‌آوری فیل دریایی تأثیر می‌گذارند، X_{second}^t موقعیت فیل دریایی دوم در تکرار جاری است، $|X_{second}^t - X_{i,j}^t|$ نشان‌دهنده فاصله بین فیل دریایی فعلی و فیل دریایی دوم، a و b ضرایب جمع‌آوری هستند، r_5 ، یک عدد تصادفی است که در محدوده (۰، ۱) قرار دارد و θ مقادیری از 0 تا π را می‌گیرد.

به‌منظور ارزیابی هر راه‌حل، یک تابع برازندگی (رابطه (۲۲))، در طی بهینه‌سازی مورد استفاده قرار گرفته‌است. در طرح جاری، تلاش می‌شود که مجموعه ویژگی به دست آمده، دارای دقت بالایی در تشخیص تومورهای سرطانی باشد. لذا تابع برازش هر راه‌حل بر مبنای دقت تشخیصی مدل است:

$$fitness(sol_i) = Accuracy(sol_i) \quad (22)$$

۳-۵. مرحله پنجم روش پیشنهادی: دسته‌بند ترکیبی

در مرحله پنجم، از قدرت سه دسته‌بند معروف حاوی درخت تصمیم (DT)، ماشین بردار پشتیبان و K نزدیک‌ترین همسایه (KNN) به‌صورت دسته‌بند مشارکتی به کار می‌روند تا یک دسته‌بند ترکیبی مبتنی بر رأی‌گیری داشته‌باشند. بدین منظور، مجموعه ویژگی به دست آمده و مقادیر آن در مجموعه داده آموزشی به این سه روش دسته‌بندی نظارت‌شده داده می‌شوند. بر مبنای خروجی ایجادشده، مشخص می‌شود که برجسب نهایی خروجی این مرحله چه خواهد بود.

دسته‌بند اول، درخت تصمیم است که یک ساختار درختی شبیه به ریشه یک درخت می‌باشد. الگوریتم ID3 به‌عنوان کلاسیک‌ترین الگوریتم شناخته می‌شود. گره ریشه درخت تصمیم، بسته به پاسخ، اولین سؤال مهم را مطرح می‌کند، سپس گره بعدی از گره‌های فرزند انتخاب می‌شود، فرزند جدید یک سؤال جدید مطرح می‌کند و این روند تا رسیدن به گره برگ تکرار می‌شود و نقطه داده در نهایت بر اساس نتیجه دسته‌بندی می‌شود. گره برگ نگه می‌دارد. هر گره غیربرگ نشان‌دهنده ویژگی

می گردد. بر این مبنا، پارامترهای چهارگانه طرح حاوی صحت، دقت، شاخص های فراخوانی و F-Measure تعریف می شوند. دقت، استانداردترین متریک جهت خلاصه سازی عملکرد تشخیص در همه کلاس ها است که به صورت رابطه (۲۳) محاسبه می گردد. صحت (رابطه (۲۴)) غالباً مربوط به مقادیر پیش گوی مثبت است و نسبت تعداد نمونه های مثبت درست دسته بندی شده به همه نمونه های دسته بندی شده با برچسب مثبت است. فراخوانی یا نرخ گزارش مثبت درست (رابطه (۲۵))، نسبت نمونه های مثبت درست دسته بندی شده به تمامی نمونه های درست است. F-Measure دو معیار فراخوانی و صحت را در یک مقدار به صورت رابطه (۲۶) ترکیب می کند.


$$accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (23)$$

$$Precision = \frac{TP}{TP + FP} \quad (24)$$

$$Recall = \frac{TP}{TP + FN} \quad (25)$$

$$F - Measure = 2 \cdot \frac{Precision \cdot Recall}{Precision + Recall} \quad (26)$$

مجموعه داده: مجموعه داده یکسان برای شبیه سازی روش پیشنهادی و روش های مورد مقایسه استفاده شده است تا نتایج با یکدیگر مقایسه شوند. مجموعه داده مورد استفاده، مجموعه داده از سایت kaggle^{۱۹} است. داده مورد استفاده، حاوی ۱۵۰ تصویر MRI اخذ شده از افراد می باشد که تمامی تصاویر به اندازه ۳۷۸*۳۷۸ می باشند. طبق گفته سازمان بهداشت جهانی (WHO)، تشخیص صحیح تومور مغزی شامل تشخیص، شناسایی محل تومور مغزی و طبقه بندی تومور بر اساس بدخیمی، درجه و نوع است. این کار تجربی در تشخیص تومورهای مغزی با استفاده از MRI شامل تشخیص تومور، طبقه بندی تومور از نظر درجه، نوع و شناسایی محل تومور است. این روش از نظر استفاده از یک مدل برای طبقه بندی MRI مغز در وظایف طبقه بندی مختلف به جای یک مدل فردی برای هر کار طبقه بندی آزمایش شده است.



شکل (۲): تصاویر فرد برای تشخیص تومور

ورودی مجموعه داده است، "مقدار ویژگی" نشان دهنده مقدار این ویژگی است و گره برگ نشان دهنده ارزش ویژگی خروجی است. هر راه از ریشه تا برگ به بسیاری از ویژگی های پیوندها مربوط می شود، تفکیک این پیوندها با خود درخت مقایسه می شود. بنابراین تغییر قوانین ترتیب به نوع IF-THEN هر چیزی دشوار است. همان طور که توسط قوانین ترتیب نشان داده شده است، آیتم اطلاعات مبهم را می توان مشخص و پیش بینی کرد.


دسته بند دوم، روش ماشین بردار پشتیبان است که بر اساس آن، یک شبه صفحه جداکننده N-1 بعدی برای تشخیص دو کلاس در یک فضای N بعدی ساخته می شود. N بعد شامل تعداد کلاس های مورد نظر می باشد؛ که در هر کلاس، تعداد مشخصی قرار داده می شود. یک نقطه داده به عنوان یک بردار n بعدی مورد استفاده قرار می گیرد. به عنوان مثال، دو متغیر در یک مجموعه داده یک فضای دوبعدی ایجاد می کنند؛ صفحه جداکننده یک خط مستقیم (یک بعدی) است که فضا را به دو قسمت تقسیم می کند. هنگامی که ابعاد بیشتری درگیر هستند، ماشین بردار پشتیبان یک شبه صفحه جداکننده بهینه را جستجو می کند که حداکثر حاشیه شبه صفحه جداکننده نامیده می شود. فاصله بین شبه صفحه و نزدیک ترین نقطه داده در هر طرف (به نام بردار پشتیبان) به حداکثر می رسد. بهترین سناریو این است که دو دسته توسط یک شبه صفحه خطی جدا شوند. با این حال، شرایط دنیای واقعی همیشه ساده نیست. برخی از داده ها در دو دسته ممکن است به یک ناحیه خاکستری تبدیل شوند که جداسازی آن ها ساده نمی باشد. ماشین بردار پشتیبان این مسئله را حل می کند.

دسته بند سوم، الگوریتم k نزدیک ترین همسایه است که اغلب برای دسته بندی استفاده می شود، اگرچه می توان از آن برای تخمین و پیش بینی نیز استفاده کرد. k- نزدیک ترین همسایه نمونه ای از یادگیری مبتنی بر نمونه است که در آن، مجموعه داده های آموزشی ذخیره می شود، به طوری که می توان به سادگی با مقایسه آن با مشابه ترین رکوردها در مجموعه آموزشی، دسته بندی برای یک رکورد دسته بندی نشده جدید پیدا کرد. اما چگونگی انتخاب مقدار k مهم است. در واقع، ممکن است بهترین راه حل بدیهی وجود نداشته باشد. یک مقدار کوچک را برای k در نظر بگیرید. سپس این امکان وجود دارد که دسته بندی یا تخمین به طور نامناسب تحت تأثیر مشاهدات پرت یا غیرمعمول ("صدا") قرار گیرد. با k کوچک (به عنوان مثال، k=1)، الگوریتم به سادگی مقدار هدف نزدیک ترین مشاهده را برمی گرداند، فرآیندی که ممکن است منجر شود.

۴. نتایج شبیه سازی و مقایسه با طرح پایه


طرح جاری به دنبال تشخیص و شناسایی بیماری و عارضه های مغزی بر مبنای تصاویر MRI می باشد. تشخیص یک روش دسته بندی روی داده ها که فقط دو کلاس دارد با یکی از موارد مثبت درست (TP)، منفی نادرست (FN)، منفی درست (TN) و مثبت نادرست (FP) مطرح

در شکل (۴) ماتریس درهم‌ریختگی روش پیشنهادی برای تعداد ۵۰ نمونه آزمون مشخص شده است. از ماتریس درهم‌ریختگی برای اندازه‌گیری اثربخشی مدل پیشنهادی استفاده شده است. این ماتریس یک روش اندازه‌گیری عملکرد برای مسئله دسته‌بندی یادگیری ماشین است که در آن، خروجی می‌تواند دو یا چند کلاس باشد. جدول یا ماتریس درهم‌ریختگی، نتایج دسته‌بندی را بر مبنای اطلاعات واقعی موجود، نشان می‌دهد.



شکل (۴): ماتریس درهم‌ریختگی برای روش پیشنهادی

در شکل (۵)، معیار دقت برای ۵۰ نمونه مشخص شده است. محور افقی در شکل (۵)، نشان‌دهنده تعداد نمونه‌های آزمایش می‌باشد. محور عمودی نشان‌دهنده میزان دقت روش پیشنهادی، طرح پایه و روش مبتنی بر الگوریتم جست‌وجوی خزنده است. به منظور ارزیابی دقت طرح، شبیه‌سازی با مجموعه آزمون مورد بررسی قرار می‌گیرد، بهبود عملکرد روش ارائه شده نسبت به طرح پایه مشخص می‌گردد. همان‌طور که در شکل (۵) نشان داده شده است، دقت طرح پیشنهادی در بیشتر موارد، بهتر یا مساوی با طرح پایه می‌باشد. علت این بهبود، قدرت شبکه عصبی و تبدیلات حوزه فرکانس و ادغام آن با الگوریتم بهینه‌ساز فیل دریایی جهت انتخاب ویژگی می‌باشد.




شکل (۵): بررسی معیار دقت در تشخیص تومور مغزی

نتایج شبیه‌سازی روش پیشنهادی با دو روش مقایسه می‌شوند که عبارت‌اند از:


روش مبتنی بر الگوریتم جست‌وجوی خزنده: نتایج شبیه‌سازی روش پیشنهادی با یک روش فراابتکاری به نام الگوریتم جست‌وجوی خزنده (RSA) [۳۵] مقایسه می‌شود. در [۳۵]، یک بهینه‌ساز فراابتکاری الهام‌گرفته از طبیعت جدید به نام الگوریتم جست‌وجوی خزنده (RSA) پیشنهاد کرده‌اند که با انگیزه رفتار شکار کروکودیل‌ها انجام می‌شود. دو مرحله اصلی رفتار کروکودیل اجرامی شود، مانند احاطه کردن که با راه رفتن بالا یا راه رفتن شکمی انجام می‌شود و شکار که با هماهنگی شکار یا همکاری شکار انجام می‌شود.

طرح پایه (روش ترکیبی K-Means و ماشین بردار پشتیبان): همچنین نتایج شبیه‌سازی روش پیشنهادی با نتایج مقاله [۳۶] مقایسه می‌شوند. سیستمی را پیشنهاد نموده‌اند که با به‌کارگیری روش ترکیبی K-Means و ماشین بردار پشتیبان، تصمیم می‌گیرد که آیا تصویر اخذ شده از مغز دارای تومور است یا خیر. در مرحله اول، تصویر ورودی با به‌کارگیری آستانه باینری به مقیاس خاکستری تبدیل می‌گردد و لکه‌ها تشخیص داده می‌شوند. لکه‌های تشخیص داده شده بر اساس شدت آن‌ها جهت تمایز میان مغز طبیعی و تومور نمایش داده می‌شوند. سپس با به‌کارگیری الگوریتم K-Means، مجموعه ویژگی‌های استخراج شده تعیین می‌گردند، پس از آن، شناسایی تومور با به‌کارگیری ماشین بردار پشتیبان صورت می‌گیرد [۳۶].

در شکل (۳)، نمودار همگرایی الگوریتم بهینه‌ساز فیل دریایی در روش پیشنهادی نشان داده شده است. محور افقی نشان‌دهنده تعداد تکرار (۳۰ تکرار) است. محور عمودی نشان‌دهنده بهترین تناسب به دست آمده است. مطابق با نتایج به دست آمده الگوریتم بهینه‌ساز فیل دریایی توانسته است تابع هدف را به خوبی حل نماید که در نمودارهای بعدی نتایج به دست آمده از تأثیر مرحله انتخاب ویژگی در روش پیشنهادی که مبتنی بر الگوریتم بهینه‌ساز فیل دریایی است، مشخص می‌شود.



شکل (۳): نمودار همگرایی الگوریتم بهینه‌ساز فیل دریایی



شکل (۸): بررسی معیار F-Measure در تشخیص تومور مغزی


۵. نتیجه گیری

هدف طرح پیشنهادی این است تا یک سیستم تشخیص عارضه های مغزی بر مبنای تصاویر MRI حاوی پنج مرحله ارائه گردید که ترکیبی از دو روش نظارت شده (مبتنی بر الگو) و نظارت نشده است. با بهره گیری از مزیت های هر دو گروه روش های یادگیری ماشین، معایب آن ها پوشش داده شد. نوآوری اصلی روش پیشنهادی استفاده از الگوریتم بهینه ساز فیل دریایی برای مرحله انتخاب ویژگی است. از قدرت سه دسته بند معروف حاوی درخت تصمیم (DT)، ماشین بردار پشتیبان و K نزدیک ترین همسایه (KNN) به صورت دسته بند مشارکتی استفاده شده است تا یک دسته بند ترکیبی مبتنی بر رأی گیری داشته باشند. نرم افزار متلب جهت شبیه سازی به کار گرفته شده است. پارامترهای ارزیابی طرح حاوی دقت، صحت، فراخوانی و F-Measure می باشد. نتایج شبیه سازی نشان داده است که پارامترهای ارزیابی دقت روش پیشنهادی بهتر از روش پایه بوده است. علت این بهبود در شاخص های دقت، به کارگیری دسته بندهای استاندارد در کنار مکانیسم های استخراج ویژگی نظیر شبکه عصبی کانولوشن و تبدیل موجک است که برای کاهش ابعاد داده و افزایش دقت تشخیص، از الگوریتم بهینه ساز فیل دریایی نیز استفاده کرده است.

منابع


- [1] Hariri, Mehdi, (1402), face recognition in the image using the Viola-Jones method and image texture analysis, intelligent multimedia processing and communication systems. 1-10. [Persian]
- [2] Mousavi, Zeinab, Kerami, Elaha, Gholami, Kobra, (1402), Using discrete-time Zhang neural networks for time-varying nonlinear optimization, intelligent multimedia processing and communication systems. 31-42. [Persian]
- [3] Sangeeta, D. N. H. (2023). Brain tumor detection and classification with feature extraction and reduction using DWT and PCA. Journal of Survey in Fisheries Sciences, 10(2S), 948-963.
- [4] Kandimalla, S. Y., Vamsi, D. M., Bhavani, S., & VM, M. (2023). Recent Methods and Challenges in Brain Tumor

بر مبنای نتایج به دست آمده در شکل (۶)، شاخص صحت در طرح پیشنهادی بیشتر از طرح پایه و الگوریتم جست و جوی خزنده می باشد. دلیل این بهبود، قدرت مدل ترکیبی ارائه شده با بهره گیری از قدرت روش های نظارت شده می باشد.



شکل (۶): بررسی معیار صحت در تشخیص تومور مغزی

در ادامه، به بررسی معیار فراخوانی یا نرخ گزارش مثبت درست در اجرای شبیه سازی با نمونه های آزمون پرداخته می شود. همان طور که در شکل (۷) مشخص شده است، این شاخص که به آن Sensitivity نیز گفته می شود، در طرح پیشنهادی بیشتر از طرح پایه و الگوریتم جست و جوی خزنده است و بهبود چشمگیری داشته است. لذا ترکیب شبکه عصبی و دسته بندهای مرسوم (سه دسته بند معروف حاوی درخت تصمیم (DT)، ماشین بردار پشتیبان و K نزدیک ترین همسایه (KNN) به صورت دسته بند مشارکتی) توانسته است با دقت بالا به تشخیص تومور مغزی بپردازد.



شکل (۷): بررسی معیار فراخوانی در تشخیص تومور مغزی

در آخرین گام، به ارزیابی معیار F-Measure پرداخته شده است که میانگین هندسی دو معیار فراخوانی و دقت می باشد. با توجه به نتایج به دست آمده در شکل (۸)، مقدار این شاخص در طرح پیشنهادی، بهتر از طرح پایه و الگوریتم جست و جوی خزنده است.

- [21] Khan, M. A., Khan, A., Alhaisoni, M., Alqahtani, A., Alsubai, S., Alharbi, M.,... & Damaševičius, R. (2023). Multimodal brain tumor detection and classification using deep saliency map and improved dragonfly optimization algorithm. *International Journal of Imaging Systems and Technology*, 33(2), 572-587.
- [22] Pedada, K. R., Rao, B., Patro, K. K., Allam, J. P., Jamjoom, M. M., & Samee, N. A. (2023). A novel approach for brain tumour detection using deep learning based technique. *Biomedical Signal Processing and Control*, 82, 104549.
- [23] Ramtekkar, P. K., Pandey, A., & Pawar, M. K. (2023). Innovative brain tumor detection using optimized deep learning techniques. *International Journal of System Assurance Engineering and Management*, 1-15.
- [24] Harahap, M., Husein, A. M., Deol, S. S., Singh, S., Situmorang, S. D., & Saputra, J. (2022). Comparative Analysis of Deep Learning Approach for Detection and Segmentation of Brain Tumor. In *2022 IEEE International Conference of Computer Science and Information Technology (ICOSNIKOM)* (pp. 01-05). IEEE.
- [25] Raiyan, T., Anonna, H. H., Mondal, S. K., & Khan, M. M. (2022). Brain Tumor Detection using Smart Deep Learning. In *2022 IEEE 13th Annual Information Technology, Electronics and Mobile Communication Conference (IEMCON)* (pp. 0186-0190). IEEE.
- [26] Mathew, J., & Srinivasan, N. (2022). Deep Convolutional Neural Network with Transfer Learning for Automatic Brain Tumor Detection from MRI. In *2022 International Conference on Computing, Communication, Security and Intelligent Systems (IC3SIS)* (pp. 1-6).
- [27] Vankdothu, R., Hameed, M. A., & Fatima, H. (2022). A brain tumor identification and classification using deep learning based on CNN-LSTM method. *Computers and Electrical Engineering*, 101, 107960.
- [28] Gajula, S., & Rajesh, V. (2024). An MRI brain tumour detection using logistic regression-based machine learning model. *International Journal of System Assurance Engineering and Management*, 15(1), 124-134.
- [29] Narasimham, N. V. S. L. (2024). Fuzzy Logic-Based System for Brain Tumour Detection and Classification. *arXiv preprint arXiv:2401.14414*.
- [30] Dhole, N. V., Dixit, V. V., & Desai, D. (2024). Detection of brain tumour in multi-modality images using hybrid features. *Multimedia Tools and Applications*, 83(2), 4613-4638.
- [31] Anantharajan, S., Gunasekaran, S., Subramanian, T., & Venkatesh, R. (2024). MRI brain tumor detection using deep learning and machine learning approaches. *Measurement: Sensors*, 31, 101026.
- [32] Potnuru, M., & Naick, B. S. (2023). Semantic Segmentation of MRI Images for Brain Tumour Detection with ShuffleNet-Based UNet. *SN Computer Science*, 4(5), 445.
- [33] Paul, I., Sahu, A., Das, P. K., & Meher, S. (2023). Deep convolutional neural network-based automatic detection of brain tumour. In *2023 2nd international conference for innovation in technology (INOCON)* (pp. 1-6). IEEE.
- [34] Maji, K., & Gupta, S. (2023). Evaluation of various loss functions and optimization techniques for mri brain tumor detection. In *2023 International Conference on Distributed Computing and Electrical Circuits and Electronics (ICDCECE)* (pp. 1-6). IEEE.
- [35] Abualigah, L., Abd Elaziz, M., Sumari, P., Geem, Z. W., & Gandomi, A. H. (2022). Reptile Search Algorithm (RSA): A nature-inspired meta-heuristic optimizer. *Expert Systems with Applications*, 191, 116158.
- [36] Suresha, D., Jagadisha, N., Shrisha, H. S., & Kaushik, K. S. (2020). Detection of brain tumor using image processing. In *2020 Detection Using Medical Image Processing. Recent Patents on Engineering*, 17(5), 8-23.
- [5] Kumar, A. (2023). Study and analysis of different segmentation methods for brain tumor MRI application. *Multimedia Tools and Applications*, 82(5), 7117-7139.
- [6] Zhu, Z., He, X., Qi, G., Li, Y., Cong, B., & Liu, Y. (2023). Brain tumor segmentation based on the fusion of deep semantics and edge information in multimodal MRI. *Information Fusion*, 91, 376-387.
- [7] Qin, C., Li, B., & Han, B. (2023). Fast brain tumor detection using adaptive stochastic gradient descent on shared-memory parallel environment. *Engineering Applications of Artificial Intelligence*, 120.
- [8] Purni, J. T., Vedhapriyavadhana, R., Jayalakshmi, S. L., & Girija, R. (2023). High Performance Classifier for Brain Tumor Detection Using Capsule Neural Network. In *Computer Vision and Machine Intelligence Paradigms for SDGs: Select Proceedings of ICRTAC-CVMIP 2021* (pp. 151-164). Singapore: Springer Nature Singapore.
- [9] Baji, F. S., Abdullah, S. B., & Abdulsattar, F. S. (2023). K-mean clustering and local binary pattern techniques for automatic brain tumor detection. *Bulletin of Electrical Engineering and Informatics*, 1586-1594.
- [10] Panigrahi, A., & Subasi, A. (2023). Magnetic resonance imagining-based automated brain tumor detection using deep learning techniques. In *Applications of Artificial Intelligence in Medical Imaging* (pp. 75-107). Academic Press.
- [11] Bashkandi, A. H., Sadoughi, K., Aflaki, F., Alkhazaleh, H. A., Mohammadi, H., & Jimenez, G. (2023). Combination of political optimizer, particle swarm optimizer, and convolutional neural network for brain tumor detection. *Biomedical Signal Processing and Control*.
- [12] Han, M., Du, Z., Yuen, K. F., Zhu, H., Li, Y., & Yuan, Q. (2024). Walrus optimizer: A novel nature-inspired metaheuristic algorithm. *Expert Systems with Applications*, 239, 122413.
- [13] Bedi, K. P., & Jadon, J. S. (2024). Comparison of Deep Learning Methods for Detecting Brain Tumor. In *2024 14th International Conference on Cloud Computing, Data Science & Engineering (Confluence)* (pp. 897-901). IEEE.
- [14] Curci, A., & Esposito, A. (2024). Detecting Brain Tumors through Multimodal Neural Networks. *arXiv preprint arXiv:2402.00038*.
- [15] Yang, Y., & Razmjoo, N. (2024). Early detection of brain tumors: Harnessing the power of GRU networks and hybrid dwarf mongoose optimization algorithm. *Biomedical Signal Processing and Control*, 91.
- [16] Bhimavarapu, U., Chintalapudi, N., & Battineni, G. (2024). Brain Tumor Detection and Categorization with Segmentation of Improved Unsupervised Clustering Approach and Machine Learning Classifier. *Bioengineering*, 11(3), 266.
- [17] Joshi, A. A., & Aziz, R. M. (2024). Deep learning approach for brain tumor classification using metaheuristic optimization with gene expression data. *International Journal of Imaging Systems and Technology*, 34(2), e23007.
- [18] Mandle, A. K., Sahu, S. P., & Gupta, G. P. (2024). WSSOA: whale social spider optimization algorithm for brain tumor classification using deep learning technique. *International Journal of Information Technology*, 1-17.
- [19] Neetha, K. S., & Narayan, D. L. (2024). Feature selection using adaptive manta ray foraging optimization for brain tumor classification. *Pattern Analysis and Applications*, 27(2), 29.
- [20] Mohammed, N. A., Khedr, O. E., El-Rabaie, E. S. M., & Khalaf, A. A. (2023). Early detection of brain cancers biomedical sensor with low losses and high sensitivity in the terahertz regime based on photonic crystal fiber technology. *Optical and Quantum Electronics*, 55(3), 1-21.

پی‌نوشت

- ¹ Walrus optimizer (WO)
- ² Vigilantes
- ³ Gated Recurrent Unit (GRU)
- ⁴ Enhanced Hybrid Dwarf Mongoose Optimization (EHDMO)
- ⁵ Recurrent Neural Network (RNN)
- ⁶ fuzzy C-means
- ⁷ grey-level co-occurrence matrix (GLCM)
- ⁸ Whale Social Spider-based Optimization Algorithm (WSSOA)
- ⁹ Deep Convolutional Neural Network (DCNN)
- ¹⁰ adaptive manta ray foraging optimization (AMRFO)
- ¹¹ linear intensity distribution information and regularization parameter-based intuitionistic fuzzy C-means
- ¹² attention-based long short-term memory (ALSTM)
- ¹³ Tumour Core (Tc)
- ¹⁴ Whole Tumour (Wt)
- ¹⁵ Enhancing Core (Ec)
- ¹⁶ Transfer Learning (Tl)
- ¹⁷ quasi-Monte Carlo method
- ¹⁸ Halton sequence
- ¹⁹ <https://www.kaggle.com/datasets/masoudnickparvar/brain-tumor-mri-dataset>
- ²⁰ Reptile Search Algorithm