

Accuracy and Precision Improving of Brain Tumors Diagnosis in MRI Images using Deep Learning Methods based on Swarm Intelligence Algorithms

Banifatemeh, Manijeh-Sadat¹ / Ghaemi, Reza^{2*} / Tabatabaee, Amir³

¹ – MSc in AI, Department of Computer Engineering, Qu.C., Islamic Azad University, Quchan, Iran

² - Assistant Professor, Department of Computer Engineering, Qu.C., Islamic Azad University, Quchan, Iran

³ - Associate Professor, Department of Nursing, Qu.C., Islamic Azad University, Quchan, Iran

ARTICLE INFO

DOI: 10.22041/ijbme.2026.2077589.2008

Received: 12-11-2025

Revised: 4-5-2026

Accepted: 5-7-2026

KEYWORDS

*Brain Tumor Diagnosis
Deep Learning
Swarm Intelligence
Metaheuristic Algorithm
Image Processing
MRI Image Data
Artificial Neural Network*

ABSTRACT


Accurate and rapid brain tumors diagnosis of brain tumors in magnetic resonance imaging (MRI) is one of the major challenges in the health and medical fields, especially in radiology. The deep learning models have been widely used in the medical field due to their high capabilities in extracting complex and nonlinear features from image data. However, deep learning models may have unstable results due to their strong dependence on model settings and sensitivity to input data quality. In this study, in order to improve the accuracy and precision in diagnosis of brain cancer tumors, a deep learning model is proposed based on two swarm intelligence algorithms, in which the particle swarm algorithm is employed to adjust the hyperparameters of the deep neural network and the ant colony algorithm is applied to select the most effective features of MRI images. Experimental results of tests on the Kaggle MRI brain tumor as benchmark dataset indicate 95% accuracy and 91% accuracy of brain tumor diagnosis obtained from the proposed model in this study, as well as improved performance compared to conventional deep learning methods.

***Corresponding Author:** Reza Ghaemi

Address: Department of Computer Engineering, Qu.C., Islamic Azad University, Quchan, Iran

E-Mail: rezaghaemi@iaau.ac.ir





بهبود دقت و صحت تشخیص تومورهای مغزی در تصاویر MRI با استفاده از روش‌های یادگیری عمیق مبتنی بر الگوریتم‌های هوش جمعی

بنی فاطمه، منیژه سادات^۱ / قائمی، رضا^{۲*} / طباطبایی، امیر^۳

^۱ - کارشناس ارشد هوش مصنوعی، گروه مهندسی کامپیوتر، واحد قوچان، دانشگاه آزاد اسلامی، قوچان، ایران

^۲ - استادیار گروه مهندسی کامپیوتر، واحد قوچان، دانشگاه آزاد اسلامی، قوچان، ایران

^۳ - دانشیار گروه پرستاری، واحد قوچان، دانشگاه آزاد اسلامی، قوچان، ایران

مشخصات مقاله

شناسه‌ی دیجیتال: 10.22041/ijbme.2026.2077589.2008

پذیرش: ۱۴۰۵/۴/۱۴

بازنگری: ۱۴۰۵/۲/۱۴

ثبت در سامانه: ۱۴۰۴/۸/۲۱

چکیده

تشخیص دقیق و سریع تومورهای مغزی از روی تصاویر پرتو مغناطیسی (MRI)، یکی از چالش‌های مهم در حوزه سلامت و پزشکی، به‌ویژه در رادیولوژی است. استفاده از مدل‌های یادگیری عمیق، به دلیل قابلیت‌های بالا در استخراج ویژگی‌های پیچیده و غیرخطی از داده‌های تصویری، به‌طور گسترده‌ای در حوزه پزشکی مورد توجه قرار گرفته است. با این حال، مدل‌های یادگیری عمیق به دلیل وابستگی شدید به تنظیمات مدل و حساسیت به کیفیت داده‌های ورودی، ممکن است نتایج ناپایداری داشته باشند. در این پژوهش، به منظور بهبود دقت و صحت در تشخیص تومورهای سرطانی مغزی، یک مدل یادگیری عمیق مبتنی بر الگوریتم هوش جمعی پیشنهاد شده است، به طوری که از الگوریتم ازدحام ذرات برای تنظیم ابرپارمترهای شبکه عصبی عمیق و از الگوریتم کلونی مورچگان برای انتخاب موثرترین ویژگی‌های تصاویر MRI استفاده شده است. نتایج تجربی آزمایش‌ها بر روی مجموعه داده‌های محک تومورهای مغزی Kaggle Brain MRI، نشان‌دهنده ۹۵٪ دقت و ۹۱٪ صحت تشخیص تومورهای مغزی به دست آمده از مدل پیشنهادی این تحقیق و همچنین، بهبود عملکرد آن نسبت به روش‌های معمول یادگیری عمیق می‌باشد.

واژه‌های کلیدی

تشخیص تومورهای مغزی
یادگیری عمیق
الگوریتم فرامکاشفه‌ای
هوش جمعی
پردازش تصویر
داده‌های تصویری MRI
شبکه عصبی مصنوعی

*نویسنده‌ی مسئول: رضا قائمی


نشانی: گروه مهندسی کامپیوتر، واحد قوچان، دانشگاه آزاد اسلامی، قوچان، ایران

پست الکترونیک: rezaghaemi@iau.ac.ir



۱- مقدمه

تومورهای مغزی در بیماران سرطانی ایالات متحده آمریکا، حدود ۱٪ به‌طور سالانه تشخیص داده می‌شوند که مقدار پایینی است و می‌تواند به‌طور قابل‌توجهی بر کیفیت زندگی بیماران تأثیر بگذارد. تومورهای مغزی به‌طور معمول به موارد مختلفی از جمله تومورهای هیپوفیز^۱، لنفوم^۲، مدولوبلاستوما^۳، گلیوما^۴، مننژیوم^۵، بدخیم و غیره، تقسیم‌بندی می‌شوند [۲، ۱]. گلیوما [۴، ۳]، شایع‌ترین نئوپلاسم^۶ اولیه مغز در بزرگسالان است و در سلول‌های گلیال^۷ که از نورون‌های^۸ مغز از جمله آستروسیت‌ها^۹، الیگودندروسیت‌ها^{۱۰} و سلول‌های آپاندیمی^{۱۱} حمایت می‌کنند، منشأ می‌گیرند. گلیوما، براساس نوع سلول گلیال درگیر در تومور و ویژگی‌های ژنتیکی تومور طبقه‌بندی می‌شود که بسته به محل و سرعت رشد آن می‌تواند بر عملکرد مغز تأثیر بگذارد و تهدیدکننده زندگی بیمار باشد. مننژیوم‌ها ۱۵٪ تا ۲۰٪ از کلیه تومورهای اولیه داخل جمجمه را در سری‌های جراحی تشکیل می‌دهند، اما بروز آن‌ها در غربال‌گری معمول، ۱٪ جمعیت است که هر سه نوع آن در شکل (۱) نشان داده شده است. اعتقاد بر این است که تومورهای اولیه داخل جمجمه، از سلول کلاهیك عنكبوتیه در نزدیکی سینوس‌های وریدی حرکت کرده و طیف گسترده‌ای از رفتارهای خوش‌خیم را نشان می‌دهند [۵].



شکل (۱) - تصاویر MRI تومور مغزی به‌ترتیب از سمت راست، هیپوفیز، گلیوما و مننژیوم [۵]

سرطان تومور مغزی، چالش برانگیزترین بیماری در انسان‌ها به‌شمار می‌رود، با این حال شناسایی دستی تومورهای مغزی و بدون استفاده از فناوری‌های نوین نظیر هوش مصنوعی^{۱۲}، برای پزشکان متخصص مغز و اعصاب چالش برانگیز است. بنابراین،

مدل‌های شناسایی و تشخیص به‌کمک رایانه و مبتنی بر هوش مصنوعی و با استفاده از تکنیک‌های یادگیری ماشین^{۱۳} و نیز یادگیری عمیق^{۱۴}، برای طبقه‌بندی^{۱۵} و تحلیل بهتر تومورهای مغزی از روی تصاویر پرتو مغناطیسی^{۱۶} (MRI) مغز بیمار، برای یاری‌رسانی به متخصصان پزشکی ضروری و مورد نیاز می‌باشد [۶]. بنابراین، ارزیابی دقیق و به‌موقع تومورهای سرطانی مغز برای تصمیم‌گیری معقول در مورد این تشخیص بسیار حیاتی محسوب می‌شوند [۷]. بهبود کیفیت تصاویر MRI، به‌طور معمول با مقیاس‌هایی همچون قدرت تفکیک سنجیده می‌شوند و یکی از پیش‌پردازش‌های مهم در مرحله آماده‌سازی تصاویر MRI، به‌منظور کاربردهای متفاوتی مانند تشخیص بیماری‌ها، روند بیماری‌ها، و بررسی تأثیر معالجات می‌باشد [۸].

عملکردهای اخیر روش‌های یادگیری عمیق، به‌ویژه شبکه‌های عصبی حلقوی^{۱۷} در شناسایی اشیاء و تقسیم‌بندی تصاویر بیولوژیکی و پزشکی، محبوبیت آن‌ها را افزایش داده است. برخلاف روش‌های طبقه‌بندی سنتی که در آن‌ها، ویژگی‌های دست‌ساز وارد می‌شوند، شبکه‌های عصبی حلقوی ویژگی‌های پیچیده را به‌طور مستقیم از خود داده‌ها آموزش می‌بینند. با توجه به این مشخصه، پژوهش‌های حوزه تقسیم‌بندی تومورهای مغز با استفاده از شبکه‌های عصبی حلقوی، به‌طور عمده روی طراحی معماری شبکه عصبی متمرکز است تا عملیاتی مانند پردازش تصویر^{۱۸} برای استخراج ویژگی‌ها^{۱۹} [۹].

طبقه‌بندی دقیق و صحیح تومورهای مغزی، به‌منظور تشخیص و درمان به‌موقع بسیار ضروری و حیاتی است، چراکه تومورهای مغزی تهدیدی برای مردم در سراسر جهان به‌شمار می‌روند. با این حال، طبقه‌بندی دقیق و صحیح تومورهای مغزی از طریق روش‌های رایانه‌ای، به‌دلیل تفاوت در اندازه، شکل، محل تومورها و نیز محدودیت‌های موجود در زمینه پزشکی دشوار بوده است. بهبود معیارهای دقت^{۲۰} و صحت^{۲۱} تشخیص تومورهای مغزی بسیار حیاتی می‌باشد، زیرا اشتباهات کوچک در قضاوت انسانی می‌تواند منجر به افزایش نرخ مرگ و میر شود [۸].

با این حال و بر اساس بررسی‌های پژوهش‌های موجود در پیشینه تحقیق، درکنار مشکل مطلوب‌نبودن دقت و صحت

¹² Artificial Intelligence (AI)

¹³ Machine Learning (ML)

¹⁴ Deep Learning (DL)

¹⁵ Classification

¹⁶ Magnetic Resonance Imaging (MRI)

¹⁷ Convolutional Neural Network (CNN)

¹⁸ Image Processing

¹⁹ Feature Extraction

²⁰ Precision

²¹ Accuracy

¹ Pituitary gland

² Lymphoma

³ Medulloblastoma

⁴ Glioma

⁵ Meningioma

⁶ Neoplasm

⁷ Glial Cells

⁸ Neurons

⁹ Astrocyte

¹⁰ Oligodendrocyte

¹¹ Ependyma

این مقاله، با هدف اصلی بهبود معیارهای دقت، صحت، پایداری و سرعت مدل یادگیری عمیق برای تشخیص تومورهای مغزی از روی مجموعه داده‌های محک^۹ تصاویر MRI تومورهای مغزی، از طریق یک رویکرد ترکیبی پیشنهادی یادگیری عمیق مبتنی بر هوش جمعی انتظار می‌رود که نتایج مورد قبول و مطلوبی حاصل گردد. در مدل پیشنهادی یادگیری عمیق، از الگوریتم‌های هوش جمعی بهینه‌سازی ازدحام ذرات^{۱۰} و کلونی مورچگان^{۱۱}، به ترتیب به منظور تنظیم بهینه ابرپارامترهای مدل یادگیری عمیق و استخراج موثرترین ویژگی‌های تصاویر MRI استفاده شده است. به علاوه، برای آموزش مدل یادگیری عمیق، نیازی به برچسب‌گذاری مجموعه داده‌های تصاویر MRI نمی‌باشد. به دلیل نمایش متراکم تر تصاویر، دستیابی به نتایج دقیق تر بسیار مهم می‌باشد.

در ادامه این مقاله، در بخش ۲ کارهای مرتبط در حوزه تشخیص و شناسایی تومورهای سرطانی مغزی از روی تصاویر MRI و با استفاده از تکنیک‌های پردازش تصویر بررسی شده است و در بخش ۳، روش پیشنهادی مقاله به منظور تشخیص تومورهای مغزی از روی داده‌های تصویری MRI، با استفاده از مدل‌های یادگیری عمیق مبتنی بر الگوریتم‌های هوش جمعی، با جزئیات روش پیشنهادی در چندین زیرعنوان توصیف شده است. در بخش ۴، نتایج حاصل از آزمایش‌ها تحلیل و ارزیابی گردیده است و در نهایت، بخش ۵ به نتیجه‌گیری و کارهای آتی این مقاله پرداخته است.

۲- ادبیات و پیشینه پژوهش

شناسایی و تشخیص تومورهای مغزی یکی از پیچیده‌ترین و حساس‌ترین چالش‌ها در حوزه پزشکی به شمار می‌رود. تصاویر MRI، به عنوان یک ابزار کلیدی به منظور تشخیص و ارزیابی تومورهای سرطانی مغزی به کار می‌روند، اما تشخیص دقیق و صحیح این تومورها نیازمند تخصص بالا و تجربه فراوان پزشکان متخصص می‌باشد. این چالش به‌ویژه زمانی افزایش می‌یابد که تومور مغزی دارای شکل نامنظم باشد و یا در مراحل اولیه رشد قرار داشته باشد [14]. روش‌های سنتی تشخیص تومورهای سرطانی مغزی براساس تحلیل دستی تصاویر MRI، علاوه بر این که زمان‌بر و مستعد خطا هستند، به شدت وابسته به مهارت و تجربه پزشکان است. در این راستا، سیستم‌های هوشمند

مدل‌های ارائه شده، هنوز با چالش‌هایی نظیر کاهش نویز^۱ و دشواری در تعیین سطح درجه تومورها مواجه می‌باشند. برای حل این مشکلات، تعدادی از الگوریتم‌ها یا تکنیک‌های موجود توسعه یافته‌اند که هر یک مزایا و محدودیت‌های خود را دارند [۶، ۱۰]. شبکه‌های عصبی حلقوی معمولاً مشکل سازگاری داده‌ها را حل می‌کنند و همچنین، نرخ طبقه‌بندی دقیقی را ارائه می‌دهند که به زمان بیشتری برای آموزش مدل یادگیرنده نیاز دارد [۱۱].

هدف تقسیم‌بندی تومورهای سرطانی مغزی، شناسایی خودکار و دقیق اندازه و محل تومور مغزی از روی تصاویر MRI است، در حالی که تکنیک‌های یادگیری ماشین سنتی برای عملکرد مناسب به ویژگی‌های دست‌ساز نیاز دارند. بیشتر پژوهش‌های موجود در پیشینه تحقیق حوزه تقسیم‌بندی تومورهای سرطانی مغزی، بر روی استفاده از شبکه‌های یادگیری عمیق برای تقسیم‌بندی منطقه مورد علاقه^۲ از روی یک تصویر ورودی متمرکز شدند [۱۲]. مدل‌های یادگیری ماشین متفاوتی بر روی ویژگی‌های تصویری ساخته شده است که بافت‌های طبیعی یا بدخیم را دسته‌بندی می‌کنند. تقسیم‌بندی تومورهای سرطانی مغزی‌ای که با استفاده از یک مدل تولیدشده توسط یادگیری ماشین به دست می‌آید، به اطلاعاتی از تصاویر احتمالی نیاز دارد، در حالی که مدل‌های طبقه‌بندی نظیر ماشین بردار پشتیبان^۳ و جنگل تصادفی^۴، مدل‌های متمایز براساس ویژگی‌های بصری [۱۲] همچون هیستوگرام^۵ و بافت تصویر [۱۱] می‌باشند.

بهره‌برداری از الگوریتم‌های فرامکاشفه‌ای^۶ هوش جمعی^۷ برای بهینه‌سازی ابرپارامترهای مدل یادگیری ماشین شامل وزن‌های شبکه عصبی مصنوعی مبتنی بر یادگیری عمیق، که عملکردی مبتنی بر الگوریتم شبکه عصبی مصنوعی شعاعی خطی محلی تقویت شده^۸ می‌باشد، چراکه ظرفیت بالایی دارد و برای تجسم و بصری‌سازی و نیز انتقال استفاده می‌شود. نقطه کانونی مهم در مورد معاینه بیماران از روی تصاویر MRI تومورهای سرطانی مغزی، کاهش نویز در تصاویر رزونانس مغناطیسی نویزدار برای دفع بافت‌های سرطان مغز است. الگوریتم‌های هوش جمعی می‌توانند به منظور بهینه‌سازی ابرپارامترها و همچنین، تنظیم بهینه وزن‌های شبکه‌های عصبی مصنوعی مبتنی بر یادگیری عمیق استفاده گردند [۱۳].

⁸ Enhanced Local Linear Radial Artificial Neural Network (ELLR-ANN)

⁹ Benchmark Dataset

¹⁰ Particle Swarm Optimization (PSO)

¹¹ Ant Colony Optimization (ACO)

¹ Noise Reduction

² Region of Interest (ROI)

³ Support Vector Machine (SVM)

⁴ Random Forest (RF)

⁵ Histogram

⁶ Metaheuristic Algorithm

⁷ Swarm Intelligence (SI)

دارند. الگوریتم‌های طبقه‌بندی ماشین بردار پشتیبان و شبکه عصبی به دلیل دقت بالا مورد توجه بوده‌اند، اما چالش‌های نیازمندی به داده‌های زیاد و هزینه‌های محاسباتی هم‌چنان پابرجاست. تحلیل و ارزیابی این مطالعات نشان می‌دهد که مدل‌های مبتنی بر یادگیری عمیق و استفاده از الگوریتم‌های فرامکاشف‌های موجب بهبود دقت، صحت و سرعت مدل‌های یادگیرنده تشخیص تومورهای مغزی شده‌اند. به طور کلی، ترکیب هوشمندانه مدل‌های مختلف و بهینه‌سازی آن‌ها براساس ویژگی‌های داده‌های تصاویر MRI می‌تواند به توسعه الگوریتم‌های یادگیری دقیق‌تر و کارآمدتری در تشخیص تومورهای مغزی منجر گردد.

۳- روش پیشنهادی تحقیق

تقسیم‌بندی تومورهای مغزی نقش مهمی در پردازش تصاویر پزشکی دارد که موجب شناسایی زود هنگام، بهبود درمان و افزایش بقا بیماران می‌شود. تقسیم‌بندی دستی تومورها از روی حجم بالای تصاویر MRI کاری دشوار و زمان‌بر است، بنابراین تقسیم‌بندی خودکار و هوشمند تصاویر MRI تومورهای مغزی حیاتی است [۹]. در این بخش، چارچوب کلی مقاله و روش‌ها و الگوریتم‌های به کار رفته برای افزایش دقت و صحت تشخیص تومورهای مغزی معرفی شده‌اند. چارچوب پژوهش به گونه‌ای طراحی شده است که با استفاده از بهره‌گیری از یادگیری عمیق و الگوریتم‌های هوش جمعی، توانایی تشخیص تومورهای مغزی از تصاویر MRI بهبود یابد.

مراحل توسعه مدل یادگیری عمیق پیشنهادی تشخیص تومورهای مغزی از روی داده‌های تصویری MRI با استفاده از یک روش ترکیبی یادگیری عمیق و الگوریتم‌های هوش جمعی، در شکل (۲) نشان داده شده است. در مرحله اول، مجموعه داده‌های تصویری MRI مغزی به عنوان مجموعه داده‌های محک، از پایگاه داده جهانی Kaggle^۴ گردآوری شده است که شامل تصاویری با شفافیت و وضوح^۵ مختلف و اطلاعات مرتبط با تومورهای مغزی است. لذا، این مجموعه داده‌ها نیاز به عملیات پیش‌پردازش نظیر حذف نویز، نرمال‌سازی و تقسیم‌بندی تصاویر ندارند تا برای استفاده در مدل‌های یادگیری‌های ماشین و عمیق آماده‌سازی گردند.

در گام‌های دوم و سوم، مدل‌های متفاوتی از یادگیری عمیق با بهره‌برداری از شبکه‌های عصبی حلقوی عمیق (Deep CNN)، به منظور تشخیص تومورهای مغزی توسعه داده شده است. در

تشخیص تومورهای مغزی خودکار مبتنی بر یادگیری عمیق، توانسته‌اند با دقت و صحت بیشتری تومورهای سرطانی مغزی را شناسایی و تشخیص دهند. با این حال، این سیستم‌ها نیز با محدودیت‌هایی مواجه‌اند، از جمله نیازمندی به تنظیم بهینه و دقیق پارامترهای مدل یادگیرنده، مشکل حساسیت به داده‌های نویزی و عدم تعمیم‌پذیری به داده‌های متنوع [۱۵].

مدل‌های یادگیری عمیق مبتنی بر الگوریتم‌های فرامکاشف‌های، نظیر الگوریتم‌های تکاملی^۱ و هوش جمعی، حوزه کاربردی در پردازش تصویر هستند که به طور گسترده‌ای در مسائلی مانند تشخیص الگو^۲، تشخیص اجسام، تحلیل تصویر، و استخراج ویژگی‌ها از آن‌ها بهره‌برداری شده است. از رایج‌ترین الگوریتم‌های بهینه‌سازی فرامکاشف‌های هوش جمعی می‌توان به ازدحام ذرات (PSO) [۱۶] و کلونی مورچگان (ACO) [۲۰] اشاره نمود که در بسیاری از پژوهش‌های حوزه‌های مختلف نظیر پزشکی استفاده شده‌اند. الگوریتم‌های هوش جمعی، از رفتار و تعاملات اجتماعی پرندگان، ماهیان، و مورچگان در طبیعت الهام گرفته شده و براساس این تعاملات اجتماعی طراحی و شبیه‌سازی شده‌اند.

هدف اصلی الگوریتم‌های بهینه‌سازی هوش جمعی، یافتن بهینه سراسری^۳ در مسائل غیرخطی و چندبعدی است که هر ذره، پرند، مورچه و غیره نماینده یک پاسخ بالقوه در فضای جستجو است که اغلب با دو مؤلفه اصلی بهترین موقعیت شخصی و بهترین موقعیت سراسری جمعیت به‌روزرسانی می‌شوند. رفتار و حرکت هر نماینده پاسخ در فضای جستجو براساس ترکیبی از تجربه فردی و یادگیری اجتماعی صورت می‌پذیرد که منجر به هم‌گرایی تدریجی به سمت جواب بهینه می‌گردد.

در ادامه، به برخی از پژوهش‌های بررسی‌شده در حوزه تشخیص تومورهای سرطانی مغزی از روی تصاویر MRI که علاوه بر پردازش تصویر، از روش‌های یادگیری ماشین، یادگیری عمیق و الگوریتم‌های فرامکاشف‌های بهینه‌ساز هوشمند استفاده کرده‌اند، اشاره شده است که در جدول (۱) به طور خلاصه نشان داده شده است.

براساس جدول (۱) و نیز تحلیل و یافته‌های پیشینه پژوهش در حوزه تشخیص تومورهای سرطانی مغزی از روی تصاویر MRI با بهره‌گیری از یادگیری‌های ماشین و عمیق، و الگوریتم‌های بهینه‌ساز هوشمند، می‌توان بیان نمود که مدل‌ها و الگوریتم‌های گوناگونی برای تشخیص و طبقه‌بندی تومورهای مغزی از تصاویر MRI بررسی شدند که هر یک مزایا و محدودیت‌هایی

^۴ <https://www.kaggle.com/datasets/sartajbhuvaji/brain-tumor-classification-mri>

^۵ Resolution

^۱ Evolutionary Algorithm (EA)

^۲ Pattern Recognition (PR)

^۳ Global Optimal

نقاط قوت و محدودیت‌های مدل یادگیری عمیق پیشنهادی مبتنی بر الگوریتم‌های هوش جمعی شناسایی گردد. یافته‌ها می‌توانند مبنایی برای ارتقای دقت و صحت تشخیص خودکار تومورهای مغزی در پژوهش‌های آینده باشند. در ادامه، محیط نرم‌افزاری و سخت‌افزاری شبیه‌سازی، مجموعه داده‌های استفاده‌شده، معیارهای ارزیابی، فرآیند شبیه‌سازی مدل و نتایج ارزیابی آن مورد بررسی قرار گرفته است.

گام چهارم، مدل‌های یادگیری عمیق متفاوتی از شبکه‌های عصبی حلقوی که با هدف بهبودسازی، از الگوریتم‌های هوش جمعی ازدحام ذرات (Deep CNN-PSO) و کلونی مورچگان (Deep CNN-ACO) استفاده شده است، روی مجموعه داده تصاویر MRI مغزی پیش‌پردازش‌شده، آموزش داده شده و اجرا گردیدند تا الگوهای پیچیده و مشخصه‌های تومورهای مغزی سرطانی (بدخیم) و غیرسرطانی (خوش‌خیم) را شناسایی کنند. در گام پنجم، نتایج ارزیابی مدل‌های متفاوت تحلیل شده‌اند تا

جدول (۱)- برخی از پژوهش‌های تشخیص تومورهای مغزی از روی تصاویر MRI مبتنی بر یادگیری‌های ماشین و عمیق، و الگوریتم‌های بهینه-سازی فرامکاشف‌های

مرجع	روش پیشنهادی	معایب	نتایج آزمایش
[۱۶] ۲۰۱۱	SVM و تبدیل موجک ^۱ برای استخراج ویژگی‌های MRI	حجم کم داده‌های آموزشی، کاهش معیار دقت در تصاویر ناهنجار	دقت ۶۵٪
[۱۷] ۲۰۱۲	شبکه عصبی سلولی ^۲	افت دقت در تصاویر کم‌کیفیت، نیاز به تنظیمات پیچیده مدل CNN	دقت ۹۲.۵٪
[۱۸] ۲۰۱۷	محدودسازی توده‌ای سلول‌های غیرطبیعی با SVM و شبکه عصبی برای بخش‌بندی تصویر براساس ویژگی-ها و ابعاد ناحیه تومور	پیچیدگی آموزش شبکه‌های عصبی، حساسیت به تغییرات نوری در تصاویر، وجود نویز تصاویر	افزایش دقت و صحت نسبت به KNN ^۳ و درخت تصمیم
[۱۹] ۲۰۱۷	SVM وزنی ^۴ با فیلترهای میانگین برای حذف نویزهای تصاویر MRI و تبدیل موجک برای استخراج ویژگی‌های بافت تصویر	کاهش عملکرد در تصاویر با شرایط متفاوت (وجود نویز، تنوع بافت تومور)	دقت ۸۸.۷۲٪
[۲۰] ۲۰۱۸	الگوریتم ترکیبی PSO-LLRBFNN و تبدیل موجک برای تقسیم‌بندی و استخراج ویژگی‌های تصاویر MRI	فقدان جزئیات هزینه و پیچیدگی، گرافتان الگوریتم‌های بهینه‌سازی در حداقل‌های محلی	افزایش دقت و کاهش زمان نسبت به SVM و LMS-LLRBFNN
[۲۰] ۲۰۲۱	الگوریتم ترکیبی ACO-K-Means برای تقسیم‌بندی تصاویر MRI و بهبود فرآیند خوشه‌بندی	Grab Cut، مستعد گرافتان در کمینه‌های محلی	۷٪ بهبود دقت نسبت به تنها یک روش Grab Cut، مستعد گرافتان در کمینه‌های محلی
[۹] ۲۰۲۱	مرور روش‌های مؤثر تقسیم‌بندی تصاویر پزشکی با استفاده از یادگیری عمیق	نیاز به مجموعه داده‌های بزرگ، برچسب‌گذاری دقیق، منابع قوی محاسباتی، سخت‌افزار مناسب	آزمایش با مجموعه داده BRATS
[۲۱] ۲۰۲۲	شبکه رمزگذار خودکار U-Net برای تقسیم‌بندی تومورهای مغزی در تصاویر MRI	فقدان مقایسه با شبکه‌های عمیق دیگر، نیاز به تحلیل بهبود تشخیص نادرست تصاویر	دقت ۸۹٪
[۲۲] ۲۰۲۳	تشخیص بین پیشرفت تومور و پاسخ به درمان با رگرسیون داده‌های چندپارامتری و ترکیب ویژگی‌های هیستوگرام و بافت از روی چندقله‌ای ^۵ MRI	نیاز به تعداد زیاد ویژگی برای استخراج، تحلیل با وجود مشکل ابعاد، منابع محاسباتی قدرتمند	نتایج مطلوب در تمایز بین پیشرفت تومور و پاسخ به درمان در بیماران با GBM
[۶] ۲۰۲۳	دو مدل یادگیری عمیق DeepLab3 و ALCResNet مبتنی بر الگوریتم فرامکاشف‌های خفاش بهبودیافته برای بهینه‌سازی پیوسته ^۶	وابستگی دقت مدل به کیفیت و تعداد داده‌های آموزشی، استفاده از روش‌های پیچیده محاسباتی، نیاز به منابع محاسباتی قوی و زمان بیشتر برای آموزش و اجرا	بهبود ۱.۳٪ تا ۴.۴٪ دقت نسبت به سایر مدل‌های طبقه‌بندی
[۲۳] ۲۰۲۳	شبکه عصبی حلقوی تنظیم‌شده با ResNet50 و U-Net با مجموعه داده‌های TCGA-LGG و TCIA	پیچیدگی دو مدل ResNet50 و U-Net و نیاز به منابع محاسباتی قوی و زمان و هزینه بیشتر برای آموزش مدل	دقت بالا در تفکیک تومورهای مغزی

⁴ Weighted Support Vector Machine (WSVM)

⁵ Multi Modal

⁶ Improved Bat Algorithm for Continuous Optimization (IBCO)

¹ Wavelet Transform

² Cellular Neural Network (CNN)

³ K-Nearest Neighbor (KNN)


بافتی غیرخطی و تغییرات ساختاری کلان است، در مدل یادگیری پیشنهادی مبتنی بر شبکه عصبی حلقوی عمیق از چندین لایه استخراج ویژگی و به صورت سلسله مراتبی روی سیگنال‌های MRI استفاده شده است، به طوری که در لایه‌های ابتدایی ویژگی‌های فرکانس بالا و لایه‌ها، در لایه‌های میانی ناهمگنی‌های بافتی و در لایه‌های عمیق تر رفتار ساختاری و معنایی تومور استخراج و مدل سازی می‌شوند.

جدول (۲) - جریان داده در مدل پیشنهادی یادگیری عمیق

مبتنی بر الگوریتم هوش جمعی			
تغییرات ایجاد شده	پردازش انجام شده	ورودی داده	مرحله
یکنواخت سازی شدت، کاهش واریانس، آماده سازی برای یادگیری	تغییر اندازه به ۲۵۶×۲۵۶، نرمال سازی [۰،۱]، تقسیم داده	200 تصویر خام MRI (ابعاد متغیر)	پیش پردازش
استخراج ویژگی‌های چندمقیاسی (لبه، بافت، ساختار)	Conv + Pooling چندلایه	تصویر نرمال شده	استخراج ویژگی Deep CNN
بهبود همگرایی و کاهش بیش برزش	تنظیم نرخ یادگیری ^۱ و نورون‌ها	مدل CNN+آموزشی	بهینه سازی با PSO
افزایش نسبت سیگنال به نویز، کاهش پیچیدگی	حذف ویژگی‌های افزونه با فرومون	بردار ویژگی استخراج شده	انتخاب ویژگی با ACO
بهینه سازی همزمان ساختار و داده	آموزش نهایی شبکه	ویژگی‌های منتخب + ابر پارامترهای بهینه	مدل نهایی PSO+ACO

جدول (۳) - تحلیل کمی تغییرات داده در مسیر مدل پیشنهادی یادگیری عمیق مبتنی بر الگوریتم هوش جمعی

نتیجه بر عملکرد	اثر بر داده	نوع تغییر	سطح پردازش
پایداری یادگیری	کاهش نویز نسبی	مقیاس شدت	پیکسلی → نرمال شده
بهبود جداسازی کلاس	کاهش وابستگی به نویز	افزایش انتزاع	ویژگی سطح پایین → سطح بالا
افزایش دقت	حذف همبستگی اضافی	کاهش بعد	ویژگی کامل → ویژگی منتخب
کاهش خطا	بهبود همگرایی	تنظیم فضای جستجو	ابر پارامتر تصادفی → بهینه



شکل (۲) - مراحل توسعه مدل پیشنهادی یادگیری عمیق مبتنی بر الگوریتم هوش جمعی

در هر مرحله از توسعه مدل پیشنهادی یادگیری عمیق مبتنی بر الگوریتم هوش جمعی در شکل (۲)، داده از سطح خام پیکسلی به سطح انتزاعی ویژگی‌های معنایی منتقل شده است. در ابتدا، شدت سیگنال نرمال شده و سپس، ویژگی‌های چندمقیاسی استخراج شدند. در ادامه، الگوریتم هوش جمعی PSO به منظور تنظیم دقیق و بهینه ابر پارامترهای مدل یادگیری شبکه عصبی حلقوی عمیق پیشنهادی استفاده شده است و نیز، الگوریتم هوش جمعی ACO برای حذف ویژگی‌های غیر ضروری تصاویر MRI بهره‌برداری گردید. این تغییرات باعث افزایش نسبت سیگنال به نویز، کاهش پیچیدگی و در نهایت، افزایش ۱۲٪ معیار دقت نسبت به مدل پایه گردید که به طور کامل با هدف اصلی پژوهش هم‌سو بوده است.

علاوه بر آن، جریان داده در هر مرحله از توسعه مدل پیشنهادی که در شکل (۲) نشان داده شد، در جدول (۲) نمایش داده شده است، به طوری که ورودی داده، پردازش اعمال شده و تغییرات انجام شده در هر مرحله از پیاده سازی مدل پیشنهادی مشخص شده است.

علاوه بر آن، تحلیل کمی تغییرات داده در مسیر مدل پیشنهادی یادگیری عمیق مبتنی بر الگوریتم‌های هوش جمعی، در جدول (۳) نمایش داده شده است.

نوآوری‌های مدل پیشنهادی Deep CNN-PSO-ACO در این مقاله و تفاوت‌های عمده آن با سایر مدل‌های یادگیری عمیق تشخیص تومورهای مغزی مشابه بررسی شده در پیشینه پژوهش، در این است که به دلیل ماهیت چندمقیاسی در سیگنال‌های MRI که شامل تغییرات شدت موضعی، الگوهای

¹ Learning Rate

قالب آزمایش‌ها روی همین سیستم انجام شده است تا شرایط محیطی یکسان حفظ شده و امکان مقایسه دقیق فراهم گردد.

۳-۲- مجموعه داده‌های آزمایش‌شده

در این تحقیق، کلیه داده‌های تصویری MRI تومورهای مغزی آزمایش‌شده که توسط چندین مدل متفاوت یادگیری عمیق مبتنی بر شبکه‌های عصبی حلقوی بهینه‌شده با استفاده از الگوریتم‌های هوش جمعی، شامل Deep CNN استاندارد، Deep CNN-ACO، Deep CNN-PSO و Deep CNN-PSO-ACO اجرا گردیده‌اند، از وبسایت معتبر پزشکی Kaggle برداشت شده که قابل دسترسی می‌باشد. علاوه بر این که داده‌های تصویری MRI تومورهای مغزی جمع‌آوری شده در پایگاه اطلاعاتی Kaggle، به طور پیش‌فرض پاک‌سازی شده هستند، رکوردهای دارای مقادیر ناقص^۲ نیز حذف گردیدند که باعث شده تا اطلاعات تمیزی به مدل‌های یادگیری‌های ماشین و عمیق مختلف ارائه شده در مقاله داده شوند و میزان هزینه آماده‌سازی اطلاعات، به طور قابل توجهی کاهش یابد.

مجموعه داده‌های محک استفاده شده در این تحقیق، شامل مجموعه‌ای از ۱۰۰ عکس با تومور مغزی و ۱۰۰ عکس بدون تومور مغزی بوده است و همچنین، نمونه تصاویر دوبعدی MRI تومورهای مغزی با اندازه‌ها و وضوح متفاوت و از نوع JPEG و PNG است، که به منظور طبقه‌بندی تومورهای مغزی، براساس دو دسته برجسب تصاویر شامل با تومور سرطانی مغزی و بدون تومور مغزی، مورد استفاده قرار می‌گیرند. این تصاویر MRI تومورهای مغزی، قبل از ورود به مدل یادگیری عمیق، تحت فرآیندهای پیش‌پردازش، شامل تغییر اندازه تصاویر MRI و نرمال‌سازی قرار گرفتند. از آن جایی که ابعاد تصاویر دوبعدی MRI در اندازه‌های متفاوتی بودند، برای پردازش این تصاویر MRI در مدل‌سازی یادگیری عمیق مبتنی بر هوش جمعی، اندازه کلیه تصاویر به 256×256 پیکسل تغییر داده شده است. همچنین، مقادیر پیکسل‌های هر تصویر، در مقیاس صفر تا یک نرمال‌سازی شدند تا مدل‌های یادگیری عمیق بتوانند به طور مناسب‌تری با داده‌ها تعامل داشته باشند. به منظور تحلیل و ارزیابی مدل‌های یادگیری عمیق، مجموعه داده‌های تصاویر MRI تومورهای مغزی محک، به سه بخش داده‌های آموزش^۳ (۷۰٪)، آزمون^۴ (۱۵٪) و اعتبارسنجی^۵ (۱۵٪) تقسیم‌بندی شده است که به دلایلی شامل دقت بالای تقسیم‌بندی، تعداد مناسب نمونه‌ها، و تنوع تصاویر، نتایج ارزشمندی را برای تحلیل

به علاوه، در این مقاله از دو الگوریتم رایج هوش جمعی شامل PSO به منظور بهینه‌سازی ساختار و تنظیم ابرپارامترهای شبکه عصبی حلقوی عمیق پیشنهادی، و همچنین ACO برای انتخاب موثرترین ویژگی‌های تصاویر MRI بهره‌برداری شده است. این رویکرد باعث می‌شود که وابستگی شدید به تنظیمات دستی و همچنین، حساسیت به کیفیت داده‌های ورودی که در مدل‌های معمول وجود دارند، به طور چشم‌گیری کاهش یابد و منجر به نتایج پایدارتر با دقت و صحت مطلوبی گردد.

۳-۱- محیط نرم‌افزاری و سخت‌افزاری شبیه‌سازی و

اجرای آزمایش‌ها

به منظور پیاده‌سازی و شبیه‌سازی‌های مدل‌های یادگیری عمیق با هدف تشخیص تومورهای مغزی از روی تصاویر MRI، با استفاده از شبکه‌های عصبی حلقوی عمیق مبتنی بر الگوریتم‌های هوش جمعی شامل ازدحام ذرات (Deep CNN-PSO) و کلونی مورچگان (Deep CNN-ACO) و مدل ترکیبی نهایی پیشنهادی (Deep CNN-PSO-ACO)، از محیط نرم‌افزاری شامل زبان برنامه‌نویسی پایتون نسخه ۳.۱۲، کتابخانه‌های مربوط به یادگیری‌های ماشین و بهینه‌سازی‌ها، و ابزار Jupyter Notebook در پایتون استفاده شده است که دارای ابزارهای قوی برای توسعه پروژه‌های یادگیری ماشین می‌باشد، به طوری که مبتنی بر وب و منبع باز^۱ می‌باشد که امکان اجرای کدهای برنامه‌نویسی، تجزیه و تحلیل نتایج و اشتراک‌گذاری دستاوردها را در محیطی یکپارچه فراهم آورده است.

علاوه بر آن، به منظور شبیه‌سازی‌های فرآیند پیاده‌سازی مدل یادگیری عمیق، آموزش مدل، اجرای آزمایش‌ها، و ارزیابی نتایج آن‌ها، از مجموعه‌ای از کتابخانه‌های تخصصی مربوط به پردازش تصاویر برای پردازش تصاویر MRI تومورهای مغزی (Pandas و OpenCV)، مدل‌های یادگیری‌های ماشین و عمیق مبتنی بر شبکه‌های عصبی (Tensorflow و Keras)، الگوریتم‌های بهینه‌سازی هوش جمعی (Numpy)، مصورسازی داده‌ها و ارزیابی نتایج آموزش مدل (Matplotlib) استفاده شده است. محیط سخت‌افزاری مورد استفاده برای پیاده‌سازی الگوریتم‌های پیشنهادی در این مقاله، شامل یک سیستم رایانه شخصی با پردازنده Core i7 و معماری ۶۴ بیتی، به همراه ۲۵۶ مگابایت حافظه اختصاص یافته برای مجموعه داده تصاویر MRI و ۵۰ مگابایت برای نصب افزونه‌ها و ابزارهای شبیه‌سازی است. کلیه مراحل شبیه‌سازی و اجرای الگوریتم‌های یادگیری عمیق در

⁴ Test Data

⁵ Validation Data

¹ Open Source

² Missing Values

³ Train Data

که بیشترین تأثیر را در تفکیک کلاس‌ها دارند، باقی می‌مانند. به عبارتی دیگر، به‌طور عملی نویزهای پنهان، ویژگی‌های تکراری و الگوهای کم‌اثر حذف می‌شوند که نتیجه آن، افزایش نسبت سیگنال به نویز می‌باشد. الگوریتم هوش جمعی PSO در واقع به‌طور مستقیم ویژگی‌های سیگنال MRI را استخراج نمی‌کند، بلکه با تنظیم نرخ یادگیری و نیز تعداد نوروهای شبکه عصبی حلقوی عمیق باعث می‌شود تا شبکه عصبی عمیق ویژگی‌های پایدارتری را یاد بگیرد، از یادگیری نوسانی جلوگیری کند و به حداقل بهتر برسد. جمع‌بندی از طبقه‌بندی ویژگی‌های استخراج‌شده در معماری لایه‌ای شبکه عصبی حلقوی عمیق پیشنهادی، در جدول (۴) نمایش داده شده است.

جدول (۴) - طبقه‌بندی ویژگی‌های استخراج‌شده در مدل پیشنهادی یادگیری عمیق مبتنی بر الگوریتم هوش جمعی		
نقش در تشخیص	نوع ویژگی	سطح
مرزبندی تومور	لبه، گرادیان	اولیه
تمایز سالم / ناسالم	بافت، ناهمگنی	میانی
تصمیم نهایی	ساختار معنایی	عمیق
افزایش دقت	ویژگی منتخب	پس از الگوریتم ACO
بهبود همگرایی	ویژگی پایدار	پس از الگوریتم PSO

به‌طور کلی می‌توان بیان داشت که با توجه به ماهیت فیزیکی تصاویر MRI که حاصل برهم‌کنش سیگنال‌های رزونانس مغناطیسی با بافت‌های مختلف مغزی می‌باشند، این تصاویر دارای رفتار چندمقیاسی در حوزه شدت و نیز ساختار فضایی می‌باشند. سیگنال‌های MRI نه تنها شامل تغییرات شدت موضعی هستند، بلکه الگوهای بافتی پیچیده و تغییرات ساختاری کلان را نیز در برمی‌گیرند. از این‌رو، بهره‌گیری از معماری چندلایه در شبکه‌های عصبی حلقوی عمیق برای استخراج سلسله‌مراتبی ویژگی‌ها امری ضروری می‌باشد.

به‌عنوان جمع‌بندی عملیات استخراج سلسله‌مراتبی ویژگی‌های سیگنال MRI در معماری چندلایه شبکه عصبی حلقوی عمیق پیشنهادی (Deep CNN-PSO-ACO)، باید بیان نمود که در لایه‌های اولیه، فیلترهای پیچشی به‌طور عمده ویژگی‌های سطح پایین، شامل ویژگی‌های لبه‌ها، گرادیان شدت، تغییرات فرکانس بالا، و نواحی دارای کنتراست موضعی را استخراج کردند که نشان‌دهنده مرزهای بافتی بوده و برای شناسایی مرزهای اولیه تومور مغزی و تغییرات ناگهانی شدت سیگنال که ناشی از ناهمگنی بافت سرطانی است، اهمیت به‌سزائی دارند.

و ارزیابی مدل پیشنهادی یادگیری عمیق مبتنی بر هوش جمعی در این پژوهش فراهم کرده است.

۳-۳- استخراج ویژگی در مدل شبکه عصبی حلقوی عمیق پیشنهادی

استخراج ویژگی در مدل شبکه عصبی حلقوی عمیق پیشنهادی (Deep CNN-PSO-ACO)، به‌صورت سلسله‌مراتبی و چند مقیاسی انجام شده است. هر لایه پیچشی در شبکه عصبی، مسئول استخراج نوع خاصی از اطلاعات از سیگنال MRI است. ویژگی‌های استخراج‌شده در لایه‌های اولیه مدل، شامل نوع ویژگی‌های لبه‌ها، گرادیان شدت^۱، مرز بافت‌ها، تغییرات ناگهانی کنتراست، ساختارهای خطی، و منحنی کوچک هستند. سیگنال MRI دارای تغییرات موضعی است که ناشی از تفاوت چگالی پروتون، زمان لختی (T_1/T_2) و نیز ناهمگنی میدان مغناطیسی است. همچنین، در مرز بین ماده سفید، ماده خاکستری و بافت توموری، گرادیان شدت افزایش می‌یابد. خروجی این لایه‌ها شامل نقشه لبه‌ها و کنتراست‌ها می‌باشد که نقش این لایه، مشخص نمودن مرز اولیه تومور و شناسایی نواحی با تغییر شدت غیرعادی است.

ویژگی‌های استخراج‌شده در لایه‌های میانی مدل، شامل نوع ویژگی‌های الگوهای بافتی^۲، ناهمگنی بافت^۳، ساختارهای توده‌ای^۴، الگوهای غیرخطی شدت، و توزیع مکانی کنتراست می‌باشند. سیگنال MRI در این سطح، شامل بافت توموری، نواحی نکروتیک و تغییرات نامنظم است که این ناهمگنی در مقیاس متوسط ظاهر می‌شود. شبکه عصبی حلقوی عمیق در این لایه‌ها، ویژگی‌هایی مشابه GLCM، الگوهای موجکی و ساختارهای تکرارشونده را یاد می‌گیرد. ویژگی‌های استخراج‌شده در لایه‌های عمیق مدل، شامل نوع ویژگی‌های شکل کلی تومور، عدم تقارن مغزی، تغییر ساختار آناتومیک، الگوی رشد تومور و توزیع فضایی غیرطبیعی هستند. شبکه عصبی حلقوی عمیق در این سطح وابستگی‌های غیرموضعی را مدل‌سازی می‌کند. ویژگی‌های استخراج‌شده دیگر، لبه یا بافت نیستند، بلکه نمایش انتزاعی از وجود تومور می‌باشند. این همان چیزی است که در نهایت وارد لایه Dense شبکه عصبی حلقوی عمیق می‌شود.

پس از استخراج اولیه ویژگی‌ها، به‌منظور انتخاب ویژگی‌های موثر و بهینه با استفاده از الگوریتم هوش جمعی ACO، ویژگی‌هایی با همبستگی بالا حذف می‌شوند و فقط ویژگی‌هایی

³ Heterogeneity Texture

⁴ Mass-like Patterns

¹ Intensity Gradient

² Texture Patterns



در لایه‌های میانی، الگوهای بافتی پیچیده‌تر، ناهمگنی‌های غیرخطی تومور مغزی و ساختارهای موضعی در مقیاس متوسط مدل‌سازی شدند. از آن‌جا که بافت‌های توموری معمولاً دارای ساختار ناهمگن، رشد نامتقارن و تغییرات غیرخطی در شدت سیگنال می‌باشند، استخراج این نوع ویژگی‌ها نقش بسیار مهمی در تمایز دقیق بافت سالم از بافت آسیب‌دیده ایفا می‌کند. در لایه‌های عمیق، ویژگی‌های سطح بالا و ساختار معنایی و تغییرات آناتومیک مغز استخراج شدند که بیانگر ساختار کلی تومور مغزی، الگوی رشد، تغییرات مورفولوژیک و اختلال در تقارن طبیعی مغز می‌باشند. در نهایت، الگوریتم هوش جمعی ACO ویژگی‌های افزونه و بی‌اثر را حذف کرده و نیز الگوریتم PSO موجب پایداری یادگیری آن‌ها گردید.

این سطح از مراحل و رویکرد استخراج سلسله‌مراتبی، مبتنی بر رفتار چندمقیاسی سیگنال MRI می‌باشد، به‌طوری‌که امکان تصمیم‌گیری نهایی طبقه‌بندی تومور مغزی را براساس روابط فضایی گسترده‌تر و وابستگی‌های غیرموضعی فراهم می‌سازد. بنابراین، استفاده از چندین لایه استخراج ویژگی در مدل پیشنهادی، نه صرفاً به دلیل افزایش عمق شبکه عصبی، بلکه مبتنی بر رفتار چندمقیاسی سیگنال‌های MRI و ماهیت پیچیده و غیرخطی تومورهای مغزی طراحی شده است. این ساختار سلسله‌مراتبی امکان یادگیری تدریجی از ویژگی‌های ساده به ویژگی‌های پیچیده و معنایی را فراهم کرده و موجب بهبود دقت و پایداری مدل پیشنهادی در تشخیص تومورهای مغزی گردیده است.

۴-۳- شبیه‌سازی مدل یادگیری عمیق پیشنهادی

در این بخش، توسعه و پیاده‌سازی مدل پیشنهادی یادگیری عمیق ارائه شده است. ابتدا، مدل شبکه‌های عصبی حلقوی (Deep CNN) و نسخه‌های بهینه‌شده آن با الگوریتم‌های هوش جمعی شامل ازدحام ذرات (Deep CNN-PSO)، کلونی مورچگان (Deep CNN-ACO) و مدل ترکیبی نهایی (Deep CNN-PSO-ACO) شبیه‌سازی شدند. در این پیاده‌سازی، از ساختار Sequential برای ایجاد لایه‌های شبکه Conv2D، MaxPooling2D، Flatten و Dense استفاده گردید تا مدل یادگیری عمیق پیشنهادی به صورت ساختاریافته و قابل توسعه طراحی شود. لایه‌های حلقوی Conv2D برای استخراج ویژگی‌های مهم از روی تصاویر MRI تومورهای مغزی، و نیز لایه‌های تجمیع بیشینه MaxPooling2D برای

کاهش ابعاد^۱ فضایی استفاده شدند که باعث کاهش پیچیدگی محاسباتی و نیز کنترل بیش‌برازش^۲ شده است. به‌علاوه در فرآیند یادگیری، لایه‌های پیچشی با فیلترهای ۳×۳، ۶×۶ و ۱۲×۱۲ بیتی پیاده‌سازی شدند، با این هدف که ویژگی‌های ساده تا پیچیده‌تر در تصاویر، به صورت سلسله‌مراتبی استخراج گردند. پس از لایه‌های حلقوی، داده‌ها توسط لایه Flatten به یک بردار یک‌بعدی تبدیل گردیده و سپس، به لایه‌های کاملاً متصل Dense ارسال شدند. لایه‌های Dense به گونه‌ای طراحی شده‌اند که هر نورون آن با کلیه نورون‌های لایه قبلی ارتباط دارد، به‌طوری‌که این ساختار امکان ترکیب و تحلیل ویژگی‌های استخراج‌شده در مراحل قبل را فراهم می‌سازد و منجر به تصمیم‌گیری نهایی دسته‌بندی نمونه‌ها می‌شود.

در بخش خروجی مدل یادگیری عمیق، از تابع فعال‌سازی Softmax استفاده شده است. این تابع، برداری از مقادیر حقیقی را به یک توزیع احتمالی تبدیل می‌کند، به‌طوری‌که مجموع مقادیر خروجی برابر یک باشد، و به این ترتیب امکان طبقه‌بندی چندگانه را فراهم می‌آورد که برای تشخیص نوع تومور مغزی در تصاویر MRI مناسب می‌باشد. برای ارزیابی اختلاف بین خروجی مدل و برچسب‌های واقعی، از تابع Categorical Cross-Entropy استفاده شده است. این تابع ویژه مسائل طبقه‌بندی چندکلاسه طراحی شده است که با کمینه‌سازی آن، مدل قادر به پیش‌بینی‌های دقیق‌تر می‌شود. به‌منظور آموزش مدل‌های یادگیری عمیق مبتنی بر شبکه‌های عصبی حلقوی عمیق که شامل لایه‌های پیچشی و تجمیع است، ویژگی‌های موثر تصاویر MRI تومورهای مغزی توسط مدل‌های یادگیری عمیق استخراج شده و در نهایت طبقه‌بندی می‌کنند. دو مدل یادگیری عمیق مبتنی بر الگوریتم‌های هوش جمعی، شامل مدل Deep CNN-PSO که در آن، وزن‌ها و ابرپارامترهای شبکه عصبی حلقوی عمیق، با استفاده از الگوریتم بهینه‌سازی ازدحام ذرات تنظیم می‌شوند و مدل Deep CNN-ACO که در آن، موثرترین ویژگی‌های تصاویر MRI توسط الگوریتم بهینه‌سازی کلونی مورچگان استخراج می‌گردد. از داده‌های آموزشی تصاویر MRI تومورهای مغزی، در طول ۱۰ مرتبه Epochs انجام شده است، به‌طوری‌که در هر Epoch، کلیه نمونه‌های مجموعه داده آموزشی یک‌بار به مدل یادگیری عمیق ارائه می‌شوند و سپس، وزن‌ها و ابرپارامترهای شبکه عصبی حلقوی عمیق براساس میزان خطای موجود در شبکه عصبی، توسط الگوریتم PSO بهینه و به‌روزرسانی می‌گردند. تکرار این فرآیند در چند Epoch متوالی باعث می‌شود که مدل

² Overfitting

¹ Dimensional Reduction

یادگیری به تدریج الگوها و ویژگی‌های پنهان داده‌های تومور مغزی در تصاویر MRI را بهتر آموزش ببیند تا دقت و صحت طبقه‌بندی آن افزایش یابد. پس از آموزش مدل یادگیری عمیق، عملکرد و کارایی مدل با داده‌های آزمون ارزیابی شده‌اند. کد پیاده‌سازی شده پایتون و اجرای الگوریتم یادگیری عمیق مبتنی بر شبکه عصبی حلقوی با بهینه‌ساز هوش جمعی ازدحام ذرات Deep CNN-PSO در شکل (۳) نشان داده شده است که در آن، از الگوریتم بهینه‌سازی PSO برای یافتن بهینه‌ترین مقدار تعداد لایه‌ها، تعداد نرون‌ها در یک لایه Dense، و نیز نرخ یادگیری شبکه عصبی مصنوعی حلقوی به کار رفته است. مدل Deep CNN-PSO پیشنهادی بر روی داده‌های آزمون تصاویر MRI تومورهای مغزی تحلیل و ارزیابی گردیده است، به طوری که متغیر Score نتایج ارزیابی عملکرد و کارایی مدل پیشنهادی شامل خطا و دقت، صحت و خطای تشخیص تومورهای مغزی است. الگوریتم بهینه‌ساز PSO به دنبال کمینه کردن تابع هدف است، لذا برای بهبود دقت و صحت تشخیص تومورهای مغزی، مقدار 1-Accuracy بازگشت داده می‌شود تا الگوریتم PSO این مقدار را کمینه کند. اگر دقت مدل Deep CNN-PSO برابر ۰.۹۵ باشد، مقدار بازگشتی برابر ۰.۰۵ است که الگوریتم PSO به دنبال کمینه کردن آن است. الگوریتم Deep CNN-PSO با جستجو در فضای ابرپارامترهای شبکه عصبی حلقوی عمیق، بهینه‌ترین مقادیر را برای دو پارامتر نرخ یادگیری و تعداد نرون‌ها پیدا می‌کند تا دقت و صحت مدل Deep CNN افزایش یابد و خطا نیز به کمینه‌ترین مقدار برسد.

```
# تعریف مدل Deep CNN و تابع هدف برای PSO
def cnn_train_eval(params:(learning_rate,
num_neurons = params
model = sequential()
model.add(Conv2D(32,(3,3),activation='relu',input_shape=(128,128,3)))
model.add(MaxPooling2D((2,2)))
model.add(Conv2D(64,(3,3),activation='relu'))
model.add(MaxPooling2D((2,2)))
model.add(Flatten())
model.add(Dense(int(num_neurons),activation='relu'))
# تعداد نرون‌های بهینه‌شونده
model.add(Dropout(0.5))
model.add(Dense(1,activation='sigmoid'))
# خروجی دودویی

شکل (۳) - کد پایتون الگوریتم یادگیری عمیق مبتنی بر شبکه عصبی حلقوی با بهینه‌ساز ازدحام ذرات
```

مرحله بعدی، شبیه‌سازی و اجرای مدل یادگیری عمیق مبتنی - بر شبکه عصبی حلقوی با استفاده از الگوریتم هوش جمعی کلونی مورچگان (Deep CNN-ACO)، به منظور بهینه‌سازی انتخاب ویژگی‌های تصاویر MRI می‌باشد. در الگوریتم Deep CNN-ACO، مورچه‌ها مسیرهایی را در فضای ویژگی‌های تصاویر MRI جستجو می‌کنند تا بهینه‌ترین و موثرترین مجموعه ویژگی‌ها را برای مدل یادگیری عمیق انتخاب کنند. الگوریتم بهینه‌سازی ACO به شبکه عصبی حلقوی عمیق کمک کرده است تا با استفاده از بهترین ویژگی‌ها، دقت و صحت مطلوب‌تری در تشخیص تومورهای مغزی داشته باشد. شکل (۴)، کد پیاده‌سازی شده پایتون مربوط به الگوریتم پیشنهادی یادگیری عمیق مبتنی بر شبکه عصبی حلقوی با الگوریتم کلونی مورچگان (Deep CNN-ACO) که برای انتخاب موثرترین ویژگی‌های تصاویر MRI استفاده گردیده، نشان داده است.

ابتدا، بهترین زیرمجموعه از ویژگی‌های تصاویر MRI تومورهای مغزی و همچنین، بهترین دقت مدل یادگیری عمیق Deep CNN-ACO، برابر صفر قرار داده شدند. با استفاده از متغیر max_iter، الگوریتم به تعداد مشخصی تکرار اجرا شده است و با متغیر num_ants در هر تکرار، مورچه‌ها زیرمجموعه‌هایی از ویژگی‌ها را با توجه به مقادیر فرومون^۱ ایجاد کرده‌اند. دقت هر زیرمجموعه از ویژگی‌ها با یک مدل Deep CNN-ACO ارزیابی شده است. اگر دقت زیرمجموعه جدید از دقت قبلی بهتر بود، به عنوان بهترین زیرمجموعه ویژگی انتخاب می‌گردد. بعد از هر تکرار، فرومون‌ها با استفاده از بهترین زیرمجموعه ویژگی به روزرسانی می‌شوند. به عبارتی، الگوریتم با استفاده از فرومون‌ها، ویژگی‌های مناسب را جستجو و انتخاب کرده و سپس، با به روزرسانی فرومون‌ها، ویژگی‌های بهتر را تقویت می‌کند. هدف نهایی الگوریتم ACO، بهبود دقت و صحت مدل Deep CNN-ACO با انتخاب ویژگی‌های مناسب و حذف ویژگی‌های غیر ضروری است.

در گام نهایی شبیه‌سازی مدل یادگیری عمیق مبتنی بر شبکه عصبی حلقوی بهینه‌شده توسط الگوریتم‌های هوش جمعی، با الگوریتم PSO برای تنظیم ابرپارامترهای شبکه عصبی حلقوی عمیق شامل نرخ یادگیری و تعداد نرون‌ها، و همچنین الگوریتم ACO برای انتخاب بهترین ویژگی‌ها به طور هم‌زمان استفاده شده است. پس از بهینه‌سازی ابرپارامترهای Deep CNN و انتخاب موثرترین ویژگی‌های تصاویر MRI، مدل نهایی Deep CNN-PSO-ACO براساس همین مقادیر بهینه پیدا شده، به منظور آموزش تنظیم گردیده‌اند.

¹ Pheromone

تعداد نمونه‌های غلط شناسایی شده با تومور مغزی، و FN تعداد نمونه‌های غلط شناسایی شده بدون تومور مغزی می‌باشند [5].

$$\text{Precision} = \text{TP}/(\text{TP}+\text{FP}) \quad (1)$$

$$\text{Accuracy} = (\text{TP}+\text{TN})/(\text{TP}+\text{TN}+\text{FN}+\text{FP}) \quad (2)$$

دقت معیاری است که نشان می‌دهد، مدل یادگیری عمیق چه تعداد از پیش‌بینی‌ها را به درستی انجام داده است که با نسبت تعداد نمونه‌های صحیح پیش‌بینی شده به کل نمونه‌ها محاسبه شده است [5]. برای محاسبه معیار دقت مدل، از تابع evaluate موجود در کتابخانه Keras پایتون استفاده شده است، به طوری که پس از آموزش مدل یادگیری عمیق، معیار دقت بر روی داده‌های آزمون محاسبه شده است.

صحت معیاری است که نشان می‌دهد، مدل یادگیری عمیق چه تعداد از نمونه‌هایی که به عنوان مثبت با تومور سرطانی مغزی تشخیص داده است، واقعاً نمونه‌هایی با تومور سرطانی مغزی بوده‌اند. در واقع معیار صحت مدل یادگیری عمیق، نشان‌دهنده تعداد نمونه‌هایی است که مدل به عنوان تومور سرطانی مغزی شناسایی کرده است که به طور یقین تومور سرطانی بوده‌اند [5]. به منظور محاسبه معیار صحت مدل، از تابع precision_score موجود در کتابخانه sklearn در پایتون استفاده گردیده است، به طوری که پس از آموزش مدل، معیار صحت بر روی داده‌های آزمون محاسبه شده است.

۴- تحلیل و ارزیابی نتایج آزمایش مدل

یادگیری عمیق پیشنهادی

در این بخش، عملکرد و نتایج آزمایش‌های انجام شده توسط مدل‌های مختلف یادگیری عمیق به منظور تشخیص تومورهای مغزی، بر روی مجموعه داده تصاویر MRI مورد ارزیابی قرار گرفته است. تحلیل و ارزیابی نتایج آزمایش‌ها و اجرای چهار مدل متفاوت یادگیری عمیق روی مجموعه داده‌های تصاویر MRI، به منظور تشخیص تومورهای سرطانی مغزی، شامل مدل یادگیری شبکه عصبی حلقوی عمیق پایه (Deep CNN)، مدل یادگیری شبکه عصبی حلقوی عمیق با ابرپارامترهای بهینه‌شده توسط الگوریتم ازدحام ذرات (Deep CNN-PSO)، مدل یادگیری شبکه عصبی حلقوی عمیق با موثرترین ویژگی‌های تومورهای مغزی انتخاب شده توسط الگوریتم کلونی مورچگان (Deep CNN-ACO)، و در نهایت مدل نهایی یادگیری شبکه عصبی حلقوی عمیق با ابرپارامترهای بهینه‌شده و موثرترین ویژگی‌ها با ترکیب هم‌زمان الگوریتم‌های هوش جمعی ازدحام ذرات و کلونی مورچگان (Deep CNN-PSO-ACO) پرداخته شده است.

انتخاب ویژگی با ACO #

class ACOFeatureSelection :

def __init__(self, num_features) :

self.pheromone = np.ones(num_features)

def select_features(self) :

subset = self.generate_subset()

acc = self.evaluate(subset)

self.update_pheromones(subset)

return subset

def generate_subset(self) :

return np.random.rand(len(self.pheromone)) < self.pheromone

def evaluate(self, subset) :

model = build_cnn_model(input_shape=(128, 128, np.sum(subset)))

model.fit(train_data, epochs=5, verbose=0)

return model.evaluate(test_data, verbose=0)[1]

def update_pheromones(self, subset):

self.pheromone=0.9*self.pheromone+0.1*subset

aco = ACOFeatureSelection(num_features=128)

best_features = aco.select_features()

شکل (۴) - کد پایتون الگوریتم یادگیری عمیق مبتنی بر


شبکه عصبی حلقوی با بهینه‌ساز کلونی مورچگان

در جریان پیدا کردن بهینه‌ترین مقادیر متعلق به ابرپارامترهای مدل Deep CNN، شامل نرخ یادگیری و تعداد نرون‌ها توسط الگوریتم PSO و سپس، انتخاب موثرترین ویژگی‌های تومورهای مغزی توسط الگوریتم ACO، تابع cnn_train_eval مدل نهایی Deep CNN-PSO-ACO را در هر تکرار ارزیابی کرده است که در آن، تعداد ذرات ازدحام روی ۱۰ تنظیم گردیده و تعداد تکرار ارزیابی‌ها ۱۰ مرتبه در نظر گرفته شده است. در مرحله نهایی، ترکیب هم‌زمان الگوریتم‌های PSO و ACO به کار گرفته شده است تا بهینه‌ترین ابرپارامترهای مدل Deep CNN و موثرترین ویژگی‌های تصاویر MRI انتخاب گردد تا مدل Deep CNN-PSO-ACO آموزش داده شود و به بهترین نتایج ممکن در تشخیص تومورهای مغزی نائل گردد.

۵-۳- معیارهای ارزیابی آزمایش

در این تحقیق، به منظور ارزیابی عملکرد و کارایی مدل یادگیری عمیق پیشنهادی در تشخیص تومورهای مغزی از روی تصاویر MRI، از معیارهای استاندارد دقت و صحت استفاده شده است. رابطه‌های (۱) و (۲)، به ترتیب چگونگی محاسبه دقت و صحت مدل یادگیری عمیق را نشان می‌دهند، به طوری که پارامترهای TP تعداد نمونه‌های درست شناسایی شده با تومور مغزی، TN تعداد نمونه‌های درست شناسایی شده بدون تومور مغزی، FP

۰.۹۵ را نشان می‌دهد که قابل‌رقابت با مدل DeepLabV3 با همین مقدار است و بالاتر از مقادیر AUC حاصل از مدل‌های U-Net با مقدار ۰.۹۱، و Deep CNN با مقدار ۰.۹۳ می‌باشد. این افزایش مقدار AUC در مدل Deep CNN-PSO-ACO، نشان‌دهنده قدرت تفکیک‌پذیری بالای آن در تشخیص صحیح کلاس‌های تومورهای سرطانی و غیرسرطانی مغزی می‌باشد. نتایج نمودار ROC بیانگر آن است که ترکیب همزمان بهینه‌سازی ابرپارامترهای مدل Deep CNN توسط الگوریتم PSO و انتخاب ویژگی‌های مؤثر توسط الگوریتم ACO موجب بهبود توان تشخیص مدل پیشنهادی Deep CNN-PSO-ACO در جداسازی نمونه‌های مثبت و منفی تومورهای مغزی شده است.



شکل (۵)- نمودار ROC عملکرد و کارایی مدل‌های یادگیری عمیق پایه و مدل پیشنهادی Deep CNN-PSO-ACO

نتایج به‌دست‌آمده از آزمایش ارزیابی معیار دقت تشخیص تومورهای مغزی از روی تصاویر MRI توسط مدل یادگیری عمیق پیشنهادی Deep CNN-PSO-ACO، در مقایسه با دقت تشخیص تومورهای مغزی حاصل از مدل‌های یادگیری عمیق U-Net مبتنی بر شبکه رمزگذار خودکار [۲۱]، Deep CNN [۲] و DeepLabV3 [۶] در شکل (۶) نشان داده شده است، به‌طوری‌که نشان‌دهنده بهبود قابل‌توجهی در میزان دقت تشخیص مدل یادگیری عمیق پیشنهادی Deep CNN-PSO-ACO است. معیار دقت تشخیص تومورهای مغزی توسط مدل یادگیری عمیق پیشنهادی Deep CNN-PSO-ACO با مقدار ۰.۹۵، بالاترین دقت تشخیص تومورهای مغزی را در بین مدل‌های یادگیری عمیق داشته است و پس از آن به‌ترتیب، مدل U-Net با مقدار دقت ۰.۹۰، مدل یادگیری عمیق DeepLabV3 با مقدار دقت ۰.۸۹، و در نهایت مدل یادگیری عمیق Deep CNN با مقدار دقت ۰.۸۷ قرار گرفته‌اند.

ابتدا نتایج شبیه‌سازی آزمایش‌های حاصل از مدل‌های متفاوت یادگیری عمیق، شامل چهار مدل Deep CNN، Deep CNN-PSO، Deep CNN-ACO، و Deep CNN-PSO-ACO براساس معیارهای ارزیابی عملکرد و کارایی مدل شامل دقت و صحت، تحلیل و ارزیابی شده‌اند. علاوه بر این، نتایج شبیه‌سازی آزمایش‌های مربوط به مدل‌های یادگیری عمیق پیشنهادی در این تحقیق با نتایج مدل‌های یادگیری عمیق معتبر و مرور شده در پیشینه تحقیق که به‌منظور تشخیص تومورهای مغزی روی مجموعه داده‌های تصاویر MRI توسط محققان دیگر مورد استفاده و بهره‌برداری گرفته شده است، مقایسه شده است. همان‌طور که در بخش معیارهای ارزیابی آزمایش بیان گردید، معیارهای میزان هزینه (Loss)، دقت (Precision) و صحت (Accuracy) حاصل از اجرای مدل‌های یادگیری عمیق روی مجموعه داده‌های آزمون تصاویر MRI تومورهای مغزی، محاسبه شده‌اند.

عملکرد و کارایی الگوریتم‌های طبقه‌بندی دوکلاسه، به‌طور معمول با استفاده از معیارهایی نظیر دقت، صحت، حساسیت^۱ و صراحت^۲ سنجیده می‌شوند. معیار نمودار مشخصه عملکرد^۳ (ROC) که از دو معیار ترکیبی حساسیت و صراحت به‌صورت یک منحنی استفاده می‌کند، اغلب به‌منظور ارزیابی عملکرد و کارایی الگوریتم‌های طبقه‌بندی و مدل‌های یادگیری عمیق در یادگیری‌های ماشینی با نظارت به‌کار گرفته شده است. نمودار ROC نتایج به‌دست‌آمده از آزمایش سنجش میزان عملکرد و کارایی مدل پیشنهادی Deep CNN-PSO-ACO و چند مدل یادگیری عمیق دیگر که به‌عنوان پژوهش‌های پایه‌ای در این تحقیق به‌شمار می‌روند، شامل مدل U-Net مبتنی بر شبکه رمزگذار خودکار [۲۱]، دو مدل یادگیری عمیق Deep CNN [۲] و DeepLabV3 [۶] که مدل‌های طبقه‌بندی و درجه‌بندی کاملاً خودکار هستند، در شکل (۵) نشان داده شده است.


نمودار ROC نتایج حاصل از میزان عملکرد و کارایی مدل یادگیری عمیق پیشنهادی Deep CNN-PSO-ACO، در مقایسه با نتایج حاصل از مدل‌های U-Net، Deep CNN و DeepLabV3 نشان از بهبود قابل‌توجه عملکرد و کارایی تشخیص مدل یادگیری عمیق پیشنهادی Deep CNN-PSO-ACO دارد. به‌علاوه، مدل یادگیری عمیق پیشنهادی Deep CNN-PSO-ACO، دقت و حساسیت بالاتری نسبت به مدل‌های دیگر داشته است، به‌طوری‌که منطقه زیر منحنی^۴ (AUC) مدل پیشنهادی Deep CNN-PSO-ACO، مقدار

³ Receiver Operating Characteristic (ROC)

⁴ Area Under the Curve (AUC)

¹ Sensitivity

² Specificity




مطابق نتایج شکل (۷)، اختلاف اندک ۱٪ معیار صحت بین دو مدل Deep CNN-PSO-ACO و DeepLabV3 را می‌توان از چند منظر تحلیل نمود. اول این که معماری DeepLab3 دارای ساختار پیشرفته‌تری در استخراج ویژگی‌های چند مقیاسی است که ممکن است در کاهش نرخ مثبت کاذب مؤثرتر عمل نماید. دوم این که مدل Deep CNN-PSO-ACO اگرچه در تنظیم ابر پارامترهای Deep CNN و انتخاب ویژگی‌های مؤثرتر بهبود یافته است، اما معماری پایه‌ای آن همچنان مدل Deep CNN است که از نظر عمق و پیچیدگی معماری نسبت به مدل DeepLab3 ساده‌تر می‌باشد. با این حال، اختلاف ۱٪ معیار صحت از نظر عملیاتی چندان معنادار نبوده و با توجه به برتری مدل پیشنهادی در معیارهای AUC و دقت، می‌توان نتیجه گرفت که عملکرد کلی آن رقابتی و قابل قبول است.

نتایج به‌دست‌آمده از آزمایش ارزیابی معیار صحت تشخیص تومورهای مغزی از روی تصاویر MRI حاصل از اجرای مدل‌های یادگیری عمیق پیشنهادی Deep CNN-PSO-ACO، و سه مدل دیگر یادگیری عمیق شامل شبکه عصبی حلقوی عمیق استاندارد (Deep CNN)، شبکه عصبی حلقوی عمیق بهینه‌شده با ازدحام ذرات (Deep CNN-PSO)، و شبکه عصبی حلقوی عمیق بهینه‌شده با کلونی مورچگان (Deep CNN-ACO) در جدول (۵) نشان داده شده است.

جدول (۵) - نتایج معیارهای دقت و صحت تشخیص مدل‌های Deep CNN-ACO، Deep CNN-PSO، و Deep CNN

مدل یادگیری عمیق	Deep CNN-PSO-ACO			
	Deep CNN	Deep CNN-PSO	Deep CNN-ACO	Deep CNN-PSO-ACO
معیار دقت	۸۳٪	۸۷٪	۹۰٪	۹۵٪
معیار صحت	۸۰٪	۸۵٪	۸۸٪	۹۱٪



مطابق نتایج شکل (۶)، مدل پیشنهادی Deep CNN-PSO-ACO با دقت ۹۵٪، بالاترین مقدار را میان مدل‌های مقایسه‌شده کسب کرده است که این بهبود را می‌توان ناشی از دو عامل اصلی دانست: (۱) تنظیم بهینه ابر پارامترهای شبکه عصبی حلقوی عمیق توسط PSO که موجب جلوگیری از بیش‌برازش و بهبود همگرایی شد و (۲) انتخاب ویژگی‌های مؤثر توسط ACO که موجب کاهش نویز و حذف ویژگی‌های غیرضروری گردیده است.

نتایج به‌دست‌آمده از آزمایش ارزیابی معیار صحت تشخیص تومورهای مغزی از روی تصاویر MRI توسط مدل یادگیری عمیق پیشنهادی Deep CNN-PSO-ACO، در مقایسه با صحت تشخیص تومورهای مغزی حاصل از مدل‌های یادگیری عمیق U-Net مبتنی بر شبکه رمزگذار خودکار [۲۱]، و دو مدل یادگیری عمیق Deep CNN [۲] و DeepLabV3 [۶]، در شکل (۷) نشان داده شده است، به‌طوری که بهبود نسبی را در میزان صحت تشخیص تومورهای مغزی توسط مدل یادگیری عمیق پیشنهادی Deep CNN-PSO-ACO نسبت به مدل‌های U-Net و Deep CNN نشان می‌دهد. به‌عبارتی دقیق‌تر، میزان صحت تشخیص تومورهای مغزی توسط مدل یادگیری عمیق DeepLabV3 با مقدار ۹۸٪، بالاترین صحت تشخیصی را در بین مدل‌های یادگیری عمیق داشته است و پس از آن، مدل یادگیری عمیق پیشنهادی Deep CNN-PSO-ACO با مقدار صحت ۹۷٪ عملکرد مناسبی را نشان داده است، به‌طوری که میزان صحت تشخیصی بالاتری نسبت به مدل U-Net با مقدار صحت ۸۴٪ و مدل یادگیری عمیق Deep CNN با مقدار صحت ۸۸٪ را داراست.

۵- نتیجه‌گیری و کارهای آینده

در این پژوهش، مدل Deep CNN-PSO-ACO برای بهبود تشخیص و طبقه‌بندی تومورهای مغزی از تصاویر MRI ارائه شد. این مدل بر پایه شبکه عصبی عمیق (Deep CNN) طراحی شده و از دو الگوریتم هوش جمعی بهره می‌برد، PSO برای بهینه‌سازی ابرپارامترهای شبکه عصبی و ACO برای انتخاب مؤثرترین ویژگی‌های تصاویر MRI. هدف این ترکیب، افزایش دقت و کارایی مدل در شناسایی تومورهای مغزی سرطانی و غیرسرطانی است. نتایج شبیه‌سازی‌ها نشان داد که مدل پیشنهادی با دقت ۹۵٪ عملکرد مطلوبی در تشخیص تومورهای خوش‌خیم مغزی دارد و استفاده هم‌زمان از PSO و ACO موجب بهبود عملکرد و کارایی، افزایش دقت تشخیص و کاهش نرخ خطا شده است.

در ادامه، پیشنهاداتی برای توسعه و بهبود این پژوهش در آینده ارائه شده است:

- توسعه معماری‌های پیشرفته‌تر مبتنی بر شبکه‌های عصبی عمیق‌تر، و یا ترکیب معماری‌های مختلف نظیر ترکیب CNN و شبکه‌های عصبی بازگشتی^۱، یا مدل‌های مبدل^۲ که می‌تواند به بهبود عملکرد و کارایی مدل‌های یادگیری عمیق کمک شایانی نماید.
- بهره‌برداری از مدل‌های یادگیری انتقالی از پیش آموزش دیده‌شده که می‌تواند عملکرد و کارایی مدل‌های یادگیری عمیق را در داده‌هایی با حجم کوچک بهبود داده و سرعت یادگیری مدل را نیز افزایش دهد.

منابع

1. M.K. Abd-Ellah, A.I. Awad, H.F.A. Hamed, and A.A.M. Khalaf, Parallel deep CNN structure for Glioma detection and classification via brain MRI images, 31st Int. Conf. Microelectron. (ICM), 2019, pp. 304-307.
2. I.A.A. Alwan and F.A. Almarsoomi, MRI images series segmentation using the geodesic deformable model, Period. Engin. Natural Sci. 9 (2021), no. 1, 216-226.
3. N. Amiri Golilarz, H. Gao, R. Kumar, L. Ali, Y. Fu and C. Li, Adaptive wavelet-based MRI brain image de-noising, Front. Neuro. sci. 14 (2020), 728\.
4. S.M. Anwar, M. Majid, A. Qayyum and M. Awais, Medical image analysis using convolutional neural networks: a review, J. Med. Syst. 42 (2018), no. 11, 1-13.
5. Zadeh, N. and Ghaffari, "Detection of brain tumors from MRI images using 2D convolutional

نتایج ارزیابی معیارهای دقت و صحت تشخیص تومورهای مغزی توسط مدل‌های یادگیری عمیق، نشان‌دهنده بهبود قابل توجه-ای است که مدل یادگیری پیشنهادی شبکه عصبی حلقوی عمیق Deep CNN-PSO-ACO با مقدار ۹۵٪ دقت و ۹۱٪ صحت نسبت به سه مدل یادگیری شبکه عصبی حلقوی عمیق شامل Deep CNN با مقدار ۸۳٪ دقت و ۸۰٪ صحت، Deep CNN-PSO با مقدار ۸۷٪ دقت و ۸۵٪ صحت، و Deep CNN-ACO با مقدار ۹۰٪ دقت و ۸۸٪ صحت از خود نشان داده است که دلیل و نتیجه به کارگیری هم‌زمان دو الگوریتم هوش جمعی ازدحام ذرات PSO برای بهینه‌سازی ابرپارامترهای شبکه عصبی حلقوی عمیق، و ACO به منظور انتخاب مؤثرترین ویژگی‌های انتخاب‌شده از روی تصاویر MRI تومورهای مغزی در مدل Deep CNN-PSO-ACO می‌باشد.

تحلیل و ارزیابی نتایج آزمایش‌ها نشان می‌دهد که مدل پیشنهادی Deep CNN-PSO-ACO در مقایسه با سه مدل دیگر شبکه عصبی حلقوی عمیق شامل Deep CNN، Deep CNN-PSO و CNN-ACO عملکرد برتری دارد. بر اساس معیارهای AUC، دقت و صحت، این مدل با بهینه‌سازی هم‌زمان ابرپارامترهای شبکه عصبی و انتخاب مؤثرترین ویژگی‌ها از تصاویر MRI، توانسته است کارایی بالاتری نسبت به مدل‌های بدون بهینه‌سازی ارائه دهد.

روند افزایشی عملکرد و کارایی از مدل Deep CNN به سه مدل Deep CNN-PSO، Deep CNN-ACO و مدل پیشنهادی Deep CNN-PSO-ACO، نشان‌دهنده تأثیر مثبت هر دو الگوریتم هوش جمعی است. افزایش ۱۲٪ معیار دقت نسبت به مدل پایه Deep CNN نشان می‌دهد که بهینه‌سازی هم‌زمان تنظیم ابرپارامترهای Deep CNN و همچنین، انتخاب ویژگی‌های مؤثرتر، اثر هم‌افزایی داشته است که موجب بهبود پایدار عملکرد مدل پیشنهادی شده است.

از طرفی دیگر، با وجود برتری مدل پیشنهادی در اغلب معیارها، ارزیابی نتایج آزمایش‌ها نشان می‌دهد که معماری مدل‌های یادگیری عمیق‌تر مانند DeepLab3 در برخی شاخص‌ها نظیر صحت، عملکرد بهتری دارند. این موضوع نشان می‌دهد که علاوه بر بهینه‌سازی ابرپارامترهای Deep CNN، نوع معماری شبکه عصبی عمیق نیز نقش تعیین‌کننده‌ای در عملکرد نهایی مدل دارد. بنابراین در پژوهش‌های آتی می‌توان از ترکیب الگوریتم‌های هوش جمعی با معماری‌های عمیق‌تر و چندمقیاسی شبکه عصبی استفاده نمود تا به بهبود بیشتر عملکرد مدل یادگیری دست یافت.

² Transformer Model

¹ Recursive Neural Network (RNN)

Sensing, Signal Processing and Security. (2017) (ICSSS), IEEE.

19. Rezaei, K., et al. "Segmentation and Classification of Brain Tumor CT Images Using SVM with Weighted Kernel Width." *Computer Science & Information Technology*. (2017) 39.

20. Krishna, T. G., et al. "Detection and classification of brain tumor from MRI medical image using wavelet transform and PSO based LLRBFNN algorithm." *Int. J. Comput. Sci. Eng.* (2018)6(1): 18-23.

21. Walsh J. et al. (2022). "Using U-Net network for efficient brain tumor segmentation in MRI images." *Healthcare Analytics* 2: 100098.

22. H. Wang, Y. Li, S. Xi, S. Wang, M.S. Pathan, S. Dev, AMDCNet: An attentional multi-directional convolutional network for stereo matching, *Displays* (2022)102243.

23. Asiri .A. A. et al. (2023). "Brain tumor detection and classification using fine-tuned CNN with ResNet50 and U-Net model: A study on TCGA-LGG and TCIA dataset for MRI applications." *Life* 13(7): 1449.

network." *Scientific Research Journal of Internal Medicine* 26(4): 398-413(2020).

6. Yaqub .M. et al. (2023). "DeepLabV3 .JBCO-based ALCResNet: A fully automated classification and grading system for brain tumor." *Alexandria Engineering Journal* 76: 609-627.

7. Sultan, H.H., N.M. Salem, and W.J.I.a. Al-Atabany, Multiclassification of brain tumor images using deep neural network.2019. 7: p. 69215-69225.

8. Asiri .A.A.; Shaf .A.; Ali .T.; Aamir .M.; Usman .A.; Irfan .M.; Alshamrani .H.A.; Mehdar .K.M.; Alshehri .O.M.; Alqhtani .S.M. Multi-Level Deep Generative Adversarial Networks for Brain Tumor Classification on Magnetic Resonance Images. *Intell. Autom. Soft Comput.* 2023\۲۷. ۳۶. ۱۴۳-143 .

9. X. Liu .L. Song .S. Liu .Y. Zhang .A review of deep-learning-based medical image segmentation methods .*Sustainability* 13 (3) (2021) 1224

10. M. Sajjad et al, Multi-grade brain tumor classification using deep CNN with extensive data augmentation 30 (2019) 174–182.

11. Meier .R.; Bauer .S.; Slotboom J.; Wiest .R.; Reyes .M. Appearance-and context-sensitive features for brain tumor segmentation. In *Proceedings of the MICCAI BraTS Challenge* .Boston .MA .USA ۱۴ . September 2014; pp. 20–26.

12. Kleesiek J.; Biller .A.; Urban .G.; Köthe .U.; Bendzsus .M.; Hamprecht .F.A. Ilastik for multi-modal brain tumor segmentation. In *Proceedings of the MICCAI BraTS (Brain Tumor Segmentation Challenge)* .Boston .MA .USA ۱۴ .September 2014; pp. 12–17.

13. Kasihmuddin, M. S. B. M., et al. "Satisfiability logic analysis via radial basis function neural network with artificial bee colony algorithm." (2021)

14. Hunnur, S. S., et al. (2017). Implementation of image processing for detection of brain tumors. 2017 *International Conference on Computing Methodologies and Communication (ICCMC)*, IEEE.

15. Haraty, R. A., et al. "An enhanced k-means clustering algorithm for pattern discovery in healthcare data." *International Journal of distributed sensor networks*. (2015) 11(6): 615740.

16. Othman, M. F. B., et al. MRI brain classification using support vector machine fourth international conference on modeling, simulation and applied optimization IEEE.

17. Abdullah, A. A., et al. (2012). "Design of cellular neural network (CNN) simulator based on MATLAB for brain tumor detection." *Journal of medical imaging and health informatics*, (2011)2(3): 296-306.

18. Kumar, T. S., et al. Brain tumor detection using SVM classifier. 2017 *Third International Conference on*