

Brain Tumor Detection and Classification Based on MRI Images Using Deep Learning and Transfer Learning Models

Samira Mavaddati¹, Hanieh Sadat Azhari Lamraski²

¹ Assistant Professor, Department of Electrical Engineering, Faculty of Engineering and Technology, University of Mazandaran, Babolsar, Iran
s.mavaddati@umz.ac.ir

² BSc, Department of Electrical Engineering, Faculty of Engineering and Technology, University of Mazandaran, Babolsar, Iran,
hahaazlem@gmail.com

Abstract:

Brain tumors are among the most common and fatal types of cancer. Accurate and timely diagnosis of these tumors is essential for disease management and successful patient prognosis. Additionally, the precise identification of the tumor type is crucial in determining the treatment path. By recognizing the type of tumor, doctors can select the most appropriate treatment method, which may include surgery, radiation therapy, chemotherapy, or a combination of these methods. Furthermore, the tumor type helps predict disease progression and the quality of life post-treatment. In recent years, deep learning has been a powerful tool for various image-processing tasks, including brain tumor detection. In this paper, various deep learning models such as CNN, RNN, VGG16, InceptionV3, and ResNet101 are evaluated for classifying brain tumor types from the Figshare dataset based on MRI images of glioma, meningioma, pituitary tumors, and no tumor. Finally, a suitable deep model based on ResNet101 combined with transfer learning is proposed. Based on various metrics and statistical tests, the findings indicate that deep learning models can be effectively used for brain tumor detection. Among these, the ResNet101 model achieved an accuracy of 98.37% in classifying the four tumor classes. This study demonstrates that deep learning holds significant potential for improving brain tumor detection accuracy.

Keywords: Brain tumor detection, Deep learning, Transfer learning, Figshare dataset, Image processing, ResNet101, Deep neural network

Article Type: Research

Received: 25. 12. 2024

Revised: 26. 02. 2025

Accepted: 15. 03. 2025

Corresponding author: S. Mavaddati

Corresponding author's address: Department of Electrical Engineering, Faculty of Engineering and Technology, University of Mazandaran, Babolsar, Iran



1. Motivation of the work

Brain tumors are among the most severe and life-threatening types of cancer, requiring accurate and early detection to improve patient survival and treatment outcomes. Traditional diagnostic approaches rely on manual MRI analysis, which is time-intensive and susceptible to human error. The rapid advancements in deep learning have provided automated, highly accurate solutions for medical image analysis, significantly enhancing diagnostic precision. With the increasing availability of medical imaging datasets, deep learning techniques have emerged as transformative tools in diagnosing and classifying brain tumors. Despite these advancements, there remains a need to optimize model performance and ensure generalizability across diverse datasets. This study seeks to leverage state-of-the-art deep learning architectures to enhance the accuracy and efficiency of brain tumor classification, contributing to improved medical decision-making and patient care.

2. Contributions

This research makes several significant contributions. Firstly, it systematically evaluates multiple deep learning architectures, including CNN, RNN, VGG16, InceptionV3, and ResNet101, to determine their effectiveness in brain tumor classification. Secondly, it utilizes the Figshare dataset, which includes MRI images of glioma, meningioma, pituitary tumors, and non-tumor cases, ensuring comprehensive model training and validation. Thirdly, it introduces an enhanced classification approach by integrating transfer learning with ResNet101, demonstrating a substantial improvement in diagnostic accuracy. Finally, statistical analysis and performance metrics are employed to validate the effectiveness of the proposed model, highlighting its superiority over conventional methods. The insights derived from this study provide valuable contributions to the field of medical imaging and AI-driven diagnostics.

3. Procedures

The research follows a structured methodology to achieve high-accuracy brain tumor classification. Initially, dataset preprocessing is performed to enhance image quality, normalize pixel values, and standardize input dimensions. Various deep learning models, including CNN, RNN, VGG16, InceptionV3, and ResNet101, are trained and fine-tuned on the Figshare dataset. Transfer learning is applied to ResNet101 to facilitate feature extraction and improve generalization. The models are evaluated using performance metrics such as accuracy, precision, recall, and F1-score to assess their classification capabilities. Additionally, statistical significance tests are conducted to ensure the reliability of the results. The proposed framework is designed to optimize classification performance while ensuring computational efficiency and robustness.

4. Findings

The findings of this study highlight the effectiveness of deep learning models in brain tumor detection. Among the evaluated architectures, ResNet101 with transfer learning achieves the highest classification accuracy of 98.37%, significantly outperforming other models. The proposed approach demonstrates superior generalization capabilities, making it a viable solution for real-world medical diagnostics. The results emphasize the potential of deep learning to reduce diagnostic errors, streamline the classification process, and assist radiologists in making more informed decisions. Furthermore, the study underscores the importance of transfer learning in leveraging pre-trained models for enhanced feature extraction and classification accuracy. These findings confirm that AI-driven methodologies can play a transformative role in medical imaging and brain tumor diagnostics.

5. Conclusion

This research illustrates the substantial advantages of employing deep learning techniques, particularly transfer learning with ResNet101, in brain tumor classification. The high accuracy achieved underscores the feasibility of integrating AI-based solutions into medical diagnostics, paving the way for more reliable and efficient tumor detection. The study provides evidence that deep learning can enhance diagnostic accuracy, reduce human error, and support clinical decision-making. Future research may focus on further optimizing model performance, incorporating larger datasets, and deploying AI-driven systems in real-world clinical environments. These advancements will contribute to the continuous evolution of AI applications in healthcare, improving patient outcomes and medical workflow efficiency.

تشخیص و طبقه‌بندی تومورهای مغزی با استفاده از مدل‌های یادگیری عمیق و یادگیری انتقالی بر پایه تصاویر MRI

سمیرا مودتی^۱، هانیه سادات اظهري لمراسکی^۲

۱- استادیار گروه مهندسی برق- دانشکده مهندسی و فناوری- دانشگاه مازندران- بابلسر- ایران

s.mavaddati@umz.ac.ir

۲- کارشناسی مهندسی برق- دانشکده مهندسی و فناوری- دانشگاه مازندران- بابلسر- ایران

hahaazlem@gmail.com

چکیده: تومورهای مغزی یکی از شایع‌ترین و کشنده‌ترین نوع سرطان هستند. تشخیص دقیق و به موقع این دسته از تومورها برای مدیریت بیماری و پیش‌آگهی موفق بیمار، ضروری است. همچنین تشخیص دقیق نوع تومور مغزی نقشی حیاتی در تعیین مسیر درمان ایفا می‌نماید. با شناخت نوع تومور، پزشک می‌تواند مناسب‌ترین روش درمانی را انتخاب کند که می‌تواند شامل جراحی، پرتودرمانی، شیمی درمانی یا ترکیبی از این روش‌ها باشد. همچنین نوع تومور به پیش‌بینی پیشرفت بیماری و کیفیت زندگی پس از درمان بیمار کمک می‌نماید. در سال‌های اخیر، یادگیری عمیق به عنوان ابزاری قدرتمند برای وظایف مختلف پردازش تصویر، از جمله تشخیص تومور مغزی، بکار گرفته شده است. در این مقاله، مدل‌های مختلف یادگیری عمیق مانند RNN، CNN، VGG16، InceptionV3 و رزنت ۱۰۱ به منظور تشخیص نوع تومور مغزی از مجموعه داده Figshare مبتنی بر تصاویر ام‌آر‌آی تومورهای مغزی گلیوم، مننژیوم، هیپوفیز، و بدون تومور بررسی و در نهایت یک مدل عمیق مناسب مبتنی بر رزنت ۱۰۱ در ترکیب با یادگیری انتقالی پیشنهاد می‌شود. یافته‌های مقاله براساس معیارهای مختلف و نیز تست آماری نشان می‌دهد که مدل‌های عمیق می‌توانند به طور موثر برای تشخیص تومور مغزی مورد استفاده قرار گیرند. در این میان مدل عمیق رزنت ۱۰۱ توانسته است دقت ۹۸٪/۳۷ در تشخیص چهار کلاس معرفی شده را بدست آورد. این مطالعه نشان می‌دهد که یادگیری عمیق پتانسیل قابل توجهی برای بهبود دقت تشخیص تومور مغزی را دارد.

کلمات کلیدی: تشخیص تومور مغزی، یادگیری عمیق، یادگیری انتقالی، مجموعه داده Figshare، رزنت ۱۰۱، پردازش تصویر، شبکه‌های عصبی عمیق

نوع مقاله: پژوهشی

دریافت: ۱۴۰۳/۱۰/۰۵

بازنگری: ۱۴۰۳/۱۲/۰۸

پذیرش: ۱۴۰۳/۱۲/۲۵

نام نویسنده‌ی مسئول: سمیرا مودتی

نشانی نویسنده‌ی مسئول: ایران - مازندران - پردیس دانشگاه مازندران - دانشکده‌ی مهندسی و فناوری

۱- مقدمه

در سال‌های اخیر، شاهد افزایش نگران‌کننده‌ای در آمار شیوع تومورهای مغزی در سراسر جهان هستیم. تشخیص تومورهای مغزی فرآیندی پیچیده اما ضروری برای ارائه مراقبت مناسب از بیماران مبتلا به این بیماری است. تشخیص دقیق نوع و محل تومور برای انتخاب بهترین روش درمانی و پیش‌بینی نحوه پیشرفت بیماری حیاتی است [۱-۲]. در این راستا، پردازش تصویر و یادگیری ماشین نقش حیاتی ایفا می‌کنند. پردازش تصویر به تجزیه و تحلیل تصاویر پزشکی مانند ام‌آر‌آی^۱ MRI و سی‌تی اسکن^۲ CT می‌پردازد، در حالی که یادگیری ماشین الگوریتم‌هایی را ارائه می‌دهد که می‌توانند از این تصاویر برای شناسایی و طبقه‌بندی تومورها به طور خودکار یاد بهره بگیرند. مدل‌های عمیق^۳ نیز، نوعی از شبکه‌های عصبی مصنوعی هستند که در این زمینه به طور خاص مفید بوده‌اند و به طور قابل توجهی دقت تشخیص را افزایش می‌دهند [۳-۴]. مزایای استفاده از مدل‌های عمیق شامل دقت بالا، سرعت بالا، ماهیت غیرتجانسی و توانایی یادگیری و انطباق با داده‌های جدید است. پژوهش‌ها در این زمینه به طور فعال در حال انجام است و مدل‌های یادگیری ماشینی و عمیق به طور فزاینده‌ای به منظور ارتقای دقت، کارایی و قابلیت اطمینان در تشخیص تومور مغزی به کار گرفته می‌شوند. این امر به طور بالقوه می‌تواند منجر به بهبود قابل توجهی در نتایج درمانی و کیفیت زندگی بیماران مبتلا به این بیماری چالش‌برانگیز شود.

[۵]، روشی مبتنی بر یادگیری عمیق برای تشخیص دقیق تومورهای مغزی با استفاده از تصاویر ام‌آر‌آی ارائه می‌دهد. شبکه پیشنهادی بر پایه U-Net است و با تغییراتی در لایه‌ها، عملکرد آن در تشخیص بخش‌های مختلف تومور بهبود یافته است. مراحل اصلی این روش شامل پیش‌پردازش تصویر با استفاده از روش‌هایی مانند افزایش دامنه شدت و بهبود کنتراست است. در [۶]، روشی مبتنی بر یادگیری عمیق دو مسیره برای تشخیص تومور مغزی از تصاویر ام‌آر‌آی ارائه شده است. در این روش، تصاویر به صورت تکه‌هایی با چهار حالت برش داده

اطلاعات موجود در تصاویر ام‌آر‌آی و سی‌تی اسکن، از استخراج ویژگی‌های متمایزکننده بافت تومور و بافت سالم مغز استفاده می‌نماید. [۹]، به بررسی تعداد زیادی مقاله در مورد کاربرد روش‌های یادگیری عمیق برای تشخیص تومور مغزی گلیوم از تصاویر ام‌آر‌آی می‌پردازد. در این روش‌ها، پس از جمع‌آوری تصاویر ام‌آر‌آی، تصاویر پیش‌پردازش شده و سپس برای آموزش مدل یادگیری عمیق با یکی از رویکردهای بخش‌بندی، دسته‌بندی یا آشکارسازی تومور استفاده می‌شوند. در [۱۰]، روشی برای تشخیص هوشمند تومورهای مغزی با استفاده از مدل‌های یادگیری عمیق ارائه شده است که شامل دو مرحله است. مرحله اول استخراج ویژگی است که از یک شبکه عصبی کانولوشنی عمیق دوازده لایه برای استخراج ویژگی‌های تصاویر ام‌آر‌آی تومور مغزی استفاده می‌نماید. در مرحله دوم از یک طبقه‌بندی‌کننده Softmax تک لایه برای طبقه‌بندی تصاویر بر اساس سه کلاس تومور مننژیوم، گلیوم و هیپوفیز استفاده می‌شود. در [۱۱]، یک الگوریتم طبقه‌بندی‌کننده ارائه شده است که از هفت مدل عمیق کانولوشنالی از قبل آموزش‌دیده با استفاده از تصاویر شاخص خطر بدخیمی برای طبقه‌بندی تومورهای مغزی بهره می‌گیرد. همچنین، یادگیری انتقالی برای مدلی که از قبل بر روی یک مجموعه داده ImageNet آموزش دیده‌اند، اعمال می‌شود. در [۱۲]، یک روش طبقه‌بندی خودکار چندوجهی مبتنی بر یادگیری عمیق برای دسته‌بندی انواع مختلف تومورهای مغزی در پنج مرحله معرفی شده است. در مرحله اول، تبدیل کسینوس گسسته و یکسان‌سازی هیستوگرام مبتنی بر لبه برای شبیه‌سازی کشش کنتراست خطی استفاده می‌شود. در ادامه، دو مدل CNN^۴ از پیش آموزش‌دیده، VGG16^۵ و VGG19^۶، برای استخراج ویژگی‌های عمیق براساس تکنیک یادگیری انتقالی، پیاده‌سازی می‌شوند. روش‌های افزونگی داده^۷ تصویر و یادگیری انتقالی برای در نظر گرفتن اثر اندازه مجموعه داده و قدرت محاسباتی در طبقه‌بندی تومورهای مغزی در [۱۳]، استفاده شده است. در این مقاله، اثر پارامترهای مختلف تنظیم شده در مرحله یادگیری مانند عرض، عمق و ویژگی‌های مقیاس‌بندی وضوح شرح داده شد. یک مرور جامع از طبقه‌بندهای تومور مغز و روش‌های تقسیم‌بندی مورد استفاده بر روی مدل‌های مبتنی بر یادگیری ماشین، مبتنی بر CNN، مبتنی بر شبکه‌های عصبی کپسولی و مبتنی بر ViT^۸ در [۱۴] ارائه شده است. همچنین محدودیت‌های مختلف هر یک از این مدل‌ها شرح داده شده است. یک مدل جدید مبتنی بر همجوشی عمیق در [۱۵] برای طبقه‌بندی تومورهای مغزی از تصاویر ام‌آر‌آی مورد مطالعه قرار گرفته است. ویژگی‌های سطح پایین و سطح بالا از معماری‌های AlexNet، GoogLeNet و رزنت۱۸ با تنظیم پارامترهای عمق و طراحی مختلف استخراج شده‌اند. بردارهای ویژگی ادغام‌شده برای شناسایی تومورهای مغزی با استفاده از طبقه‌بندی‌کننده‌های ماشین بردار پشتیبان -K- نزدیکترین همسایه مورد استفاده قرار گرفته‌اند. مجموعه مدل‌های یادگیری عمیق در ترکیب با مدل‌های مختلف مانند CNN، تومورهای

می‌شوند و فقط پیکسل‌های داخلی هر بخش برای آموزش مدل استفاده می‌شود. مدل از دو مسیر تشکیل شده است، یک مسیر کوچک برای استخراج ویژگی‌های محلی و یک مسیر بزرگتر برای استخراج اطلاعات زمینه. یک روشی جدید برای تشخیص خودکار تومور مغزی با استفاده از تصاویر ام‌آر‌آی در [۷] معرفی شده است. این روش از یادگیری عمیق و مکانیزم توجه برای بهبود دقت تشخیص استفاده می‌کند. مراحل اصلی این روش شامل پیش‌پردازش تصویر با استفاده از روش‌هایی مانند افزایش دامنه شدت و بهبود کنتراست است. از مکانیزم توجه، به منظور تمرکز مدل بر روی تومور و بافت‌های اطراف آن و حذف نویز پس‌زمینه استفاده می‌شود. در [۸]، روشی جدید برای تشخیص تومور مغزی با استفاده از تصاویر ام‌آر‌آی و سی‌تی اسکن ارائه شده است. این روش از یادگیری عمیق برای تلفیق

شده است. همچنین الگوریتم ارائه شده، با طبقه‌بندی‌کننده مبتنی بر یادگیری واژه‌نامه براساس فاکتورسازی ماتریس غیرمنفی تَنک (SNMF^۹) نیز مقایسه می‌شود. در زمینه تشخیص تومور مغزی، مدل‌های عمیق می‌توانند به طور خودکار ویژگی‌های مرتبط با تومور را از تصاویر استخراج نمایند و دقت تشخیص را به طور قابل توجهی افزایش دهند. یافته‌ها در این مقاله عبارتند از:

- تشخیص دقیق نوع تومور مغزی از تصاویر ام‌آرآی با استفاده از مدل‌های یادگیری عمیق.
- مقایسه عملکرد مدل‌های مختلف یادگیری عمیق از جمله CNN، VGG16 و InceptionV3، RNN.
- معرفی یک مدل عمیق جدید مبتنی بر رزنت ۱۰۱ با یادگیری انتقالی برای بهبود دقت تشخیص.
- حصول دقت تشخیص ۹۸/۳۷٪ با استفاده از مدل پیشنهادی، که از روش‌های سنتی پیشی می‌گیرد.
- ارائه شواهدی مبنی بر اینکه یادگیری عمیق می‌تواند ابزاری قدرتمند برای تشخیص تومور مغزی باشد.
- نشان دادن عملکرد برتر این روش در مقایسه با روش‌های موجود از طریق شبیه‌سازی‌ها.
- قابلیت انعطاف‌پذیری بالای مدل و امکان تنظیم آسان برای سایر مجموعه داده‌ها.

جدول ۱، گزیده‌ای از پژوهش‌های انجام‌شده در سال‌های اخیر براساس مفاهیم یادگیری مدل عمیق به منظور تشخیص تومورهای مغزی را نشان می‌دهد. بررسی‌های انجام شده در این جدول مقایسه‌ای بر روی روش‌های ارائه‌شده، اهداف تحقیقاتی، منابع داده‌ای، تعداد دسته‌ها برای طبقه‌بندی و سال‌های انتشار ارائه می‌دهد.

در بخش دوم این مقاله، شرح جامعی از رویکرد پیشنهادی شامل پایگاه داده، مراحل پیش‌پردازش، نگاشت ویژگی‌ها و تبدیل داده‌ها و تنظیمات پارامتر برای معماری طراحی‌شده شرح داده می‌شود. نتایج تجربی و ارزیابی عملکرد در بخش سوم گزارش شده است. همچنین نتایج استفاده از روش پیشنهادی مورد بحث قرار گرفته و در بخش آخر نتیجه‌گیری در مورد تحقیق انجام شده است

۲- تشخیص تومورهای مغزی براساس مدل عمیق

طبقه‌بندی تومورهای مغزی یک مسئله مهم برای تشخیص مبتنی بر کامپیوتر در کاربردهای پزشکی است. با توجه به شیوع انواع مختلف تومورهای مغزی، توسعه یک سیستم کامپیوتری که بتواند بین فعالیت طبیعی و غیرطبیعی مغز تمایز قائل شود، حیاتی است. داشتن تجربه متخصص در تشخیص انواع تومور مهم است. با این حال، پیشرفت‌های اخیر در شبکه‌های مبتنی بر یادگیری عمیق، عملکردهای پیشرفته‌ای را برای طبقه‌بندی تومور مغزی ارائه نموده‌اند. بهبود دقت و کارایی طبقه‌بندی تومور مغزی می‌تواند پیامدهای قابل توجهی برای تشخیص و درمان داشته باشد. استفاده از قدرت بازنمایی مدل‌های یادگیری

مغزی را با دقت بیشتری نسبت به مدل‌های منفرد ارائه‌شده در [۱۶] برای تشخیص دو دسته طبقه‌بندی کردند. این پژوهش از روش یادگیری عمیق گروهی انباشته برای پیش‌بینی بیماری سرطان از تصاویر ام‌آرآی استفاده نموده است. یک طبقه‌بند خودکار تومورهای مغزی با سه کلاس با استفاده از یادگیری انتقالی در [۱۷] معرفی شد. تومورهای گلیوم، مننژیوم و هیپوفیز با استفاده از یک مدل GoogLeNet از پیش‌آموزش دیده برای استخراج ویژگی‌هایی از تصاویر ام‌آرآی مغز شناسایی شدند. در [۱۸]، یک طبقه‌بند با کارایی بالا با استفاده از یک شبکه VGG-16 از پیش‌آموزش دیده برای تشخیص بیماری آلزایمر از تصاویر ام‌آرآی معرفی شد. همچنین، یادگیری انتقال برای بازبانی تصویر مبتنی بر محتوا برای طبقه‌بندی تومورهای مغزی استفاده گردید [۱۹]. [۲۰]، یک طبقه‌بندی‌کننده ترکیبی مبتنی بر ویژگی و یک طبقه‌بندی‌کننده مبتنی بر ویژگی تصویر تقسیم‌بندی شده برای تشخیص تومور مغزی معرفی نمود. مدل‌های شبکه عصبی عمیق برای طبقه‌بندی پیشنهاد شدند. یک طبقه‌بندی خودکار قوی برای تشخیص ۱۸ دسته از تومورهای مغزی در [۲۱] معرفی شد. این سیستم‌های یادگیری عمیق بر روی تصاویر با وزن T1 و T2 و توالی‌های ام‌آرآی کنتراست T2 آموزش دیده‌اند. در [۲۲]، یک مدل CNN برای طبقه‌بندی تصاویر ام‌آرآی مغز به سه دسته تومورهای گلیوم، مننژیوم و هیپوفیز پیشنهاد شد. درجه‌بندی خودکار در این مقاله بر روی سه مجموعه داده مغز، برش‌خورده، برش‌خورده و منطقه‌ای مورد علاقه انجام شد. در [۲۳]، یک مدل شبکه عصبی کانولوشنال CNN با استفاده از VGG16 برای تشخیص تومورهای مغزی در تصاویر ام‌آرآی پیشنهاد شده است. مدل یادگیری انتقالی مبتنی بر VGG16 در این مطالعه، بر اثربخشی یادگیری عمیق و یادگیری ماشین در طبقه‌بندی تومورهای مغزی تأکید می‌کند. [۲۴]، یک رویکرد یادگیری و یک مدل یادگیری عمیق سه-طبقه‌ای برای تشخیص تومورهای مغزی گلیوم، مننژیوم و تومورهای هیپوفیز طراحی نموده است. این مدل از یک مدل آماده به نام InceptionV3 برای استخراج ویژگی‌های تصاویر مغز استفاده می‌کند و با دقت بالا، عملکردی فراتر از روش‌های قبلی بر روی مجموعه داده‌ای استاندارد CE-X-ray به دست می‌آورد.

هدف این مقاله بکارگیری معماری‌های یادگیری عمیق برای شناسایی انواع مختلف تومورهای مغزی است. در روش طبقه‌بندی، شبکه‌های عمیق مختلف مانند CNN^۸، RNN^۸، InceptionV3، VGG16 و رزنت ۱۰۱ برای طبقه‌بندی سه نوع تومور مغزی، مننژیوم، گلیوم، و هیپوفیز که سه نوع رایج و حائز اهمیت تومور مغزی را تشکیل می‌دهند و یک دسته داده بدون تومور استفاده می‌شوند. این مدل‌های عمیق، از پرکاربردترین معماری‌های یادگیری عمیق برای طبقه‌بندی در کاربردهای پزشکی است. در مدل رزنت ۱۰۱، آموزش لایه‌های افزونگی داده و تنظیم دقیق با تکنیک یادگیری انتقالی برای ارزیابی قابلیت مدل ارائه شده برای طبقه‌بندی تومورهای مغزی در نظر گرفته

عمیق، یکی از راه‌های رسیدن به این هدف است. به منظور پیشرفت در زمینه مراقبت‌های بهداشتی و بهبود نتایج معالجه بیماران، بررسی مزایای بالقوه روش‌های مبتنی بر هوش مصنوعی حائز اهمیت است. این مطالعه بر توسعه یک طبقه‌بند مبتنی بر رزنت ۱۰۱ تمرکز دارد که می‌تواند به طور دقیق سه نوع تومور مغزی مننژیوم، گلیوم و هیپوفیز و وضعیت بدون تومور را تشخیص دهد. چند نمونه از این دسته تومورهای مغزی در شکل ۱ نشان داده شده است.

جدول (۱): پژوهش‌های اخیر در زمینه تشخیص تومورهای مغزی براساس مدل‌های عمیق

مرجع	کلاس‌ها	مجموعه دادگان	دسته‌بند	انتشار
[۵]	۳ کلاس (یافت مرده هسته تومور، بخش ورم کرد تومور و تومور افزایشی)	BRATS 2018	U-Net	۱۴۰۰
[۶]	۳ کلاس (بخش تومور مجزا، بخش هسته تومور، بخش تقویت کننده تومور)	BRATS 2013	CNN دو مسیره	۱۴۰۲
[۷]	۳ کلاس (کل تومور، هسته تومور، بخش افزایشی تومور)	BRATS 2020	3D-UNet	۱۴۰۱
[۸]	۳ کلاس (گلیوم، مننژیوم، هیپوفیز)	CPTAC/Allen Brain Atlases	VGG16	۱۳۹۹
[۹]	-	Arxiv/IEEE /Springer /ScienceDirect	-	۱۴۰۰
[۱۰]	۳ کلاس (گلیوم، مننژیوم، هیپوفیز)	Cancer Net.	CNN	۱۳۹۹
[۱۱]	۳ کلاس (گلیوم، مننژیوم، هیپوفیز)	CE-MRI Figshare	CNN	۲۰۱۹
[۱۲]	۲ کلاس (تومور، بدون تومور)	MRI scanner تولید شده با	VGG16	۲۰۲۳
[۱۳]	۳ کلاس (گلیوم، مننژیوم، هیپوفیز)	Figshare's CE-X-ray	Inception V3	۲۰۲۳
[۱۴]	۲ کلاس (گلیوما درجه پایین (LGG) و گلیوما درجه بالا (HGG))	Brain tumor segmentation (BRATS 2019)	CNN	۲۰۲۱
[۱۵]	۲ کلاس (بدخیم و خوش خیم)	BRATS 2015/ BRATS 2017/ BRATS 2018	VGG16/ VGG19	۲۰۲۰
[۱۶]	۳ کلاس (گلیوم، مننژیوم، هیپوفیز)	Kaggle/ figshare2/ SARTAJ/ Br35H	CNN	۲۰۲۲
[۱۷]	۳ کلاس (گلیوم، مننژیوم، هیپوفیز)	CE-MRI Figshare	VGG19	۲۰۱۹
[۱۸]	۳ کلاس (گلیوم، مننژیوم، هیپوفیز)	CE-MRI Figshare	CNN	۲۰۲۰
[۱۹]	۳ کلاس (گلیوم، مننژیوم، هیپوفیز)	CE-MRI Figshare	CNN	۲۰۲۱
[۲۰]	۴ کلاس (گلیوم، مننژیوم، هیپوفیز، خوش خیم)	Kaggle dataset	CNN	۲۰۲۲
[۲۱]	۳ کلاس (گلیوم، مننژیوم، هیپوفیز)	General hospital/ Kaggle/ Nanfang Hospital/ China	Inception V3/ DenseNet201	۲۰۲۴
[۲۲]	۴ کلاس (گلیوم، مننژیوم، هیپوفیز، بدون تومور)	Kaggle	/AlexNet/VGG16 رزنت ۵۰	۲۰۲۴
[۲۳]	۳ کلاس (گلیوم، مننژیوم، هیپوفیز)	CE-MRI Figshare	EfficientNets	۲۰۲۳
[۲۴]	۲ کلاس (دارای تومور و بدون تومور)	Kaggle/BR35H-Brain Tumor Detection 2020	CNN	۲۰۲۲
روش پیشنهادی	۴ کلاس (گلیوم، مننژیوم، هیپوفیز، بدون تومور)	CE-MRI Figshare	رزنت ۱۰۱	-

تصاویر به 256×256 پیکسل و افزودن سه کانال برای تکرار مقادیر مقیاس خاکستری. اهداف این مراحل پیش پردازش عبارتند از: سرعت بخشیدن به فرآیند یادگیری، حل مشکلات حافظه، و تنظیم اندازه تصاویر برای تزریق به مدل عمیق.

۲-۲-۲- افزونگی داده


یک مدل عمیق برای دستیابی به عملکرد مطلوب به حجم مطلوبی از داده ورودی نیاز دارد. مجموعه داده مورد استفاده در این مقاله دارای تعداد محدودی نمونه ام آر آی در کلاس‌های مختلف است. شایان ذکر است که ترکیب داده‌های اضافی در فرآیند آموزش اغلب می‌تواند به جلوگیری از تطبیق بیش از حد و بهبود اثربخشی کلی مدل‌های یادگیری ماشین کمک نماید [۲۶-۲۸]. بررسی راه‌هایی برای تکمیل یا افزایش داده‌ها، مانند تولید مصنوعی داده‌های جدید، می‌تواند

۲-۱- مجموعه داده و پیش پردازش

به منظور ارزیابی روش پیشنهادی، از مجموعه داده تومور مغزی CE-MRI dataset استفاده شده است [۲۵]. این مجموعه شامل 3064 تصویر با کنتراست T1 از 233 بیمار در سه کلاس مننژیوم (708 تصویر مربوط به 82 بیمار، گلیوم (1426 تصویر مربوط به 89 بیمار) و هیپوفیز (930 تصویر مربوط به 62 بیمار) است. تصاویر متعلق به مودالیت‌های T1-CE و شامل نماهای کروئال، سائیتال و محوری در ابعاد 512×512 با اندازه پیکسل 49×49 میلی‌متر می‌باشد. تصاویر به صورت برخط و به صورت رایگان در دسترس هستند و برای هر تصویر، ماسک تومور، مرز تومور و برچسب کلاس موجود است. مراحل پیش‌پردازش قبل از آموزش مدل شامل موارد زیر است: نرمال‌سازی تصاویر ام آر آی با استفاده از تکنیک حداقل-حداکثر، تغییر اندازه

جدول (۲): تعداد تصاویر در مجموعه داده قبل و بعد از استفاده از

افزونی داده		
نوع تومور مغزی	# قبل از افزونی	# بعد از افزونی
مننژیوم	۷۰۸	۲۸۰۰
گلیوم	۱۴۲۶	۴۸۶۰
هیپوفیز	۹۳۰	۳۲۵۰
مجموع	۳۰۶۴	۱۰۹۱۰




شکل (۲): نمایشی از تصاویر تومور مغزی (ستون سمت راست) و فرم افزونه شده آن به کمک روش افزونی داده در ستون‌های دیگر

ساختار اولیه هر بلوک در این مدل براساس یک بلوک ساختمانی مانده است که برای همه ۱۰۱ لایه طراحی شده است. هر بلوک ساختمانی باقیمانده از چندین لایه کانولوشنال، توابع فعالسازی واحدهای خطی اصلاح شده و حداکثر ادغام و به دنبال آن یک لایه کاملاً متصل تشکیل شده است. همچنین، روال‌های مختلف یادگیری مانند نرمال‌سازی دسته‌ای به طور معمول برای مدل رزنت استفاده می‌شود. ویژگی‌های مستقل لایه‌های کانولوشن قبلی با استفاده از هسته‌های کانولوشن درهم پیچیده شده‌اند و به یک تابع فعال‌سازی غیرخطی نگاشت می‌شوند. پس از اعمال لایه کانولوشن، یک لایه نرمال‌سازی دسته‌ای و یک تابع فعال‌سازی اعمال می‌شود. تابع فعال‌سازی غیرخطی است که در صورت دریافت هر ورودی کمتر از صفر، صفر را برمی‌گرداند و سپس نورون‌ها را غیرفعال می‌کند. اما برای هر مقدار ورودی مثبت، آن مقدار را به صورت زیر برمی‌گرداند. بلوک‌های مختلف یک شبکه عمیق به طور معمول با لایه‌های کانولوشن و ادغام شروع می‌شوند تا تصویر را در ویژگی‌های ساختار یافته ترسیم کرده و آن‌ها را تجزیه و تحلیل نمایند. در ادامه، لایه‌های ادغام قرار گرفته‌اند تا با کاهش ابعاد خروجی‌های لایه پیچیدگی، پیچیدگی مدل عمیق کاهش یابد. با استفاده از این لایه‌ها از مشکل بیش از حد برازش جلوگیری می‌شود. خروجی‌های لایه پیچیدگی با استفاده از تابع ادغام یا مقادیر متوسط این لایه‌ها به حداکثر می‌رسد [۳۷]. در مرحله بعد، یک لایه به طور کامل متصل با نتیجه بلوک قبلی تغذیه می‌شود تا تصمیم نهایی طبقه‌بندی را از طریق یک تابع تبدیل اتخاذ نماید. در آخرین لایه، یک بلوک نرمال‌سازی دسته‌ای ورودی توابع فعال‌سازی را عادی می‌کند و آن‌ها را مقیاس می‌کند تا سرعت فرآیند یادگیری را

رویکرد ارزشمندی برای بررسی باشد [۲۷-۲۸]. این امر به ویژه برای کلاس‌هایی با داده‌های کمتر در مجموعه داده مهم است. در پردازش داده‌های بالینی، ثبت کلاس‌های غیرطبیعی یا کلاس‌های شامل یک نوع خاص تومور معمولاً دشوارتر از موارد عادی است و در نتیجه، میزان داده‌ها در این دسته‌ها بسیار کمتر از سایر دسته‌ها است [۲۹-۳۱]. در واقع، با یک عدد نامتعادل ثبت شده از کلاس‌های مختلف، ممکن است یک مشکل یادگیری بیش از حد یا مغرضانه رخ دهد. بنابراین، در این مقاله، از تکنیک افزایش داده‌ها برای به دست آوردن داده‌های بیشتر برای طبقه‌بندی شده با داده استفاده شده است [۳۲]. روش مبتنی بر اغتشاش برای تقویت داده‌ها برای بزرگ کردن مصنوعی پایگاه داده ام‌آرآی مغز با آینه‌سازی چپ/راست، مقیاس‌گذاری، جابجایی، بُرش، چرخش ۴۵ درجه‌ای با اعمال درون‌یابی دوخطی، و افزودن نویز نمک و فلفل استفاده می‌شود [۳۳]. این روال، تصاویر ام‌آرآی را از ۳۰۶۴ به ۱۰۹۱۰ تصویر افزایش داده که این افزونی در جدول ۲ گزارش شده است. برخی از تصاویر ام‌آرآی تقویت شده تومور مغزی از سه دسته ذکر شده تولید شده توسط الگوریتم تقویت داده تعریف شده در [۳۴] در شکل ۲ نمایش داده شده است.

۳- معماری مدل عمیق

الگوریتم مبتنی بر یادگیری عمیق پیشنهادی به منظور طبقه‌بندی تومورهای مغزی در این بخش معرفی می‌شود. در این روش از مدل عمیق رزنت ۱۰۱ در کنار سایر مدل‌های عمیق، استفاده می‌شود. این شبکه می‌تواند به طور دقیق محتوای بافت تصویر ام‌آرآی ورودی را نشان دهد و سه تومور مغزی را که به عنوان مننژیوم، گلیوم و هیپوفیز ذکر شده‌اند طبقه‌بندی نماید. رزنت ۱۰۱، یک شبکه عصبی کانولوشن مبتنی بر شبکه‌های مانده است که می‌تواند مشکل ناپدید شدن گرادیان را به دلیل لایه‌های بسیار عمیق خود برطرف نماید. در این مدل، گرادیان‌ها می‌توانند به طور مستقیم از طریق پیوندهای میانبر به یکدیگر متصل شوند تا یک یا چند لایه نادیده گرفته شود [۳۵-۳۶].



شکل (۱): نمایشی از انواع تومور مغزی شایع: ردیف اول: تومور گلیوما


(Glioma). ردیف دوم: مننژیوم (Meningioma). ردیف سوم:

هیپوفیز (Pituitary). ردیف چهارم: تصویر ام‌آرآی بدون تومور

گزارش داده شده است. الگوریتم پیشنهادی با مدل‌های عمیق مختلف CNN معرفی شده در [۱۱، ۱۵-۱۶]، یک معماری RNN و یک طبقه‌بندی کننده تومور مغزی مبتنی بر یادگیری واژه‌نامه ارائه شده در [۴۱] مقایسه شده است.

۴-۱- جزئیات شبیه‌سازی

برای مدل رزنت ۱۰۱ طراحی شده، از بهینه‌ساز برآورد لحظه تطبیقی آدام (Adam) استفاده شده است که نرخ یادگیری تطبیقی را برای هر پارامتری محاسبه می‌کند [۴۵]. این روش یکی از تکنیک‌های بهینه‌سازی تصادفی محسوب می‌شود و نقش کلیدی در طراحی معماری‌های یادگیری عمیق دارد.



شکل (۳): لایه‌های مختلف مدل رزنت ۱۰۱ طراحی شده در روش طبقه‌بندی تومور مغزی پیشنهادی

جدول (۳): معماری رزنت ۱۰۱ مورد استفاده در الگوریتم طبقه‌بندی تومور مغزی پیشنهادی

نام لایه	ابعاد خروجی	۱۰۱ لایه
Conv1	112×112	7×7, 64, stride 2
pool1		3×3, max pool, stride 2
Conv2_x	56×56	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$
Conv3_x	28×28	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 4$
Conv4_x	14×14	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 23$
Conv5_x	7×7	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$
fc1	1×1	1000-d fc, softmax
pool time		average pool, stride 1

بهینه‌ساز آدام در فرآیند نزول گرادیان تصادفی به منظور آموزش لایه‌های مدل به کار گرفته شده است. در این روش، نرخ یادگیری اولیه 10^{-3} در نظر گرفته شده که در دوره‌های ۲۰ و ۳۰ در ۰/۱ ضرب می‌شود. علاوه بر این، نرخ یادگیری هر ۱۰ دوره، ۵۰ درصد کاهش پیدا می‌کند تا همگرایی بهینه‌تر حاصل شود. برای افزایش بهره‌وری، تعداد تکرارها روی ۲۰ تنظیم شده و مدل برای ۱۰۰ دوره در هر تکرار آموزش داده می‌شود. همچنین، در تمامی آزمایش‌ها، شبکه به مدت ۲۰۰ دوره آموزش داده شده است تا به همگرایی مطلوب برسد. اندازه دسته براساس نتایج تجربی روی ۶۴ تنظیم شده است، چرا که افزایش بیش‌ازحد اندازه دسته می‌تواند منجر به کاهش دقت مدل و افزایش

افزایش داده و شبکه را قادر می‌سازد تا با کارایی بالاتر یاد شود. این تکنیک براساس نرمال‌سازی ورودی‌های هر لایه انجام می‌شود. در این مقاله از سودمندی تکنیک یادگیری انتقالی به منظور مقداردهی اولیه ضرایب وزن لایه‌های پنهان با مقادیر اولیه مناسب و افزایش دقت عملکرد طبقه‌بندی استفاده شده است. معماری رزنت ۱۰۱ ارائه شده در ترکیب با این تکنیک بر روی یک مجموعه داده ImageNet از قبل آموزش داده شده است تا مشکل عملی در دسترس بودن مقدار زیادی از داده‌های آموزشی را حل نماید. در مورد داده‌های تومور مغزی نیز جستجو برای بیماران مبتلا به انواع مختلف تومور دشوار است و از طرف دیگر برچسب‌گذاری داده‌های ثبت شده بسیار گران و حساس است. بنابراین، تکنیک یادگیری انتقالی اغلب زمانی استفاده می‌شود که مسئله با مقدار ناکافی داده‌های آموزشی مواجه شود [۳۸-۴۰]. اثربخشی این تکنیک یادگیری جامع در پژوهش‌های اخیر در زمینه‌های مختلف طبقه‌بندی ثابت شده است [۴۰]. مدل رزنت ۱۰۱ پیشنهادی بر روی مجموعه داده ImageNet که شامل بیش از صد هزار تصویر در ۲۰۰ کلاس مختلف است، پیش آموزش داده می‌شود. ImageNet بر روی یک مجموعه داده تصویر مبتنی بر محتوا در مقیاس بزرگ یادگیری شده است. این روش قبل از آموزش بر روی مجموعه داده‌های تومور مغزی اعمال می‌شود. همانطور که گفته شد، اغلب یک مشکل اساسی با داده‌های کم، به ویژه در یک کلاس یا کلاس‌های خاص به عنوان بیش‌آموزش وجود دارد، که ممکن است منجر به همگرایی در دوره‌های بیشتر در طول مرحله آموزش و یک مدل ضعیف با نرخ پیش‌بینی پایین شود. بنابراین می‌توان با استفاده از تکنیک یادگیری انتقالی و بهینه‌سازی مدل طبقه‌بندی تومورهای مغزی به نتایج تشخیصی بهتر امیدوار بود. مدل رزنت ۱۰۱ در الگوریتم طبقه‌بندی کننده تومور مغزی پیشنهادی با تمام لایه‌های طراحی شده در شکل ۳ نشان داده شده است. در این مقاله، پس از شبیه‌سازی‌های تجربی برای مصاحبه میان اندازه داده‌های آموزشی و پیچیدگی مدل، از مدل رزنت ۱۰۱ استفاده شده است.

۴-۲- نتایج شبیه‌سازی

در این مقاله، یک سیستم خودکار برای طبقه‌بندی تومورهای مغزی با استفاده از تصاویر ام‌آر‌آی ارائه شده است. تصویر ورودی از قبل پردازش شده و بعد از افزودن داده به مدل رزنت ۱۰۱ با تنظیم فرآیندهای دقیق داده می‌شود. لایه ورودی مدل تصاویری با اندازه $256 \times 256 \times 3$ دریافت می‌نماید. پس از مرحله نرمال‌سازی دسته‌ای، کلاس خروجی از لایه نهایی کاملاً متصل به دست می‌آید. مدل هوشمند آموخته شده، سه نوع تومور مغزی مننژیوم، گلیوم و هیپوفیز را به همراه دسته بدون تومور طبقه‌بندی می‌کند. سپس با تغییر پارامترهای مختلف مانند تابع فعال‌سازی، دوره‌ها، اندازه دسته و نرخ یادگیری، معماری طراحی شده با برخی از روش‌های ذکر شده مقایسه می‌شود. همچنین، معماری رزنت ۱۰۱ طراحی شده در جدول ۳

اوبونتو^{۱۱} ۱۸/۰۴ را با ۱۹۲ گیگابایت رم DDR4 اجرا می‌کند، آموزش داده شده است. الگوریتم پیشنهادی با مدل‌های مختلف CNN ارائه شده در [۱۱، ۱۵-۱۶]، RNN، VGG16 [۱۲]، InceptionV3 [۱۳] و یک روش تشخیص تومور مغزی مبتنی بر یادگیری واژه‌نامه ارائه شده در [۴۴] مقایسه می‌شود. همانطور که ذکر شد، در [۱۵]، ویژگی‌های عمیق با استفاده از CNN و به همراه یک ماشین بردار پشتیبان طبقه‌بندی شده‌اند. در [۱۶]، تلفیقی از ویژگی‌های عمیق به‌دست‌آمده بر اساس AlexNet، CNN، رزنت ۱۸ و GoogLeNet برای شناسایی تومور مغزی برای تبدیل چندین ویژگی سطح پایین و بالا به یک بردار ویژگی واحد و افزایش عملکرد مدل معرفی شد. در [۱۶]، یک مدل CNN با مدل‌های دیگر ترکیب می‌شود تا کلاس‌های شناسایی شده را براساس روش مجموعه ایجاد کند تا طبقه‌بندی دقیق‌تری نسبت به الگوریتم‌های یادگیری ماشین منفرد داشته باشد. این مقاله با استفاده از روش مجموعه انباشته شامل سه مدل یادگیری عمیق تنظیم شده است. یک سیستم طبقه‌بندی خودکار با استفاده از یک مدل CNN آموخته‌شده انتقال عمیق برای استخراج ویژگی از تصاویر ام‌آر‌آی مغز در [۱۱] پیشنهاد شد. طبقه‌بندی‌کننده پیشنهادی از یک سیستم GoogLeNet از پیش آموزش‌دیده برای استخراج ویژگی‌هایی از تصاویر ام‌آر‌آی مغز مطابق با مفهوم تکنیک یادگیری انتقال عمیق استفاده می‌نماید.

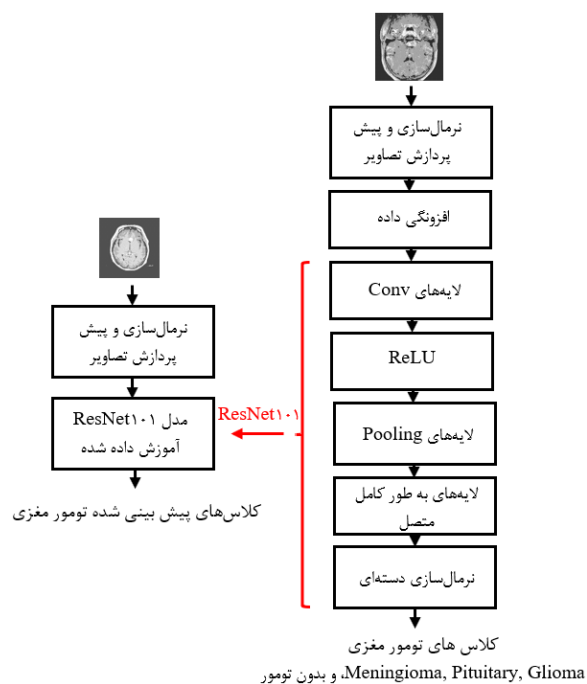
خطای تعمیم شود. پارامترهای تنظیم‌شده‌ی شبکه به‌طور خلاصه در جدول ۴ ارائه شده‌اند. مدل پیشنهادی رزنت ۱۰۱ با اعمال بهینه‌سازی‌هایی مانند استفاده از بهینه‌ساز آدام با نرخ یادگیری تطبیقی، تنظیم کاهش تدریجی نرخ یادگیری در دوره‌های مشخص، و انتخاب اندازه دسته بهینه، عملکرد بهتری نسبت به نسخه استاندارد رزنت ۱۰۱ و سایر مدل‌های متداول طبقه‌بندی ارائه داده است. در حالی که نسخه استاندارد رزنت ۱۰۱ معمولاً با بهینه‌سازهای پیش‌فرض مانند SGD و نرخ یادگیری ثابت یا کاهش نمایی آموزش داده می‌شود، مدل پیشنهادی با تنظیم دقیق نرخ یادگیری و تعداد تکرارها باعث بهبود همگرایی و کاهش نوسانات آموزش شده است. همچنین، بررسی‌ها نشان می‌دهد که انتخاب اندازه دسته ۶۴ در مدل پیشنهادی، تعادل مناسبی میان سرعت همگرایی و دقت مدل ایجاد کرده، در حالی که در مدل استاندارد، انتخاب اندازه دسته‌های متفاوت می‌تواند بر تعمیم‌پذیری مدل تأثیر منفی بگذارد. مقایسه عملکرد مدل پیشنهادی با سایر روش‌های متداول نیز نشان می‌دهد که مدل پیشنهادی از نظر دقت، حساسیت، ویژگی و نرخ پیش‌بینی مثبت برتری محسوس دارد، که این امر به بهینه‌سازی‌های انجام‌شده در ساختار و فرآیند آموزش شبکه بازمی‌گردد. الگوریتم پیشنهادی بر روی یک رایانه شخصی با پردازنده Intel Xeon E5 2600 (۱۶ هسته)، ۳/۲۰ گیگاهرتز رم و یک دستگاه لینوکس که

جدول (۴): فراپارامترهای تنظیم شده برای مدل‌های عمیق مورد استفاده

دوره	بهینه‌ساز	دسته	ابعاد کرنل	تابع فعال‌ساز	یادگیری	تعداد لایه‌ها
مدل‌های CNN [۱۵، ۱۶]	۶۰	آدام	۳۲	۳×۳	سیگموئید	۲۵-۳
مدل CNN [۱۱]	۲۰	آدام	۶۴	۳×۳	سیگموئید	۲۵-۲
مدل RNN	۲۰	آدام	۶۴	۳×۳	سیگموئید	۲۵-۲
VGG16 [۱۲]	-	-	-	۳×۳	-	۱۶
InceptionV3 [۱۳]	۱۰	RMSprop	۳۲	۳×۳	-	۱۵۹-۴
مدل رزنت ۱۰۱ در روش پیشنهادی	۴۰	آدام	۶۴	۳×۳	غیرخطی	۱۰۱-۳

که پیش‌تر ذکر شد، معماری طراحی‌شده‌ی رزنت ۱۰۱، در جدول ۳ ارائه شده است. این مدل با استفاده از بهینه‌ساز آدام آموزش داده شده و مقادیر نرخ یادگیری، کاهش وزن و اندازه دسته به ترتیب 10^{-3} و ۶۴ تنظیم شده‌اند. به منظور ارزیابی عملکرد الگوریتم‌های مختلف طبقه‌بندی تومور مغزی، از معیارهای مختلفی مانند دقت 13 (Acc)، ویژگی 14 (Spe)، نرخ پیش‌بینی مثبت 15 (Ppr)، حساسیت 16 (Sen) یا یادآوری 17 (R)، F-Measure استفاده می‌شود. ماتریس سردرگمی 18 درصد دقت توانایی طبقه‌بندی کننده را در تشخیص کلاس واقعی تصویر ورودی نشان می‌دهد. شاخص اختصاصی بودن توانایی طبقه‌بندی تومور مغزی را به صورت منفی تعریف می‌نماید. اندازه‌گیری Ppr درصد مثبت تومورهای برچسب‌گذاری شده صحیح را گزارش می‌دهد و Sen توانایی تشخیص طبقات مختلف را محاسبه می‌کند.

در [۱۲]، پژوهشگران از یک مدل CNN با استفاده از VGG16 به منظور تشخیص تومورهای مغزی در تصاویر ام‌آر‌آی استفاده نمودند. همچنین، محققان دیگری یک رویکرد یادگیری عمیق سه لایه‌ای برای تشخیص گلیوم، مننژیوم و تومورهای هیپوفیز ارائه دادند. این مدل از InceptionV3 برای استخراج ویژگی‌ها از تصاویر X-ray مغز استفاده می‌کند و با دقت بالایی از روش‌های قبلی بر روی مجموعه داده CE-X-ray پیشی می‌گیرد. در [۴۱]، ترکیبی از ویژگی‌های آماری و بافتی مختلف که شامل ماتریس هم‌وقوع سطح خاکستری 12 است برای یادگیری واژه‌نامه جامع برای نمایش محتوای هر دسته تومور مغزی در نظر گرفته شده استفاده می‌شود. همچنین در این روش آموزشی، تنظیم مناسب پارامتر انسجام برای به دست آوردن نتایج طبقه‌بندی مناسب بر اساس SNMF انجام می‌شود. همان‌طور



شکل (۴): بلوک دیاگرام الگوریتم پیشنهادی به منظور طبقه‌بندی تومورهای مغزی براساس مدل عمیق رزنت ۱۰۱

نمودار پیشرفت آموزش عملکرد دقت و تلفات در مراحل آموزش و آزمایش برای مدل رزنت ۱۰۱ ارائه شده براساس پارامترها و معماری تعریف شده در جداول ۴ در شکل ۵ قابل مشاهده است. این شکل روند همگرایی مدل پیشنهادی مبتنی بر رزنت ۱۰۱ و یادگیری انتقالی را در مراحل آموزش و آزمون نشان می‌دهد. نمودار (ب) میزان تابع هزینه را در طول دوره‌های آموزشی نمایش می‌دهد که کاهش تدریجی آن نشان‌دهنده یادگیری مؤثر مدل و کاهش خطا در هر دو مجموعه آموزش و آزمون است. مشاهده می‌شود که در اوایل فرآیند آموزش، مقدار تلفات به سرعت کاهش یافته و پس از چندین دوره، به مقدار ثابتی نزدیک می‌شود که نشان‌دهنده همگرایی مدل است. در نمودار (الف)، روند تغییرات مدل در مراحل آموزش و آزمون قابل مشاهده است. این نمودار نشان می‌دهد که دقت مدل به سرعت افزایش یافته و پس از چندین دوره، در حدود ۹۸/۳۷٪ به پایداری رسیده است. همگرایی نزدیک خطوط مربوط به مجموعه‌های آموزش و آزمون بیانگر عدم بیش‌برازش و عمومی‌سازی مناسب مدل برای داده‌های جدید است. این نتایج تأیید می‌کنند که مدل پیشنهادی قادر به تشخیص دقیق تومورهای مغزی بر اساس تصاویر ام‌آرآی است و می‌تواند در کاربردهای پزشکی مورد استفاده قرار گیرد. به منظور داشتن یک ارزیابی عملکرد دقیق برای الگوریتم پیشنهادی، دقت کلی، ویژگی، نرخ پیش‌بینی مثبت، حساسیت، F-Measure و ماتریس سردرگمی در جداول ۶-۷ گزارش شده است. نتایج طبقه‌بندی تومورهای مغزی مننژیوما، گلیوما و هیپوفیز با استفاده از تصاویر ام‌آرآی براساس مدل رزنت ۵۰ آموخته شده، مدل‌های CNN، معماری RNN و طبقه‌بندی مبتنی بر یادگیری واژه‌نامه در جدول ۸ گزارش

معیارهای به کار رفته در این مقاله برای مقایسه مدل‌های مختلف به شرح زیر تعریف می‌شوند:

$$Acc = (TP+TN)/(TP+TN+FP+FN) \quad (۱)$$

$$Spe = TN/(TN+FP) \quad (۲)$$

$$Ppr = TP/(TP+FP) \quad (۳)$$

$$Sen = TP/(TP+FN) \quad (۴)$$

$$F-Measure = 2 \times (Ppr \times Sen) / (Ppr + Sen) \quad (۵)$$

که در آن $TP^{۱۹}$ ، $TN^{۲۰}$ ، $FP^{۲۱}$ و $FN^{۲۲}$ به ترتیب نشان دهنده مثبت واقعی، منفی واقعی، مثبت کاذب و منفی کاذب هستند [۴۳]. TP ، به عنوان تعداد کلاس‌های تومور درست تشخیص داده شده، شناخته می‌شود. TN ، مخفف تعداد کلاس‌های منفی است که به درستی به عنوان منفی طبقه‌بندی شده‌اند. FP ، تعداد تصاویر ام‌آرآی را نشان می‌دهد که به طور کاذب به عنوان مثبت تشخیص داده می‌شوند و FN ، مخفف تعداد تصاویر ام‌آرآی دسته مثبت است که به اشتباه به عنوان منفی پیش‌بینی شده‌اند.

۵- نتایج شبیه‌سازی روش پیشنهادی



بلوک دیاگرام روش پیشنهادی با توجه به توضیحات بیان شده در بخش‌های قبلی در شکل ۴ نشان داده شده است. همانطور که در بخش‌های قبل ذکر شد، برای یادگیری مدل عمیق در مرحله یادگیری در این آزمایش، پایگاه داده با استفاده از تکنیک ارزیابی اعتبار متقابل بر ۱۰ تقسیم می‌شود. در این تکنیک، تمام تصاویر موجود در پایگاه داده استفاده شده به طور مساوی به ۱۰ قسمت تقسیم می‌شوند. سپس در هر تکرار، ۹ قسمت از ۱۰ قسمت برای یادگیری مدل به کار گرفته می‌شود و قسمت باقی مانده برای اعتبار سنجی آزمایش می‌شود. این روش با جابجایی قسمت‌های آموزشی و بخش تست ۱۰ بار تکرار می‌شود. درصد دقت نهایی با میانگین دهی بر مقادیر دقت به دست آمده محاسبه می‌شود. نتایج طبقه‌بندی تومورهای مغزی مننژیوم، گلیوم و هیپوفیز با استفاده از تصاویر ام‌آرآی براساس مدل رزنت ۱۰۱، مدل‌های CNN، معماری RNN و طبقه‌بندی‌کننده مبتنی بر یادگیری واژه‌نامه در جدول ۵ گزارش شده است. پارامترهای وزن در شبکه RNN با استفاده از الگوریتم گرادینت مزدوج مقیاس شده که براساس جهت‌های مزدوج بدون نیاز به جستجوی خطی است، به روز می‌شود [۴۳]. عملکرد برجسته رزنت ۱۰۱ به عوامل متعددی از جمله عمق ۱۰۱ لایه‌ای آن و معماری باقیمانده که به استخراج ویژگی‌های پیچیده از تصاویر ام‌آرآی کمک می‌کند، نسبت داده می‌شود. علاوه بر این، استفاده از یادگیری انتقالی با وزنی از مدل‌های پیش‌آموده شده و آموزش بر روی مجموعه داده فیگشیر با تصاویر ام‌آرآی با کیفیت بالا، به یادگیری سریع‌تر و دقیق‌تر ویژگی‌های مرتبط با تومور مغزی منجر می‌شود. تنظیم دقیق مدل و عملکرد الگوریتم‌های پیش‌پردازش و پس‌پردازش تصویر نیز در نتیجه نهایی نقش دارند.

رزنت ۱۰۱ دارای عمق شبکه بسیار بیشتری از سایر مدل‌ها است و سایر مدل‌ها عمق کمتری دارند (مانند VGG16 با ۱۶ لایه). عمق بیشتر شبکه به مدل اجازه می‌دهد تا ویژگی‌های پیچیده‌تر و سلسله مراتبی‌تری را از تصاویر ام‌آر‌آی استخراج نماید [۴۶]. این امر به ویژه برای تشخیص تومورهای مغزی که ممکن است دارای ساختارهای ظریف و پیچیده باشند، حائز اهمیت است. مدل‌های با عمق کمتر ممکن است قادر به استخراج این ویژگی‌های ظریف نباشند و در نتیجه دقت تشخیص آن‌ها پایین‌تر باشد. معماری باقیمانده: مدل رزنت ۱۰۱ از معماری مانده استفاده می‌کند که به مدل اجازه می‌دهد تا اطلاعات ورودی را به طور مستقیم به خروجی هر بلوک منتقل نماید. این امر به حل مشکل ناپدید شدن گرادینان^{۲۳} کمک می‌کند که در شبکه‌های عمیق رایج است. ناپدید شدن گرادینان می‌تواند منجر به کند شدن فرآیند یادگیری و افت عملکرد مدل شود. معماری باقیمانده با جلوگیری از ناپدید شدن گرادینان، به مدل رزنت ۱۰۱ اجازه می‌دهد تا از اطلاعات تصاویر ام‌آر‌آی به طور موثرتری برای یادگیری استفاده و در نتیجه به دقت بالاتری دست یابد. اتصالات میانبری: مدل رزنت ۱۰۱ از اتصالات میانبری^{۲۴} بین بلوک‌های مختلف شبکه استفاده می‌نماید. این اتصالات به مدل کمک می‌کند تا اطلاعات مربوط به سطوح مختلف تصاویر ام‌آر‌آی را به طور یکپارچه در نظر بگیرد.

شده است. در آزمون معناداری فریدمن، هر چه مقادیر p کوچکتر باشد، شواهد برای رد فرضیه صفر قوی‌تر است. علاوه بر میانگین دقت هر کلاس، مقدار p در روش‌های ذکر شده در جدول ۸ نیز قابل مشاهده است. همانطور که گفته شد، فرضیه صفر بر این اساس است که تمامی روش‌های بررسی شده در ردیف‌های این جدول، در امتداد با الگوریتم معرفی شده مبتنی بر رزنت ۱۰۱، در سطح معناداری مشخص شده ۰/۰۰۵ به همان اندازه خوب عمل می‌نمایند. مقادیر p -value به دست آمده از جدول ۸ نشان می‌دهد که تمام مقادیر p کمتر از سطح مشخص شده ۰/۰۵ هستند. بنابراین فرضیه صفر با شواهد کامل رد می‌شود. بنابراین، الگوریتم پیشنهادی در این زمینه از طبقه‌بندی تومور مغزی مؤثرتر از سایر روش‌های ذکر شده در ردیف‌های جدول ۶ و ۷ عمل می‌کند. نتایج نشان می‌دهد که با بهره‌گیری از یادگیری مدل مبتنی بر رزنت می‌توان تومورهای مغزی را با دقت بالایی نسبت به سایر روش‌های ذکر شده طبقه‌بندی کرد. همچنین، نتایج پایداری مشابهی برای سایر معیارهای ارزیابی مانند ویژگی، نرخ پیش‌بینی، حساسیت و F-Measure در پایگاه‌های داده انتخاب‌شده برای الگوریتم پیشنهادی به دست می‌آید. با توجه به نتایج گزارش شده، مدل رزنت ۱۰۱ در مقایسه با سایر مدل‌های نام برده شده در تشخیص نوع تومور مغزی از تصاویر ام‌آر‌آی عملکرد بهتری را نشان می‌دهد. دلایل این برتری می‌تواند به شرح زیر باشد: عمق شبکه: مدل

جدول (۵): درصد دقت طبقه‌بندی کننده تومور مغزی پیشنهادی در مقایسه با سایر الگوریتم‌های ذکر شده

مننژیوم(%)	گلیوم(%)	هیپوفیز(%)	بدون تومور(%)	میانگین دقت (%)
۹۶/۶۷	۹۷/۰۲	۹۷/۲۳	۹۶/۹۸	۹۶/۹۷
۹۷/۵۶	۹۶/۴۳	۹۶/۸۵	۹۷/۱۱	۹۶/۹۹
۹۷/۳۹	۹۷/۲۲	۹۶/۸۹	۹۶/۴۳	۹۶/۹۹
۹۶/۲۳	۹۶/۰۹	۹۶/۴۵	۹۶/۱۳	۹۶/۲۲
۹۷/۶۷	۹۷/۷۳	۹۶/۹۱	۹۷/۵۵	۹۷/۴۶
۹۶/۹۸	۹۶/۶۳	۹۷/۰۶	۹۶/۷۶	۹۶/۸۶
۹۵/۱۲	۹۵/۶۴	۹۶/۱۸	۹۵/۸۸	۹۵/۷۰
۹۸/۶۲	۹۷/۹۸	۹۸/۵۴	۹۸/۴۳	۹۸/۳۷
رزنت ۱۰۱ و یادگیری انتقالی (روش پیشنهادی)				



شکل (۵): پیشرفت آموزش (الف) دقت و (ب) تابع از دست دادن برای روش پیشنهادی یادگیری رزنت ۱۰۱ در مراحل آموزش و آزمون

جدول (۶): دقت کلی، ویژگی، نرخ پیش‌بینی مثبت، حساسیت، و اندازه‌گیری F طبقه‌بندی کننده‌های تومور مغزی

دقت (%)	Spe (%)	Ppr (%)	Sen (%)	F-Measure (%)	
مننژیوم	۹۶/۶۷	۹۶/۸۱	۹۶/۶۷	۹۶/۷۵	۷۱/۹۶
گلیوم	۹۷/۰۲	۹۷/۹۶	۹۷/۵۹	۹۷/۸۸	۷۳/۹۷
هیپوفیز	۹۷/۲۳	۹۷/۴۵	۹۷/۶۱	۹۷/۳۹	۵۰/۹۷
بدون تومور	۹۶/۹۸	۹۶/۸۵	۹۶/۷۷	۹۶/۸۷	۸۲/۹۶
مننژیوم	۹۷/۵۶	۹۷/۶۹	۹۷/۴۳	۹۷/۶۷	۵۵/۹۷
گلیوم	۹۶/۴۳	۹۶/۷۲	۹۶/۶۵	۹۶/۶۰	۶۳/۹۶
هیپوفیز	۹۶/۸۵	۹۶/۵۵	۹۶/۶۰	۹۶/۶۷	۶۴/۹۶
بدون تومور	۹۷/۱۱	۹۷/۲۳	۹۷/۱۹	۹۷/۳۵	۲۷/۹۷
مننژیوم	۹۷/۳۹	۹۷/۵۶	۹۷/۴۸	۹۷/۴۸	۴۸/۹۷
گلیوم	۹۷/۲۲	۹۷/۳۵	۹۷/۳۲	۹۷/۴۱	۳۷/۹۷
هیپوفیز	۹۶/۸۹	۹۷/۱۱	۹۷/۰۸	۹۷/۲۳	۱۵/۹۷
بدون تومور	۹۶/۴۳	۹۶/۶۸	۹۶/۵۹	۹۶/۶۳	۶۱/۹۶
مننژیوم	۹۶/۲۳	۹۶/۴۱	۹۶/۴۶	۹۶/۵۰	۴۸/۹۶
گلیوم	۹۶/۰۹	۹۶/۲۱	۹۶/۳۲	۹۶/۲۲	۲۷/۹۶
هیپوفیز	۹۶/۴۵	۹۶/۶۲	۹۶/۴۹	۹۶/۵۸	۵۴/۹۶
بدون تومور	۹۶/۱۳	۹۶/۱۸	۹۶/۲۲	۹۶/۲۳	۲۳/۹۶
مننژیوم	۹۷/۶۷	۹۷/۷۳	۹۷/۶۷	۹۷/۷۸	۷۶/۹۷
گلیوم	۹۷/۷۳	۹۷/۶۸	۹۷/۷۰	۹۷/۷۱	۷۱/۹۷
هیپوفیز	۹۶/۹۱	۹۶/۸۹	۹۶/۷۹	۹۶/۹۰	۸۵/۹۶
بدون تومور	۹۷/۵۵	۹۷/۴۹	۹۷/۵۵	۹۷/۵۵	۵۵/۹۷
مننژیوم	۹۶/۹۸	۹۷/۰۳	۹۷/۱۰	۹۷/۰۹	۶۵/۹۷
گلیوم	۹۶/۶۳	۹۶/۸۱	۹۶/۸۵	۹۶/۷۹	۸۲/۹۶
هیپوفیز	۹۷/۰۶	۹۷/۲۲	۹۷/۳۴	۹۷/۲۷	۷۰/۹۷
بدون تومور	۹۶/۷۶	۹۶/۸۳	۹۶/۷۹	۹۶/۷۶	۷۸/۹۶
مننژیوم	۹۵/۱۲	۹۵/۲۵	۹۵/۳۳	۹۵/۳۱	۳۲/۹۵
گلیوم	۹۵/۶۴	۹۵/۸۱	۹۵/۷۸	۹۵/۷۷	۷۸/۹۵
هیپوفیز	۹۶/۱۸	۹۶/۱۳	۹۶/۰۹	۹۶/۰۹	۴۷/۹۷
بدون تومور	۹۵/۸۸	۹۵/۹۱	۹۵/۸۱	۹۵/۸۰	۸۱/۹۵
مننژیوم	۹۸/۶۲	۹۸/۴۹	۹۸/۵۶	۹۸/۵۶	۵۶/۹۸
گلیوم	۹۷/۹۸	۹۷/۸۳	۹۷/۶۱	۹۷/۷۹	۷۰/۹۷
هیپوفیز	۹۸/۵۴	۹۸/۶۲	۹۸/۵۸	۹۸/۵۳	۵۶/۹۸
بدون تومور	۹۸/۴۳	۹۸/۳۶	۹۸/۴۱	۹۸/۴۰	۴۱/۹۸

جدول (۸): تجزیه و تحلیل آزمون آماری الگوریتم پیشنهادی مبتنی بر رزنت ۱۰۱ و سایر روش های مختلف ذکر شده

میانگین دقت مقدار- ρ	میانگین دقت (%)	
۰/۰۰۷	۹۶/۹۷	[۱۵] CNN
۰/۰۰۷	۹۶/۹۹	[۱۱] CNN
۰/۰۰۷	۹۶/۹۹	[۱۶] CNN
۰/۰۰۸	۹۶/۲۲	RNN
۰/۰۱۳	۹۷/۴۶	[۱۲] VGG16
۰/۰۱۱	۹۶/۸۶	[۱۳] InceptionV3
۰/۰۲۷	۹۵/۷۰	[۴۱] SNMF-based
۰/۰۰۵	۹۸/۳۷	رزنت ۱۰۱ و یادگیری انتقالی (روش پیشنهادی)

جدول (۷): ماتریس سردرگمی برای روش پیشنهادی مبتنی بر رزنت ۱۰۱ برای طبقه بندی تومورهای مغزی

مننژیوم	۹۸/۶۲	٪ ۰/۳۵	٪ ۰/۵۶	٪ ۰/۴۷
گلیوم	٪ ۰/۶۸	٪ ۹۷/۹۸	٪ ۰/۷۶	٪ ۰/۵۸
هیپوفیز	٪ ۰/۶۱	٪ ۰/۳۲	۹۸/۵۴	٪ ۰/۵۳
بدون تومور	٪ ۰/۶۲	٪ ۰/۲۴	٪ ۰/۷۱	٪ ۹۸/۴۳
بدون تومور	مننژیوم	گلیوم	هیپوفیز	

یافته‌های این مطالعه نشان می‌دهد که مدل‌های یادگیری عمیق، به ویژه مدل رزنت ۱۰۱، می‌توانند به عنوان ابزارهای تشخیصی قدرتمندی برای تشخیص نوع تومور مغزی با دقت بالا مورد استفاده قرار گیرند. این مدل‌ها پتانسیل کاهش خطاهای تشخیصی و کمک به پزشکان در انتخاب روش درمانی مناسب برای بیماران را دارند. علاوه بر این، یادگیری عمیق می‌تواند به تشخیص تومورهای مغزی در مراحل اولیه بیماری که احتمال درمان آن‌ها بیشتر است، کمک نماید.

مراجع

- [1] R. Kaifi, "A Review of Recent Advances in Brain Tumor Diagnosis Based on AI-Based Classification", *Diagnostics (Basel)*, Vol. 13, No. 18, Sep. 2023.
- [2] M. Toğaçar, B. Ergen, and Z. Cömert, "BrainMRNet: Brain tumor detection using magnetic resonance images with a novel convolutional neural network model", *Medical Hypotheses*, Vol. 134, 2020.
- [3] K. V. Chaithanyadas, and G. R. G. King, "Brain tumor classification: a comprehensive systematic review on various constraints", *Computer Methods in Biomechanics and Biomedical Engineering: Imaging & Visualization*, Vol. 11, No. 3, pp. 517-529, 2023.
- [4] U. Aeman, M. Kaleem, M. Sarwar, M. Azhar, et al., "A systematic literature review on classification of brain tumor detection", *Journal of Computing & Biomedical Informatics*, Vol. 5, No. 2, pp. 327-337, 2023.
- [5] R. Akbari Doutepeh Sofla and M. Akhoundzadeh Hanzaei, "A deep learning-based method for brain tumor detection from magnetic resonance images," *Computational Science*, vol. 6, no. 2, pp. 54-64, 2021.
- [6] M. Yousefi, "Brain tumor detection from MRI images using deep learning method," *Scientific Journal of Research Studies in Basic Sciences and Future Medical Sciences*, vol. 1, no. 1, 2024.
- [7] A. Gholipour and K. Sabri Loghaei, "Brain tumor detection with deep learning and attention mechanism using multimodal MRI images," in *Proceedings of the 1st International and 6th National Conference on Computer, Information Technology, and Artificial Intelligence Applications*, 2022.
- [8] D. Jafarkhah Seyghalani, M. Yazdi, and M. Faghihi, "Brain tumor detection using MRI and CT image fusion based on deep learning methods," *Scientific Journal of Biomedical Engineering*, vol. 14, no. 4, pp. 267-276, 2020.
- [9] Z. Khazaei, M. Langarizadeh, and M. A. Shiri Ahmadabadi, "Glioma brain tumor detection using magnetic resonance imaging with deep learning methods: A systematic review," *Health and Biomedical Informatics Journal*, vol. 2, no. 8, pp. 218-233, 2021.
- [10] A. Najafzadeh and H. R. Ghaffari, "Brain tumor detection from MRI images using two-dimensional convolutional neural network," *Current Internal Medicine*, vol. 26, no. 4, pp. 398-413, 2020.
- [11] H. El Hamdaoui, A. Benfares, S. Boujraf, et al., "High precision brain tumor classification model based on deep transfer learning and stacking concepts", *Indonesian Journal of Electrical Engineering and Computer Science*, Vol. 24, pp. 167-177, 2021.
- [12] M. A. Khan, I. Ashraf, M. Alhaisoni, et al., "Multimodal brain tumor classification using deep learning and robust feature selection: A machine learning

تصاویر ام‌آرآی دارای اطلاعات در سطوح مختلف رزولوشن هستند. سطوح رزولوشن بالا جزئیات ظریف تومور را نشان می‌دهند، در حالی که سطوح رزولوشن پایین اطلاعات کلی‌تری در مورد ساختار تومور ارائه می‌دهند. اتصالات میانبری به مدل رزنت ۱۰۱ اجازه می‌دهد تا از اطلاعات هر دو سطح رزولوشن به طور همزمان استفاده کند و در نتیجه به درک دقیق‌تری از ساختار تومور و نوع آن دست یابد. تنظیم شبکه: مدل رزنت ۱۰۱ به طور خاص برای وظایف تشخیص تصویر، مانند تشخیص تومور مغزی، طراحی و تنظیم شده است. در حالی که مدل‌های VGG16 و InceptionV3 برای وظایف طبقه‌بندی تصویر عمومی طراحی شده‌اند. این بدان معناست که مدل‌های VGG16 و InceptionV3 ممکن است نیاز به تنظیمات بیشتری برای عملکرد بهینه در تشخیص تومور مغزی داشته باشند. تنظیمات شبکه شامل مواردی مانند انتخاب توابع فعال‌سازی، تعداد لایه‌ها و اندازه فیلترها می‌شود. تنظیم دقیق این پارامترها می‌تواند به طور قابل توجهی بر عملکرد مدل در یک وظیفه خاص مانند تشخیص تومور مغزی تأثیر بگذارد.

۶- نتیجه‌گیری

تومورهای مغزی یکی از پیچیده‌ترین و چالش برانگیزترین انواع سرطان هستند. تشخیص دقیق و به موقع نوع تومور، برای انتخاب روش درمانی مناسب حیاتی است. روش‌های تشخیصی سنتی مانند معاینات عصبی، تصویربرداری با ام‌آرآی و سی‌تی اسکن، علیرغم پیشرفت‌های قابل توجه، گاه با محدودیت‌هایی در تشخیص دقیق نوع و درجه تومور و تمایز آن از بافت سالم مغز مواجه هستند. در این راستا، هوش مصنوعی و به ویژه یادگیری عمیق به عنوان ابزاری نوین و قدرتمند، پتانسیل قابل توجهی برای ارتقای دقت و کارایی فرآیند تشخیص تومور مغزی از طریق تجزیه و تحلیل تصاویر پزشکی ارائه می‌دهد. در زمینه تشخیص تومور مغزی، مدل‌های یادگیری عمیق می‌توانند با تجزیه و تحلیل تصاویر ام‌آرآی و استخراج ویژگی‌های مرتبط با تومور، به طور خودکار آن‌ها را طبقه‌بندی و نوع و درجه آن‌ها را مشخص نمایند. این مدل‌ها قادر به شناسایی ساختارها و ناهنجاری‌های ظریف در تصاویر هستند که ممکن است از دید چشم انسان پنهان بماند. در این مطالعه، به بررسی کارایی مدل‌های مختلف یادگیری عمیق در تشخیص نوع تومور مغزی از تصاویر ام‌آرآی پرداخته شده است. برای این منظور، مجموعه داده Figshare شامل تصاویر ام‌آرآی تومورهای مغزی گلیوم، مننژیوم، هیپوفیز و بدون تومور مورد استفاده قرار گرفته است. مدل‌های CNN، RNN، VGG16، InceptionV3 رزنت ۱۰۱ با استفاده از این مجموعه داده آموزش داده شدند و عملکرد آن‌ها در تشخیص نوع تومور ارزیابی شد. نتایج نشان داد که مدل رزنت ۱۰۱ بهترین عملکرد را در بین مدل‌های بررسی شده داشته و از نظر آماری نیز برتری خود را نسبت به سایر مدل‌ها اثبات کرده است.

- https://figshare.com/articles/brain_tumor_dataset/151242
Z.
- [26] Y. Zhou, et al., "Forecasting emerging technologies using data augmentation and deep learning", *Scientometrics*, Vol. 123, pp. 1-29, 2020.
- [27] Z. Liu, et al., "Automatic diagnosis of fungal keratitis using data augmentation and image fusion with deep convolutional neural network", *Computers in Methods and Programs in Biomedicine*, Vol. 187, 2020.
- [28] Z. Mushtaq, S. F. Su, and Q. V. Tran, "Spectral images based environmental sound classification using CNN with meaningful data augmentation", *Applied Acoustics*, Vol. 172, 2021.
- [29] M. Sajjad, et al., "Multi-grade brain tumor classification using deep CNN with extensive data augmentation", *Journal of Computer Science*, Vol. 30, pp. 174-182, 2019.
- [30] Q. Xiao, et al., "Deep learning-based ECG arrhythmia classification: A systematic review", *Applied Sciences*, Vol. 13, No. 8, 2023.
- [31] X. Li, et al., "Automatic heartbeat classification using S-shaped reconstruction and a squeeze-and-excitation residual network", *Computers in Biology and Medicine*, Vol. 140, 2021.
- [32] Z. Zhong, et al., "Random erasing data augmentation", in *Proceedings of the 34th AAAI Conference on Artificial Intelligence*, pp. 13001-13008, 2020.
- [33] D. Zhang, et al., "Interpretable deep learning for automatic diagnosis of 12-lead electrocardiogram", *iScience*, Vol. 24, 2021.
- [34] R. Aniruddh, et al., "Data augmentation for electrocardiograms", in *Conference on Health, Inference, and Learning*, pp. 282-310, 2022.
- [35] M. Gao, et al., "A transfer residual neural network based on ResNet-34 for detection of wood knot defects", *Forests*, Vol. 12, No. 2, Art. no. 212, 2021. doi: 10.3390/f12020212.
- [36] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition", in *Proceedings of CVPR*, 2016.
- [37] A. Deshpande, V. Estrela, and P. Patavardhan, "The DCT-CNN-ResNet50 architecture to classify brain tumors with super-resolution, convolutional neural network, and the ResNet50", *Neuroscience Informatics*, Vol. 1, No. 4, 2021.
- [38] Y. Gao, and K. M. Mosalam, "Deep transfer learning for image-based structural damage recognition", *Computer-Aided Civil and Infrastructure Engineering*, Vol. 33, pp. 748-768, 2018.
- [39] S. Kentsch, et al., "Computer vision and deep learning techniques for the analysis of drone-acquired forest images: A transfer learning study", *Remote Sensing*, Vol. 12, 2020.
- [40] P. Yan, et al., "A Comprehensive Survey of Deep Transfer Learning for Anomaly Detection in Industrial Time Series: Methods, Applications, and Directions", *IEEE Access*, Vol. 12, pp. 3768-3789, 2024. doi: 10.1109/ACCESS.2023.3349132.
- [41] S. Mavaddati, "Classification of Brain Tumor Using Model Learning Based on Statistical and Texture Features", *Journal of Iranian Association of Electrical and Electronics Engineers*, Vol. 19, pp. 177-188, 2022.
- [42] M. Wu, Y. Lu, W. Yang, and S. Y. Wong, "A study on arrhythmia via ECG signal classification using the convolutional neural network", *Frontiers in Computational Neuroscience*, Vol. 14, 2021.
- application for radiologists", *Diagnostics*, Vol. 10, pp. 1-19, 2020.
- [13] D. Filatov, and H. Yar, "Brain tumor diagnosis and classification via pre-trained convolutional neural networks", [Online]. Available: <http://arxiv.org/abs/2208.00768>, 2022.
- [14] A. A. Akinyelu, F. Zaccagna, J. T. Grist, M. Castelli, and L. Rundo, "Brain tumor diagnosis using machine learning, convolutional neural networks, capsule neural networks and vision transformers applied to MRI: A survey", *Journal of Imaging*, Vol. 8, pp. 1-40, 2022.
- [15] H. Kibriya, R. Amin, A. H. Alshehri, M. Masood, S. S. Alshamrani, and A. A. Alshehri, "Novel and effective brain tumor classification model using deep feature fusion and famous machine learning classifiers", *Computational Intelligence and Neuroscience*, 2022.
- [16] Z. Al-Azzwi, and A. Nazarov, "Brain tumor classification based on improved stacked ensemble deep learning methods", *Asian Pacific Journal of Cancer Prevention (APJCP)*, Vol. 24, pp. 2141-2148, 2023. doi: 10.31557/APJCP.2023.24.6.2141.
- [17] S. Deepak, and P. Ameer, "Brain tumor classification using deep CNN features via transfer learning", *Computers in Biology and Medicine*, Vol. 111, Art. no. 103345, 2019. doi: 10.1016/j.combiomed.2019.103345.
- [18] R. Jain, N. Jain, A. Aggarwal, and D. J. Hemanth, "Convolutional neural network-based Alzheimer's disease classification from magnetic resonance brain images", *Cognitive Systems Research*, 2019. doi: 10.1016/j.cogsys.2018.12.015.
- [19] Z. N. K. Swati, Q. Zhao, M. Kabir, F. Ali, A. Zakir, S. Ahmad, and J. Lu, "Content-based brain tumor retrieval for MR images using transfer learning", *IEEE Access*, Vol. 7, pp. 17809-17822, 2019.
- [20] A. Veeramuthu, S. Meenakshi, G. Mathivanan, K. Kotecha, J. Saini, V. Vijayakumar, and V. Subramaniaswamy, "MRI brain tumor image classification using a combined feature and image-based classifier", *Frontiers in Psychology*, Vol. 13, Art. no. 848784, 2022.
- [21] P. Gao, et al., "Development and validation of a deep learning model for brain tumor diagnosis and classification using magnetic resonance imaging", *JAMA Network Open*, Vol. 5, Art. no. e2225608, 2022.
- [22] A. M. Alqudah, H. Alquraan, I. A. Qasmieh, A. Alqudah, and W. Al-Sharu, "Brain tumor classification using deep learning technique—A comparison between cropped, uncropped, and segmented lesion images with different sizes", *International Journal of Advanced Trends in Computer Science and Engineering*, Vol. 8, No. 6, pp. 3684-3691, 2020.
- [23] R. Sankaranarayanan, M. S. Kumar, B. Chidhambaraman, and P. Sireenjeevi, "Brain tumor detection and classification using VGG 16", *International Conference on Artificial Intelligence, Knowledge Discovery, and Concurrent Engineering (ICECONF)*, Chennai, India, pp. 1-5, 2023. doi: 10.1109/ICECONF57129.2023.10083866.
- [24] T. S. Kumar, R. Lohanandd, K. Kaviyanandh, and J. Gunabharathi, "Brain tumor classification with Inception V3 network model using transfer learning", 2023 9th International Conference on Advanced Computing and Communication Systems (ICACCS), Coimbatore, India, pp. 1392-1395, 2023. doi: 10.1109/ICACCS57279.2023.10112951.
- [25] "Brain tumor dataset", figshare, 2020. [Online]. Available:

- [43] M. F. Moller, "A scaled conjugate gradient algorithm for fast supervised learning", Neural Networks, Vol. 6, pp. 525-533, 1993.
- [44] J. Demsar, "Statistical comparisons of classifiers over multiple data sets", The Journal of Machine Learning Research, Vol. 7, pp. 1-30, 2006.
- [45] D. J. Sheskin, Handbook of Parametric and Nonparametric Statistical Procedures, 4th ed., Boca Raton, FL: Chapman & Hall/CRC, 2000.
- [46] N. Aghaei, G. Akbarizadeh, and A. Kosarian, "Using ShuffleNet to design a deep semantic segmentation model for oil spill detection in synthetic aperture radar images", Journal of Iranian Association of Electrical and Electronics Engineers, Vol. 19, pp. 131-144, 2022.

زیر نویس ها

-
- ^۱ Magnetic resonance imaging
 - ^۲ Computed tomography
 - ^۳ Deep learning
 - ^۴ Convolutional neural network
 - ^۵ Visual Geometry Group
 - ^۶ Data augmentation
 - ^۷ Vision Transformer
 - ^۸ Recurrent neural network
 - ^۹ Sparse non-negative matrix factorization
 - ^{۱۰} Adaptive moment estimation
 - ^{۱۱} Ubuntu
 - ^{۱۲} Gray level co-occurrence matrix
 - ^{۱۳} Accuracy
 - ^{۱۴} Specificity
 - ^{۱۵} Positive prediction rate
 - ^{۱۶} Sensitivity
 - ^{۱۷} Recall
 - ^{۱۸} Confusion matrix
 - ^{۱۹} True Positive
 - ^{۲۰} True Negative
 - ^{۲۱} False Positive
 - ^{۲۲} False Negative
 - ^{۲۳} Gradient vanishing
 - ^{۲۴} Shortcut connections