



Classification of Glial Brain Tumors Based on Deep Neural Network (ConvNet) and Brownian Curve

Alireza Zarei*

Master of Science in Biomedical Engineering,
Imam Reza International University, Mashhad,
Iran.

Fatemeh Zakeri

Bachelor Student of Science in Biomedical
Engineering, Apadana Higher Education
Institute, Shiraz, Iran.

Abstract

The diagnosis of benign and malignant brain tumors from MRI images is a fundamental challenge in Artificial Intelligence and Biomedical Engineering, as the early identification of these lethal lesions plays a decisive role in improving patient outcomes and survival. This research presents a comprehensive system for the automatic segmentation and classification of brain tumors using advanced image processing and machine learning techniques. The dataset used is BraTS, which includes standardized MRI images with uniform intensity, brightness, and color distribution. The proposed method, by utilizing optimal preprocessing, multi-scale feature extraction, and a fine-tuned machine learning model, achieved superior performance compared to previous methods. Evaluation results indicate a segmentation accuracy (Dice Score) of 93.62%, a Mean Squared Error (MSE) of 0.85, a Peak Signal-to-Noise Ratio (PSNR) of 41.70 dB, and a sensitivity of 84.66%. This performance introduces the proposed system as an accurate and reliable tool for early diagnosis and tumor segmentation in clinical applications.

Keywords: classification, glial brain tumors, deep neural network, ConvNet, Brownian curve

Received: 23/December/2025

Accepted: 19/February/2025

eISSN: 3115-7610

ISSN: 3115-7572

* Corresponding Author: zarei.alireza@live.com

طبقه‌بندی تومورهای گلیوما مغز بر پایه شبکه عصبی عمیق ConvNet و منحنی براونی

علیرضا زارعی*

کارشناسی ارشد مهندسی پزشکی، دانشگاه بین‌المللی امام رضا (ع)، مشهد، ایران.

فاطمه ذاکری

دانشجوی کارشناسی مهندسی پزشکی، مؤسسه آموزش عالی آپادانا، شیراز، ایران.

چکیده

تشخیص تومورهای مغزی خوش‌خیم و بدخیم از تصاویر MRI، چالشی اساسی در هوش مصنوعی و مهندسی پزشکی است؛ زیرا شناسایی زودهنگام این ضایعات کشنده، نقش تعیین‌کننده‌ای در بهبود و بقای بیماران دارد. این پژوهش سیستمی جامع برای تقطیع و طبقه‌بندی خودکار تومورهای مغزی با استفاده از تکنیک‌های پیشرفته پردازش تصویر و یادگیری ماشین ارائه می‌دهد. مجموعه داده مورد استفاده، BraTS شامل تصاویر استاندارد MRI با شدت نور، روشنایی و توزیع رنگی یکسان است. روش پیشنهادی با بهره‌گیری از پیش‌پردازش بهینه، استخراج ویژگی‌های چندمقیاسی و مدل یادگیری ماشین تنظیم‌شده، عملکردی برتر نسبت به روش‌های پیشین به دست آورد. نتایج ارزیابی نشان‌دهنده دقت تقطیع (Dice Score) $0.93/0.62$ ، میانگین مربعات خطا (MSE) 0.0085 ، اوج نسبت سیگنال به نویز (PSNR) 41.70 دسی‌بل و حساسیت 84.66% است. این عملکرد، سیستم پیشنهادی را به عنوان ابزاری دقیق و قابل اعتماد برای تشخیص زودهنگام و تقطیع تومور در کاربردهای بالینی معرفی می‌کند.

کلیدواژه‌ها: تومور مغزی، بخش‌بندی، طبقه‌بندی، ConvNet، شبکه عصبی عمیق، منحنی براونیان

مقدمه

همواره در زندگی، مواردی وجود دارند که انسان مایل است بداند انجام آن خوب است یا بد. به کارگیری تجربه‌های انسان در برابر یک سری مسائل جهت فائق آمدن بر آن‌ها، الگوی اصلی برای ایجاد یادگیری ماشین بوده است. شاخه‌ها و زمینه‌های متعددی از یادگیری ماشین وجود دارد که یکی از آن‌ها طبقه‌بندی است. در طبقه‌بندی، داده‌ها دارای برچسب می‌باشند و دسته‌بندی داده‌ها بعد از عملیات جهت قرارگیری هر ویژگی یا داده در کلاس خود، انجام می‌شود. اصول یادگیری ماشین در حوزه‌های متنوع، کاربرد دارند که یکی از آن‌ها، پردازش تصاویر پزشکی است. به کارگیری طبقه‌بندی در چنین زمینه‌ای، می‌تواند امکانات و اطلاعات مفیدی از داده‌های تصویری را در اختیار پزشکان قرار بدهد. امروزه دنیای پزشکی نیازمند تجهیزات پیشرفته‌ای است که به پزشکان در تشخیص و شناسایی بیماری‌ها، دقت و سرعت بهتری بدهند. لذا ساخت سیستم‌های تشخیص هوشمند پزشکی می‌تواند از خطاهای انسانی تا حد چشمگیری جلوگیری نماید. یکی از این سیستم‌ها، سیستم تشخیص هوشمند تومور و توده‌ها از سطح تصاویر ام‌آرآی مغزی است. این عملیات در دنیای کامپیوتر و الکترونیک، مبتنی بر روش‌های یادگیری ماشین و پردازش تصویر انجام می‌شود.

تومورهای اولیه مغز می‌توانند خوش‌خیم^۱ و یا بدخیم^۲ باشند. تومورهای خوش‌خیم مغزی دارای سلول‌های سرطانی نیستند. تومورهای مغزی بدخیم (که سرطان مغزی نیز نامیده می‌شود) حاوی سلول‌های سرطانی هستند. شناسایی و تشخیص تومور مغزی یک امر حیاتی در سیستم‌های سلامتی به شمار می‌رود. شناخت زود هنگام نوع تومور، می‌تواند به شخص کمک کند تا طول عمر بیشتری را داشته باشد. مغز دارای بافت‌های گوناگونی است که از تجمع و رشد سلولی بیش از حد، تومورهای مغزی پدید می‌آیند. بعضی از علائم تومورهای مغزی شامل سردرد، تشنج، تغییرات خلق و خو و اختلالات حرکتی است. به طور کلی، سه روش درمانی جهت درمان تومور مغزی وجود دارد که شامل جراحی، پرتو درمانی و شیمی درمانی است که هر کدام از این سه روش، دارای عوارض جانبی می‌باشند. تصاویر ام‌آرآی به دلیل داشتن رزولوشن مکانی عالی و کنتراست^۳ بافت عالی، به طور گسترده مورد استفاده واقع می‌گردند. میزان تهدیدکنندگی یک تومور، بستگی به ترکیبی از مجموعه عوامل مختلف، همچون: نوع تومور، محل و اندازه تومور و نحوه گسترش و توسعه آن است. برای تشخیص آن، عناصر ام‌آرآی^۴ باید به چهار دسته تقسیم شوند: ماده سفید (WM)، ماده خاکستری (GM)، مایع مغزی نخاعی (CSF) و بافت مغزی غیر طبیعی (تومور). هدف قطعه‌بندی تومور مغزی هم جداسازی بافت‌های مختلف تومور نظیر سلول‌های فعال، مرکز بافت مرده، ورم در بافت‌های مغزی نرمال ماده سفید (WM)، ماده خاکستری (GM) و مایع نخاعی (CSF) است.

استفاده از علوم کامپیوتری چون پردازش تصویر^۵ و بینایی ماشین^۶ به دلایل قابلیت‌های بالایی که در زمینه تشخیص پزشکی دارند، به وفور در حوزه‌های مختلف این علم، مورد استفاده واقع شده‌اند. این پژوهش سعی در ارائه یک روش همه‌جانبه در تشخیص تومور مغزی خوش‌خیم و بدخیم را دارد. رویکرد پیشنهادی، شامل چهاربخش است که شامل نرمال‌سازی تصاویر با هدف کاهش نویز و یکسان‌سازی اندازه تصاویر و همچنین بهبود کنتراست و میزان شدت روشنایی در تصاویر، تقطیع و استخراج ویژگی‌ها مبتنی بر منحنی براونی و در نهایت انتخاب کلاس‌های بهینه با برای طبقه‌بندی توسط شبکه عصبی عمیق است.

1. benign
2. malignant
3. contrast
4. MRI
5. image processing
6. machine vision

پیشینه پژوهش

پیشرفت یادگیری عمیق، به‌ویژه شبکه‌های کانولوشنی (CNN)، توجه گسترده‌ای را به تقطیع و تشخیص تومورهای مغزی از تصاویر MRI^۱ معطوف کرده است. در [۱] معماری CNN^۲ عمیق با هسته‌های ۳×۳ برای طبقه‌بندی گلیوما پیشنهاد شد. در [۲] مدل دو مسیری CNN را برای استخراج ویژگی‌های محلی و سراسری ارائه شد، در حالی که در [۳] از CNN آبخاری و آموزش دومارحله‌ای برای رفع عدم تعادل برچسب‌ها بهره برده است.

استخراج ویژگی‌های چندمقیاسی در کارهای متعددی برجسته شده است [۴-۱۰]. روش اول، ادغام نگاشت‌های ویژگی از لایه‌های مختلف [۱۱]؛ روش دوم، ورودی تصاویر مقیاس‌یافته متفاوت [۱۲]. کامنیتساس و همکاران [۱۲] با ترکیب CNN کامل و CRF^۴ سه‌بعدی، دقت را بهبود بخشید اما پیچیدگی محاسباتی بالایی داشت. مدل‌های سه‌بعدی CNN [۱۳-۱۵] و دوبعدی [۱۶] برای داده‌های حجمی MRI پیشنهاد شدند؛ در [۱۵] از معماری رمزگذار-رمزگشا و [۱۶] از تقطیع سلسله‌مراتبی با دیدگاه‌های محوری، ساژیتال و تاجی استفاده شده است. برای کاهش پیچیدگی، مدل‌های CRF/Markov اطلاعات زمینه‌ای فضایی را مدل‌سازی کردند [۱۷-۱۹]. میتال و همکاران [۱۹] با GCNN^۵ و تبدیل موجک ثابت، عملکرد را بر BraT S2018^۶ ارتقا دادند.

در [۲۰]، CNN کامل با پیرامید اتروس-کانولوشن بر BraTS2013-2018، امتیازات دایس (۷۶٫۸۸٪/۷۶٫۸۸٪/۷۶٫۸۸٪) (هسته)، (۷۴٫۴۳٪/۷۴٫۴۳٪/۷۴٫۴۳٪) (بهسازی‌شده) و (۸۶٫۵۸٪/۸۶٫۵۸٪/۸۶٫۵۸٪) (کل تومور) به‌دست آورد. ونگ و همکاران [۲۱] با CNN سه‌بعدی و افزایش زمان آزمون، به نتایج ۹۰٫۲۱٪/۹۰٫۲۱٪/۹۰٫۲۱٪، ۷۹٫۷۲٪/۷۹٫۷۲٪/۷۹٫۷۲٪ و ۸۵٫۸۳٪/۸۵٫۸۳٪/۸۵٫۸۳٪ رسید (فاصله هاسدورف: ۶٫۱۸۶، ۱۸۶٫۱۸، ۱۳۳٫۱۳۳، ۳ و ۶٫۳۷۶، ۳۷۶٫۳۷ میلی‌متر). هو و همکاران [۲۲] با MCCNN (چند آبخاری + CRF) به امتیازات ۷۴٫۸۱٪/۷۴٫۸۱٪/۷۴٫۸۱٪، ۷۱٫۷۸٪/۷۱٫۷۸٪/۷۱٫۷۸٪ و ۸۸٫۲۴٪/۸۸٫۲۴٪/۸۸٫۲۴٪ دست یافت.

رویکردهای بدون نظارت شامل خوشه‌بندی [۲۳، ۲۴] با SOM^۷ و فازی K-means/انترپوی گرادیان، و رویکردهای ترکیبی [۲۵] با فیلتر گابور، تبدیل موجک و طبقه‌بندهای SVM^۸/RBF^۹/KNN بودند. در [۲۶] از شبکه عصبی-فازی، در [۲۷] از الگوریتم ژنتیک، در [۲۸] از کلونی مورچگان، در [۲۹] از کرم شب‌تاب، در [۳۰] از PSO^{۱۰}، و در [۳۱] از الگوریتم خفاش برای تقطیع چندکاناله به‌کار رفته است (ارزیابی با معیارهای MSE^{۱۱}، PSNR^{۱۲}، Jaccard، Dice).

روش‌های پردازش تصویر کلاسیک شامل طیف‌بینی MRS^{۱۳} و DWI^{۱۴} [۳۲]، لبه‌یابی سوبل ارتقایافته [۳۳]، واترشد + خوشه‌بندی سلسله‌مراتبی [۳۴]، و انتشار آنیزوتروپیک + FCM^{۱۵}/SVM [۳۵] بودند. تقطیع دستی [۳۶-۳۹]

1. magnetic resonance imaging
2. convolutional neural network
3. Kamnitsas et al.
4. conditional random field
5. Mittal et al.
6. graph convolutional neural network
7. brain tumor segmentation
8. Wang et al.
9. Hu et al.
10. self-organizing map
11. support vector machine
12. radial basis function
13. particle swarm optimization
14. mean squared error
15. peak signal-to-noise ratio
16. magnetic resonance spectroscopy
17. diffusion-weighted imaging
18. fuzzy c-means

خسته‌کننده و وابسته به ناحیه مورد علاقه (ROI) است؛ لذا مدل‌های تولیدی (اطلس‌محور [۳۹-۴۲] و تبعیض‌آمیز CRF [۴۳-۴۵]، جنگل تصادفی [۴۶-۴۸]، SVM [۴۹]، درخت تصمیم [۵۰]) ترجیح داده می‌شوند. در [۵۱] با شبکه عمیق فعال و PSO، امتیازات دایس $0.83/0.73$ ، $0.93/0.7$ و $0.79/0.94$ (BraTS2017) و $0.88/0.34$ ، $0.91/0.2$ و $0.81/0.84$ (BraTS2018) به‌دست آمد (دقت میانگین 0.92%). در [۵۲] با استفاده از PSO برای حذف مجموعه، LBP و ویژگی عمیق و ژنتیک و ANN، دقت 0.98% گزارش شده است. در [۵۳] الگوریتم داروین-PSO و فیلتر گوسی و عصبی-فازی برای تقطیع و طبقه‌بندی پیشنهاد شده است.

روش پیشنهادی

روش پیشنهادی شامل سه فاز اصلی پیش‌پردازش، تقطیع و استخراج ویژگی (بر پایه مدل منحنی براونیان) و طبقه‌بندی نهایی با شبکه کانولوشنی بهینه‌شده (ConvNet) است. این ساختار با هدف کاهش نویز، حفظ جزئیات بافتی، تقطیع دقیق و تشخیص خودکار تومورهای خوش‌خیم و بدخیم از تصاویر MRI مجموعه داده BraTS طراحی شده است. در فاز پیش‌پردازش، تصاویر ورودی ابتدا به ابعاد 256×256 پیکسل نرمال‌سازی می‌شوند تا سازگاری با ورودی شبکه و کاهش پیچیدگی محاسباتی تضمین گردد. سپس، برای جبران تغییرات زاویه تصویربرداری، فاصله کانونی با رابطه ۱ محاسبه و مبدأ مختصات با روابط ۲ و ۳ تعیین می‌شود:

$$BASE = \sqrt{(x_5 - x_{10})^2 + (y_5 - y_{10})^2} \quad (1)$$

$$x_0 = \frac{x_5 - x_{10}}{2} \quad (2)$$

$$y_0 = \frac{y_5 - y_{10}}{2} \quad (3)$$

این عملیات، مرجع ثابتی برای مقایسه تومورها ایجاد می‌کند. در ادامه، یکپارچه‌سازی هیستوگرام برای افزایش کنتراست در نواحی کم‌نور و برجسته‌سازی بافت تومور اعمال می‌شود. فیلتر میانه، نویزهای impulsive را بدون تخریب لبه‌ها حذف می‌کند و فیلتر بالاگذر با تأکید بر لبه‌ها، جزئیات ساختاری را تقویت می‌نماید. در نهایت، برای هم‌ترازی تصاویر با محور افقی و کاهش خطای تقطیع ناشی از چرخش سر، زاویه دوران با رابطه ۴ محاسبه و اثر آن با رابطه ۵ حذف می‌شود:

$$\theta = \arctan\left(\frac{y_5 - y_{10}}{x_5 - x_{10}}\right) \quad (4)$$

$$y_a = y_b - y_{\text{original}} \quad (5)$$

جدول ۱. روابط فاز پیش‌پردازش و هم‌ترازی هندسی

رابطه	کاربرد فرمول	هدف در فرآیند
(۱)	محاسبه فاصله کانونی ^۲	جبران تغییرات ناشی از تنظیمات دوربین یا اسکنر و ایجاد یک مرجع هندسی ثابت برای مقایسه تصاویر.
(۲ و ۳)	تعیین مبدأ مختصات ^۳	تعیین نقطه مرجع مرکزی (صفر مختصات) در تصویر، که برای هم‌ترازی فضایی تصاویر مختلف ضروری است.
(۴)	محاسبه زاویه دوران ^۴	تعیین میزان انحراف تصویر از حالت افقی (مثلاً به دلیل چرخش سر بیمار).
(۵)	حذف اثر چرخش ^۵	اعمال تبدیل هندسی برای هم‌ترازی تصویر با محور افقی استاندارد، کاهش خطای تقطیع ناشی از این چرخش‌ها.

1. artificial neural network
2. focal length
3. origin determination
4. rotation angle calculation
5. rotation removal

فاز تقطیع و استخراج ویژگی با مدل منحنی براونین و عملیات ریخت‌شناسی ریاضی انجام می‌شود. ابتدا، مانایی^۱ با رابطه ۶ نواحی کوچک و نويز را حذف کرده و ساختار اصلی تومور را حفظ می‌کند:

$$A \ominus B = \{z \mid (B)_z \subseteq A\} = \{z \mid (B)_z \cap A^c = \emptyset\} \quad (۶)$$

سپس، گسترش^۲ با رابطه ۷ حفره‌های داخلی تومور را پر کرده و مرزهای از دست رفته را بازیابی می‌کند:

$$A \oplus B = \{z \mid (\hat{B})_z \cap A \neq \emptyset\} \quad (۷)$$

مرز تومور با رابطه ۸ استخراج می‌شود:

$$\beta(A) = A - (A \ominus B) \quad (۸)$$

جدول ۲. فاز تقطیع با عملیات ریخت‌شناسی ریاضی

رابطه	کاربرد و هدف فرمول	توضیحات
(۶)	مانایی	حذف نویزهای نقطه‌ای کوچک و حفظ ساختار اصلی بافت تومور با فرسایش مرزها.
(۷)	گسترش	پر کردن حفره‌های داخلی و ترمیم مرزهای تومور که در مرحله مانایی از بین رفته‌اند.
(۸)	استخراج مرز ^۳	تفاضل دو تصویر (گسترش یافته منهای مانده) برای به دست آوردن ماسک دقیق مرز تومور.

برای استخراج ویژگی، تصاویر به بردارهای ستونی تبدیل شده و ماتریس $M * N^2 = A$ تشکیل می‌شود. میانگین تصاویر با رابطه ۹ و انحراف هر تصویر با رابطه ۱۰ محاسبه می‌گردد:

$$\Psi = \frac{1}{M} \sum_{i=1}^M \Gamma_i \quad (۹)$$

$$\phi_i = \Gamma_i - \Psi \quad (۱۰)$$

ماتریس کواریانس با رابطه ۱۱ و بردارهای ویژه با رابطه ۱۲ به دست می‌آیند:

$$C = A^T A \quad (۱۱)$$

$$U_i = A V_i \quad (۱۲)$$

کاهش بعد با ماتریس پراکندگی کل (رابطه ۱۳) و ماکزیمم‌سازی واریانس (رابطه ۱۴) انجام می‌شود:

$$S_T = \sum_{k=1}^N (x_k - \mu)(x_k - \mu)^T \quad (۱۳)$$

$$W_{\text{Brownian}} = \arg \max[W^T S_T W] \quad (۱۴)$$

1. erosion
2. dilation
3. boundary extraction

جدول ۳. روابط فاز استخراج ویژگی و کاهش بعد

رابطه	کاربرد فرمول	هدف در فرآیند
(۹)	میانگین تصاویر	محاسبه مقدار متوسط روشنایی یا شدت پیکسل‌ها در کل مجموعه تصاویر یا ناحیه مورد نظر.
(۱۰)	انحراف استاندارد ^۱ هر تصویر	اندازه‌گیری میزان پراکندگی شدت پیکسل‌ها نسبت به میانگین. این یک معیار کلیدی برای میزان پیچیدگی یا تنوع بافتی در تصویر است.
(۱۱)	ماتریس کواریانس ^۲	اندازه‌گیری چگونگی تغییر دو یا چند متغیر (در اینجا شدت پیکسل‌ها در ابعاد مختلف) به طور همزمان. این ماتریس برای تحلیل ساختار داده‌ها در PCA استفاده می‌شود.
(۱۲)	بردارهای ویژه ^۳	این بردارها جهت‌هایی را نشان می‌دهند که بیشترین واریانس (تغییرات) در داده‌ها وجود دارد. آن‌ها اساس کاهش بعد را تشکیل می‌دهند.
(۱۳)	کاهش بعد با ماتریس پراکندگی کل ^۴	استفاده از بردارهای ویژه برای انتخاب مهم‌ترین ابعاد (مولفه‌ها) که بیشترین اطلاعات را حفظ می‌کنند.
(۱۴)	ماکزیم‌سازی واریانس	در ترکیب با رابطه ۱۳، این گام اطمینان می‌دهد که ویژگی‌هایی که انتخاب می‌شوند، بیشترین اطلاعات تمایزدهنده را نسبت به سایر ابعاد حفظ می‌کنند.
مقایسه با آستانه اقلیدسی	شناسایی تومور (نه طبقه‌بندی نهایی)	با مقایسه فاصله بردار ویژگی‌های استخراج شده (پس از کاهش بعد) با فواصل از پیش تعریف شده، نواحی تومورال از بافت سالم تفکیک می‌شوند.

شناسایی تومور با مقایسه فاصله اقلیدسی بردارهای ویژه با آستانه صورت می‌گیرد؛ این روش واریانس حداکثری را حفظ کرده و ابعاد غیرمرتبط را حذف می‌کند.

در فاز طبقه‌بندی، ویژگی‌های بهینه‌شده به ConvNet وارد می‌شوند. ابتدا، آستانه‌گذاری پتانسیل عمل با روابط ۱۵ سیگنال‌های ضعیف را حذف می‌کند:

$$\sigma_n = \frac{\text{median}(|x|)}{0.6745}, \quad \text{Threshold} = 3.5\sigma_n \quad (15)$$

تابع پایه گوسین با رابطه ۱۶ پاسخ نرون‌های بصری را مدل‌سازی می‌کند:

$$\phi(v) = \exp\left(-\frac{v^2}{2\sigma^2}\right) \quad (16)$$

آموزش با الگوریتم Levenberg-Marquardt و محاسبه گرادیان با رابطه ۱۷ انجام می‌شود:

$$g = J_e^T \quad (17)$$

در صورت خطا، وزن‌ها با رابطه ۱۸ به‌روزرسانی می‌شوند:

$$w_i^{\text{new}} = w_i^{\text{old}} + ax_{it} \quad (18)$$

جدول ۴. روابط فاز طبقه‌بندی نهایی با ConvNet بهینه‌شده

رابطه	کاربرد فرمول	هدف در فرآیند
(۱۵)	آستانه‌گذاری پتانسیل عمل ^۱	در شبکه‌های عصبی بیولوژیکی/مدل‌های تقلید شده، این آستانه تعیین می‌کند که یک نورون چه زمانی باید فعال شود. در اینجا، برای حذف سیگنال‌های بسیار ضعیف (نویز باقی‌مانده) به کار می‌رود.
(۱۶)	تابع پایه گوسین ^۲	یک تابع فعال‌سازی مبتنی بر فاصله (مشابه RBF) که پاسخ نورون‌ها را با یک توزیع نرمال مدل‌سازی می‌کند. این تابع به شبکه اجازه می‌دهد تا پاسخ‌های محلی و پیوسته داشته باشد.
(۱۷)	الگوریتم Levenberg-Marquardt (LM) و محاسبه گرادیان	LM یک روش بهینه‌سازی ترکیبی (بین نزول گرادیان و روش گاوس-نیوتن) است که برای به‌روزرسانی وزن‌های شبکه (W) استفاده می‌شود. محاسبه گرادیان تعیین می‌کند که وزن‌ها باید در چه جهتی و به چه میزان تنظیم شوند تا خطا کاهش یابد.
(۱۸)	به‌روزرسانی وزن‌ها ^۳	فرمول اصلی آموزش شبکه عصبی که در آن وزن‌ها (W) با استفاده از گرادیان محاسبه شده در مرحله قبل و نرخ یادگیری مناسب، تنظیم می‌شوند تا خطای پیش‌بینی (E) در تکرار بعدی کاهش یابد.


معماری ConvNet بهینه‌شده شامل ورودی (۳۲ نرون)، یک لایه پیچشی 3×3 برای استخراج الگوهای محلی، دو لایه پولینگ (Max + Random) برای کاهش ابعاد و جلوگیری از بیش‌برازش، یک لایه تمام‌متصل برای ترکیب ویژگی‌های جهانی و خروجی Softmax (۲ کلاس) است. آموزش با ۷۰٪ داده آموزشی، ۳۰٪ آزمون، ۱۰۰۰ دوره، نرخ یادگیری ۰/۰۰۱ انجام می‌شود.

این رویکرد با ادغام ریخت‌شناسی براونیان (تقطیع دقیق) و ConvNet بهینه‌شده (طبقه‌بندی قوی)، سیستمی دقیق، پایدار و قابل تعمیم برای تشخیص خودکار تومورهای مغزی از تصاویر MRI ارائه می‌دهد.

شبیه‌سازی و نتایج

مجموعه داده‌های تومور مغزی استفاده شده در این پژوهش، داده‌های TCGA-GBM می‌باشد که به دارای ۱۴۵ پوشه برای بیماران در شرایط مختلف عکسبرداری به صورت ام‌آرآی هستند. این مجموعه داده از ۴ نسخه در سال‌های ۲۰۱۲ الی ۲۰۱۸ تشکیل شده است که در هر نسخه، مجموعه داده‌ها بیشتر و کیفیت آن‌ها بالاتر می‌رود. داده‌های اصلی این مجموعه داده با فرمت DICOM می‌باشند که در این پژوهش جهت استفاده ساده‌تر از طریق نرم افزار DICOM Viewer به فرمت JPEG تبدیل شده اند. تعدادی از تصاویر استفاده شده اند که در بخش نتایج به‌دست آمده نشان داده خواهند شد. یک نمونه از ورودی‌های مدنظر این تحقیق، مانند داده ذیل است که در شکل ۱ و شکل ۲ در محیط DICOM VIEWER نشان داده شده است.

1. action potential thresholding
2. gaussian basis function
3. weight update



شکل ۱. انتخاب داده در محیط DICOM VIEWER



شکل ۲. انتخاب داده در محیط DICOM VIEWER

شبیه‌سازی روش پیشنهادی در محیط MATLAB R2015b بر روی سیستم مجهز به پردازنده ۷ هسته‌ای با فرکانس ۳/۶ GHz، حافظه کش ۶ مگابایت و ۶ گیگابایت RAM تحت سیستم‌عامل Windows 8 انجام شده است. این پیکربندی سخت‌افزاری، امکان اجرای الگوریتم‌های پیچیده یادگیری عمیق و پردازش تصویر را با سرعت و کارایی بالا فراهم می‌آورد. هدف اصلی، طراحی الگوریتمی سریع، کارآمد و قابل تعمیم به داده‌های ورودی با ابعاد و حجم بالا است تا نرخ تشخیص تومورهای مغزی در تصاویر MRI (مجموعه داده BraTS) به صورت دقیق و پایدار ارزیابی شود.

رویکرد پیشنهادی بر پایه یادگیری عمیق بدون نظارت طراحی شده و از ترکیب دو مؤلفه کلیدی تشکیل می‌شود: مدل منحنی براونی و شبکه کانولوشنی ConvNet. در ابتدا، تمامی تصاویر ورودی تحت نرمال‌سازی اولیه قرار می‌گیرند که شامل یکسان‌سازی ابعاد (۲۵۶×۲۵۶)، بهبود شدت روشنایی و کاهش نویزهای احتمالی با استفاده از فیلتر


میانه است. این فیلتر، نویزهای impulsive را بدون تخریب لبه‌ها حذف کرده و زمینه‌ای مناسب برای مراحل بعدی فراهم می‌کند.

سپس، مدل منحنی براونین به‌عنوان مؤلفه بدون نظارت وارد عمل می‌شود. این مدل با بهره‌گیری از عملگرهای ریخت‌شناسی ریاضی — یعنی مانایی و گسترش — ویژگی‌های محلی کلیدی شامل بافت، لبه و شدت روشنایی را شناسایی می‌کند. فرآیند در سه مرحله انجام می‌شود: کاهش بعد ویژگی‌ها با تحلیل کواریانس و حذف ابعاد غیرمرتبط، انتخاب ویژگی‌های معنادار بر اساس واریانس حداکثری، استخراج ویژگی‌های ذاتی تومور برای ورودی به شبکه عصبی.

این مرحله، با استدلال احتمالاتی، الگوهای پیچیده تومور را حتی در حضور نویز و تنوع ساختاری تصاویر MRI تشخیص می‌دهد.


در ادامه، ویژگی‌های بهینه‌شده به شبکه کانولوشنی ConvNet وارد می‌شوند. این شبکه، با معماری بهینه‌شده (شامل لایه‌های پیچشی، پولینک و تمام‌متصل)، وظیفه آموزش الگوهای پیچیده و طبقه‌بندی نهایی (خوش‌خیم/بدخیم) را بر عهده دارد. آموزش با تقسیم‌بندی ۷۰٪ داده آموزشی و ۳۰٪ آزمون، ۱۰۰۰ دوره تکرار و نرخ یادگیری ۰/۰۰۱ انجام می‌شود. پنجره آموزش و آزمون ترکیبی (مدل براونین + ConvNet) در شکل ۳ نمایش داده شده است که مراحل استخراج ویژگی، کاهش بعد و طبقه‌بندی را به‌صورت یکپارچه نشان می‌دهد.

این روش، با سرعت پردازش بالا، مصرف حافظه بهینه و قابلیت جستجوی کارآمد در داده‌های حجیم، عملکردی دقیق، پایدار و قابل تعمیم در تشخیص خودکار تومورهای مغزی ارائه می‌دهد و به‌عنوان ابزاری کمکی بالینی، پتانسیل بالایی برای کاربرد در سیستم‌های تشخیصی واقعی دارد.




شکل ۳. پنجره آموزش و آزمون شبکه عصبی کانولوشن ConvNet با مدل منحنی براونین

شکل ۴ نمودار کارایی برای رسیدن به همگرایی و هدف نهایی در فاز آموزش را نشان می‌دهد.




شکل ۴. نمودار کارایی برای رسیدن به همگرایی و هدف نهایی در فاز آموزش

همین‌طور شکل ۵ نمودار خطای موجود در زمان آموزش از کل مجموعه داده‌ها را بر اساس یک احتمال خطا در زمان شبیه‌سازی، نشان می‌دهد.




شکل ۵. نمودار خطای موجود در زمان آموزش از کل مجموعه داده‌ها را بر اساس یک احتمال خطا در زمان شبیه‌سازی

برای آزمون داده‌ها، نیاز است تا یک تصویر ورودی مورد نظر قرار گیرد. در واقع ۷۰٪ داده‌ها آموزش و ۳۰٪ آن‌ها مورد آزمون قرار گرفته‌اند. اما نیاز است تا یکی از تصاویر به صورت بصری نشان داده شود. از یکی از تصاویر در مجموعه داده استفاده کرده‌ایم که در شکل ۶ مشخص است.




شکل ۶. تصویر ورودی

سپس هیستوگرام^۱ آن تصویر محاسبه می‌شود که مانند شکل ۷ می‌باشد.



شکل ۷. هیستوگرام تصویر

این هیستوگرام، در واقع کانال‌های رنگی قرمز، سبز و آبی را بر اساس ۲۵۶ رنگ در یک آستانه نشان می‌دهد. سپس تصویر نرمال‌سازی می‌شود و از حالت رنگی یا فضای رنگی RGB به سطح خاکستری تبدیل می‌شود که نتیجه آن مانند شکل ۸ است.




شکل ۸. تبدیل تصویر از فضای رنگی RGB به سطح خاکستری

سپس تقطیع مبتنی بر مدل منحنی براونین بر اساس ویژگی‌های محلی شامل بافت، شدت روشنایی و لبه تصویر، مبتنی بر دو عامل شامل خودمتشابه بودن و مانایی، انجام می‌گیرد که نتیجه آن مانند شکل ۹ می‌باشد.



شکل ۹. نتیجه تقطیع تصویر بر پایه مدل منحنی براونین

قابل ذکر است که تقطیع با شناسایی سه ویژگی از جمله شدت روشنایی و لبه‌های جدا از تصویر اصلی و همین طور بافت، انجام می‌شود که نتیجه آن در شکل ۱۰ نمایش داده شده است.



شکل ۱۰. نتیجه تقطیع نهایی در فازهای آموزش شبکه عصبی کانولوشن با مدل منحنی براونین


ویژگی‌هایی که استفاده شده است، بر پایه لبه یابی (نقاط اتصال یافته در داخل شی دیگر)، شدت روشنایی و بافت، می‌باشد. در واقع سه ویژگی محلی برای تقطیع مورد استفاده واقع شده است. در علوم پایه این طور بیان می‌شود که هر چه تعداد ویژگی‌های برای عملیات استخراج ویژگی کمتر باشد، اعتبار کار در صورتی که پاسخی مناسب ارائه دهد، نسبت به روش‌هایی که از تعداد ویژگی‌هایی بیشتری استفاده کرده اند، اعتبار علمی بالاتری خواهد داشت. در نهایت، در ادامه از شبکه عصبی کانولوشن برای تشخیص نهایی استفاده خواهد شد که با هدف بهبود تقطیع و انتخاب کلاس‌های بهینه ویژگی‌ها جهت تشخیص ویژگی‌های موجود در تصاویر ام‌آر‌آی در تصویر انجام می‌گیرد که نتیجه آن، شکل ۱۱ خواهد بود.



شکل ۱۱. نتیجه نهایی کار

همان‌طور که در شکل ۱۱ نیز مشخص است، عملیات تقطیع و طبقه‌بندی تصویر، به خوبی انجام گرفته است و

ناحیه ویژگی‌های تومور شناسایی و تشخیص داده شده است. در شکل ۱۲، روش ارائه شده بر روی چند تصویر دیگر از مجموعه داده‌ها اعمال شده است.



شکل ۱۲. نتایج روش ارائه شده بر روی سایر تصاویر

حال نیاز است تا ویژگی‌های محلی نام برده شامل شدت روشنایی، لبه‌ها و هرگونه عامل یافت شده در بخش تقطیع و استخراج ویژگی‌ها، عملیات طبقه‌بندی نوع تومور شامل خوش خیم، بدخیم و مشکوک را انجام بدهند. لذا بعد از اعمال ساختار آموزشی شبکه عصبی کانولوشن مبتنی بر مدل منحنی براونیان، این کار انجام می‌شود که خروجی آن مانند شکل ۱۳ و ۱۴ خواهد بود.

```
case with ID : 915460 have Benign
case with ID : 91550 have Malignan
case with ID : 915664 Malingal ----- Error: suspicious one
case with ID : 915691 Benign ----- Error: suspicious one
case with ID : 915940 Malingal ----- Error: suspicious one
case with ID : 91594602 have Benign
case with ID : 916221 have Malignan
case with ID : 916799 have Benign
case with ID : 916838 have Benign
case with ID : 917062 have Malignan
case with ID : 917080 have Malignan
case with ID : 917092 have Malignan
case with ID : 91762702 have Benign
case with ID : 91789 have Malignan
case with ID : 917896 have Malignan
case with ID : 917897 have Malignan
case with ID : 91805 have Malignan
```

شکل ۱۳. تحلیل حالات تومور


```

case with ID : 89812 have Benign
case with ID : 89813 Malingal ----- Error: suspicious one
case with ID : 898143 have Malignan
case with ID : 89827 have Malignan
case with ID : 898431 have Benign
case with ID : 89864002 have Malignan
case with ID : 898677 have Malignan
case with ID : 898678 have Malignan
case with ID : 89869 Malingal ----- Error: suspicious one
case with ID : 898690 have Malignan
case with ID : 899147 have Malignan
case with ID : 899187 have Malignan
case with ID : 899667 have Benign
case with ID : 899987 have Benign
case with ID : 9010018 have Benign
case with ID : 901011 have Malignan

```

شکل ۱۴. تحلیل حالات تومور

در مجموعه داده‌های استفاده شده، تمامی داده‌ها برای هر بیمار، دارای یک شناسه یا ID هستند. حالت Benign یعنی خوش خیم، حالت Malignant یعنی بدخیم و حالت Suspicious یعنی مشکوک هستند. به طور مثال، شناسه ۹۱۵۵۰ در شکل ۱۳، دارای حالت بدخیم است، شناسه ۹۰۱۰۰۱۸ دارای حالت خوش خیم است، شناسه ۸۹۸۶۹ دارای حالت مشکوک می‌باشد. در ادامه نیاز است تا از یک سری معیارهای ارزیابی به منظور صحت کار، پرداخته شود. در این پژوهش از چند معیار ارزیابی استفاده شده است که شامل میانگین مربعات خطا^۱، اوج نسبت سیگنال به نویز^۲، نسبت سیگنال به نویز^۳، دقت^۴ است که در فصل سوم به تفصیل مورد بررسی واقع شدند. در نهایت نتایج به دست آمده از پژوهش انجام شده با هر روش ارزیابی، ذکر می‌شود.

جدول ۵ به ارائه نتایج به دست آمده برای معیارهای نام برده شده برای تصویر ورودی از ۱۰ تصویر آموزش دیده شده و قطعه بندی شده پرداخته است. در واقع ۱۴۵ تصویر را در برنامه وارد کرده و ۱۴۵ بار اجرا می‌کنیم و نتایج هر بار از این معیارها را با هم جمع و بر ۱۰ تقسیم می‌کنیم. هر چقدر مجموعه آموزشی و تست، بیشتر باشد، می‌توان درصد موفقیت بیشتر و بهتری را به دست بیاوریم.

جدول ۵. نتایج ارزیابی

۹۳/۶۲۹۹٪	دقت
۸۴/۶۶۶۷	حساسیت
۸۱/۵۴۶۷٪	مقدار ویژگی‌ها
۰/۸۵۹۸	میانگین مربعات خطا
۴۱/۷۰۸۱ dB	اوج نرخ سیگنال به نویز
۶/۴۲۲۷ dB	نرخ سیگنال به نویز


جدول ۶ به نمایش مقایسه روش ارائه شده با سه جدید دیگر که در مطالعات پیشین بررسی شدند، انجام گرفته است. این مقایسه با توجه به دو معیار دقت و حساسیت است. هر سه روشی که مقایسه با آن‌ها انجام گرفته است نیز از مجموعه داده همین تحقیق استفاده کرده اند.

-
1. Mean square error (MSE)
 2. Peak signal-to-noise ratio (PSNR)
 3. Signal-to-noise-ratio (SNR)
 4. accuracy


جدول ۶. نتیجه مقایسه روش پیشنهادی با سایر روش‌ها

الگوریتم	حساسیت	دقت
Linear SVM	۴۸/۲۱	٪ ۸۲/۲۰
SVM-RBF	۴۸/۸۵	٪ ۹۰/۰۹
KNN-SVM	۴۷/۱۸	٪ ۸۳/۱۰
روش ارائه شده	۸۴/۶۶۶۷	٪ ۹۳/۶۲۹۹

نتایج جدول ۶ در شکل ۱۵ بر اساس دقت و در شکل ۱۶ بر اساس حساسیت نیز نشان داده شده است.



شکل ۱۵. نتیجه مقایسه روش پیشنهادی با سایر روش‌ها بر اساس دقت



شکل ۱۶. نتیجه مقایسه روش پیشنهادی با سایر روش‌ها بر اساس حساسیت

همان‌طور که در جدول ۶ و شکل ۱۵ و ۱۶ مشاهده می‌شود، روش پیشنهادی دارای معیار دقت و حساسیت بالاتری در مقایسه با سایر روش‌های جدید است.

نتیجه‌گیری

با توجه به اینکه سیستم‌های تشخیص پزشکی نیازمند روش‌های مطمئن و سریع هستند تا پزشکان بتوانند به آن‌ها اطمینان کنند، نیاز است تا از اصول هوشمندسازی در ساخت این برنامه‌ها بهره جست. همچنین ساخت سیستم‌های تشخیص

پزشکی هوشمند، خطاهای انسانی را کاهش می‌دهد و پزشکان را در تشخیص و شناسایی بیماری‌ها کمک می‌نماید. این شناسایی و تشخیص زودهنگام منجر به شناخت وضعیت سلامت افراد و همچنین مراقبت بیشتر آن‌ها تا زمان بهبودی کامل می‌شود.

توده‌ها سرطانی که در نواحی مختلف بدن شکل می‌گیرند، دایا شکل منظم و اصول خاصی نیستند. تصویربرداری از نواحی مختلف بدن می‌تواند به شناسایی نواحی و همین‌طور اندازه این تومورها کمک نماید. همچنین می‌توان با استفاده از اصول پزشکی، حالات بدخیم و خوش‌خیم آن را نیز تخمین زد. این توده‌های توموری که یکی از مهم‌ترین عامل‌های مرگ و میر در دنیا هستند، نیاز است تا حد ممکن به درستی تشخیص داده شوند. لذا ساخت سیستم‌های هوشمند، امری مهم و اجتناب‌ناپذیر به شمار می‌رود.

در این تحقیق، سعی بر آن است تا با استفاده از عکس برداری از ناحیه مغز، تصاویر ام‌آرآی را تولید نمود که دارای توده توموری هستند و بعضاً نیستند. مجموعه داده‌های استفاده شده در این تحقیق، شامل BraTS هستند که یک سری تصویر استاندارد ام‌آرآی از سطح مغز هستند که دارای ویژگی‌های یکسانی از لحاظ شدت نور و روشنایی و همین‌طور حالات رنگی است. با استفاده از اصول پردازش تصویر و یادگیری ماشین، می‌توان یک سیستم همه‌جانبه جهت تشخیص تومورهای مغزی از سطح تصاویر ام‌آرآی را ارائه داد.

نتایج شبیه‌سازی نشان می‌دهند که رویکرد پیشنهادی از لحاظ معیارهای ارزیابی نسبت به روش‌های پیشین، دارای برتری عملکردی است. از جمله این نتایج ارزیابی، می‌توان به دقت در تقطیع و تشخیص ناحیه دقیق توده در تصاویر ام‌آرآی با دقتی برابر ۹۳/۶۲٪ اشاره نمود. همین‌طور میانگین مربعات خطا برابر ۰/۸۵، اوج نسبت سیگنال به نویز برابر ۴۱/۷۰ دسی‌بل و حساسیت ۸۴/۶۶ است. که نسبت به روش‌های مشابه پیشین، برتری عملکردی را نشان می‌دهد.

منابع

1. Pereira S, Pinto A, Alves V, Silva CA. Brain tumor segmentation using convolutional neural networks in MRI images. *IEEE Transactions on Medical Imaging*. 2016;35(5):1240-51.
2. Urban G, Bendszus M, Hamprecht F, Kleesiek J, editors. Multi-modal brain tumor segmentation using deep convolutional neural networks. *Proceedings of MICCAI BraTS Challenge*; 2014.
3. Havaei M, Davy A, Warde-Farley D, Biard A, Courville A, Bengio Y, et al. Brain tumor segmentation with deep neural networks. *Medical Image Analysis*. 2017;35:18-31.
4. Wang G, Zuluaga MA, Li W, Pratt R, Patel PA, Aertsen M, et al. Deepigeos: a deep interactive geodesic framework for medical image segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 2019;41(7):1559-72.
5. Zhao X, Wu Y, Song G, Li Z, Zhang Y, Fan Y. A deep learning model integrating fcnn and crfs for brain tumor segmentation. *Medical Image Analysis*. 2017;43:98-111.
6. Zhan T, Shen F, Hong X, Wang X, Chen Y, Lu Z, Yang G. A glioma segmentation method using cotraining and super pixel-based spatial and clinical constraints. *IEEE Access*. 2018;6:57113-22.
7. Wei J, Xia Y. Multi-scale networks for segmentation of brain magnetic resonance images. *Deep learning in medical image analysis and multimodal learning for clinical decision support*. Cham: Springer; 2017. p. 312-20.
8. Isensee F, Kickingereder P, Bonekamp D, Bendszus M, Wick W, Schlemmer HP, Maier-Hein K, editors. Brain tumor segmentation using large receptive field deep convolutional neural networks. *Bildverarbeitung für die Medizin*; 2017.
9. Chen S, Ding C, Liu M. Dual-force convolutional neural networks for accurate brain tumor segmentation. *Pattern Recognition*. 2019;88:90-100.

10. Davy A, Havaei M, Warde-Farley D, Biard A, Courville A, Bengio Y, et al., editors. Brain tumor segmentation with deep neural networks. Proceedings of MICCAI BraTS Challenge; 2014; Boston, MA.
11. Hu K, Zhang Z, Niu X, Zhang Y, Cao C, Xiao F, Gao X. Retinal vessel segmentation of color fundus images using multiscale convolutional neural network with an improved cross-entropy loss function. *Neurocomputing*. 2018;309:179-91.
12. Kamnitsas K, Ledig C, Newcombe VFJ, Simpson JP, Kane AD, Menon DK, et al. Efficient multi-scale 3dcnn with fully connected crf for accurate brain lesion segmentation. *Medical Image Analysis*. 2017;36:61-78.
13. Zheng S, Jayasumana S, Romera-Paredes B, Vineet V, Su Z, Du D, et al., editors. Conditional random fields as recurrent neural networks. Proceedings of IEEE International Conference on Computer Vision; 2015.
14. Kistler M, Bonaretti S, Pfahrer M, Niklaus R, Büchler P. The virtual skeleton database: an open access repository for biomedical research and collaboration. *Journal of Medical Internet Research*. 2013;15(11):e245.
15. Myronenko A, editor 3d mri brain tumor segmentation using autoencoder regularization. International MICCAI Brainlesion Workshop; 2018; Granada: Springer.
16. Wang G, Li W, Ourselin S, Vercauteren T, editors. Automatic brain tumor segmentation using cascaded anisotropic convolutional neural networks. International MICCAI Brainlesion Workshop; 2017; Quebec City: Springer.
17. Chen LC, Papandreou G, Kokkinos I, Murphy K, Yuille AL. Semantic image segmentation with deep convolutional nets and fully connected crfs. *arXiv*. 2014.
18. Zheng S, Jayasumana S, Romera-Paredes B, Vineet V, Su Z, Du D, et al., editors. Conditional random fields as recurrent neural networks. Proceedings of the IEEE international conference on computer vision; 2015.
19. Mittal M, Goyal LM, Kaur S, Kaur I, Verma A, Hemanth DJ. Deep learning based enhanced tumor segmentation approach for MR brain images. *Applied Soft Computing*. 2019;78:346-54.
20. Zhou Z, He Z, Jia Y. AFPNet: A 3D fully convolutional neural network with atrous-convolution feature pyramid for brain tumor segmentation via MRI images. *Neurocomputing*. 2020;402:235-44.
21. Wang G, Li W, Ourselin S, Vercauteren T, editors. Automatic brain tumor segmentation using convolutional neural networks with test-time augmentation. International MICCAI Brainlesion Workshop (BrainLes); 2018.
22. Hu K, Gan Q, Zhang Y, Deng S, Xiao F, Huang W, et al. Brain tumor segmentation using multi-cascaded convolutional neural networks and conditional random field. *IEEE Access*. 2019;7:92615-29.
23. Vishnuvarthanan G, Rajasekaran MP, Subbaraj P, Vishnuvarthanan A. An unsupervised learning method with a clustering approach for tumor identification and tissue segmentation in magnetic resonance brain images. *Applied Soft Computing*. 2015.
24. Ortiz A, Gorris JM, Ramirez J, Salas-Gonzalez D. Improving MR brain image segmentation using self-organizing maps and entropy-gradient clustering. *Information Sciences*. 2014;262:117-36.
25. Nabizadeh N, Kubat M. Brain tumors detection and segmentation in MR images: gabor wavelet vs. statistical features. *Computers and Electrical Engineering*. 2015;45:286-301.
26. Shanthakumar P, Ganeshkumar P. Performance analysis of classifier for brain tumor detection and diagnosis. *Computers and Electrical Engineering*. 2015.
27. Chandra GR, Rao KRH, editors. Tumor detection in brain using genetic algorithm. *Procedia Computer Science*; 2016.
28. Karnan M, Selvanayagi K, editors. Improved implementation of brain MR image segmentation using meta heuristic algorithms. IEEE International Conference on Computational Intelligence and Computing Research (ICICR); 2010.
29. Ghosh P, Mali K, Das SK. Chaotic firefly algorithm-based fuzzy C-means algorithm for segmentation of brain tissues in magnetic resonance images. *Journal of Visual Communication and Image Representation*. 2018;54:63-79.

30. Zhu Q, Du B, Yan P, Lu H, Zhang L. Shape prior constrained pso model for bladder wall MRI segmentation. *Neurocomputing*. 2018;294:19-28.
31. Alagarsamy S, Kamatchi K, Govindaraj V, Zhang YD, Thiagarajan A. Multi-channelled MR brain image segmentation: a new automated approach combining bat and clustering technique for better identification of heterogeneous tumors. *Biocybernetics and Biomedical Engineering*. 2019;39(4):1005-35.
32. Darwiesh AMN, Abd-El Maboud NM, Khalil AMR, ElSharkawy AM. Role of magnetic resonance spectroscopy and diffusion weighted imaging in differentiation of supratentorial brain tumors. *The Egyptian Journal of Radiology and Nuclear Medicine*. 2016.
33. Aslam A, Khan E, Beg MMS, editors. Improved edge detection algorithm for brain tumor segmentation. *Procedia Computer Science*; 2015.
34. Rajeswari R, Gunasekaran G. Tumor detection and segmentation using watershed and hierarchical clustering algorithms. *International Journal of Innovative Research in Computer and Communication Engineering*. 2014;2(5).
35. Ain Q, Jaffar MA, Choi T-S. Fuzzy anisotropic diffusion based segmentation and texture based ensemble classification of brain tumor. *Applied Soft Computing*. 2014;21:330-40.
36. Olabarriaga SD, Smeulders AW. Interaction in the segmentation of medical images: a survey. *Medical Image Analysis*. 2001;5(2):127-42.
37. Yao J. Image processing in tumor imaging. *New techniques in oncologic imaging*. London, U.K.: Taylor & Francis; 2006. p. 79-102.
38. Menze BH. The multimodal brain tumor image segmentation benchmark (BRATS). *IEEE Transactions on Medical Imaging*. 2015;34(10):1993-2024.
39. Prastawa M, Bullitt E, Ho S, Gerig G. A brain tumor segmentation framework based on outlier detection. *Medical Image Analysis*. 2004;8(3):275-83.
40. Cuadra MB, Pollo C, Bardera A, Cuisenaire O, Villemure JG, Thiran JP. Atlas based segmentation of pathological MR brain images using a model of lesion growth. *IEEE Transactions on Medical Imaging*. 2004;23(10):1301-14.
41. Menze BH, van Leemput K, Lashkari D, Weber MA, Ayache N, Golland P. A generative model for brain tumor segmentation in multimodal images. *Proceedings of the International Conference on Medical Image Computing and Computer-Assisted Intervention*. Beijing, China: Springer; 2010. p. 151-9.
42. Gooya A, Pohl KM, Bilello M, Cirillo L, Biros G, Melhem ER, Davatzikos C. GLISTR: glioma image segmentation and registration. *IEEE Transactions on Medical Imaging*. 2012;31(10):1941-54.
43. Lee CH, Schmidt M, Murtha A, Bistriz A, Sander J, Greiner R. Segmenting brain tumors with conditional random fields and support vector machines. *Proceedings of the International Workshop on Computer Vision for Biomedical Image Applications*. Beijing, China: Springer; 2005. p. 469-78.
44. Chen LC, Papandreou G, Kokkinos I, Murphy K, Yuille AL. Semantic image segmentation with deep convolutional nets and fully connected crfs. *arXiv preprint arXiv:1412.7062*. 2014.
45. Kamnitsas K, Ledig C, Newcombe VF, Simpson JP, Kane AD, Menon DK, et al. Efficient multi-scale 3D CNN with fully connected CRF for accurate brain lesion segmentation. *Medical image analysis*. 2017;36:61-78.
46. Tustison NJ, Shrinidhi KL, Wintermark M, Durst CR, Kandel BM, Gee JC, et al. Optimal symmetric multimodal templates and concatenated random forests for supervised brain tumor segmentation (simplified) with ANTsR. *Neuroinformatics*. 2015;13(2):209-25.
47. Meier R, Bauer S, Slotboom J, Wiest R, Reyes M. Appearance and context sensitive features for brain tumor segmentation. *Proceedings of the MICCAI BRATS Challenge2014*. p. 20-6.
48. Reza S, Iftekharuddin KM. Improved brain tumor tissue segmentation using texture features. *Proceedings of the MICCAI BraTS Brain Tumor Segmentation Challenge2014*. p. 27-30.
49. Bauer S, Nolte LP, Reyes M. Fully automatic segmentation of brain tumor images using support vector machine classification in combination with hierarchical conditional random field regularization. *Proceedings of the International Conference on Medical Image Computing and Computer-Assisted Intervention*. Toronto, ON, Canada: Springer; 2011. p. 354-61.

50. Zikic D, Glocker B, Konukoglu E, Criminisi A, Demiralp C, Shotton J, et al. Decision forests for tissue specific segmentation of high grade gliomas in multi channel MR. Proceedings of the International Conference on Medical Image Computing and Computer-Assisted Intervention. Nice, France: Springer; 2012. p. 369-76.
51. Sharif MI, Li JP, Khan MA, Saleem MA. Active deep neural network features selection for segmentation and recognition of brain tumors using MRI images. Pattern Recognition Letters. 2020;129:181-9.
52. Sharif M, Amin J, Raza M, Yasmin M, Satapathy SC. An integrated design of particle swarm optimization (PSO) with fusion of features for detection of brain tumor. Pattern Recognition Letters. 2020;129:150-7.
53. Vijay V, Kavitha AR, Rebecca SR. Automated brain tumor segmentation and detection in MRI using enhanced Darwinian particle swarm optimization (EDPSO). Procedia Computer Science. 2016;92:475-80.

استناد به این مقاله: زارعی، علیرضا، و ذاکری، فاطمه. (۱۴۰۴). طبقه‌بندی تومورهای گلیوما مغز بر پایه شبکه عصبی عمیق ConvNet و منحنی براونی. فصلنامه پیشرفت‌های مهندسی در حوزه‌ی پزشکی و مواد، ۱(۳)، ۶۵-۸۴.



Journal of Recent Advancements in Material Science and Biomedical Engineering is licensed under a Creative Commons Attribution-NonCommercial 4.0 International License.