

استفاده از روش‌های طبقه‌بندی بر مبنای یادگیری عمیق برای تفسیر تصاویر MRI مغزی به منظور تشخیص تومور

فاطمه باقری^۱، اصغر میلان^{۲*}، غلامرضا فلاحي^۲

^۱ دانشجوی کارشناسی ارشد دانشکده مهندسی عمران، آب و محیط زیست دانشگاه شهید بهشتی
f.bagheridizabadi@mail.sbu.ac.ir

^۲ استادیار دانشکده مهندسی عمران، آب و محیط زیست دانشگاه شهید بهشتی
a_milan@sbu.ac.ir, g_fallahi@sbu.ac.ir

(دریافت: اردیبهشت ۱۴۰۳، تصویب: تیر ۱۴۰۳)

چکیده

طبقه‌بندی تومورهای مغزی برای ارزیابی و تشخیص نوع تومورها و تصمیم‌گیری به منظور درمان با توجه به مراحل پیشرفت بیماری بسیار حائز اهمیت است. تکنیک‌های تصویربرداری زیادی برای تشخیص تومورهای مغزی استفاده می‌شود. با این حال، روش MRI به دلیل کیفیت تصویر بهتر و عدم تکیه بر پرتوهای یونیزان در مقایسه با سایر روش‌ها برتری دارد. بدیهی است هر چقدر تفسیر با دقت بالایی صورت بگیرد به مراحل درمان کمک شایانی خواهد نمود که برای این منظور می‌توان از روش‌های طبقه‌بندی تصاویر که در سنجش‌از دور کاربرد زیادی دارد استفاده نمود. یادگیری عمیق زیرشاخه‌ای از یادگیری ماشین است و در سال‌های اخیر خصوصاً در مباحث طبقه‌بندی و قطعه‌بندی تصاویر عملکرد قابل توجهی داشته‌است. در این مطالعه، یک مدل یادگیری عمیق با استفاده از شبکه عصبی پیچشی به منظور طبقه‌بندی سه نوع تومور مغزی مننژیوم، گلیوما و هیپوفیز پیشنهاد شد و از روش داده‌افزایی به عنوان یک راهکار اساسی در راستای افزایش دقت و استحکام مدل بهره گرفته شد. همچنین، به منظور افزایش سرعت آموزش در شبکه پیشنهادی و جلوگیری از بیش‌برازش داده‌ها، از لایه‌های حذفی در ساختار شبکه‌ی پیشنهادی استفاده شد. در این تحقیق از یک مجموعه داده استفاده شد که شامل ۳۰۶۴ تصویر می‌باشد که بر اساس پروتکل T1 تهیه شدند. با ساختار پیشنهادی دقت کلی ۹۷/۴۱٪ برای مجموعه داده‌ها به دست آمد و نتایج تحقیق نشان‌دهنده توانایی مدل برای اهداف طبقه‌بندی تومور مغزی می‌باشد.

واژگان کلیدی: تومور مغزی، شبکه عصبی پیچشی، داده‌افزایی، یادگیری عمیق، MRI

* نویسنده رابط

۱- مقدمه

تومور مغزی رشد غیر طبیعی و کنترل نشده در سلول‌های مغزی است. از آنجایی که جمجمه انسان یک بدنه سفت و با حجم محدود است، در نتیجه، هر گونه رشد غیرمنتظره ممکن است بر عملکرد انسان با توجه به بخش درگیر مغز تأثیر بگذارد. علاوه بر این، ممکن است به سایر اندام‌های بدن گسترش یابد و بر عملکرد آنها تأثیر بگذارد [۱]. تومورهای مغزی را می‌توان به روش‌های مختلفی مانند تومورهای اولیه و ثانویه طبقه‌بندی کرد و این طبقه‌بندی بر اساس منشاء تومور تعیین می‌شود، تومورهای که ابتدا در مغز منشاء می‌گیرند، تومورهای اولیه نامیده می‌شوند و تومورهایی که ابتدا در قسمت دیگری از بدن به وجود می‌آیند و سپس به مغز منتقل می‌شوند، تومورهای ثانویه نامیده می‌شوند که بیشتر آنها بدخیم هستند [۲]. برای شناسایی و طبقه‌بندی تومورهای مغزی، می‌توان از تکنیک‌های تصویربرداری متعددی استفاده کرد. با این حال، MRI^۱ یکی از رایج‌ترین تکنیک‌های غیر تهاجمی است. محبوبیت MRI ناشی از عدم استفاده از پرتوهای یونیزان^۲ در طول اسکن و همچنین وضوح بالای بافت نرم آن به علاوه توانایی گرفتن تصاویر مختلف با استفاده از پارامترهای تصویربرداری مختلف یا با استفاده از عوامل کنتراست افزایش یافته است [۳، ۴].

گلیوما^۳ شایع‌ترین نوع تومور مغزی است که از سلول‌های گلیال^۴ مغز منشاء می‌گیرد [۵]. گلیوما ۳۰ درصد از تومورهای مغزی و دستگاه عصبی مرکزی و ۸۰ درصد از کل تومورهای بدخیم مغزی را تشکیل می‌دهد [۵]. گلیوماها بر اساس سازمان جهانی بهداشت از نوع I تا IV به چهار درجه طبقه‌بندی می‌شوند [۶]. تومورهای درجه I خوش‌خیم هستند و بافت بسیار مشابهی با سلول‌های گلیال طبیعی دارند، درجه II از نظر بافت کمی متفاوت است، تومورهای درجه III بدخیم و با ظاهر بافتی غیرطبیعی هستند در حالی که درجه IV از شدیدترین مرحله گلیوما و ناهنجاری‌های بافتی می‌باشد که با چشم غیر مسلح قابل مشاهده است [۱].

مننژیوم^۵، توموری است که روی غشایی که مغز و نخاع را در داخل جمجمه انسان می‌پوشاند ایجاد می‌شود و به آرامی رشد می‌کند. بیشتر تومورهای مننژیوم خوش‌خیم هستند [۶]. تومور هیپوفیز^۶ نیز از غدد هیپوفیز شروع می‌شود که هورمون‌ها را کنترل می‌کنند و عملکردهای بدن را تنظیم می‌کنند که می‌تواند خوش‌خیم یا بدخیم باشد. تومورهای هیپوفیز ممکن است باعث کمبود دائمی هورمون و از دست دادن بینایی شوند [۱].

با توجه به مطالب بیان شده، تشخیص زودهنگام و طبقه‌بندی تومورهای مغزی بسیار حائز اهمیت است و بر این اساس به انتخاب راحت‌ترین روش درمانی برای نجات جان بیماران کمک می‌کند [۶]. علاوه بر این، مرحله طبقه‌بندی ممکن است در برخی موارد پیچیده و برای پزشکان یا رادیولوژیست‌ها یک کار گیج‌کننده و خسته‌کننده باشد. این موارد به متخصصانی نیاز دارند که روی آن کار کنند، موقعیت تومور را تعیین کنند، بافت‌های تومور را با مناطق مجاور مقایسه و در صورت لزوم فیلترهایی را روی تصویر اعمال کنند. برای روشن‌تر شدن بینش انسان و در نهایت نتیجه‌گیری جهت تشخیص نوع تومور و درجه آن در صورت موجود بودن، این کار نسبتاً زمان می‌برد و به همین دلیل است که نیاز به یک سیستم تشخیص رایانه‌ای^۷ (CAD) برای تشخیص زودهنگام تومورهای مغزی در زمان بسیار کمتری و بدون دخالت انسان وجود دارد. این تشخیص سریع و دقیق را می‌توان از طریق پیشرفت‌های فن‌آوری پیشگامانه در زمینه هوش مصنوعی به دست آورد، که نویدهایی را برای دقت بالاتر در زمینه بینایی ماشین، طبقه‌بندی تصویر و تقسیم‌بندی تصویر به واسطه روش‌های مختلف یادگیری ماشین^۸ (ML)، نشان داده است.

یادگیری ماشینی به عنوان یک زیرشاخه از هوش مصنوعی، سیستم را قادر می‌سازد تا با استفاده از الگوریتم‌ها و مدل‌های آماری، از داده‌ها یاد بگیرد و بدون نیاز به دستورالعمل‌های صریح، اطلاعات را تحلیل کرده و بر اساس آن پیش‌بینی‌ها و تصمیم‌گیری‌هایی را انجام دهد [۷]. الگوریتم‌های یادگیری ماشینی به طور گسترده در زمینه

۵ - Meningioma

۶ - Pituitary

۷ - Computer Aided Diagnosis

۸ - Machine Learning

۱ - Magnetic Resonance Imaging

۲ - Ionizing Radiation

۳ - Glioma

۴ - Glial

تصویربرداری پزشکی به عنوان بخشی از هوش مصنوعی پدیدار شده‌اند [۲].

یادگیری عمیق^۱ (DL) زیرمجموعه‌ای از یادگیری ماشین است که در آن سیستمی از شبکه‌های عصبی مصنوعی که ساختار مغز انسان را تقلید می‌کنند با حجم عظیمی از داده‌ها آموزش داده می‌شوند. این نوع از شبکه‌ها به صورت نظارت شده، نیمه نظارت شده یا بدون نظارت و تقویتی، در زمینه تجزیه و تحلیل تصاویر پزشکی در تحقیقات مختلف مورد استفاده قرار گرفته‌اند. این شبکه‌ها به چند لایه تقسیم می‌شوند که لایه اول به عنوان لایه ورودی، لایه‌های داخلی به عنوان لایه‌های پنهان و لایه‌نهایی به عنوان لایه خروجی شناخته می‌شوند. الگوریتم‌های یادگیری عمیق از این آرایش لایه‌های متعدد شبکه برای استخراج و رمزگذاری ویژگی استفاده می‌کنند. خروجی هر لایه متوالی، ورودی لایه بعدی است و این به انتزاع داده‌ها در حین ورود به عمق شبکه کمک می‌کند [۸]. شبکه‌های عصبی پرسپترون^۲ و شبکه‌های عصبی پیچشی^۳ (CNN) دو نوع از شبکه‌های عصبی هستند که امروزه به طور گسترده در کاربردهای مختلف استفاده می‌شوند. به طور کلی، CNNها جهت طبقه‌بندی تصویر ترجیح داده می‌شوند.

مزایای اصلی CNNها در یادگیری ویژگی‌های پیچیده و ارائه دقت‌های بسیار بالا به جای یادگیری ماشین سنتی و شبکه‌های عصبی وانیلی^۴ است که ممکن است با افزایش نمونه‌های آموزشی به دست آید و بنابراین منجر به یک مدل قوی‌تر و دقیق‌تر می‌شود [۴]. در معماری CNN، فیلترهای کانولوشن به عنوان استخراج کننده ویژگی‌ها عمل می‌کنند و هرچه به عمق می‌رود، ویژگی‌های پیچیده‌تر و بیشتری (اطلاعات مکانی و ساختاری) استخراج می‌شود. استخراج ویژگی از طریق فیلترهای درهم پیچیده و ادغام با الگوهای ورودی و به دنبال آن انتخاب متمایزترین ویژگی‌ها انجام می‌شود و سپس شروع به آموزش شبکه طبقه‌بندی می‌کند [۹].

در قرن گذشته، اولین استفاده از شبکه عصبی پیچشی عمیق با شکل مشابه فعلی آن با معرفی شبکه عصبی عمیق

«lenet» توسط Lecun بود که در برنامه‌های کاربردی تشخیص اسناد در سال ۱۹۹۸ استفاده شد [۱۰]. پس از سال‌ها، استفاده از یک شبکه عصبی پیچشی عمیق برای طبقه‌بندی تصاویر (ImageNet LSVRC-2010)، با استفاده از مدلی به نام AlexNet بسیار محبوب شد [۱۱]. مدل AlexNet نتایج برجسته‌ای را در مقایسه با سایر ساختارهای شبکه مورد استفاده در این دوره نشان می‌دهد. در ادامه، موفقیت آن منجر به شروع موفقیت‌های متوالی CNN در جامعه یادگیری عمیق گردید.

طبقه‌بندی تومورهای مغزی با استفاده از بسیاری از تکنیک‌های یادگیری ماشینی و روش‌های تصویربرداری در طول سال‌ها انجام شده‌است. در سال ۲۰۰۹، زچارکی^۵ و همکاران [۱۲] سیستمی را برای طبقه‌بندی درجات مختلف گلیوما علاوه بر یک طبقه‌بندی دودویی برای درجه بالا و پایین با استفاده از SVMs^۶ و KNN^۷ پیشنهاد کردند. دقت ۸۵ درصد برای طبقه‌بندی چند کلاسه و ۸۸ درصد برای طبقه‌بندی دودویی به دست آمد. الدهشان^۸ و همکاران [۱۳] نیز روشی را برای طبقه‌بندی ۸۰ تصویر طبیعی و غیر طبیعی تومور مغزی پیشنهاد کردند. روش آنها شامل سه مرحله بود؛ استخراج ویژگی‌ها، کاهش ابعاد و طبقه‌بندی. آنها برای کاهش ویژگی‌ها از تبدیل موجک گسسته^۹ (DWT) و به منظور کاهش ابعاد از تجزیه و تحلیل مولفه اصلی^{۱۰} (PCA) استفاده کردند و در انتها با به کارگیری از طبقه‌بندی کننده‌ی FP-ANN^{۱۱} و KNN، تصاویر را با دقت کلی ۹۷ درصد و ۹۸ درصد طبقه‌بندی کردند. در سال ۲۰۱۵، چنگ^{۱۲} و همکاران [۱۴] روشی را برای افزایش عملکرد طبقه‌بندی تومور مغزی با تقویت ناحیه تومور از طریق اتساع تصویر^{۱۳} و سپس با تقسیم به مناطق فرعی پیشنهاد کردند. آنها از سه رویکرد هیستوگرام شدت، ماتریس هم‌رخداد درجه خاکستری^{۱۴} (GLCM) و کیف کلمات^{۱۵} (BOW) برای استخراج ویژگی‌ها استفاده کردند و

۵ - Zacharaki

۶ - Support Vector Machines

۷ - k-Nearest Neighbors

۸ - El-Dahshan

۹ - Discrete Wavelet Transform

۱۰ - Principal Component Analysis

۱۱ - Feedforward Perceptron Artificial Neural Network

۱۲ - Cheng

۱۳ - Image Dilation

۱۴ - Gray Level Cooccurrence Matrix

۱۵ - Bag of Words

۱ - Deep learning

۲ - Perceptron Neural Networks

۳ - Convolutional Neural Network

۴ - Vanilla Neural Networks

داشتند، از روش داده‌افزایی، به منظور کارایی بیشتر و عملکرد بهتر شبکه پیشنهادی استفاده شد و علاوه بر آن تلاش شد تا با استفاده از لایه‌های حذفی در ساختار شبکه، سرعت آموزش بالا رود و از بیش‌برازش^{۱۰} داده‌ها جلوگیری شود. همچنین، تصاویر تومور مغزی برای دریافت سه کلاس مربوطه گلیوما، مننژیوم و هیپوفیز به طور مستقیم بارگذاری شدند و از تصاویر قطعه‌بندی شده استفاده نشد. در ادامه به شرح روش و ساختار شبکه پیشنهادی پرداخته می‌شود.

۲- مواد و روش‌ها

۲-۱- داده‌های مورد استفاده در این تحقیق

در این پژوهش از یک مجموعه داده که در سایت Figshare به صورت آنلاین در دسترس است و در سال ۲۰۱۷ منتشر شده است، استفاده شد [۲۰]. این پایگاه داده شامل ۳۰۶۴ تصویر MRI با ابعاد ۵۱۲×۵۱۲ می‌باشد که در آن‌ها از پروتکل تصویربرداری MRI-T1 استفاده شده است. دو نوع اصلی از تصاویر MRI، تصاویر T1-weighted و T2-weighted هستند که اغلب به عنوان تصاویر T1 و T2 شناخته می‌شوند. تصاویر T1 برای نمایش آناتومی بدن هستند و بافت‌ها را با همان رنگ واقعی منعکس می‌کنند و تصاویر T2 حساس به آب هستند و برای بررسی پاتولوژی به کار می‌روند که چنانچه بیان شد در این پژوهش از تصاویر T1 استفاده شده است. تصاویر مربوطه از ۲۳۳ بیمار مبتلا به سه نوع تومور مغزی مننژیوم، گلیوما و تومور هیپوفیز به دست آمده است. جدول (۱) جزئیات تکمیلی را در مورد مجموعه داده نشان می‌دهد.

جدول ۱. جزئیات تکمیلی در مورد مجموعه داده

نوع تومور	تعداد بیماران	تعداد تصاویر
مننژیوم	۸۲	۷۰۸
گلیوما	۹۱	۱۴۲۶
هیپوفیز	۶۰	۹۳۰
مجموع	۲۳۳	۳۰۶۴

تومورهای مغزی می‌توانند از نظر شکل، مکان و اندازه با توجه به نوع و درجه آنها متفاوت باشند. این مجموعه داده

در نهایت با استفاده از تقسیمات حلقه‌ای علاوه بر تقویت ناحیه تومور، دقتی در حدود ۹۱/۲۸٪ را به دست آوردند.

در [۱۵] ارتوسون^۱ و روبین^۲ از CNN برای طبقه‌بندی درجه‌های مختلف تصاویر پاتولوژیک^۳ گلیوما (درجه II، III و IV) استفاده کردند و دقت کلی ۷۱٪ را بدست آوردند. پاول^۴ و همکاران [۱۶] از تصاویر تومور مغزی محوری^۵ برای آموزش شبکه استفاده کردند. معماری CNN آنها از دو لایه کانولوشن به همراه دو لایه حداکثر ادغام^۶ و دو لایه اتصال کامل تشکیل شده بود و حداکثر دقت ۹۱/۴۳ درصد را به دست آوردند. پس از آن، افشار و همکاران [۱۷] یک شبکه کپسولی^۷ ارائه کردند که تصویر MRI مغز و مرزهای تومور را برای طبقه‌بندی تومور مغزی ادغام می‌کند. در این مطالعه دقت ۹۰/۸۹ درصد به دست آمد. در پژوهشی دیگر، انارکی و همکاران [۱۸] دو مدل ترکیبی را برای طبقه بندی تصاویر تومور مغزی بر اساس CNN و الگوریتم‌های ژنتیک^۸ (GA-CNN) پیشنهاد کردند، در مطالعه موردی اول، دقت ۹۰/۹ درصد در طبقه بندی گلیومای درجه سه به دست آمد، در حالی که در طبقه بندی گلیوم، مننژیوم و تومور هیپوفیز در مطالعه موردی دوم دقت ۹۰/۸۹٪ محقق شد.


نجف‌زاده و همکاران [۱۹] نیز از یک سیستم دو مرحله‌ای شامل استخراج ویژگی و طبقه‌بندی استفاده کردند. در این پژوهش جهت استخراج ویژگی، از یک شبکه کانولوشنی ۱۲ لایه و در نهایت، جهت طبقه‌بندی ویژگی‌ها از تابع فعال‌ساز Softmax استفاده شد. سیستم پیشنهادی بر روی پایگاه داده استاندارد و شامل سه کلاس گلیوما، مننژیوم و هیپوفیز، اعمال شد و دقت ۹۵/۰۱٪ به دست آمد.

در این مقاله، یک ساختار CNN با رویکرد داده‌افزایی^۹ پیشنهاد شده است و بر خلاف کارهای مشابه گذشته که تنها با ایجاد تغییر در ساختار شبکه یا تغییر در نوع شبکه عصبی سعی در بالا بردن دقت و بهبود عملکرد شبکه


۱ - Ertosun
 ۲ - Rubin
 ۳ - Pathological Images
 ۴ - Paul
 ۵ - Axial
 ۶ - Max-Pooling
 ۷ - CapsNet
 ۸ - Genetic Algorithms
 ۹ - Data Augmentation

۱۰ - Overfitting

شامل سه نمای مختلف؛ نمای محوری، تاجی^۱ و سائیتال^۲ است که نمونه‌های از آن در شکل (۱) نشان داده شده است.



(الف)



(ب)

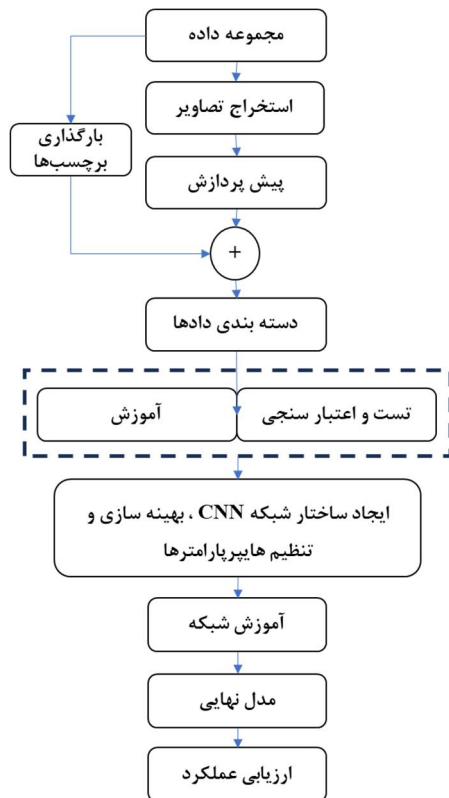
شکل ۱. در قسمت (الف) تصویر سه نوع مختلف تومور مغزی محوری مننژیوم، گلیوما و تومور هیپوفیز به ترتیب از چپ به راست و در قسمت (ب) تصویر تومور هیپوفیز در سه نمای اخذ مختلف (محوری، تاجی و سائیتال) به ترتیب از چپ به راست نشان داده شده است. تومورها در داخل یک مستطیل قرمز قرار دارند.

۲-۲- روش تحقیق

شکل (۲) نمودار روش پیشنهادی را نشان می‌دهد که در آن سیستم شروع به بارگیری و استخراج تصاویر و برچسب‌ها از فایل‌های خام مجموعه داده‌ها می‌کند، سپس پیش‌پردازش‌های لازم روی تصاویر انجام شده و تقویت و داده‌افزایی پس از تقسیم مجموعه داده‌ها به مجموعه‌های آموزش و تست و اعتبارسنجی ایجاد می‌شود. در ادامه، ساختار روش پیشنهادی معرفی شده و به دنبال آن پارامترهای مربوطه، تکنیک‌ها و الگوریتم‌های بهینه‌سازی تنظیم و در نهایت، آموزش شبکه و ارزیابی عملکرد ارائه می‌شود.

در مرحله پیش‌پردازش، قبل از ورود داده‌ها به شبکه، به منظور کاهش محاسبات و کمک به شبکه برای عملکرد بهتر در زمان کوتاه‌تر، ابعاد تصاویر کاهش یافت. سپس داده‌های هر سه نوع تومور با هم ترکیب شدند تا سیستم برای آموزش بر روی داده‌های مرتب نشده نیز آمادگی داشته باشد.

پس از آن داده‌ها به مجموعه‌های آموزشی و تست و اعتبارسنجی تقسیم شدند. در ادامه برای جلوگیری از بیش‌برازش و افزایش استحکام مدل [۱۱، ۲۱]، تعداد تصاویر با روش داده‌افزایی، افزایش یافتند و سپس ساختار CNN ایجاد گردید.



شکل ۲. نمودار روش پیشنهادی

شکل (۳) ساختار CNN پیشنهادی را نشان می‌دهد. این ساختار شامل ۱۶ لایه است که از لایه ورودی شروع شده و تصاویر تقویت شده‌ی مرحله پیش‌پردازش قبلی را از لایه‌های کانولوشن و توابع فعال ساز آن‌ها که برای انتخاب ویژگی‌ها و کاهش نمونه‌برداری استفاده می‌شود، عبور می‌دهد (کانولوشن، یک سوسازخطی^۳ (ReLU)، نرمال‌ساز و حداکثرادغام^۴). برای جلوگیری از بیش‌برازش، یک لایه‌ی حذف کننده^۵ استفاده می‌شود و به دنبال آن، یک لایه اتصال کامل^۶ و یک لایه softmax برای پیش‌بینی خروجی و در نهایت یک لایه طبقه‌بندی که کلاس پیش‌بینی شده را تولید می‌کند. در ادامه توضیحات هر لایه بیان می‌شود.

۳- Rectified Linear Unit

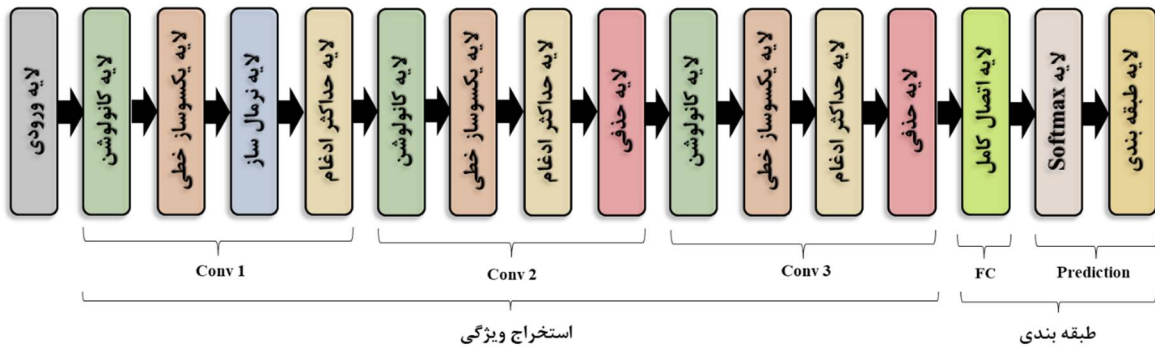
۴- Max-Pooling

۵- Drop Out

۶- Fully Connected

۱ - Coronal


۲ - Sagittal



شکل ۳. معماری CNN پیشنهادی.

لایه، برخی از گره‌ها به‌طور تصادفی حذف می‌شوند که به طور قابل‌توجهی به سرعت آموزش شبکه کمک می‌کند [۲۵].

در نهایت، از سه لایه پیشرفته‌ی، لایه اتصال کامل، لایه Softmax و لایه طبقه بندی استفاده شد. اولی برای اتصال هر نورون در یک لایه به هر نورون در یک لایه دیگر (بعدی و قبلی) استفاده می‌شود. خروجی این لایه سه کلاس است.



شکل ۴. نمونه ای از لایه حذفی

سپس لایه اتصال کامل توسط فعال‌ساز Softmax که به آن تابع بیشینه‌ی هموار یا تابع نمایی نرمال شده نیز می‌گویند، تنظیم می‌شود. لایه Softmax برای تنظیم و فشرده‌سازی تمام کلاس‌های پیش‌بینی شده بین ۰ و ۱ استفاده می‌شود و مجموع مؤلفه‌های آن برابر با ۱ است. خروجی این لایه را می‌توان با استفاده از فرمول (۱) محاسبه کرد که در آن z نشان‌دهنده بردار ورودی، e^{z_i} تابع نمایی استاندارد بردار ورودی، k نشان‌دهنده تعداد کلاس‌ها و e^{z_j} تابع نمایی استاندارد خروجی می‌باشد.

$$y(z)_i = \frac{e^{z_i}}{\sum_{j=1}^k e^{z_j}} \quad (1)$$

احتمال هر کلاس (i) را می‌توان بر روی (k) کلاس‌های مختلف به عنوان تابع $y(z)$ محاسبه کرد و جمع کل آن‌ها

در معماری پیشنهادی، از سه لایه کانولوشن استفاده شده‌است. یک لایه کانولوشن دوبعدی با حرکت دادن فیلترها در امتداد ورودی و محاسبه حاصل ضرب نقطه‌ای وزن فیلترها و ورودی، فیلترهای کانولوشن K به اندازه $(M \times N)$ را روی تصاویر ورودی اعمال می‌کند. فیلترها به صورت عمودی و افقی که گام (S) نامیده می‌شوند روی تصویر می‌لغزند. همچنین حاشیه‌گذاری (P) تصاویر اصلی قبل از لغزش فیلترها به منظور حفظ اطلاعات در لبه‌ها نیز انجام شد. فیلترها در لایه‌های اولیه فقط ویژگی‌های سطح پایین مانند لبه‌ها و خطوط را شناسایی می‌کنند، در حالی که فیلترهای بعدی برای شناسایی ویژگی‌های پیچیده‌تر و بیشتر استفاده می‌شوند [۱۰].

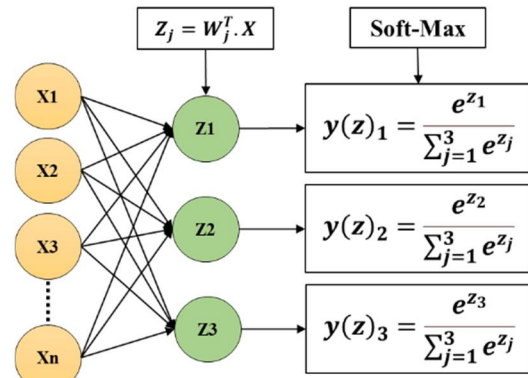
هر لایه کانولوشن به همراه یک تابع فعال‌ساز ReLU آورده شده‌است که عمدتاً برای کاهش زمان آموزش در مقایسه با سایر توابع فعال‌ساز استفاده می‌شود [۱۱، ۲۲]. در ادامه از یک لایه نرمال‌ساز برای نرمال‌سازی لایه ورودی به منظور تطبیق با فعال‌سازهای مربوطه استفاده شد که یک لایه نرمال‌ساز محلی با اندازه خاص ایجاد می‌کند. نرمال‌سازی را می‌توان به منظور پخش انتشار و شتاب آموزش شبکه استفاده کرد [۱۱، ۲۲]. در ادامه برای کاهش تعداد پارامترها و در نتیجه کاهش محاسبات در شبکه از لایه حداکثر ادغام استفاده شد. استفاده از لایه‌های ادغام بین لایه‌های کانولوشن امری رایج است. استفاده از این لایه موجب کاهش نگاشت ویژگی‌ها و پارامترهای شبکه شده و بیش‌برازش را کنترل می‌کند [۲۳، ۲۴]. یکی از متداول‌ترین روش‌ها برای کاهش بیش‌برازش، استفاده از لایه حذفی است (نمونه‌ی آن در شکل ۴ نشان داده شده است). در این

۴۰ - Stride

۴۱ - Padding

برابر با ۱ است. در شکل ۵ عملکرد تابع Softmax به عنوان لایه خروجی نشان داده شده است [۲۶].

در ادامه، از یک لایه طبقه‌بندی استفاده شد که بر اساس زبان آنتروپی متقابل^{۴۴} برای تخمین زبان طبقه‌بندی و ارائه برچسب طبقه‌بندی پیش‌بینی شده نهایی، برای هر تصویر ورودی می‌باشد.



شکل ۵. نمونه‌ای از تابع Soft-Max را به عنوان لایه خروجی در شبکه عصبی نشان می‌دهد. بردار ورودی x از طریق لایه‌های پنهان به بردار خروجی z تبدیل می‌شود تا امتیازات هر یک از سه کلاس مشخص شود. سپس با اعمال تابع Softmax بر روی z توزیع احتمال کلاس‌ها به دست می‌آید.

زبان را می‌توان از رابطه (۲) تخمین زد، که در آن p بردار برچسب‌های هدف، و $q(x)$ بردار خروجی از لایه Softmax است.

$$H(p, q) = - \sum_x (p(x) * \log(q(x))) \quad (2)$$

همه‌ی تنظیمات و بهینه‌سازی‌های انجام شده در ساختار شبکه جهت برازندگی تابع هدف در حین آموزش و در عین حال جلوگیری از بیش‌برازش سیستم و در نهایت کاهش تابع هزینه (Loss) می‌باشد. تکنیک‌های زیادی در این زمینه در مراحل پیش‌پردازش و آموزش وجود دارد [۲۱، ۲۵، ۲۷، ۲۸]، که تکنیک‌های به کار گرفته شده در ساختار پیشنهادی بیان شدند، در این پژوهش همچنین از نظم دهی $L2$ ^{۴۳} برای افزودن جریمه به تابع هزینه و معرفی کاهش وزن‌ها همانطور که در معادله (۳) زیر نشان داده شده‌است، استفاده شد [۲۹].

$$L2Cost \text{ function} = \text{Cost function(Loss)} + \lambda \sum_{i=1}^k w_i^2 \quad (3)$$

که در آن λ پارامتر تنظیم است و برای کنترل فرآیند یادگیری استفاده می‌شود، w وزن(های) مربوطه برای $i=1, \dots, k$ و همچنین به منظور نظارت بر عملکرد آموزش و اعتبارسنجی از «تکنیک توقف زودهنگام^{۴۴}» استفاده شد که فرآیند آموزش را قبل از اتمام اپک‌های کامل آموزش در صورت پایداری سیستم یا قبل از شروع بیش‌برازش متوقف می‌کند [۲۹].

بهینه‌سازی عمدتاً برای به روزرسانی پارامترهای شبکه و به حداقل رساندن تابع هزینه، برای رسیدن به کمینه‌ی سراسری در حالت ایده‌آل با برداشتن گام‌های کوچک در جهت گرادین کاهشی (همگرایی) استفاده می‌شود [۳۰]. لازم به ذکر است که در این مقاله از «گرادین کاهشی تصادفی با تکانه^{۴۵}» نیز به عنوان یک بهینه‌ساز در ساختار پیشنهادی استفاده شد.

۳- پیاده‌سازی و ارائه نتایج

همانگونه که ذکر گردید در روش پیشنهادی برای شروع، سیستم اقدام به بارگیری و استخراج تصاویر و برچسب‌ها از فایل‌های خام مجموعه داده‌ها نموده، سپس پیش‌پردازش‌های لازم روی تصاویر انجام می‌گردد، در مرحله پیش‌پردازش، ابعاد تصاویر از 512×512 به 128×128 پیکسل کاهش می‌یابد. و بعد از ترکیب داده‌های هر سه نوع تومور با هم، داده‌ها به مجموعه‌های آموزشی به مقدار ۶۸٪ و تست و اعتبارسنجی به مقدار ۳۲٪ تقسیم می‌شوند. همچنین برای جلوگیری از بیش‌برازش و افزایش استحکام مدل، تصاویر به روش داده افزایی ۵ برابر افزایش می‌یابد تا سیستم بتواند آن‌ها را به عنوان تصاویر جدید شناسایی کند. شکل (۶) تغییرات اعمال شده روی تصاویر را در مقابل تصویر اصلی نشان می‌دهد. تغییرات شامل چرخاندن حول محور x ، چرخاندن حول محور y ، اضافه کردن نویز نمک و چرخش تصویر به میزان ۴۵ درجه می‌باشد. با انجام فرآیند داده‌افزایی، ۳۰۶۴ تصویر اصلی با ضریب ۵ افزایش داده شد، بنابراین مجموعه داده نهایی شامل ۱۵۳۲۰ تصویر گردید.


۴۴ - Early Stop Technique

۴۵ - Stochastic Gradient Descent with Momentum

۴۲ - Cross-Entropy Loss

۴۳ - L2 Regularization

در ادامه ساختار CNN بر اساس توضیحات ارائه شده ایجاد گردید. پارامترهای مورد استفاده در لایه‌های کانولوشن ساختار پیشنهادی در جدول ۲ آورده شده است. برای رسیدن به نتیجه مطلوب پارامترهای CNN با استفاده از روش گرادیان کاهشی به دست آمدند و میزان نرخ یادگیری عدد ۰/۰۱ و تعداد اپک‌ها ۱۰۰ در نظر گرفته شد.



شکل ۶. الف) تصویر اصلی، ب) چرخش حول محور X، ج) چرخش حول محور Y، د) اضافه کردن نویز نمک به تصویر، ه) چرخش ۴۵ درجه.

جدول ۲. پارامترهای مورد استفاده در لایه‌های کانولوشن

لایه‌های کانولوشن	تعداد فیلترها (K)	ابعاد فیلتر (M x N)	اندازه گام (S)	مقدار پدینگ (P)
لایه کانولوشن اول	۶۴	۱۰x۱۰	[۱,۱]	[۰,۰,۰,۰]
لایه کانولوشن دوم	۱۲۸	۳x۳	[۱,۱]	[۲,۲,۲,۲]
لایه کانولوشن سوم	۱۲۸	۲x۲	[۱,۱]	[۲,۲,۲,۲]

در مرحله نرمال‌سازی از یک لایه نرمال‌ساز با اندازه دلخواه ۵ برای نرمال‌سازی لایه ورودی استفاده گردید. همچنین برای کاهش تعداد پارامترها و در نتیجه کاهش محاسبات در شبکه از لایه حداکثر ادغام با ابعاد ۲x۲ استفاده شد که با تقسیم تصویر به مستطیل‌های کوچک ۲x۲ روی تصویر حرکت می‌کند و تنها بیشترین مقدار بین چهار پیکسل را در نظر می‌گیرد. برای کاهش بیش‌برازش در ساختار پیشنهادی از دو لایه حذفی ۱۰٪ و ۲۰٪ استفاده شد که مناسب‌ترین مقادیر برای لایه‌های حذفی ۱ و ۲ بودند.

بعد از سه لایه کانولوشن، توابع فعال‌ساز و لایه‌های حذفی، از یک لایه‌ی اتصال کامل با سه نورون استفاده شد و سپس خروجی توسط تابع فعال‌ساز Softmax بین صفر و

یک نرمال‌ساز شده و در انتها به منظور طبقه‌بندی از لایه‌ی طبقه‌بندی استفاده شد.

شکل ۷ نمودارهای صحت و زیان را در مرحله اعتبارسنجی شبکه پیشنهادی نشان می‌دهد. همانطور که در شکل ۷ (الف) مشخص است، هر چه تعداد تکرارها افزایش می‌یابد، صحت مدل نیز روند افزایشی پیدا کرده و تقریباً ۱۰۰ درصد صحت، پس از ۵۰۰۰ تکرار به دست آمده است. پس از تکرار ۸۰۰۰، صحت نزدیک به ۱۰۰ درصد می‌شود و در نهایت، بهترین دقت کلی به دست آمده در مرحله آزمایش ۹۷/۴۱ درصد می‌باشد. در نمودار زیان شکل ۷ (ب) نیز واضح است که منحنی ابتدا به شدت شروع به کاهش کرده و تقریباً پس از ۶۰۰۰ تکرار منحنی ضرر تقریباً به صفر می‌رسد.



شکل ۷. صحت اعتبارسنجی و زیان در کل تکرارهای آموزشی، (الف) صحت اعتبارسنجی (بالتر بهتر است) و (ب) زیان (کمتر بهتر است).

یکی از ابزارها به منظور ارزیابی روش، محاسبه ماتریس ابهام^{۴۶} طبقه‌بندی است. ماتریس ابهام در اصل بیان‌کننده‌ی عملکرد سیستم می‌باشد، شکل ۸ یک ماتریس ابهام n کلاس را نشان می‌دهد که در آن سطرها نشان‌دهنده مقادیر واقعی و ستون‌ها نشان‌دهنده مقادیر پیش‌بینی شده می‌باشد که به صورت زیر می‌توان آن را خلاصه کرد.

۱- مثبت واقعی^{۴۷} (TP) تعداد موارد مثبت پیش‌بینی شده که در واقع نیز مثبت هستند.

۴۶ - Confusion Matrix

۴۷ - True Positive

۲- منفی واقعی (TN)^{۴۸} تعداد موارد منفی پیش بینی شده که در واقع نیز منفی هستند.

۳- منفی کاذب (FN)^{۴۹} تعداد موارد منفی پیش بینی شده که در واقع مثبت هستند و به آن خطای نوع دو هم می‌گویند.

۴- مثبت کاذب (FP)^{۵۰} تعداد موارد مثبت پیش بینی شده که در واقع منفی هستند، به آن خطای نوع یک هم می‌گویند.

	$C_0 \dots C_{K-1}$	C_K	$C_{K+1} \dots C_n$	
$C_{K+1} \dots C_n$	TN	FP	TN	مقادیر واقعی
C_K	FN	TP	FN	
$C_0 \dots C_{K-1}$	TN	FP	TN	

مقادیر پیش‌بینی شده

شکل ۸. ماتریس ابهام برای n کلاس

معیارهای ارزیابی که به واسطه‌ی ماتریس ابهام می‌توان آن‌ها را محاسبه نمود عبارتند از: دقت^{۵۱}، حساسیت^{۵۲}، ویژگی^{۵۳} و صحت^{۵۴} که هر کدام مطابق با معادلات زیر محاسبه می‌شوند.

$$Precision \text{ (دقت)} = \frac{\sum TP}{\sum (TP + FP)} \quad (4)$$

$$Sensitivity \text{ (حساسیت)} = \frac{\sum TP}{\sum (TP + FN)} \quad (5)$$

$$Accuracy \text{ (صحت)} = \frac{\sum (TP + TN)}{\sum (TP + TN + FP + FN)} \quad (6)$$

$$Specificity \text{ (ویژگی)} = \frac{\sum TN}{\sum (TN + FP)} \quad (7)$$

- ۴۸ - True Negative
 ۴۹ - False Negative
 ۵۰ - False Positive
 ۵۱ - Precision
 ۵۲ - Sensitivity
 ۵۳ - Specificity
 ۵۴ - Accuracy

این معیارها بیان‌کننده کارایی سیستم مورد نظر می‌باشند. شکل ۱۰ ماتریس ابهام روش پیشنهادی را نشان می‌دهد که عملکرد سیستم را خلاصه می‌کند.

جدول ۳ معیارهای استخراج شده از ماتریس ابهام را نشان می‌دهد که در نهایت صحت ۹۸/۲٪ برای طبقه بندی مننژیوم، ۹۶/۴۷٪ برای گلیوما و ۹۷/۵۶٪ برای طبقه بندی هیپوفیز به دست آمد.

به منظور طراحی یک شبکه CNN مطلوب پارامترها و مدل‌های متعددی باید تست شود و آموزش یک ساختار CNN برای رسیدن به نتایج رضایت بخش برای یک مجموعه داده امری زمان‌بر است. در این پژوهش نیز قبل از رسیدن به ساختار پیشنهادی مدل‌های متعددی استفاده شد و در نهایت بهترین ساختار انتخاب شد.

مقادیر پیش‌بینی شده

	مننژیوم	گلیوما	هیپوفیز	
مننژیوم	۵۱۲	۱۵	۴	مقادیر واقعی
گلیوما	۱۸	۱۰۲۱	۳۰	
هیپوفیز	۴	۱۸	۶۷۵	
	مننژیوم	گلیوما	هیپوفیز	

شکل ۱۰. ماتریس ابهام مدل پیشنهادی

نتایج برخی از تحقیقات قبلی که از انواع تومورهای مغزی مشابه با معماری، هایپرپارامترها و لایه‌های متفاوت استفاده کرده‌اند در جدول ۴ خلاصه شده‌است. همانطور که مشخص است، ساختار پیشنهادی نتایج پیش‌بینی بهتری را در مقایسه با سایر مطالعات قبلی مرتبط ارائه می‌دهد. در این پژوهش برخلاف مطالعات قبلی که تنها با تغییر در ساختار شبکه، توابع فعال‌ساز و استفاده از بهینه‌سازهای مختلف سعی در بهبود دقت و استحکام شبکه داشتند، تلاش شده‌است تا با استفاده از روش داده‌افزایی قدرت یادگیری را افزایش داده و دقت بالاتری را به دست آورد. همچنین، نتایج نشان داد که استفاده از لایه‌های حذفی در ساختار شبکه CNN تا حد مطلوبی می‌تواند بیش‌برازش داده‌ها را کاهش داده و موجب افزایش سرعت آموزش شبکه و استحکام بیشتر آن شود. در این پژوهش اگرچه، نتایج مطلوبی به دست آمد، با این حال، سیستم

عمیق استفاده از داده‌های آموزشی زیاد به منظور آموزش شبکه است و چنانچه حجم داده‌های آموزشی شبکه کم باشد، شبکه مذکور از استحکام قابل قبولی برخوردار نخواهد بود اما می‌توان سیستم را پس از آموزش بر روی یک مجموعه داده بزرگ، برای مجموعه داده‌های کوچک به دقت تنظیم و مدیریت کرد.

پیشنهادی نیاز به آزمایش روی مجموعه داده‌های مقیاس بزرگ‌تری دارد که شامل سنین و نژادهای مختلف باشد تا قابلیت انتقال آن را افزایش داده و آن را در سایر کاربردهای پزشکی، در آینده گسترش دهد. علاوه بر این، ساختار سیستم را نمی‌توان برای طبقه‌بندی تعداد کمی از تصاویر استفاده کرد، زیرا یکی از محدودیت‌های یادگیری

جدول ۳. معیارهای ارزیابی از نظر دقت، حساسیت، ویژگی و صحت.

تعداد	صحت	ویژگی	حساسیت	دقت	FN	FP	TN	TP	نوع تومور	مدل پیشنهادی
۵۴۷	٪۹۸/۲	۰/۹۸۷	۰/۹۶۴	۰/۹۵۸	۱۹	۲۲	۱۷۴۴	۵۱۲	مننژیوم	
۱۰۶۹	٪۹۶/۴۷	۰/۹۷۳	۰/۹۵۵	۰/۹۶۸	۴۸	۳۳	۱۱۹۵	۱۰۲۱	گلیوما	
۶۹۷	٪۹۷/۵۶	۰/۹۷۸	۰/۹۶۸	۰/۹۵۲	۲۲	۳۴	۱۵۶۶	۶۷۵	هیپوفیز	

جدول ۴. مقایسه بین مدل پیشنهادی و کارهای مرتبط قبلی.

مدل	بالاترین دقت	بالاترین حساسیت	بالاترین ویژگی	بالاترین صحت	نوع طبقه بندی	روش طبقه بندی
۱ چنگ و همکاران [۱۴]	-	٪۹۰/۷	٪۹۱/۳	٪۹۱/۲۸	چندگانه	SVM and KNN
۲ پاول و همکاران [۱۶]	٪۹۱	٪۹۴	-	٪۹۱/۴۳	چندگانه	CNN
۳ افشار و همکاران [۱۷]	-	-	-	٪۹۰/۸۹	چندگانه	CNN
۴ انارکی و همکاران [۱۸]	٪۹۶/۵	٪۹۵/۷	٪۹۷/۸	٪۹۴/۲۰	چندگانه	GA-CNN
۵ نجف‌زاده و همکاران [۱۹]	٪۹۸/۶۸	٪۹۶/۳۶	٪۹۶/۶۹	٪۹۵/۰۱	چندگانه	CNN
۶ ساختار پیشنهادی	٪۹۶/۸	٪۹۶/۸	٪۹۸/۷	٪۹۸/۲	چندگانه	CNN

۴- نتیجه‌گیری

مغز مهم‌ترین عضو بدن می‌باشد که کنترل سایر اعضا را به عهده دارد و در صورت وجود هرگونه ناهنجاری در آن خصوصاً ایجاد تومورهای مغزی، ممکن است در عملکرد سایر قسمت‌های بدن اختلال ایجاد کند و حتی باعث مرگ بیمار شود. به همین دلیل تشخیص زود هنگام تومورها و شناسایی نوع آن‌ها در مراحل ابتدایی می‌تواند روند درمان را هموارتر و موثرتر کند. لذا در این پژوهش یک سیستم تشخیص رایانه‌ای به منظور طبقه‌بندی تصاویر MRI تومور مغزی به سه نوع مننژیوم، گلیوما و هیپوفیز با استفاده از یک ساختار شبکه عصبی عمیق ارائه شد.

عموماً یکی از چالش‌های مهم در طراحی یک شبکه CNN تعیین ابعاد پنجره ورودی به CNN، تعداد لایه‌های کانولوشن، اندازه پولینگ و تعداد لایه‌های حذفی و اتصال کامل است، لذا در این راستا تلاش شد تا نحوه تاثیر پارامترهای مختلف در آموزش بر میزان دقت شبکه بررسی شود و به این ترتیب پارامترهای مختلف بر روی شبکه تست شد و نتایج آن‌ها با یکدیگر مقایسه شد و نهایتاً شبکه‌ی

پیشنهادی به گونه‌ای طراحی شد که بالاترین دقت و در عین حال بالاترین سرعت را ارائه دهد، همچنین با توجه به اینکه فرآیند کاهش بُعد و طبقه‌بندی CNN به هم وابسته‌اند، لذا روش کاهش بعد به گونه‌ای انجام شد که کیفیت داده‌های آموزشی افزایش پیدا کند و منجر به بهبود طبقه‌بندی شود. این شبکه از ۱۶ لایه ساخته شد، که از لایه ورودی شروع شده و تصاویر پیش‌پردازش شده، از لایه‌های کانولوشن و توابع فعال‌ساز آن‌ها عبور داده می‌شود (۳ کانولوشن، ۳ ReLU، نرمال‌ساز و ۳ لایه Max-pooling). علاوه بر این، از دو لایه حذفی برای جلوگیری از بیش‌برازش و به دنبال آن یک لایه اتصال کامل و یک لایه softmax برای پیش‌بینی خروجی و در نهایت یک لایه طبقه‌بندی که کلاس پیش‌بینی‌شده را تولید می‌کند، استفاده شد. اگرچه مجموعه داده نسبتاً بزرگ نبود، اما داده افزایی به خوبی در رسیدن به نتایج بهتر و غلبه بر این مشکل کمک کرد. معماری پیشنهادی دقت کلی ۹۷/۴۱٪ را برای مجموعه داده‌ها به دست آورد و نتایج تحقیق نشان‌دهنده توانایی مدل برای اهداف طبقه‌بندی تومور مغزی است.

- [۱]. DeAngelis, L.M., Brain tumors. *New England journal of medicine*, 2001. 344(2): p. 114-123.
- [۲]. Behin, A., et al., Primary brain tumours in adults. *The Lancet*, 2003. 361(9354): p. 323-331.
- [۳]. Drevelegas, A. and N. Papanikolaou, *Imaging of brain tumors with histological correlations*. 2002: Springer.
- [۴]. Litjens, G., et al., A survey on deep learning in medical image analysis. *Medical image analysis*, 2017. 42: p. 60-88.
- [۵]. Goodenberger, M.L. and R.B. Jenkins, Genetics of adult glioma. *Cancer genetics*, 2012. ۲۰۰(۱۲): p. 613-621.
- [۶]. Louis, D.N., et al., The 2016 World Health Organization classification of tumors of the central nervous system: a summary. *Acta neuropathologica*, 2016. 131: p. 803-820.
- [۷]. Bishop, C., *Pattern recognition and machine learning*. Springer google schola, 2006. 2: p. 5-43.
- [۸]. Deng, L. and D. Yu, *Deep learning: methods and applications*. Foundations and trends® in signal processing, 2014. 7(3-4): p. 197-387.
- [۹]. LeCun, Y., Y. Bengio, and G. Hinton, Deep learning. *nature*, 2015. 521(7553): p. ۴۳۶-۴۴۴.
- [۱۰]. LeCun, Y., et al., Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 1998. 86(11): p. 2278-2324.
- [۱۱]. Krizhevsky, A., I. Sutskever, and G.E. Hinton, Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems*, 2012. 25.
- [۱۲]. Zacharaki, E.I., et al., Classification of brain tumor type and grade using MRI texture and shape in a machine learning scheme. *Magnetic Resonance in Medicine: An Official Journal of the International Society for Magnetic Resonance in Medicine*, 2009. 62(6): p. 1609-1618.
- [۱۳]. El-Dahshan, E.-S.A., T. Hosny, and A.-B.M. Salem, Hybrid intelligent techniques for MRI brain images classification. *Digital signal processing*, 2010. 20(2): p. 433-4. ۴
- [۱۴]. Cheng, J., et al., Enhanced performance of brain tumor classification via tumor region augmentation and partition. *PloS one*, 2015. 10(10): p. e0140381.
- [۱۵]. Ertosun, M.G. and D.L. Rubin. Automated grading of gliomas using deep learning in digital pathology images: a modular approach with ensemble of convolutional neural networks. in *AMIA annual symposium proceedings*. 2015. American Medical Informatics Association.
- [۱۶]. Paul, J.S., et al. Deep learning for brain tumor classification. in *Medical Imaging 2017: Biomedical Applications in Molecular, Structural, and Functional Imaging*. 2017. SPIE.
- [۱۷]. Afshar, P., K.N. Plataniotis, and A. Mohammadi. Capsule networks for brain tumor classification based on MRI images and coarse tumor boundaries. in *ICASSP 2۰۱۹-۲۰۱۹ IEEE international conference on acoustics, speech and signal processing (ICASSP)*. 2019. IEEE.
- [۱۸]. Anaraki, A.K., M. Ayati, and F. Kazemi, Magnetic resonance imaging-based brain tumor grades classification and grading via convolutional neural networks and genetic algorithms. *biocybernetics and biomedical engineering*, 2019. 39(1): p. 63-74.
- [۱۹]. Najaf-Zadeh, A. and H.R. Ghaffari, A Two-Dimensional Convolutional Neural Network for Brain Tumor Detection From MRI. *Internal Medicine Today*, 2020. 26 (۴): p. 398-413.
- [۲۰]. Cheng, J., Brain tumor dataset. figshare. Dataset, 2017. 1512427.(۰)
- [۲۱]. Wong, S.C., et al. Understanding data augmentation for classification: when to warp? in *2016 international conference on digital image computing: techniques and applications (DICTA)*. 2016. IEEE.
- [۲۲]. Ioffe, S. and C. Szegedy. Batch normalization: Accelerating deep network training by reducing internal covariate shift. in *International conference on machine learning*. 2015. pmlr.
- [۲۳]. Scherer, D., A. Müller, and S. Behnke. Evaluation of pooling operations in convolutional architectures for object recognition. in *International conference on artificial neural networks*. 2010. Springer.
- [۲۴]. Nagi, J., et al. Max-pooling convolutional neural networks for vision-based hand gesture recognition. in *2011 IEEE international conference on signal and image processing applications (ICSIPA)*. 2011. IEEE.
- [۲۵]. Srivastava, N., et al., Dropout: a simple way to prevent neural networks from overfitting. *The journal of machine*

- learning research, 2014. 15(1): p. 1929-1958.
- [۲۶]. Nasrabadi, N.M., Pattern recognition and machine learning. Journal of electronic imaging, 2007. 16(4): p. 049901.
- [۲۷]. Ciregan, D., U. Meier, and J. Schmidhuber. Multi-column deep neural networks for image classification .in 2012 IEEE conference on computer vision and pattern recognition. 2012. IEEE.
- [۲۸]. Szegedy, C., et al. Going deeper with convolutions. in Proceedings of the IEEE conference on computer vision and pattern recognition. 2015.
- [۲۹]. Goodfellow, I., Y. Bengio ,and A. Courville, Deep learning. 2016: MIT press.
- [۳۰]. Bottou, L. Large-scale machine learning with stochastic gradient descent. in Proceedings of COMPSTAT'2010: 19th International Conference on Computational Statistics Paris France, August 22-27, 2010 Keynote, Invited and Contributed Papers. 2010. Springer.