



تشخیص تومور مغزی در تصاویر رزونانس مغناطیسی با استفاده از

شبکه عصبی کانولوشنی عمیق

میترا افسری نژاد^۱، نبی اله شیری^{۲*}، رامین براتی^۳

^۱ گروه مهندسی برق، واحد شیراز، دانشگاه آزاد اسلامی، شیراز، ایران
mitra_afsarinejad@yahoo.com

^۲ گروه مهندسی برق، واحد شیراز، دانشگاه آزاد اسلامی، شیراز، ایران
na.shiri@iau.ac.ir

^۳ گروه مهندسی برق، واحد شیراز، دانشگاه آزاد اسلامی، شیراز، ایران
barati.ramin@aut.ac.ir

چکیده: در این مقاله، تشخیص تومور مغز از طریق به کارگیری روشهای پیشرفته یادگیری عمیق مورد بررسی قرار گرفته است. رویکرد این مطالعه، شامل توسعه و آموزش یک معماری جامع از شبکه عصبی کانولوشنی (CNN) با بهره‌گیری از یک مجموعه داده گسترده از تصاویر رزونانس مغناطیسی مغز (MRI) می‌باشد. مدل پیشنهادی در طبقه‌بندی بافت معمولی مغز و مناطق تحت تأثیر تومور، بسیار توانمند است. این معماری شامل لایه‌های متعدد از جمله لایه‌های کانولوشنی، نرمال‌سازی دسته‌ای و لایه‌های پولینگ است که در نهایت به یک لایه قوی طبقه‌بندی منجر می‌شود. از طریق آموزش دقیق و بهینه‌سازی، شبکه عصبی کانولوشنی معرفی شده توانسته است در طبقه‌بندی تومور مغز به دقت بالایی دست یابد. اثربخشی این مدل پیشنهادی از طریق آزمایش‌های جامع به نمایش گذاشته شده، که نشان‌دهنده قابلیت آن در تشخیص دقیق تومور مغز است.

واژه های کلیدی: تومور مغزی، شبکه عصبی کانولوشنی، تصویربرداری پزشکی، یادگیری عمیق، طبقه‌بندی تصویر.

Brain Tumor Detection in Magnetic Resonance Imaging by Deep Convolutional Neural Network

Mitra Afsarinejad¹, Nabiollah Shiri^{2*}, Ramin Barati³

¹Department of Electrical Engineering, Shiraz Branch, Islamic Azad University, Shiraz, Iran
mitra_afsarinejad@yahoo.com

²Department of Electrical Engineering, Shiraz Branch, Islamic Azad University, Shiraz, Iran
na.shiri@iau.ac.ir

³Department of Electrical Engineering, Shiraz Branch, Islamic Azad University, Shiraz, Iran

Abstract:

In this paper, brain tumor detection is addressed through the application of advanced deep-learning techniques. The approach involves the development and training of a comprehensive convolutional neural network (CNN) architecture. Leveraging an extensive dataset of brain magnetic resonance imaging (MRI), the proposed model expresses its proficiency in the classification of normal brain tissue and tumor-affected regions. The architecture encompasses multiple layers, including convolutional, batch normalization, and pooling layers, culminating in a robust classification layer. Through rigorous training and optimization, the introduced CNN achieves a high level of accuracy in brain tumor classification. The effectiveness of the proposed model is showcased through comprehensive experimentation, demonstrating its potential to significantly contribute to the medical field's efforts in precise brain tumor diagnosis.

Keywords: Brain tumor, Convolutional neural network, Medical imaging, Deep learning, Image classification.

DOI:

نوع مقاله: پژوهشی

تاریخ چاپ مقاله: ۱۴۰۲/۱۲/۱۵

تاریخ پذیرش مقاله: ۱۴۰۲/۱۱/۲۸

تاریخ ارسال مقاله: ۱۴۰۲/۱۰/۰۲

۱- مقدمه

در [۴] یک رابط یادگیری ماشین ۱۶ کاناله، محاسبات محصول داخلی را در یک آرایه مبدل دلتاسیگما (IPDSM) جاسازی می‌کند که نویز کوانتیزه را از بین می‌برد. این نمونه، در CMOS ۶۵ نانومتری به مساحت ۰/۹۵ میلیمتر مربع جای می‌گیرد و هر کانال تا ۱۰۰ میلیون ضرب در ثانیه انجام می‌دهد. سیستم با یک روش استاندارد یادگیری ماشین برای تشخیص تصویر ارائه شده و دقت طبقه‌بندی برابر با استفاده از یک الگوریتم مشابه در DSP نقطه شناور است. در [۵] یک طبقه‌بندی‌کننده یادگیری ماشین معرفی می‌شود که محاسبات را درون یک آرایه SRAM استاندارد انجام می‌دهد. این سیستم، عملیات حافظه صریح را حذف کرده و در شناسایی ارقام از تصاویر پایگاه داده MNIST با دقت بالا و مصرف انرژی ۱۱۳ برابر کمتر نسبت به سیستم دیجیتال SRAM لیده‌آل عمل می‌کند. الگوریتم AdaBoost.R، یک الگوریتم تقویتی برای مسائل رگرسیون است که با حذف نمونه‌هایی با خطای تخمین نسبی بالاتر از یک آستانه، مراحل AdaBoost را انجام می‌دهد. این الگوریتم از مدل M5 به عنوان یک ماشین یادگیری ضعیف برای آزمایش‌ها استفاده می‌کند. نتایج نشان می‌دهد که AdaBoost.RT بر روی بیشتر مجموعه‌های داده بهتر از روش‌های دیگر عمل می‌کند [۶]. رگرسیون لجستیک و شبکه‌های عصبی از مدل‌های معمول در طبقه‌بندی داده‌های پزشکی هستند [۷]. این مقاله، تفاوت‌ها و شباهت‌ها را خلاصه کرده و آن‌ها را با سایر الگوریتم‌های یادگیری ماشین مقایسه می‌کند. ملاحظاتی برای ارزیابی کیفیت مدل‌ها و نتایج مطرح می‌شود. در نهایت، یافته‌ها در مورد برآورده شدن معیارهای کیفیت برای این مدل‌ها خلاصه می‌شود. در [۸] یک سامانه یادگیری با استفاده از ماشین بردار پشتیبان (SVM) برای استخراج اطلاعات (IE) ارائه می‌شود. از ویژگی منحصر به فرد سامانه، استفاده از SVM با حاشیه‌های ناهمسان برای مجموعه‌های داده کم‌حجم است. این رویکرد نیاز به تعداد کمتری طبقه‌بند SVM برای آموزش دارد و در مقایسه با سامانه‌های مبتنی بر SVM دیگر، عملکرد بهتری داشته است. مقاله [۹] به بررسی سیستم‌های تشخیصی خودکار برای تشخیص سرطان پستان می‌پردازد. هدف اصلی آن، راهنمایی برای توسعه سیستم‌های پشتیبان تصمیم خودکار جهت تشخیص سرطان پستان است. مقایسه نتایج نشان داده که ماشین بردار پشتیبان دقت تشخیص بیشتری نسبت به سایر سیستم‌های تشخیصی خودکار دارد. در [۱۰] یک مدل فازی نوین ارائه شده که امکان نمایش چندین کلاس با احتمالات مختلف را داراست. این مدل از توسعه‌ای از طبقه‌بند بیز مربعی بهره می‌برد و از الگوریتم خوشه‌بندی نظارت شده برای شناسایی استفاده می‌کند. موفقیت این رویکرد در دسته‌بندی سرطان سینه نشان داده شده است.

پیشرفت‌های صورت گرفته در تصویربرداری پزشکی، دقت تشخیص بی‌نظیری را به ارمغان آورده است. تصویر رزونانس مغناطیسی (MRI) به‌عنوان یک ابزار مهم در زمینه رادیولوژی ظاهر شده و به‌خصوص، استفاده از هوش مصنوعی در تجزیه و تحلیل داده‌های MRI، پیشرفت‌های بی‌پایانی را در تشخیص و توصیف تومورهای مغزی ایجاد کرده است. این مقاله در حوزه راه‌حل‌های مبتنی بر هوش مصنوعی برای تشخیص تومور مغز در تصاویر MRI وارد می‌شود و نقش اساسی شبکه‌های عصبی عمیق (DNNs) را در انقلاب دقت و کارایی روش‌های تشخیصی، برجسته می‌کند. با بهره‌گیری از قدرت شبکه‌های عصبی عمیق، امکان بهبود فرآیند تشخیص از طریق شناسایی زود هنگام و دقیق تومورهای مغز بررسی می‌شود.

در سال‌های اخیر، استفاده از روش‌های یادگیری عمیق تشخیص دقیق و به‌موقع تومورهای مغز نقش کلیدی در تشخیص زود هنگام و برنامه‌ریزی درمان ایفا می‌کند. در زمینه تشخیص تومور مغز، تحقیقات مختلف نتایج قابل توجهی داشته‌اند. در [۱] یک سیستم نوآورانه با استفاده از مقایسه‌گرها با مصرف انرژی کم برای طبقه‌بندی سیگنال‌های حسگرهای آنالوگ معرفی می‌شود. این سیستم با جایگزینی تقویت‌کننده‌ها و مبدل‌های آنالوگ به دیجیتال، دقت ۹۰٪ در طبقه‌بندی ده‌راهه را با مصرف انرژی ۵۴۳ پیکوژول، با کاهش ۳۳ برابری نسبت به سیستم‌های دیجیتال معمولی، ارائه می‌دهد. این پیشرفت‌ها در عملکرد و بهره‌وری انرژی، تحولات قابل توجهی را به همراه داشته‌اند. پژوهش [۲] یک ضرب‌کننده ماتریسی سوئیچ شده با ظرفیت برنامه‌پذیر را با حافظه بدون خط معرفی می‌کند. این طراحی از ظرفیت‌های یکای فرنجی برای پردازش انرژی با سرعت بالا و هزینه کم بهره‌مند می‌برد. دو کاربرد این ضرب‌کننده شامل: (۱) جلوه آنالوگ برای سیستم تشخیص تصویر با کاهش تعداد تبدیل A/D و مصرف انرژی (۲) شتاب‌دهنده هم‌پردازشی برای بهینه‌سازی نزول گرادینت تصادفی با بهره‌وری انرژی بالا [۲] می‌باشند. در [۳] یک سیستم حسگر پزشکی معرفی می‌شود که با مصرف انرژی کم، بیشترین محاسبات طبقه‌بندی را درون تبدیل آنالوگ به دیجیتال (ADC) انجام می‌دهد. از الگوریتم پردازشی برای ترکیب ویژگی خطی و طبقه‌بندی در یک تبدیل ماتریسی استفاده شده و از ADC ضرب‌کننده ماتریسی جهت ضرب با انرژی کمتر استفاده می‌شود. دو سیستم نمونه‌ای نیز ارائه شده‌اند: (۱) یک تشخیص‌گر آریتمی قلبی (۲) یک تشخیص‌گر جنسیت چهره. خطای RMS برای تمامی ضرب‌کردن‌ها ۰/۱۸٪ و صرفه‌جویی در انرژی به ترتیب ۱۳ و ۲۹ برابر سیستم‌های معمولی است.



مقاله [۱۱] یک سامانه تشخیص خودکار برای سرطان سینه با استفاده از قوانین ارتباط و شبکه عصبی معرفی می‌کند. از قوانین ارتباط برای کاهش ابعاد پایگاه داده و شبکه عصبی برای طبقه‌بندی هوشمندانه استفاده شده و نرخ درست طبقه‌بندی سامانه ۹۵/۶٪ است. این تحقیق نشان می‌دهد که مدل پیشنهادی می‌تواند برای ساخت سامانه‌های تشخیص خودکار سریع برای بیماری‌های دیگر نیز مفید باشد. در [۱۲] یک بهبود نوآورانه در آموزش شبکه‌های عصبی برای دسته‌بندی الگو ارائه می‌شود. الگوریتم آموزش، الهام‌گرفته از ویژگی متاپلاستیک نورون‌ها و نظریه اطلاعات شانون، برای شبکه‌های عصبی مصنوعی طراحی شده و بر یک ملیپرسترون چندلایه اعمال می‌شود. الگوریتم AMMLP مقادیر بالاتری برای به‌روزرسانی وزن‌ها در فعالیت‌های کمتر فراگیر اختصاص می‌دهد و به آموزش کارآمد و بهبود عملکرد MLP می‌انجامد. بر اساس آزمایش، با استفاده از پایگاه داده سرطان سینه ویسکانسین (WBCD)، AMMLP بهترین نتیجه را با دقت ۹۹/۶۳٪ ارائه داده است. مقاله [۱۳] یک سیستم CAD را با استفاده از تکنیک رمزگذاری one-hot برای تشخیص خودکار سرطان سینه ارائه می‌دهد. سیستم با استفاده از مجموعه داده BreakHis با دقت ۹۸/۶۲٪ عملکرد بهتری نسبت به روش‌های پیشین داشته و با استفاده از معیارهای مختلف، عملکرد سیستم را بهبود بخشیده است. حسگرهای تصویر اشعه ایکس بزرگ بر مبنای تکنولوژی CMOS APS برای کاربردهای پزشکی -از جمله توموسینتوز دیجیتال سینه- ارائه شده‌اند. نویز الکترونیکی پایین این حسگرها، امکان استفاده از فاصله پیکسل کوچک‌تر از ۷۵ میکرومتر برای شناسایی میکروکلسیفیکیشن و کاهش میانگین در عددی DBT را فراهم می‌کند [۱۴].

در [۱۵]، یک طبقه‌بند شبکه عصبی مصنوعی آنالوگ با استفاده از یک تابع فعال‌ساز غیرخطی مبتنی بر تقویت‌کننده منبع مشترک ارائه داده است. این شبکه با دقت ۰/۸۲ بر روی مجموعه داده MNIST (اعداد ۰ تا ۹) عمل کرده و با استفاده از ساختار تقویت‌کننده سورس مشترک، مصرف انرژی خود را ۵ برابر کاهش داده است. در [۱۶]، رویکردی برای پیشگیری از خطاهای محاسباتی ناشی از خطاهای سخت‌افزاری در پردازنده‌های دیجیتال ارائه شده است. از مراحل یادگیری ماشین تعبیه‌شده استفاده شده و دو سیستم تحلیل داده حسگر (تشخیص تشنج بر اساس EEG و تشخیص آریتمی قلب بر اساس ECG) در سخت‌افزار با دقت بازسازی شده‌اند. این سیستم‌ها با استفاده از یک هسته کوچک بدون خطا مدل حساس به خطا را ایجاد و به کار می‌برند. در [۱۷]، یک شبکه عصبی مصنوعی آنالوگ با استفاده از تقویت‌کننده سورس مشترک ارائه شده است. این شبکه با ساختار ساده‌تر و مصرف انرژی کمتر، در تشخیص سرطان سینه با دقت بالا عمل می‌کند. یک توپولوژی نوآورانه برای تقریب دقیق تابع تانژانت هایپربولیک در حلق جریانی با استفاده از ترانزیستورها در ناحیه زیرآستانه در [۱۸] معرفی می‌شود. این توپولوژی با ساختار کاملاً تفاضلی و متعادل، مصرف انرژی و مساحت را به حداقل می‌رساند.

توپولوژی با در نظر گرفتن اثر بدن، تحلیل شده و اصلاحاتی جهت ایمن‌سازی اثر بدن اعمال شده‌اند. نتایج شبیه‌سازی برای پیاده‌سازی در تکنولوژی CMOS AMI با اندازه ۰/۳۵ میکرومتر ارائه شده‌اند. مقاله [۱۹] به بررسی کاربرد گسترده روش یادگیری پس‌انتشار در تحقیقات شبکه‌های عصبی می‌پردازد. این روش نزول تصادفی از دهه ۶۰، در انواع مدل‌ها و توابع هدر کاربرد دارد. به‌ویژه، در مسئله تشخیص الگو از آن استفاده شده و یک الگوریتم یادگیری جدید بر اساس معیار اطلاعات ارائه داد. ویژگی‌های دینامیکی منحنی‌های یادگیری بر اساس مقاله‌ای قدیمی از نویسنده مورد بررسی قرار گرفته است. مقاله با بخش کوتاه تاریخی به پایان می‌رسد. در [۲۰] یک روش بهینه‌سازی برای یادگیری از منابع توزیعی مختلف را ارائه می‌شود و از اطلاعات داده‌ها در شرایط ناهمگن بهره می‌برد. این روش نسبت به روش‌های معمول، بهبود یافته و قابلیت اعمال در دامنه‌های مختلف داده را نشان می‌دهد. با توجه به محدودیت‌های ذکر شده در مقالات فوق، هدف اصلی این مقاله، پیاده‌سازی و آموزش یک مدل شبکه عصبی عمیق برای دسته‌بندی تصاویر با استفاده از الگوریتم‌ها و تنظیمات آموزش بهینه است. نتایج نشان می‌دهد که مدل پیشنهادی با ارتقاء شاخص‌های ارزیابی اصلی نظیر Dice، حساسیت و دقت، به بهبودهای مهمی دست یافته، که این امر به بهبود کارایی مدل در زمینه تصویربرداری و دسته‌بندی تصاویر اشاره دارد. در ادامه این مقاله، بررسی جامعی از معماری شبکه عصبی عمیق پیشنهادی انجام می‌شود. در بخش دوم، مدل شبکه عصبی عمیق طرح پیشنهادی بیان می‌شود. بخش سوم نتایج شبیه‌سازی و تجزیه و تحلیل نتایج را نشان می‌دهد. در نهایت، در بخش چهارم، نتایج تحقیق انجام شده بیان می‌شود.

۲- شبکه عصبی متعارف عمیق پیشنهادی

مجموعه داده‌های تصویربرداری پزشکی به طور ذاتی، پیچیده و متنوع هستند و شامل ساختارهای آناتومیک مختلف، نویز و تغییرات می‌شوند. در این زمینه، شبکه عصبی کانولوشنی عمیق پیشنهادی از ظرفیت خود برای یادگیری خودکار ویژگی‌های تمییزدهنده از داده‌های تصویر خام بهره می‌برد. قابلیت این معماری برای ضبط الگوها و نمایش‌های پیچیده در تصاویر، به همراه فرآیند استخراج ویژگی سلسله‌مراتبی، آن را به یک نامزد ایده‌آل برای وظایف تشخیص تومور تبدیل کرده است. هدف اصلی این مطالعه توسعه یک مدل موثر برای تشخیص تومور با آموزش یک شبکه عصبی کانولوشنی عمیق بر روی یک مجموعه داده تصویر پزشکی است. مجموعه داده Kaggle، پیش‌پردازش شده تا اطمینان از یکنواختی و انطباق مناسب با وظیفه مورد نظر حاصل شود. همانطور که در شکل‌های (۱،۲) نشان داده شده، معماری عصبی کانولوشنی با چندین لایه کانولوشنی و لایه پولینگ طراحی شده که این امکان را می‌دهد که ویژگی‌های مرتبط را از تصاویر با مقیاس‌های مختلف یاد بگیرد و استخراج کند.



شتاب‌دهنده گرافیکی به طور قابل توجهی آموزش را سریع‌تر می‌کند. برخلاف اثرات گذشته، استراتژی پیش‌پردازش این پژوهش، تصاویر را به ابعاد 28×28 استاندارد تبدیل می‌کند که همگرایی در کل مجموعه داده را ترویج می‌دهد. ارزیابی دقیق، تقسیم سیستماتیک مجموعه داده و انتخاب‌های ذهنی، از ویژگی‌های این پژوهش می‌باشد.

شکل (۲) معماری CNN را که برای تشخیص تومور مغز طراحی شده، نشان می‌دهد. اجزای معماری به شرح زیر می‌باشد:

۱. لایه ورودی، نمایانگر ورودی شبکه است؛ جایی که تصاویر ورودی

با ابعاد مشخص (28×28 پیکسل) به شبکه وارد می‌شوند.

۲. لایه کانولوشن ۱ اولین عمل کانولوشن را انجام داده و الگوهای مهم در تصاویر مربوط به تومور را استخراج می‌کند.

۳. لایه نرمال‌سازی دسته‌ای ۱، لایه کاهش ابعاد و نرمال‌سازی دسته‌ای (BatchNorm1) بوده و پایداری و همگرایی شبکه را

افزایش می‌دهد. تابع فعال‌سازی ReLU 1 به شبکه امکان یادگیری الگوهای پیچیده‌تر را می‌دهد. لایه کاهش ابعاد (Max Pooling 1)

ابعاد تصاویر را کاهش داده و ویژگی‌های مهم را حفظ می‌کند.

۴. لایه کانولوشن ۲ ادامه استخراج ویژگی‌های پیچیده‌تر از نقشه‌های ویژگی به دست آمده از لایه‌های قبلی را انجام می‌دهد.

۵. لایه نرمال‌سازی دسته‌ای ۲، مانند لایه‌های قبلی عمل می‌کنند و به افزایش کارایی و یادگیری اطلاعات مفید برای تشخیص تومور

کمک می‌کند.

۶. لایه کاملاً متصل ۱ و Dropout Layer ویژگی‌های استخراج شده را با هم ترکیب کرده و با اعمال Dropout از اورفیت کردن

جلوگیری می‌کنند.

۷. لایه کاملاً متصل ۲، ادامه‌ی فرآیند یادگیری را انجام می‌دهند.

۸. لایه خروجی (طبقه‌بندی)، اطلاعات نهایی پیش‌بینی را ارائه می‌دهد. در اینجا از تابع softmax استفاده شده تا اطلاعات به صورت یک توزیع احتمالی بر روی دو کلاس، تومور و عدم تومور،

تولید شود. لایه طبقه‌بندی بر اساس بیشترین احتمال تعیین کلاس پیش‌بینی شده است.

این شبکه با دقت و جزئیات طراحی شده تا ویژگی‌های تصاویر ورودی را استخراج کند، این ویژگی‌ها را بهینه‌سازی کند و پیش‌بینی

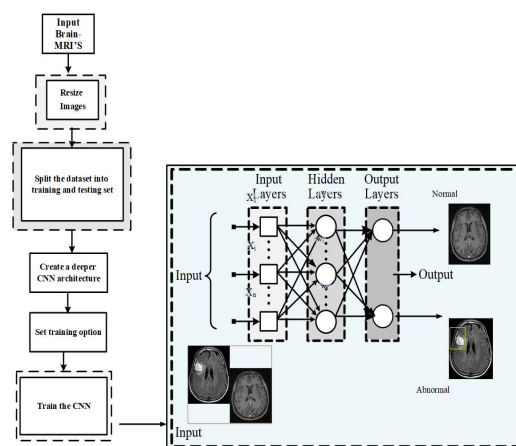
دقیقی از تشخیص تومور مغز ارائه دهد. ترکیب لایه‌های کانولوشنی، نرمال‌سازی دسته‌ای و کاملاً متصل، این شبکه را قادر به یادگیری و

تمایز الگوهای پیچیده مرتبط با ویژگی‌های تومور می‌کند.

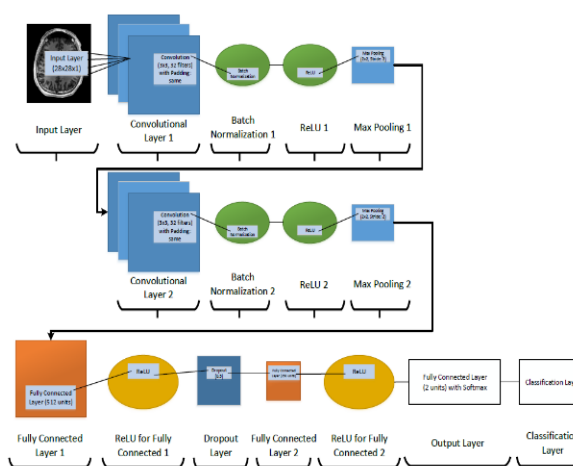
شبکه‌های عصبی کانولوشنال به عنوان یک دسته قدرتمند از مدل‌های یادگیری عمیق برای وظایف مختلف بینایی ماشین، از جمله

طبقه‌بندی تصویر، شناسایی اشیاء و تقسیم‌بندی معنایی، به وجود آمده‌اند. در اینجا، اجزای اساسی شبکه‌های عصبی کانولوشنال، روابط

ریاضی و توضیح متغیرهای درگیر در لایه‌های کانولوشنال و توابع فعال‌سازی مورد بحث قرار می‌گیرند.



شکل (۱). روش کلی عملکرد CNN عمیق پیشنهادی.



شکل (۲). الگوریتم یادگیری عمیق CNN.

آموزش شبکه شامل بهینه‌سازی پارامترهای آن با استفاده از بهینه‌ساز Adam است؛ در حالی که انتخاب دقیق از هایپرپارامترها از همگرایی بهینه اطمینان حاصل می‌کند. استفاده از واحد پردازش گرافیکی (GPU) برای آموزش فرآیند را شتاب می‌دهد و امکان آزمایش و اعتبارسنجی سریع‌تر را فراهم می‌کند. نتایج نشان می‌دهند که شبکه عصبی کانولوشنی (CNN) عمیق پیشنهادی با دقت بالا توانسته تصاویر پزشکی را به دو دسته دارای تومور و بدون تومور تقسیم کند. با دستیابی به عملکرد طبقه‌بندی بالا، امیدواری به بهبود توانایی تشخیصی پزشکی افزایش می‌یابد. معماری CNN پیشنهادی در مقایسه با تحقیقات موجود نوآوری‌های قابل توجهی ارائه می‌دهد. بر خلاف رویکردهای سنتی، مدل به طور استراتژیک از نرمال‌سازی دسته‌ای، لایه‌های dropout و نرخ‌های یادگیری تطبیقی از طریق بهینه‌ساز Adam بهره‌مند شده، که به همگرایی بهبود یافته و استخراج ویژگی قوی منجر می‌شود. افزایش تدریجی لایه‌های کانولوشنال و پولینگ، یادگیری ویژگی سلسله مراتبی را تسهیل می‌کند که مدل را از معماری‌های ساده‌تر متمایز می‌کند. علاوه بر این، اضافه شدن لایه‌های کاملاً متصل، تشخیص الگوهای پیچیده‌تر را فراهم می‌کند که قابلیت‌های برخی از مدل‌های معاصر را فراتر می‌برد. استفاده از

تابع، اختلاف میان توزیع واقعی کلاس (y) و توزیع پیش‌بینی شده کلاس (\hat{y}) را به صورت (۶) اندازه‌گیری می‌کند.

$$L(y, \hat{y}) = -\sum (y - i * \log(y - i)) \quad (۶)$$

بهینه‌ساز Adam یک الگوریتم بهینه‌سازی تطبیقی است که معمولاً برای آموزش شبکه‌های عصبی استفاده می‌شود. این الگوریتم پارامترهای مدل را بر اساس میانگین متحرک گرادینان‌ها و مربع گرادینان‌ها به‌روزرسانی می‌کند و به صورت (۷-۹) معرفی می‌شود.

$$m_t = \beta_1 * m_{t-1} + (1 - \beta_1) * \nabla L \quad (۷)$$

$$v_t = \beta_2 * v_{t-1} + (1 - \beta_2) * (\nabla L)^2 \quad (۸)$$

$$\theta_t = \theta_{t-1} - \alpha * m_t / (\sqrt{v_t} + \epsilon) \quad (۹)$$

در اینجا، m_t و v_t میانگین‌های متحرک، θ_t پارامترهای مدل، α نرخ یادگیری، β_1 و β_2 هاپرپارامترها، و ϵ یک ثابت کوچک برای جلوگیری از تقسیم بر صفر هستند.

در این پژوهش، یک رویکرد بهینه‌سازی نوآورانه بیان شده که از یادگیری انتقالی با شبکه‌های عصبی کانولوشنال بهره‌مند می‌شود. این روش از دانش جمع‌آوری شده از مجموعه داده‌های بزرگ و ساختارهای پیچیده بهره می‌برد و در نهایت به بهبود تعمیم و همگرایی در وظیفه تشخیص تومور کمک می‌کند. در هسته استراتژی بهینه‌سازی، یک مدل مناسب از شبکه عصبی کانولوشن واقع شده است. این مدل با پیچیدگی‌های تحلیل تصاویر پزشکی هماهنگ می‌باشد و عواملی نظیر پیچیدگی معماری، اندازه مجموعه داده اصلی، و ارتباط با تصویربرداری پزشکی را در نظر گرفته است. مدل‌هایی چون ResNet، VGG، و Inception عملکرد استثنایی خود را در دامنه‌های مختلف تشخیص تصویر اثبات کرده‌اند و از اینرو برای تشخیص تومور با مکانیزم این تحقیق نیز گزینه‌های مناسبی هستند. پایه روش پیشنهادی، تغییر شکل دادن شبکه عصبی به شبکه عصبی کانولوشن پیش‌آموزش یافته برای تشخیص تومور است. لایه‌های تماماً متصل نهایی مدل پیش‌آموزه با یک سر تصویب سفارشی جایگزین می‌شوند تا با تعداد کلاس‌های تومور هدف هماهنگ شود. این افزوده شدن اطمینان حاصل می‌کند که شبکه به‌طور ساده از تشخیص تصویر عمومی به وظیفه خاص تشخیص تومور منتقل می‌شود. یک اصل کلیدی، حفظ هوشی است که توسط مدل پیش‌آموزش یافته از طریق یادگیری انتقالی به‌دست آورده است. برای تسهیل این فرآیند، به طور استراتژیک وزن‌های لایه‌های کانولوشنال منجمد شده تا از تغییر مکانیسم‌های اصلی استخراج ویژگی در طول آموزش جلوگیری می‌شود. این منجمدسازی استراتژیک، ویژگی‌های سلسله مراتبی جوهری را که مدل پیش‌آموزش یافته مسلط بر آنها شده است، حفظ می‌کند و این امکان را می‌دهد که بر روی تنظیم دقیق شبکه برای دامنه خاص خود تمرکز شود.

برای بهینه‌سازی بیشتر، می‌توان از تنظیم دقیق استفاده کرد. با باهوش‌مندان آزاد کردن و آموزش لایه‌های کانولوشنال انتخاب‌شده، مدل می‌تواند به جزئیات موجود در مجموعه داده تشخیص تومور تطبیق یابد. تنظیم دقیق کنترل‌شده، امکان یک مسیر برای شبکه

سنگ بنای شبکه‌های عصبی کانولوشنال، عملگر کانولوشن است که الگوهای محلی را از داده‌های ورودی استخراج می‌کند. این عملگر شامل ضرب اندازه‌های یک تصویر ورودی با یک هسته (همچنین به عنوان فیلتر شناخته می‌شود) است. نتیجه به صورت جمع‌بندی برای تولید یک نقشه ویژگی می‌شود. این فرآیند در سراسر تصویر تکرار می‌شود. رابطه عملگر کانولوشن در زیر بیان شده است.

$$F(x, y) = \sum (i, j) [I(x - i, y - j) * K(i, j)] \quad (۱)$$

در اینجا، $F(x, y)$ مقدار در موقعیت (x, y) در نقشه ویژگی را نمایان می‌کند، I تصویر ورودی و K هسته است. تابع فعال‌سازی ReLU پس از عملگر کانولوشن برای معرفی غیرخطیت اعمال می‌شود. این تابع مقادیر منفی در نقشه ویژگی را با صفر جایگزین می‌کند و مقادیر مثبت را بدون تغییر باقی می‌گذارد.

$$\text{ReLU}[x] = \max(0, x) \quad (۲)$$

در (۲)، x خروجی یک عملیات کانولوشن است که ویژگی‌های مهمی را در تصاویر پزشکی ثبت می‌کند. تابع ReLU به شبکه این امکان را می‌دهد که ویژگی‌های مهم مرتبط با تشخیص تومور را شناسایی و تقویت کند. به عبارت ساده‌تر، زمانی که خروجی لایه کانولوشن شامل اطلاعات مرتبط با حضور تومورها است، ReLU اطمینان حاصل می‌کند که این اطلاعات ذخیره شده و برای تحلیل بیشتر ارسال شود. از سوی دیگر، اگر خروجی به تشخیص تومور کمی نکند (یعنی مقدار منفی باشد)، ReLU این اطلاعات بی‌اهمیت را با صفر کردن آن به طور مؤثر حذف می‌کند. استفاده از فعال‌ساز ReLU در بهبود قابلیت شبکه برای یادگیری الگوهای پیچیده در تصاویر پزشکی نقش اساسی دارد و در نهایت در تشخیص دقیق و کارآمد تومورها کمک می‌کند و به عنوان تابع فعال‌ساز استاندارد در مدل‌های یادگیری عمیق به دلیل سادگی و اثربخشی در یادگیری الگوهای پیچیده متداول شده است.

هدف نرمال‌سازی دسته‌ای، نرمال‌سازی فعالیت‌های یک لایه است و به استقرار و شتاب بخشی در آموزش شبکه عصبی کمک می‌کند.

$$y = \frac{(x - \mu)}{\sigma} \quad (۳)$$

در اینجا، x ویژگی ورودی، μ میانگین، و σ انحراف معیار ویژگی هستند. همچنین، Max pooling یک عملیات کاهش نمونه است که ابعاد فضایی یک نقشه ویژگی را کاهش می‌دهد و با (۴) مشخص می‌شود. این عملگر از بین یک پنجره تعریف‌شده، بیشینه مقدار را انتخاب می‌کند و به‌طور مؤثر اطلاعات بیشتری را ثبت می‌کند.

$$\text{MaxPooling}(x, y) = \max(x(2x, 2y), X(2x, 2y + 1), X(2x + 1, 2y), X(2x + 1, 2y + 1)) \quad (۴)$$

رابطه خروجی یک نرون تکی به صورت (۵) می‌باشد.

$$y = \text{activation}(Wx + b) \quad (۵)$$

در اینجا، W ماتریس وزن، x ورودی، b بایاس، و activation تابع فعال‌ساز هستند. تابع از دست دادن آنتروپی متقاطع به عنوان یک تابع از دست دادن معمولاً برای وظایف طبقه‌بندی استفاده می‌شود. این

به روزرسانی پارامترها در طول آموزش تأثیر می‌گذارد، در طول فرآیند آموزش به مقدار پایه‌ای ۰/۱۰ حفظ شد. این نتایج تأثیرگذاری معماری شبکه عصبی کانولوشنی پیشنهادی در یادگیری از داده‌های آموزش و بهبود دقت پیش‌بینی را نشان می‌دهند. با این حال، لازم به ذکر است که این معیارها، عملکرد مدل را بر روی داده‌های آموزش نشان می‌دهند. برای ارزیابی توانایی واقعی مدل در عمومی‌سازی و انجام پیش‌بینی دقیق بر روی داده‌های نامرئی، لازم است که عملکرد آن را بر روی مجموعه داده آزمون ارزیابی شود. روندهای مشاهده شده در جدول (۱) نشان‌دهنده توانمندی مدل برای عملکرد خوب بر روی داده‌های نامرئی است. با این حال، اعتبارسنجی و ارزیابی بیشتر بر روی مجموعه داده آزمون ضروری است تا نتایج قطعی‌تری به دست آید و اطمینان حاصل شود که مدل در سناریوهای واقعی تشخیص تومور مغز از اطمینان برخوردار است.

تجزیه و تحلیل و جزئیات آموزش با دقت انجام شد و به نتایج قابل توجهی منجر شد. زمان کل فرآیند آموزش تنها ۱۷ ثانیه بوده است. این سرعت قابل توجه به استفاده از یک GPU تنها بازمی‌گردد و نمونه‌ای از توانایی منابع سخت‌افزاری تخصصی در تسریع وظایف یادگیری عمیق است. دوره‌های آموزش قوی برنامه‌تربین، شامل ۳۰ دوره و هرکدام شامل ۴ تکرار بود که به مجموع ۱۲۰ تکرار مشخص شده دست یافت. در طول این فرآیند، نرخ یادگیری ثابت با مقدار ۰/۰۰۱ حفظ شد. این چرخه‌های آموزش قوی که تحت استراتژی نرخ یادگیری ثابت قرار دارند، نشان‌دهنده‌ی یک رویکرد پایدار و کارآمد برای آموزش شبکه‌های عصبی کانولوشنی عمیق می‌باشد. عملکرد موفق شبکه عصبی کانولوشنی با استفاده از یک GPU، نه تنها فرآیند آموزش را شتاب داد، بلکه نقش مهمی که سخت‌افزارهای تخصصی در برنامه‌های مدرن یادگیری عمیق ایفا می‌کنند را نیز به نمایش می‌گذارد. با بهره‌مندی از قابلیت‌های یک GPU تنها، پژوهشگران می‌توانند به طور مؤثر زمان‌های آموزش را کاهش داده و در نتیجه وظایف پیچیده را به صورت زمانی کارآمدتر و قابل دسترس‌تر اجرا کنند. فرآیند اجرای روش پیشنهادی پس از پیش‌پردازش که قبلاً بر روی پایگاه داده انجام شده با مرحله آستانه‌گذاری می‌باشد که در شکل (۵-الف) نشان داده شده است. در این شکل، شش تصویر اصلی MRI با نام‌های a1 تا a6 به عنوان ورودی در نظر گرفته شده تا ارزیابی شبکه انجام شود. این تصاویر اولیه دیدی دقیق از ساختارهای آناتومیک مغز ارائه می‌دهند. سپس، یک مجموعه متناظر شش تصویر، با نام‌های b1 تا b6، از طریق یک فرآیند دو مرحله‌ای که شامل آستانه‌گذاری و طبقه‌بندی است، تولید شده است. عملیات آستانه‌گذاری برای افزایش قابلیت رویت ناهنجاری‌های ممکن - به خصوص با تمرکز بر مناطق تومور مغز - اعمال می‌شود. پس از مرحله آستانه‌گذاری، یک الگوریتم طبقه‌بندی برای تمایز بین بافت عادی مغز و مناطق ممکن تومور استفاده می‌شود. تصاویر حاصل از b1 تا b6 نتایج این فرآیند دقیق را خلاصه می‌کنند و موفقیت این رویکرد در جدا کردن و طبقه‌بندی

فراهم می‌کند تا ویژگی‌های خاص حوزه را یاد بگیرد و در عین حفظ دانش اساسی درون لایه‌های پیش‌آموزفته حاکم بماند. تنظیم نرخ یادگیری، اندازه دسته، و تعداد اپوک‌ها شش امکان سفارشی‌سازی دینامیک آموزش شبکه را به خصوصیات مجموعه داده و سخت‌افزار موجود می‌دهد. با تنظیم مکرر پارامترها، می‌توان بین همگرایی سریع و عملکرد مدل پایدار تعادل برقرار کرد. برای اثبات کارایی روش پیشنهادی، شبکه به ارزیابی تجربی دقیق گذاشته می‌شود. شبکه سفارشی طبق روش یادگیری انتقالی مشخص شده با مجموعه داده تشخیص تومور آموزش می‌بیند. پس از همگرایی، عملکرد آن با یک مجموعه داده آزمایش مستقل ارزیابی می‌شود. معیارهایی چون دقت، بازخوانی، و امتیاز F1 ارزیابی جامعی از توانایی مدل در تمایز کلاس‌های تومور را فراهم می‌کند.


۳- نتایج و بحث

شبیه‌سازی‌ها نشان می‌دهند که روش بهینه‌سازی یادگیری انتقالی پیشنهادی، بهبودهای قابل توجهی در هر دو معیار دقت و سرعت همگرایی نسبت به آموزش از ابتدا ارائه می‌کند. روش بهینه‌سازی پیشنهادی از قابلیت‌های یادگیری انتقالی و شبکه‌های آموزش یافته بهره می‌برد و یک راه مؤثر را برای افزایش کارایی در تشخیص تومور ارائه می‌دهد. آموزش شبکه عصبی کانولوشن این مقاله با استفاده از نرم افزار MATLAB نسخه R2020a انجام شده و از GPU در طول فرآیند آموزش برای افزایش شتابدهی استفاده شده است.

عملکرد مدل از طریق معیارهای مختلف ارزیابی شد و توانایی دقیق در دسته‌بندی تصاویر به عنوان حاوی تومور یا خالی از تومور نشان داده شد. شبکه عصبی کانولوشنی عمیق ارائه شده عملکرد استثنایی در تشخیص تومور با دقت ۱۰۰٪ را نشان می‌دهد. برای ارزیابی جامع عملکرد مدل تشخیص تومور مغز، پیشرفت آن از طریق چندین اپوک آموزشی پیگیری می‌شود و تکرارهای مختلف، معیارهای کلیدی عملکرد ثبت می‌شود. جدول (۱) به طور خلاصه نشان‌دهنده نشانگرهای کارایی حیاتی در اپوک‌های انتخاب شده در طول فرآیند آموزش است؛ که بر اساس آن، عملکرد مدل به طور پیوسته در طول آموزش بهبود می‌یابد. در اپوک اول، دقت مینی‌بچ ۴۶/۸۸٪ بود، که نشان‌دهنده این بود که مدل برای کمتر از نصف نمونه‌ها در هر مینی‌بچ، پیش‌بینی صحیح انجام می‌داد. با پیشرفت آموزش، بهبود قابل توجهی در دقت مشاهده شد. بدین صورت که تا اپوک سی، به دقت ۱۰۰/۰٪ در مینی‌بچ دست یافت؛ که نشان‌دهنده یادگیری تقریباً کامل مدل از داده‌های آموزش بود. همزمان، دسترس‌ی به از دست رفتن مینی‌بچ استفاده شد که اختلاف بین برچسب‌های پیش‌بینی شده و واقعی را اندازه‌گیری می‌کند. در اپوک اول، از دست رفتن نسبتاً بالا بود و برابر با ۰/۸۳۸۷ بود، که نمایانگر ابهامات اولیه مدل بود. با پیشرفت آموزش، از دست رفتن به طور مداوم کاهش یافت و تا اپوک سی‌ام، به ۰/۰۰۹ رسیده است. نرخ یادگیری، یک هایپرپارامتر اساسی که بر تأثیر نرخ



- مثبت واقعی (TP): مدل در ۹۰ مورد پیش‌بینی کرده که کلاس 'بله' (تومور) بوده و به درستی 'بله' پیش‌بینی شده است.
- منفی واقعی (TN): در ۲۹ مورد، مدل 'نه' (بدون تومور) را پیش‌بینی کرده و کلاس واقعی 'نه' بوده است.
- مثبت غلط (FP): مدل در ۷ مورد 'بله' را پیش‌بینی کرده در حالی که کلاس واقعی 'نه' بوده است. این نمونه‌ها نشان‌دهنده مواردی هستند که مدل به اشتباه حضور تومور را نشان می‌دهد.



شکل (۶). ماتریس های سردرگمی


جدول (۱): مقداردهی اولیه داده‌های ورودی.

Epoch	Iteration	Time Elapsed (hh:mm:ss)	Mini-batch Accuracy	Mini-batch Loss	Base Learning Rate
1	1	0:00:00	46.88%	0.8387	0.01
13	50	0:00:07	90.63%	0.2313	0.01
25	100	0:00:14	96.88%	0.558	0.01
30	120	0:00:17	100.00%	0.009	0.01


جدول (۲). مقایسه با مقالات قبلی

	This Work							
	[22]	[23]	[24]	[25]	[26]	[27]	[28]	
Dice	0.92	0.92	0.84	0.89	—	88.3	—	—
Sensitivity	0.96	0.94	0.86	0.85	92.73	87.4	98.1	99.7
Precision	0.95	1	0.85	—	—	86.43	98.55	100
specificity	0.7714	—	—	—	—	—	99.75	100
F1 score	0.9010	—	—	—	—	—	—	—
Recall	0.9381	—	—	—	—	—	—	—
Accuracy	0.8485	—	—	99.30	—	—	99.6	—


تومورهای مغز در اسکن‌های MRI را برجسته می‌کنند. این مجموعه دوگانه تصاویر یک دیدگاه جامع از قبل و بعد ارائه می‌دهد و کارآمدی روش پیشنهادی در شناسایی دقیق و مکانیابی تومورهای مغز در داده‌های MRI را نشان می‌دهد. پس از انجام پردازش‌های الگوریتم، نتایج خروجی شبکه عصبی در شکل (۵-ب) نشان داده شده که بیانگر توانایی الگوریتم در مشخص کردن تصاویر دارای تومور و بدون تومور است. در این روش دو حالت ممکن برای تصاویر MRI با دو برچسب مشخص شده و داده‌های ارزیابی با دقت بالایی دسته‌بندی می‌شوند. ماتریس سردرگمی شکل (۶)، نحوه عملکرد طبقه‌بندی شبکه پیشنهادی را با جزئیات بیشتر نشان داده شده است. هر ورودی در این ماتریس با تعداد نمونه‌های متعلق به دسته‌های مختلف مرتبط است.



شکل (۳): از دست دادن در فرآیند آموزش.



شکل (۴): دقت در فرآیند آموزش.



شکل (۵). الف - بررسی نتایج آستانه‌گذاری و طبقه‌بندی تومورهای مغزی در MRI؛ ب - نتایج پردازش تومورهای مغزی در MRI

- [4] Buhler, Fred N., Adam E. Mendrela, Yong Lim, Jeffrey A. Fredenburg, and Michael P. Flynn. "A 16-channel noise-shaping machine learning analog-digital interface." In 2016 IEEE Symposium on VLSI Circuits (VLSI-Circuits), pp. 1-2. IEEE, 2016.
- [5] Zhang, Jintao, Zhuo Wang, and Naveen Verma. "A machine-learning classifier implemented in a standard 6T SRAM array." In 2016 IEEE Symposium on VLSI Circuits (vlsi-circuits), pp. 1-2. IEEE, 2016.
- [6] Solomatine, Dimitri P., and Durga L. Shrestha. "AdaBoost. RT: a boosting algorithm for regression problems." In 2004 IEEE International Joint Conference on Neural Networks (IEEE Cat. No. 04CH37541), vol. 2, pp. 1163-1168. IEEE, 2004.
- [7] Dreiseitl, Stephan, and Lucila Ohno-Machado. "Logistic regression and artificial neural network classification models: a methodology review." *Journal of biomedical informatics* 35, no. 5-6 (2002): 352-359.
- [8] Li, Yaoyong, Kalina Bontcheva, and Hamish Cunningham. "SVM based learning system for information extraction." In International Workshop on Deterministic and Statistical Methods in Machine Learning, pp. 319-339. Berlin, Heidelberg: Springer Berlin Heidelberg, 2004.
- [9] Übeyli, Elif Derya. "Implementing automated diagnostic systems for breast cancer detection." *Expert systems with Applications* 33, no. 4 (2007): 1054-106
- [10] Abonyi, Janos, and Ferenc Szeifert. "Supervised fuzzy clustering for the identification of fuzzy classifiers." *Pattern Recognition Letters* 24, no. 14 (2003): 2195-2207.
- [11] Karabatak, Murat, and M. Cevdet Ince. "An expert system for detection of breast cancer based on association rules and neural network." *Expert systems with Applications* 36, no. 2 (2009): 3465-3469.
- [12] Marcano-Cedeño, Alexis, Joel Quintanilla-Domínguez, and Diego Andina. "Breast cancer classification applying artificial metaplasticity algorithm." *Neurocomputing* 74, no. 8 (2011): 1243-1250.
- [13] Karthiga, R., G. Usha, N. Raju, and K. Narasimhan. "Transfer learning based breast cancer classification using one-hot encoding technique." In 2021 International Conference on Artificial Intelligence and Smart Systems (ICAIS), pp. 115-120. IEEE, 2021.
- [14] Zhao, Chumin, Jerzy Kanicki, Anastasios C. Konstantinidis, and Tushita Patel. "Large area CMOS active pixel sensor x-ray imager for digital breast tomosynthesis: analysis, modeling, and characterization." *Medical physics* 42, no. 11 (2015): 6294-6308.
- [15] Jayaraj, Akshay, Imon Banerjee, and Arindam Sanyal. "Common-source amplifier based analog artificial neural network classifier." In 2019 IEEE International Symposium on Circuits and Systems (ISCAS), pp. 1-5. IEEE, 2019.
- [16] Wang, Zhuo, Kyong Ho Lee, and Naveen Verma. "Overcoming computational errors in sensing platforms through embedded machine-learning kernels." *IEEE Transactions on Very Large Scale Integration (VLSI) Systems* 23, no. 8 (2014): 1459-1470.
- [17] Hua, Ruobing, and Arindam Sanyal. "39fJ Analog Artificial Neural Network for Breast Cancer Classification in 65nm CMOS." In 2019 IEEE 62nd International Midwest Symposium on Circuits and Systems (MWSCAS), pp. 436-439. IEEE, 2019.
- [18] Carrasco-Robles, Manuel, and Luis Serrano. "A novel CMOS current mode fully differential tanh (x) implementation." In 2008 IEEE International Symposium

• منفی غلط (FN): مدل در ۶ مورد 'نه' را پیش‌بینی کرده در حالی که کلاس واقعی 'بله' بوده است. این نمونه‌ها نشان‌دهنده مواردی است که مدل قادر به شناسایی حضور تومور نشده است. این تجزیه و تحلیل نکات مهمی را ارائه می‌دهد و نقاط قوت و ضعف مدل را نشان می‌دهد. تعداد زیاد مثبت‌های واقعی نمایانگر توانایی بالای مدل در تشخیص تومور است؛ در حالی که حضور مثبت‌ها و منفی‌های غلط نشان‌دهنده حوزه‌هایی برای بهبود هستند. بهینه‌سازی دقت و بازخوانی مدل برای دستیابی به عملکرد بهینه در تشخیص تومور مغز بسیار حائز اهمیت است. در جدول (۲) شاخص‌های اصلی برای مدل پیشنهادی و روش‌های [۲۲-۲۶] نشان داده شده که بیانگر برتری روش پیشنهادی است. به‌طور خاص، مقدار Dice برابر با ۰/۹۲، حساسیت به اندازه ۰/۹۶، و دقت به میزان ۰/۹۵ را نشان می‌دهد. این ارقام تاکید می‌کنند که روش پیشنهادی در این مطالعه بهبودهای مهمی ارائه داده است.

۴- نتیجه‌گیری

این مقاله در زمینه تشخیص تومور مغز با استفاده از شبکه عصبی کانولوشنی یک پیشرفت چشم‌گیر داشته است. الگوریتم استفاده شده، با دقت و حساسیت بالا به جزئیات، از لحظه بارگیری داده تا فرآیند آموزش مدل، به گونه‌ای سازمان‌دهی شده که امکان ادامه توسعه و بهینه‌سازی را فراهم می‌کند. پردازش تصویرها با توجه به تغییر اندازه، تقسیم دقیق مجموعه داده، و طراحی هوشمند شبکه، این پروژه را به یک پایگاه قابل اعتماد برای تشخیص تومور مغز تبدیل کرده است. انتخاب مناسب پارامترها، بهینه‌سازی فرآیند آموزش با الگوریتم Adam، و استفاده از GPU نشان‌دهنده تعهد جدی به بهترین عملکرد و سرعت در توسعه مدل است. این پروژه نه تنها به تشخیص دقیق تومور مغز کمک می‌کند بلکه با باز کردن راه برای بهینه‌سازی و افزودن اطلاعات جدید، امکان افزایش کارایی آن را فراهم می‌کند. این پیشرفت در زمینه تصویر پزشکی مسیری را برای ادامه تحقیقات و اثرگذاری در حوزه تشخیص بیماری‌ها با استفاده از هوش مصنوعی می‌گشاید.

مراجع:

- [1] Wang, Zhuo, and Naveen Verma. "A low-energy machine-learning classifier based on clocked comparators for direct inference on analog sensors." *IEEE Transactions on Circuits and Systems I: Regular Papers* 64, no. 11 (2017): 2954-2965
- [2] Lee, Edward H., and S. Simon Wong. "24.2 A 2.5 GHz 7.7 TOPS/W switched-capacitor matrix multiplier with co-designed local memory in 40nm." In 2016 IEEE International Solid-State Circuits Conference (ISSCC), pp. 418-419. IEEE, 2016.
- [3] Wang, Zhuo, Jintao Zhang, and Naveen Verma. "Realizing low-energy classification systems by implementing matrix multiplication directly within an ADC." *IEEE transactions on biomedical circuits and systems* 9, no. 6 (2015): 825-837.



- on Circuits and Systems (ISCAS), pp. 2158-2161. IEEE, 2008.
- [19] Amari, Shun-ichi. "Backpropagation and stochastic gradient descent method." *Neurocomputing* 5, no. 4-5 (1993): 185-196.
- [20] Selvathi, D., and R. Deiva Nayagam. "FPGA implementation of on-chip ANN for breast cancer diagnosis." *Intelligent Decision Technologies* 10, no. 4 (2016): 341-352.
- [21] Ghahramani, Marzieh, and Nabiollah Shiri. "Brain tumour detection in magnetic resonance imaging using Levenberg–Marquardt backpropagation neural network." *IET Image Processing* 17, no. 1 (2023): 88-103.
- [22] Shirali, Armaghan, and Nabiollah Shiri. "Diagnosis of brain tumours by MRI binarisation with variable fuzzy level." *IET Image Processing* 14, no. 16 (2020): 4269-4276.
- [23] Jnn, J.C.: 'A fuzzy relative of the ISODATA process and its use in detecting compact well-separated clusters', *J. Cybern.*, 1973, 3, pp. 3, pp. 32–57
- [24] Hasan, A.M., Jalab, H.A., Meziane, F., et al.: 'Combining deep and handcrafted image features for MRI brain scan classification', *IEEE Access*, 2019, 7, pp. 79959–79967
- [25] Razzak, M.I., Imran, M., Xu, G.: 'Efficient brain tumor segmentation with multiscale two-pathway-group conventional neural networks', *IEEE. J. Biomed. Health. Inf.*, 2019, 23, (5), pp. 1911–1919
- [26] Zadeh, L.A.: 'Fuzzy sets, information and control', *Inf. Control*, 1965, 8, (3), pp. 338–353
- [27] Jasmine Hephzipah, J., Thirumurugan, P.: 'Performance Analysis of Meningioma Brain Tumor Detection System Using Feature Learning Optimization and ANFIS Classification Method', *IETE Journal of Research*, 2022, 68, (2), pp. 1542-1550.
- [28] Ghahramani, Marzieh, and Nabiollah Shiri. "An Adaptive NEURO Fuzzy Inference System Optimized by Genetic Algorithm for Brain Tumor Detection in Magnetic Resonance Images." *IET Image Processing*, DOI: 10.1049/ipr2.13031.

COPYRIGHTS

©2024 by the authors. Published by the Islamic Azad University Shiraz Branch. This article is an open-access article distributed under the terms and conditions of the Creative Commons Attribution 4.0 International (CC BY 4.0)

<https://creativecommons.org/licenses/by/4.0>

