

## تشخیص تومور مغزی گلیوما با استفاده از تصاویر تصویربرداری تشدید مغناطیسی با روش‌های یادگیری عمیق: یک مرور سیستماتیک

زینب خزائی<sup>۱</sup>، مصطفی لنگری زاده<sup>۲\*</sup>، محمدابراهیم شیری احمدآبادی<sup>۳</sup>

• پذیرش مقاله: ۱۴۰۰/۱/۱۴

• دریافت مقاله: ۱۳۹۹/۱۲/۵

**مقدمه:** گلیوما یکی از شایع‌ترین تومورهای مغزی است که تشخیص به موقع و دقیق آن منجر به درمان صحیح و افزایش عمر بیمار می‌شود. در این مطالعه به بررسی و تحلیل پژوهش‌های انجام شده در زمینه تشخیص گلیوما با استفاده از تصاویر تصویربرداری تشدید مغناطیسی با روش‌های یادگیری عمیق پرداخته شد.

**روش:** این مطالعه مروری نظام‌مند است که در آن پایگاه‌های اطلاعاتی PubMed، ScienceDirect، Springer، IEEE، Arxiv در بازه زمانی سال‌های ۲۰۱۰ تا ۲۰۲۰ به منظور بازیابی مطالعات انگلیسی زبان با استفاده از کلمات کلیدی مورد جستجو قرار گرفتند. سپس مقاله‌ها بر اساس معیارهای ورود و خروج و در راستای هدف پژوهش، انتخاب و اطلاعات مورد نیاز جهت بررسی استخراج گردید.

**نتایج:** در نهایت ۳۵ مقاله پژوهشی اصیل انتخاب گردید. بررسی مقاله‌ها نشان داد که از یک خط مشی واحد شامل جمع‌آوری تصاویر، پیش پردازش، طراحی و پیاده‌سازی مدل و ارزیابی نتایج مدل، جهت آشکارسازی، دسته‌بندی و بخش‌بندی تومور مغزی گلیوما استفاده کرده‌اند. اکثر مطالعه‌ها از مجموعه تصاویر عمومی و مدل‌های از پیش آموزش دیده استفاده کرده‌اند. در اغلب پژوهش‌ها معیار ضریب تشابه دایس در بخش‌بندی و معیار صحت در دسته‌بندی به عنوان معیارهای ارزیابی کننده مدل استفاده شده‌اند.

**نتیجه‌گیری:** یافته‌های این مطالعه نشان می‌دهد که در اکثر مقاله‌ها بخش‌بندی گلیوما نسبت به آشکارسازی و دسته‌بندی بیشتر مورد توجه پژوهشگران بوده است؛ بنابراین پیشنهاد می‌گردد مطالعات بیشتری در زمینه آشکارسازی و به خصوص درجه‌بندی گلیوما به منظور تعبیه در سیستم‌های کمک تشخیص پزشکی، انجام شود.

**کلیدواژه‌ها:** یادگیری عمیق، تومور مغزی گلیوما، تصویربرداری تشدید مغناطیسی

• **ارجاع:** خزائی زینب، لنگری زاده مصطفی، شیری احمدآبادی محمدابراهیم. تشخیص تومور مغزی گلیوما با استفاده از تصاویر تصویربرداری تشدید مغناطیسی با روش‌های یادگیری عمیق: یک مرور سیستماتیک. مجله انفورماتیک سلامت و زیست پزشکی ۱۴۰۰؛ ۲۳۳(۲): ۲۱۸-۲۳۳.

۱. دانشجوی دکتری مدیریت فناوری اطلاعات، گروه مدیریت فناوری اطلاعات، دانشکده مدیریت و اقتصاد، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران

۲. دکترای انفورماتیک پزشکی، دانشیار، گروه مدیریت اطلاعات بهداشتی و درمانی، دانشکده مدیریت و اطلاع‌رسانی پزشکی، دانشگاه علوم پزشکی ایران، تهران، ایران

۳. دکترای هوش مصنوعی، استادیار، گروه علوم کامپیوتر، دانشکده ریاضی و علوم کامپیوتر، دانشگاه صنعتی امیرکبیر، تهران، ایران

\* نویسنده مسئول: مصطفی لنگری زاده

**آدرس:** تهران، خیابان ولیعصر، خیابان رشید یاسمی، دانشگاه علوم پزشکی ایران، دانشکده مدیریت و اطلاع‌رسانی پزشکی، گروه مدیریت اطلاعات بهداشتی و درمانی

• **Email:** langarizadeh.m@iums.ac.ir

• **شماره تماس:** ۰۲۱۸۸۷۹۴۳۰۱

## مقدمه

تومور مغزی گلیوما، یکی از شایع‌ترین و نوع بدخیم آن یکی از کشنده‌ترین تومورهای مغزی است و تشخیص زودهنگام و درمان به موقع آن به بقای عمر بیمار کمک می‌کند [۱، ۲]. گلیوما بر اساس بدخیمی و نرخ رشد آن به درجه‌های مختلفی تقسیم می‌شود. سازمان بهداشت جهانی، گلیوما را به دو درجه اصلی (LGG (Low Grade Glioma) (شامل دو زیر درجه فرعی ۱ و ۲) و HGG (High Grade Glioma) (شامل دو زیر درجه فرعی ۳ و ۴) دسته‌بندی کرده است. درجه ۱ معمولاً با جراحی قابل درمان است. درجه ۴ یا GBM (Glioblastoma Multiform) تهاجمی‌ترین تومور با کمترین نرخ بقاء است و درجه ۲ و ۳ نسبت به درجه ۴ کمتر تهاجمی هستند [۳]. تشخیص درجه گلیوما، محل قرارگیری، شکل و سایز تومور، اطلاعات بسیار مهمی در تعیین برنامه‌های بقاء و درمان بیماران از قبیل جراحی، شیمی‌درمانی، رادیوتراپی و یا ترکیبی از این موارد، فراهم می‌کند [۴]. (Magnetic Resonance Imaging) MRI یکی از روش‌های رایج و غیرتهاجمی برای تشخیص و ارزیابی پاسخ به درمان حین عمل جراحی تومورهای مغزی است [۵] که با ایجاد کنتراست بافت نرم، اطلاعات کاملی در مورد بافت مغز و تومور مغزی با توالی‌های مختلف شامل T1-weighted (T1), T1-weighted MRI with contrast enhancement (T1ce), T2-weighted (T2), FLAIR (Attenuated Inversion Recovery) را فراهم می‌کند و به دلیل در دسترس بودن، به عنوان یک روش استاندارد در نظر گرفته شده است [۶]. روش‌های تشخیص تومور مغزی با استفاده از تصاویر MRI شامل سه روش بخش‌بندی، دسته‌بندی و آشکارسازی است. در روش‌های آشکارسازی تومور مغزی، تصاویر دارای بافت تومور از تصاویر بافت نرمال متمایز می‌گردند. در روش‌های بخش‌بندی تعیین محل قرارگیری تومور و جداسازی بافت‌های مختلف تومور در داخل تصاویر MRI انجام می‌شود. روش‌های دسته‌بندی، برای درجه‌بندی و یا تعیین خوش‌خیم یا بدخیم بودن تومور استفاده می‌شوند [۷]. تشخیص تومور مغزی با استفاده از روش‌های نوین و خودکار بخش‌بندی و دسته‌بندی که به طور مستقیم از تصاویر MRI حاصل می‌گردد، منافع بسیاری را برای استفاده‌های کلینیکی در بر دارند [۸]. از جمله منافی که موجب شده است این روش‌ها مورد توجه بسیاری از پژوهشگران قرار گیرد، صرفه‌جویی در هزینه‌های تشخیص

بیماری، کاهش زمان تشخیص و پیشگیری از پیشرفت بیماری در مراحل اولیه، بالا رفتن رضایت بیماران به دلیل استفاده از روش‌های تشخیصی غیرتهاجمی به جای روش‌های تهاجمی، می‌باشد [۹]. یکی از این روش‌های نوین، روش یادگیری عمیق است که زیرمجموعه‌ای از یادگیری ماشین در حوزه هوش مصنوعی است و از عملکرد مغز انسان در پردازش داده‌ها و الگو برای حل مسائل پیچیده تصمیم‌گیری، تقلید می‌کند. یادگیری عمیق روشی بسیار کاربردی است که دقت پیشرفته‌ای ارائه کرده و در حوزه سلامت به خصوص تجزیه و تحلیل تصاویر پزشکی جایگاه ویژه‌ای یافته است [۱۰، ۱۱]. همچنین مدل‌های یادگیری عمیق، به ویژه شبکه‌های عصبی کانولوشنی (CNN (Convolutional Neural Network)، در زمینه تصاویر پزشکی برای بخش‌بندی اعضای بدن و تشخیص بیماری‌ها عملکرد خوبی داشته‌اند [۱۲، ۱۳]. در پژوهشی مروری که به بررسی سرطان مغز و رابطه بین آن و سایر اختلالات مغزی مانند سکته مغزی، آلزایمر، پارکینسون و بیماری ویلسون، لوکوریاوز و سایر اختلالات عصبی در زمینه یادگیری ماشین و یادگیری عمیق انجام شده، یافته‌ها نشان می‌دهد که یادگیری عمیق نتایج بهتری را نسبت به سایر روش‌های یادگیری ماشین کسب کرده است [۹]. همچنین در مطالعه دیگری که مقایسه روش‌های سنتی یادگیری ماشین و یادگیری عمیق در خصوص تشخیص تومور مغزی انجام شده است، روش‌های یادگیری عمیق صحت بهتری به دست آورده‌اند [۷].

هدف این مطالعه، بررسی نظام‌مند مقالاتی که در سال‌های اخیر به منظور تشخیص تومور مغزی گلیوما از روش‌های یادگیری عمیق استفاده کردند، است و بررسی رویکردهای مختلف تشخیص گلیوما از منظر بخش‌بندی، دسته‌بندی و آشکارسازی تومور در تصاویر MRI، برای دستیابی به یک خط‌مشی (Pipeline) مشترک جهت کمک به پژوهشگران در استفاده از روش‌های یادگیری عمیق در تشخیص تومور مغزی و سایر بیماری‌های مشابه می‌باشد.

## روش

در این مطالعه مروری نظام‌مند مقاله‌ها در پایگاه‌های اطلاعاتی Arxiv, IEEE, Springer, ScienceDirect, PubMed که در بازه زمانی سال‌های ۲۰۱۰ تا March ۲۰۲۰ منتشر شده‌اند، مورد جستجو قرار گرفتند. جستجوی مقاله‌ها بر اساس

“MRI”، طبق جدول ۱ در پایگاه‌های مذکور انجام شد.

موضوع و هدف مطالعه حاضر و ترکیبی از کلمات کلیدی “Deep learning” و “Glioma Brain Tumor” و

جدول ۱: استراتژی جستجو در پایگاه‌های اطلاعات


PubMed	((deep learning[Title/Abstract]) AND (MRI[Title/Abstract]) AND (Glioma[Title/Abstract]) AND (“2010/01/01”[Date – Publication]: “3000”[Date – Publication])) OR ((deep learning[Text Word]) AND (MRI[Text Word]) AND (Glioma[Text Word]) AND (“2010/01/01”[Date – Publication]: “3000”[Date – Publication]))
Science Direct	Year(s): 2010-2020, Find articles with these terms: “deep learning” AND “MRI” AND “Glioma”, Article types: Research articles
Springer	Where the title contains: "deep learning" AND MRI AND Glioma, Show documents published: 2010-2020
Arxiv	Query: order: - announced _ date _ first; size: 50; date _ range: from 2010-01-01 to 2020-12-31; include _ cross _ list: True; terms: AND all=deep learning; AND all=MRI; AND all=Glioma
IEEE	("All Metadata": deep learning) AND ("All Metadata ": MRI) AND (" All Metadata ": Glioma)

شد و پس از اعمال معیارهای خروج، ۶۸ مقاله حذف گردید که در نهایت ۳۵ مقاله انتخاب شد (شکل ۱). قابل ذکر است در کلیه مراحل انتخاب، مقاله‌ها توسط دو پژوهشگر بررسی گردید و موارد غیر مرتبط از مرور حذف شدند. در ضمن موارد اختلاف بین دو پژوهشگر، به پژوهشگر سوم ارجاع داده شد و در نهایت هر گونه اختلاف نظر بین پژوهشگران با اتفاق آراء برطرف گردید.

در ادامه، بر اساس جدول استخراج داده که توسط پژوهشگران طراحی شده بود، داده‌های مورد نیاز شامل: عنوان مقاله، نویسندگان، سال انتشار، مرجع نشر، هدف و نتیجه مقاله، مجموعه داده و ویژگی‌های آن، ویژگی‌های تصاویر MRI، نوع فرایند یادگیری عمیق، پیش‌پردازش تصاویر، معماری مدل، معیارهای ارزیابی مدل، محیط برنامه‌نویسی و سخت‌افزار جهت پیاده‌سازی مدل، از پژوهش‌ها استخراج شدند. بررسی کیفیت و محتوای مقاله‌ها و استخراج داده‌ها بر اساس چک‌لیست PRISMA به طور مستقل توسط دو نویسنده و در صورت وجود اختلاف نظر، جمع‌بندی و تصمیم‌گیری نهایی توسط نویسنده سوم انجام شد.

معیارهای ورود به مطالعه عبارت بودند از: مقالات پژوهشی اصیل و مقالات بازبینی شده دقیق (peer-reviewed) که متن کامل آن‌ها به زبان انگلیسی در دسترس بودند، مقالاتی که از روش‌های یادگیری عمیق استفاده کردند، مقالاتی که مرتبط با تشخیص تومور مغزی گلیوما بودند، مقالاتی که از مجموعه داده‌های حاوی تصاویر MRI برای توسعه مدل استفاده کردند. معیارهای خروج از مطالعه عبارت بودند از: مقالاتی که درباره تشخیص افتراقی گلیوما از سایر بیماری‌های مرتبط با مغز بودند، مطالعاتی که صرفاً برای تخمین زمان بقای بیماران مبتلا به گلیوما انجام شدند، مقالاتی که از سایر روش‌های تشخیصی گلیوما استفاده کردند، مقالاتی که فاقد روش‌های بخش‌بندی یا دسته‌بندی و یا آشکارسازی تومور بودند، مقالاتی که با موضوع اصلی مطالعه بی‌ارتباط بودند.

پس از اتمام جستجوی پایگاه‌های اطلاعاتی و استخراج مقالات، ۲۸۹ مقاله یافت شد. ابتدا ۹۹ رکورد تکراری با استفاده از نرم‌افزار Endnote شناسایی و حذف شد. عنوان و چکیده ۱۹۰ مقاله باقیمانده توسط پژوهشگران، مورد مطالعه قرار گرفت. پس از اعمال معیارهای ورود، ۸۷ مقاله حذف شد. سپس متن کامل مقالات باقیمانده به صورت مروری بررسی



شکل ۱: نمودار فرآیند انتخاب مقالات

### نتایج

پس از جستجو و بازیابی اطلاعات در نهایت از مجموع ۲۸۹ مقاله تعداد ۳۵ مقاله منتخب با هدف پژوهش انتخاب و توسط

نویسندگان مورد بررسی و تحلیل قرار گرفتند و بر اساس هدف پژوهش و محتوای جدول استخراج داده، اطلاعات مقاله‌ها توسط نویسندگان استخراج شد (جدول ۲).

جدول ۲: جزئیات مقالات بررسی شده

منابع	سال انتشار	روش	مجموعه داده	ابعاد	توالی‌های MRI	محیط برنامه‌نویسی	کتابخانه‌ها	سخت‌افزار
[۳۴]	۲۰۲۰	بخش‌بندی، درجه‌بندی، آشکارسازی	عمومی	دو بعدی	T1, T1ce, FLAIR	پایتون	Tensorflow, Keras	a single 11GB NVIDIA RTX 2080Ti, AMD Ryzen 2920X (32M Cache, 3.50 GHz)
[۳۹]	۲۰۲۰	بخش‌بندی	عمومی	سه بعدی	T1, T1ce, T2, FLAIR	پایتون	Tesorflow	AMD Ryzen 2920X (32M Cache, 3.50 GHz) CPU with a single 11GB NVIDIA RTX 2080Ti GPU
[۲۴]	۲۰۲۰	بخش‌بندی	عمومی	دو بعدی	FLAIR	پایتون	Tensorflow, Keras	an 11GB NVIDIA GTX 1080 Ti GPU
[۱۶]	۲۰۱۹	بخش‌بندی، درجه‌بندی	عمومی، محلی	سه بعدی	T1, T1ce, T2, FLAIR	پایتون	Pytorch	-
[۱۴]	۲۰۱۹	آشکارسازی	عمومی	دو بعدی	T1, T1ce, T2, FLAIR, DWI	متلب ۲۰۱۸	نامشخص	a server equipped with NVidia Titan GPUs
[۴۰]	۲۰۱۸	بخش‌بندی	عمومی	دو بعدی	T1, T1ce, T2, FLAIR	پایتون	Tensorflow	a single 16 GB GPU of the NVIDIA Tesla P100 graphics card

-	نامشخص	پایتون	T1, T1ce, T2, FLAIR	دوبعدی، سه بعدی	عمومی، محلی	بخش بندی	۲۰۱۹	[۲۸]
NVIDIA Tesla K80 cards	نامشخص	پایتون، ابزار Wndchrm	T2	دوبعدی	محلی	درجه بندی	۲۰۱۹	[۲۱]
a Dell workstation equipped with dual Intel E5-2603 CPUs and a middle-end GPU graphic card (GeForce GTX 1080, NVIDIA, CA, USA)	نامشخص	نرم افزار NVIDIA Digits	T1ce	دوبعدی	محلی	درجه بندی	۲۰۱۸	[۲۲]
two GPUs and one CPU on a computing workstation equipped with 4 NVIDIA 1080Ti GPUs and 2 Intel Xeon E5-2630 CPUs	Caffe	پایتون	T1, T1ce, T2, FLAIR	سه بعدی	عمومی	بخش بندی	۲۰۱۸	[۴۱]
Nvidia Titan Xp GPU with 12 Gb memory	Tensorflow, Keras	پایتون	T1, T1ce, T2, FLAIR	دوبعدی	عمومی	بخش بندی	۲۰۱۹	[۴۲]
an Intel Core i7 3.5GHZ processor and is equipped with an NVIDIA GeForce GTX1080 GPU	Tensorflow	پایتون	T1, T1ce, T2, FLAIR	سه بعدی	عمومی	بخش بندی	۲۰۲۰	[۴۳]
DELL PRECISION Tower T7910, with two NVIDIA Titan Xp GPUs	Tensorflow, Keras	پایتون	T1, T1ce, T2, FLAIR	دوبعدی	عمومی	بخش بندی	۲۰۱۹	[۶]
NVIDIA TITAN X GPU	Keras, Pytorch, Nilearn	پایتون	T1, T1ce, T2, FLAIR	دوبعدی، سه بعدی	عمومی	بخش بندی، درجه بندی	۲۰۲۰	[۳۶]
Core i7 CPU and 8GB RAM	Tesorflow, NiftyNet	پایتون	T1, T1ce, T2, FLAIR	دوبعدی	عمومی	بخش بندی	۲۰۱۸	[۴۴]
-	نامشخص	متلب ۲۰۱۸	T1, T1ce, T2, FLAIR	دوبعدی	عمومی	اشکارسازی	۲۰۲۰	[۱۵]
NVIDIA GeForce GTX 1080Ti GPU	نامشخص	پایتون	T1, T1ce, T2, FLAIR	سه بعدی	عمومی	بخش بندی	۲۰۱۹	[۳۷]
-	Pytorch	پایتون	T1, T1ce, T2, FLAIR	سه بعدی	عمومی	بخش بندی	۲۰۱۹	[۲۹]
-	Scikit-learn, Keras, SimpleITK	پایتون	T1, T1ce, T2, FLAIR	دوبعدی	عمومی	بخش بندی	۲۰۲۰	[۴۵]
a single GTX1080Ti GPU card	نامشخص	متلب ۲۰۱۷	T1, T1ce, T2, FLAIR	سه بعدی	عمومی	بخش بندی	۲۰۱۸	[۲۷]
workstation with Intel-i7 3.40GHz CPU, 48G RAM, an NVIDIA Titan Xp 12GB GPU	Pytorch	پایتون	T1, T1ce, T2, FLAIR	سه بعدی	عمومی	بخش بندی	۲۰۲۰	[۴۶]
workstation Intel-i7 2.60 GHz CPU, 19.5Go RAM equipped with NVIDIA GPU Geforce GTX 1080 Ti 11Go RAM	Tensorflow, Keras	پایتون	T1ce, T2, FLAIR	دوبعدی	عمومی	درجه بندی	۲۰۱۸	[۱۹]
four GTX 1080TI	Tensorflow, Keras	پایتون	T1ce	سه بعدی	عمومی	درجه بندی	۲۰۲۰	[۲۶]
Intel i7-7700HQ CPU (2.8 GHz), NVIDIA GTX 1060 (6 GB) GPU, 16GB RAM	MXNet	پایتون	T1, T1ce, T2, FLAIR	سه بعدی	عمومی	بخش بندی	۲۰۱۸	[۲۵]
GPU NVIDIA GeForce GTX 980 equipped on an Intel Core i7 3.5 GHz machine	نامشخص	متلب ۲۰۱۸، پایتون	T1ce	دوبعدی	عمومی	درجه بندی	۲۰۱۹	[۴۷]

-	Theano	پایتون	T1, T1ce, T2, FLAIR	سه بعدی	عمومی	بخش بندی	۲۰۱۶	[۳۳]
-	نامشخص	نامشخص	T1, T1ce, T2, FLAIR	دو بعدی	عمومی	بخش بندی	۲۰۲۰	[۴۸]
two parallel Nvidia GeForce 1080Ti GPUs	Tensorflow, Keras, SimpleITK	پایتون	T1ce, T2, FLAIR	سه بعدی	عمومی	بخش بندی	۲۰۲۰	[۲۰]
Nvidia GeForce GTX 1080 Ti GPU, RAM 11 GB, PC with CPU Intel Core i7 , RAM 16 GB	DMFNet	پایتون	T1, T1ce, T2, FLAIR	سه بعدی	عمومی	بخش بندی	۲۰۱۹	[۴۹]
NVIDIA GTX 1080 8G. The used CPU is INTEL i7 6700K	Tensorflow, Keras	پایتون	T1, T1ce, T2, FLAIR	سه بعدی	عمومی	بخش بندی	۲۰۱۹	[۵۰]
NVIDIA Titan black card	Tensorflow	پایتون	T1, T1ce, T2, FLAIR	دو بعدی	عمومی	بخش بندی	۲۰۱۹	[۵۱]
-	Pylearn2	پایتون	T1, T1ce, T2, FLAIR	دو بعدی	عمومی	بخش بندی	۲۰۱۶	[۸۱]
-	Tensorflow, Keras, Theano	پایتون	T1, T1ce, T2, FLAIR	دو بعدی	عمومی	بخش بندی	۲۰۱۷	[۵۲]
NVIDIA DGX station with processor 2.2 GHz, Intel Xeon E5-2698, NVIDIA Tesla V100 4 × 16 GB GPU	نامشخص	نامشخص	T1ce	دو بعدی	عمومی، محلی	درجه بندی	۲۰۱۹	[۲۳]
a single 11GB NVIDIA RTX 2080Ti ,AMD Ryzen 2920X (32M Cache, 3.50 GHz)	نامشخص	پایتون	T1ce, T2, FLAIR	دو بعدی	عمومی	بخش بندی	۲۰۱۹	[۵۳]

تشخیص تومور مغزی گلوبوما روی تصاویر MRI استفاده شده است. در روش دسته بندی از دو روش درجه بندی (۸ مقاله) و آشکار سازی (۲ مقاله) استفاده کرده اند. در اکثر مطالعات از مجموعه داده های عمومی (۳۳ مقاله) و از مجموعه داده های محلی در تعداد کمی از مطالعه ها (۵ مقاله) برای آموزش و ارزیابی مدل تشخیصی استفاده شده است. از مجموعه داده های عمومی، از مجموعه داده (Brain Tumor) BraTs (Segmentation The Cancer) در سال های مختلف انتشار آن از سال ۲۰۱۲ الی ۲۰۱۹ (۳۱ مقاله)، از (TCIA (Imaging Archive Ischemic)، از (۷ مقاله)، از (ISLES (Stroke Lesion Segmentation ۱) IXI (Information extraction from Images) مقاله) استفاده شده است. در اکثر مقالات (۲۵ مقاله) از توالی های مختلف MRI (FLAIR, Tce, 2T, 1T) به طور همزمان، به عنوان تصاویر ورودی به مدل و همچنین از تصاویر دوبعدی به شکل (Digital Imaging and Communications in Neuroimaging) DICOM (۲۱ مقاله) و از تصاویر سه بعدی به شکل

بیشترین تعداد مقالات در سال ۲۰۱۹ منتشر شده بود (نمودار ۱).



نمودار ۱: تعداد مقالات منتشر شده در هر سال

به طور کلی در این مطالعات از دو روش بخش بندی (۲۵ مقاله) و دسته بندی (۱۰ مقاله) از تکنیک های یادگیری عمیق برای

نرمال سازی (۲۴ مقاله) برای نرمال کردن شدت تصاویر، روش های افزون سازی داده ها (۲۱ مقاله) برای ایجاد تصاویر ساختگی، روش های اصلاح تصاویر (۱۰ مقاله)، روش های ایجاد توازن (۱۰ مقاله) در مجموعه تصاویر نامتوازن، استفاده شده است. همچنین تصاویر ground truth جهت آموزش مدل، توسط متخصص بخش بندی و برچسب گذاری و با آزمایش های پاتولوژی تأیید شده اند. مقالات برای فرآیند پیش پردازش به منظور اصلاح تصاویر، افزایش وضوح تصاویر، کاهش نویز و اصلاح فیلد بایاس از ابزارهای N3، N4ITK، N4 bias correction، bias correction inhomogeneity، N3T-spline، 3D slicer، SPM12 correction استفاده کرده اند.

NIFTI (Informatics Technology Initiative) (۱۶ مقاله) استفاده کرده اند. از محیط برنامه نویسی python به همراه چارچوب کتابخانه های Keras، Tensorflow، Nilearn، Caffe، Theano، Pytorch، SimpleITK، NiftyNet، 2Pylearn، MXNet، Scikit-learn (۲۹ مقاله)، از نرم افزار Matlab (نسخه ۲۰۱۷، ۲۰۱۸a) (۴ مقاله)، از Wndchrm tool (۱ مقاله) و از NVIDIA Digits software (۱ مقاله) برای توسعه مدل استفاده کرده اند. در مطالعات از واحد پردازش گرافیکی (Graphics Processing Unit) GPU (۲۴ مقاله) برای اجرا و پیاده سازی مدل در زیرساخت سخت افزاری استفاده کرده اند. همان گونه که در جدول ۳ نشان داده شده است در مقاله های بررسی شده، جهت پیش پردازش تصاویر از روش های

جدول ۳: روش های پیش پردازش استفاده شده در مقالات

منابع	روش ها	پیش پردازش
[۶، ۸، ۲۰، ۲۴، ۲۵، ۲۸، ۳۳، ۳۶، ۳۷، ۳۹، ۴۱، ۴۲]		
[۴۴-۴۶، ۴۸، ۵۰، ۵۲]	Z-score normalization	نرمال سازی
[۲۳، ۳۴، ۵۱]	Rescaling	
[۲۶، ۴۶]	Min-max normalization	
[۲۸]	The method was not explained	
[۲۱]	Skull-stripping	اصلاح تصاویر
[۲۵]	Shifting	
[۲۶، ۴۷]	Resizing	
[۴۳، ۳۴]	Rescaling	
[۳۴]	Padding	
[۲۲، ۲۸]	Format conversion	
[۲۵]	Eliminating outliers and noise	
[۲۰، ۲۸، ۳۴، ۴۹]	Cropping	
[۲۶]	Contrast enhancement	
[۸، ۱۶، ۲۰، ۲۴، ۲۶، ۲۸، ۳۳، ۳۷، ۳۹، ۴۲-۴۴، ۴۶، ۴۸، ۵۳]*	Skull-stripping, Resampling, Interpolation, Co-registration **	
[۸، ۱۶، ۱۹، ۲۰، ۲۲، ۲۴-۲۶، ۳۴، ۳۶، ۳۷، ۴۳، ۴۶-۴۸]	Flipping(horizontal and vertical), Random flipping, Random axes flipping, Flipping around the x-axis	افزون سازی داده ها
[۱۶، ۱۹-۲۴، ۳۳، ۳۴، ۳۶، ۴۵-۴۷]	Rotating, Random rotation	
[۲۳، ۳۴، ۳۶]	Scaling(horizontal and vertical), Random scaling	
[۲۰، ۲۲، ۳۴]	Zooming	
[۲۱، ۲۳، ۳۴]	Translation(horizontal and vertical)	
[۲۲، ۲۸، ۴۷]	Adding noise(salt, pepper,	

	blur)	
	Elastic transformation	[۲۴,۸]
	Shear	[۲۴,۲۰]
	Mirroring images, Right/left mirroring	[۲۳,۴۷]
	Reflection	[۲۸,۲۱]
	Padding	[۱۶]
	Resizing	[۲۱]
	Histogram equalization	[۲۲]
	Random Gaussian noise	[۳۷]
	Random distortion	[۴۶]
	B-spline transformation	[۲۵]
	Shifting	[۲۰]
	Brightness	[۲۰]
	Elastic distortion	[۲۰]
	Elastic deformation	[۲۸]
	Data augmentation	[۲۶, ۳۳]
	Focal loss	[۵۱]
	Generalized dice loss function	[۲۹]
	Multi-class dice loss function	[۳۷]
	Over-sampling minority class	[۴۸]
ایجاد توازن در مجموعه تصاویر	SMOTE algorithm	[۳۹]
	Soft dice coefficient loss	[۲۰]
	Under-sampling majority class	[۲۹, ۳۹]
	Up-sampling minority class	[۳۹]
	Weighted cross-entropy loss	[۲۴]
	Weighted dice loss	[۴۹]
	Weighted loss function	[۳۴]

\*در این مقاله‌ها از مجموعه تصاویر عمومی BraTs استفاده کرده اند که روش‌های \*\* از قبل روی تصاویر اعمال شده است.

جدول ۴: نتایج ارزیابی مقالات بر اساس مجموعه داده و مدل‌های بخش‌بندی یادگیری عمیق

DSC			مجموعه داده	معماری مدل	منبع
ET	TC	WT			
-	-	۰/۸۴	TCIA	U-net	[۳۴]
۰/۷۵	۰/۸۳	۰/۸۸	BraTS 2018	3D U-net	[۳۹]
-	-	۰/۸۲	BraTS 2019	Modified U-Net	[۲۴]
-	-	۰/۸۴۵۹	BraTS 2017- LGG	Modified U-Net	[۴۰]
-	-	۰/۸۹۷۶	BraTS 2017-HGG		
-	-	۰/۸۷۱۷	BraTS 2017		
-	-	۰/۸۸۵۳	BraTS 2018	3D U-net	[۱۶]
۰/۷۸۱۶	۰/۸۱۵۲	۰/۸۹۱۹	BRATS 2017, 2018, Syrian Lebanese hospital, Brasilia	AlbuNet3D (pretr.)	[۲۸]
۰/۷۶۳۱	۰/۸۰۷۲	۰/۸۹۱۳		AlbuNet3D (no pretr.)	
۰/۷۴۴۹	۰/۷۹۶۹	۰/۸۸۸۸		AlbuNet2D (pretr.)	

۰/۷۴۳۷	۰/۷۷۷۶	۰/۸۷۷۴		AlbuNet2D (no pretr.)	
۰/۸	۰/۷۷	۰/۸۹	BRATS 2015	Cascaded DL-CNN	[۴۱]
۰/۷۳۶	۰/۷۳۳	۰/۸۹	BraTs 2015	Modified U-Net	[۴۲]
۰/۶۴۲	۰/۷۶۳	۰/۸۷۶	BraTs 2017		
۰/۷۹۴۶	۰/۸۳۰۴	۰/۹۱۱۴	BRATS 2018	Ensemble of 3D U-Nets	[۴۳]
۰/۸۱	۰/۷۴	۰/۸۶	Brats 2015	SK-TPCNN	[۶]
۰/۸۷	۰/۸	۰/۸۹		SK-TPCNN + RF	
۰/۷۳۲	۰/۷۹۷	۰/۸۹۶	BraTS 2018 ,TCIA	3D U-net	[۳۶]
۰/۷۸۵۹	۰/۸۳۷۸	۰/۹۰۵	BraTS 2017	Cascaded FCNN	[۴۴]
۰/۸۰۵۲	۰/۸۴۹۴	۰/۹۰۴۴	BraTS 2018	3D CNN	[۳۷]
۰/۶۲	۰/۷۲	۰/۸۴	BRATS 2015	3D CNN based on U-net	[۳۹]
۰/۷۳	۰/۷۶	۰/۸۱	BRATS 2015	Cascaded CNN	[۴۵]
-	-	۰/۸۹۳	BRATS 2015	3D CNN	[۲۷]
۰/۸۳	۰/۸۹	۰/۹۲	BraTS 2019	3D-U-Net	[۴۶]
۰/۸۳	۰/۸۹	۰/۹۲		NAS-3D-U-Net	
۰/۷۸۴	۰/۸۴۴	۰/۹۰۸	BraTS 2018	Cascaded modified U-Net	[۲۵]
۰/۷۵	۰/۶۵	۰/۷۸	BraTS 2015-challenge		[۳۳]
۰/۶۲	۰/۷۲	۰/۸۴	BRATS 2013-leaderboard	NAS CNN	
۰/۷۷	۰/۸۳	۰/۸۸	BRATS 2013-challenge		
۰/۸	۰/۸۳	۰/۹۱	BRATS 2018	U-net	[۴۸]
۰/۹۱۵۲	۰/۹۹۸۱	۰/۹۶۷	BRATS 2019	Modified U-net, VGG16	[۲۰]
۷۶/۸۸	۸۱/۵۶	۸۹/۳۸	BraTS 2019	3D DMF-Net	[۴۹]
۰/۷۱	۰/۷۴	۰/۸۴	BraTS 2019	Modified U-Net	[۵۰]
۰/۵۸۱	۰/۶۸۱	۰/۸۵۲	BRATS 2015	DCSNN	[۵۱]
۰/۵۷	۰/۷۱	۰/۸۴	BRATS 2013	DNNs	[۸]
۰/۸۳	۰/۸۲	۰/۸۴	BRATS 2013, BRATS 2015	DCNN- LN	[۵۲]
۰/۸۹	۰/۸۳	۰/۸۲		DCNN- TPN	
۰/۸۹	۰/۸۷	۰/۸۳		DCNN- TLinear	
۰/۹	۰/۸۶	۰/۷۹		DCNN- IN	
۰/۹	۰/۸۷	۰/۸۶		DCNN- ILinear	
۰/۸۷۳۲	۰/۹۴۳۹	۰/۹۴۰۱	BraTS 2015	RescueNet	[۵۳]
۰/۹۳۵۴	۰/۸۵۶	۰/۹۴۶۳	BraTS 2017		

جدول ۵: نتایج ارزیابی مقالات بر اساس مجموعه داده‌ها و مدل درجه‌بندی یادگیری عمیق

منبع	معماری مدل	دسته‌ها	مجموعه داده	صحت	دقت	حساسیت	ویژگی
[۳۴]	Transfer Learning(VGG-16)	HGG, LGG	TCIA	۰/۹۵۰۰	-	۰/۹۳۰۰	۰/۹۸۰۰
[۱۶]	CNN	HGG, LGG	TCIA	۰/۹۱۲۵	-	۰/۹۱۱۸	۰/۹۱۳۰
			Ghent University Hospital	۰/۹۱۹۶	-	۰/۹۰۴۸	۰/۹۳۸۸
[۱۴]			BraTS 2013	۰/۹۹۴۳	۱/۰۰۰۰	۰/۹۸۳۹	۱/۰۰۰۰
			BraTS 2014	۰/۹۵۳۸	۰/۹۹۳۵	۰/۷۱۹۶	۰/۹۹۹۱
			BraTS 2015	۰/۹۹۷۸	۱/۰۰۰۰	۰/۹۹۱۹	۱/۰۰۰۰
			BraTS 2016	۰/۹۵۶۹	۰/۸۹۰۴	۰/۹۷۵۵	۰/۹۴۹۱
			BraTS 2017	۰/۹۷۷۸	۰/۹۷۲۰	۰/۹۷۸۹	۰/۹۷۷
			ISLES 2015	۰/۹۲۲۷	۱/۰۰۰۰	۰/۸۸۱۴	۱/۰۰۰۰
[۲۱]	Wndchrm tool	Grade I, Grade II, Grade III, Grade IV	Government Medical College, Calicut, India	۰/۹۲۸۶	۰/۹۲۸۹	۰/۹۱۷۵	۰/۹۷۴۸
	Transfer Learning(VGG-19)			۰/۹۴۶۴	۰/۹۴۷۱	۰/۹۲۷۲	۰/۹۸۱۳
[۲۲]	Transfer Learning(AlexNet)			۰/۸۵۵۰	-	-	-
	Transfer Learning (GoogLeNet)		Tangdu Hospital, Fourth Military Medical University ,China	۰/۹۰۹۰	-	-	-
	pre-trained AlexNet			۰/۹۲۷۰	-	-	-
	pre-trained (GoogLeNet)			۰/۹۴۵۰	-	-	-
[۳۶]	CNN(2D Mask R-CNN)		BraTS 2018, TCIA	۰/۹۶۳۰	-	۰/۹۳۵۰	۰/۹۷۲۰
	CNN(3DConvNet)			۰/۹۷۱۰	-	۰/۹۴۷۰	۰/۹۶۸۰
[۱۵]	stacked sparse auto encoder (SSAE)		BraTS2012	۱/۰۰۰۰	۱/۰۰۰۰	۱/۰۰۰۰	۱/۰۰۰۰
			BraTS2012 Synthetic	۰/۹۰۰۰	۱/۰۰۰۰	۰/۸۸۰۰	۱/۰۰۰۰
			BraTS2013	۰/۹۵۰۰	۰/۹۳۰۰	۱/۰۰۰۰	۰/۹۰۰۰
		tumor, non-tumor	BraTS2013 Leaderboard	۱/۰۰۰۰	۱/۰۰۰۰	۱/۰۰۰۰	۱/۰۰۰۰
			BraTS2014	۰/۹۷۰۰	۰/۹۸۰۰	۰/۹۸۰۰	۰/۹۶۰۰
			BraTS2015	۰/۹۵۰۰	۱/۰۰۰۰	۰/۹۳۰۰	۱/۰۰۰۰
[۱۹]	Multistream CNN		BraTS 2017	۰/۹۰۸۷	-	-	-
[۲۶]	3D CNN		BraTS 2018	۰/۹۶۴۹	-	-	-
[۴۷]	2D CNN	Grade II, Grade III, Grade IV	TCIA	۰/۹۸۷۰	-	-	-
[۲۳]	CNN	Normal, Grade II, Grade III, Grade IV	IXI, TCIA, Hazrate Rasool General Hospital, Tehran, Iran	۰/۹۰۹۰	-	-	-

زمینه کسب کرده است. انتشار صعودی مقاله‌ها در خصوص استفاده از این روش‌ها در تصاویر رادیولوژی، تمایل بسیار زیاد پژوهشگران به این حوزه را نشان می‌دهد. روش‌های یادگیری عمیق به رادیولوژیست‌ها کمک می‌کند تا تشخیص دقیق‌تری داشته باشند [۱۸، ۱۷]. یافته‌های این مطالعه نیز نشان می‌دهد که روند استفاده از روش‌های یادگیری عمیق در تحلیل تصاویر پزشکی به خصوص در زمینه تومور مغزی رو به افزایش است (نمودار ۱).

بخش‌بندی، دسته‌بندی و آشکارسازی تومور مغزی، فرآیندهایی هستند که برای ایجاد روش‌های کمک کامپیوتری برای تشخیص تومور مغزی روی تصاویر MRI مورد استفاده قرار می‌گیرند [۷]. فرآیند بخش‌بندی تومور مغزی گلیوما برای مشخص نمودن محل قرارگیری و تقسیم‌بندی نواحی مختلف تومور به سه زیر ناحیه اصلی شامل تومور کامل (Whole Tumor Core (TC) و منطقه پیشرفت تومور (Enhancing Tumor Region (ET، WT (Tumor Core) هسته تومور و منطقه پیشرفت تومور) فرآیند درجه‌بندی برای دسته‌بندی تومور مغزی گلیوما به دو نوع LGG (شامل دو زیر درجه ۱ و ۲) و HGG (شامل دو زیر درجه ۳ و ۴)، می‌باشد. فرآیند آشکارسازی، برای تشخیص تومور مغزی گلیوما در تصاویر و دسته‌بندی آن به دو بخش سالم یا دارای تومور مغزی گلیوما، است. بخش‌بندی تومور یکی از حوزه‌هایی است که جامعه پزشکی توجه بیشتری به آن داشته‌اند [۱۷]. یافته‌های این مطالعه نیز نشان می‌دهد که اغلب تحقیقات در حوزه بخش‌بندی تومور انجام شده است، در حالی که درجه‌بندی تومور و آشکارسازی آن کمتر مورد توجه قرار گرفته است.

در نهایت پس از بررسی مطالعه‌ها یک خط‌مشی مشترک شامل پیش‌پردازش، طراحی مدل و ارزیابی نتایج مدل، به دست آمد. همچنین قبل از انجام مراحل مذکور لازم است مجموعه تصاویر و زیرساخت‌های سخت‌افزاری و نرم‌افزاری لازم، فراهم باشد.

#### مجموعه داده‌ها

به دلیل سهولت دسترسی به مجموعه تصاویر عمومی پزشکی، پژوهشگران تمایل بیشتری به استفاده از آن‌ها در توسعه مدل دارند. یافته‌های این مطالعه نیز نشان می‌دهد که اغلب مطالعه‌ها از مجموعه تصاویر عمومی استفاده نموده‌اند. لازم به ذکر است که برخی از ویرایش‌های لازم روی تصاویر مجموعه داده‌های عمومی توسط منتشرکنندگان آن انجام شده است و

در اکثر مطالعات جهت ارائه مدل برای بخش‌بندی و دسته‌بندی گلیوما از CNN (۳۱ مقاله) استفاده شده است. برای بخش‌بندی، بیشتر از مدل U-Net یا مبتنی بر مدل U-Net (۱۴ مقاله) استفاده شده و از روش‌های یادگیری انتقال و مدل‌های از پیش تعریف شده و آموزش دیده (۴ مقاله) بیشتر برای دسته‌بندی و از شبکه‌های خود رمزنگار (۱ مقاله) برای آشکارسازی استفاده شده است.

برای ارزیابی کمی بخش‌بندی تومور مغزی گلیوما در نواحی مختلف آن، از معیار (Dice Similarity Coefficient) DSC (۲۶ مقاله)، از معیارهای حساسیت و ویژگی (۱۴ مقاله)، از معیار Hausdorff distance (HD) (۱۱ مقاله)، از معیار Jaccard score (۳ مقاله)، از معیار (Intersection over Union) (۱ مقاله) و از معیار صحت و Error rate - Score F (۱ مقاله) استفاده کرده‌اند (جدول ۴). برای ارزیابی کمی دسته‌بندی گلیوما برای درجه‌های مختلف آن، از معیار صحت (۱۱ مقاله)، از معیارهای حساسیت و ویژگی (۶ مقاله)، از معیار دقت (۳ مقاله) و در مطالعه‌های Amin و همکاران [۱۵، ۱۴] از معیارهای (False Positive Rate (FNR، (Negative Rate False Positive) (DSC JSI (Jaccard similarity index) FPR (Rate False Positive) (AUC (The area under the ROC Curve) و در مطالعه Decuyper و Van Holen از Matthews MCC (Correlation Coefficient) استفاده کرده‌اند [۱۶، ۱۵] (جدول ۵).

#### بحث و نتیجه‌گیری

##### تومور مغزی گلیوما

تشخیص تومور مغزی گلیوما، یکی از زمینه‌های مورد توجه پژوهشگران است [۷]. معمولاً روش‌های تشخیص تومور مغزی، تهاجمی، زمان‌بر و پرهزینه هستند؛ بنابراین لازم است روش‌های غیرتهاجمی، مقرون به صرفه و کارآمد توسعه داده شوند. یکی از روش‌های تشخیص سریع، امن و غیرتهاجمی، استفاده از تصاویر MRI است. تحلیل تصاویر MRI فرآیندی سخت و برخی اوقات همراه با خطا است؛ بنابراین نیاز به روش‌های تحلیل تصاویر با سرعت و دقت بیشتر است؛ زیرا تشخیص زود هنگام و دقیق تومور مغزی منجر به بهبود نتایج درمان و افزایش طول عمر بیماران می‌شود [۱۷، ۹]. اخیراً روش‌های یادگیری عمیق نتایج قابل قبولی را در این

یکی از چالش‌ها در تصاویر پزشکی عدم توافق در انتخاب بهترین روش نرمال‌سازی است. تصاویر پزشکی با مدالیته‌ها، توالی‌ها و از اسکنرهای مختلف که دارای نوع داده و بازه شدت تصویر متفاوت هستند، جمع‌آوری می‌شوند که این امر باعث می‌شود روش‌های نرمال‌سازی شدت تصویر تصاویر پزشکی پیچیده‌تر از سایر تصاویر باشد. نرمال‌سازی تصاویر عمدتاً برای بهینه‌سازی شبکه‌های عصبی مفید هستند [۳۰]. اکثر مطالعه‌ها از روش نرمال‌سازی Z استفاده کرده‌اند و این مسئله توافق در انتخاب این روش برای نرمال‌سازی تصاویر MRI مغزی را نشان می‌دهد.

یکی از روش‌های مهم پیش‌پردازش که در آموزش مدل‌های یادگیری عمیق مؤثر است روش‌های افزون‌سازی داده است [۳۱]. این روش‌ها باعث افزایش صحت روش‌های دسته‌بندی می‌شوند [۳۲]. از طرفی با افزایش داده‌ها از پیش‌برازش جلوگیری می‌کند [۲۴] و همچنین در مجموعه داده‌های نامتوازن به عنوان یکی از روش‌های ایجاد تعادل استفاده می‌شود [۳۳، ۲۶]. یافته‌ها نشان داد که اکثر مطالعه‌ها از روش‌های افزون‌سازی داده به ویژه Flipping و Rotating استفاده کرده‌اند. به طوری که اعمال این روش‌ها نتایج بهتری در خروجی مدل نشان داده است [۳۴، ۲۶].

#### مدل

انواع مدل‌های یادگیری عمیق شامل مدل‌های بدون نظارت مانند شبکه‌های عصبی خود‌رمنگار و شبکه‌های عصبی مولد، مدل‌های با نظارت مانند شبکه‌های عصبی بازگشتی و شبکه‌های عصبی کانولوشنی، کاربردهای متفاوتی دارند [۳۵]. یکی از کاربردهای CNN تحلیل تصاویر به ویژه تحلیل تصاویر پزشکی به منظور بخش‌بندی، دسته‌بندی و آشکارسازی است. از مزایای مهم CNN استخراج خودکار ویژگی‌های تصویر است برخلاف روش‌های سنتی یادگیری ماشین که استخراج ویژگی‌ها به روش دستی انجام می‌شود [۳۶، ۳۲]. یافته‌های این مطالعه نشان می‌دهد که در همه مطالعه‌ها، مدل‌ها بر مبنای CNN توسعه داده شده‌اند به غیر از مطالعه Amin و همکاران [۱۵] که شبکه عصبی خود‌رمنگار برای آشکارسازی را به کار برده است. برخی از پژوهش‌ها برای بخش‌بندی تومور از مدل U-Net و یا با اعمال تغییراتی در این مدل از آن استفاده کرده‌اند. معماری U-net بر پایه CNN است که هدف اصلی آن بخش‌بندی تصاویر پزشکی است [۲۷].

همین امر موجب می‌گردد پژوهشگران زمان کمتری را برای پیش‌پردازش تصاویر صرف نمایند و تمرکز بیشتری در توسعه مدل داشته باشند.

اکثر مطالعه‌ها از توالی‌های T1، T2، T1ce و FLAIR به طور هم‌زمان استفاده کرده‌اند. استفاده از توالی‌های مختلف MRI، اطلاعات با جزئیات بیشتری درباره بافت مغز فراهم می‌کند [۱۴]. همچنین چندین توالی نسبت به توالی منفرد کارایی بهتری را نتیجه می‌دهد [۱۹]. از طرفی برای سرعت بخشیدن به آموزش مدل، به جای استفاده از تمامی توالی‌های MRI، می‌توان از یک یا برخی از آن‌ها استفاده نمود [۲۰]. به خصوص زمانی که تصاویر از بیمارستان و یا مراکز دانشگاهی جمع‌آوری می‌شوند [۲۱-۲۳]. در مطالعه‌ای فقط از توالی FLAIR استفاده شده است به سبب این که این توالی در تومور مغزی وخیم و برای جراحی تومور مغزی گلوبوما با درجه LGG مورد توجه است [۲۴].

بر اساس یافته‌های مطالعه حاضر، استفاده از تصاویر دوبعدی کمی بیشتر از تصاویر سه‌بعدی است. یکی از دلایل انتخاب تصاویر دوبعدی، کوچک بودن مجموعه تصاویر برای آموزش است که منجر به بیش‌برازش می‌شود؛ بنابراین با کاهش بعد تصاویر و استفاده از برش‌های تصاویر دوبعدی از تصاویر سه‌بعدی که باعث بزرگ شدن دیتاست می‌شود، توانسته‌اند این مسئله را تا حدودی کاهش دهند [۱۹]. همچنین استفاده از تصاویر سه‌بعدی در شبکه‌های سه‌بعدی نیاز به GPU memory برای نگاشت ویژگی‌های سه‌بعدی و بخش‌بندی تومور مغزی دارد که باعث افزایش هزینه محاسباتی می‌شود [۱۶، ۴]. اگرچه تصاویر دوبعدی پیچیدگی مدل را کاهش می‌دهد؛ اما در عین حال باعث افزایش آربیبی در ارزیابی نتایج خواهد شد [۲۵]. همچنین شبکه‌های عصبی کانولوشنی دوبعدی، اطلاعات حجمی را مورد بررسی قرار نمی‌دهند در حالی که شبکه‌های عصبی کانولوشنی سه‌بعدی، تمام اطلاعات مکانی حجمی را برای یکی کردن اطلاعات متنی جزئی و کلی، بررسی می‌کند [۲۶]. در برخی شبکه‌های عصبی کانولوشنی دوبعدی کیفیت تصویر دوبعدی فشرده شده در طی پردازش، تقلیل پیدا می‌کند که باعث عدم دقت در بخش‌بندی تومور می‌شود [۲۷]. درحالی‌که با گسترش یک مدل دوبعدی به سه‌بعدی می‌توان نتایج بهتری به دست آورد و کارایی مدل را افزایش داد [۲۸، ۲۹].

#### پیش‌پردازش

GPUها، کتابخانه‌های منبع باز یادگیری عمیق مانند TensorFlow، Torch، Caffe، Theano به کاربر این امکان را می‌دهد که به طور مستقیم روی GPU برنامه‌نویسی کند. همه این کتابخانه‌ها (Programming Application Interface) در زبان‌های مختلف برنامه‌نویسی دارند که معروف‌ترین آن‌ها python است [۱۸] که در اکثر پژوهش‌ها، از آن استفاده شده است.

در این مطالعه پژوهش‌های مرتبط با تشخیص تومور مغزی گلیوما با استفاده از تصاویر MRI توسط روش‌های یادگیری عمیق، به صورت نظام‌مند بررسی شد. پس از اعمال معیارهای لازم، در نهایت ۳۵ مقاله برای بررسی نهایی انتخاب شد. پس از مطالعه دقیق و تحلیل نتایج حاصل از آن، یک خط‌مشی مشترک به دست آمد، بدین ترتیب که پس از جمع‌آوری مجموعه تصاویر، اولین مرحله، پیش‌پردازش تصاویر است که با توجه به خصوصیات و توالی‌های مختلف تصاویر MRI، روش‌های لازم و مرتبط روی تصاویر اعمال می‌گردد. در مرحله بعد مدل شبکه با توجه به یکی از رویکردهای بخش‌بندی، دسته‌بندی و یا آشکارسازی تومور طراحی گردید و تصاویر آماده شده از مرحله قبل مستقیماً وارد مدل شدند. در مرحله نهایی نتایج مدل ارزیابی شد. خروجی مدل با توجه به رویکرد انتخاب شده متفاوت خواهد بود. در بخش‌بندی، تومور به بخش‌های مختلف آن تقسیم شده و هر بخش برچسب متناظر با نوع ضایعه گرفت. در دسته‌بندی، تومور در درجه‌های مختلف آن دسته‌بندی و در آشکارسازی، تصاویر در دو دسته سالم و حاوی تومور دسته‌بندی شدند.

### تشکر و قدردانی

این مطالعه حاصل تحقیقی مستقل است که به عنوان بخشی از پایان‌نامه دکترای تخصصی در رشته مدیریت فناوری اطلاعات در دانشگاه آزاد اسلامی واحد علوم، تحقیقات و فناوری تهران و بدون حمایت هیچ سازمانی انجام شد.

### تعارض منافع

بدین‌وسیله نویسندگان تصریح می‌نمایند که هیچ‌گونه تضاد منافی در خصوص مطالعه حاضر وجود ندارد.

تعدادی از پژوهش‌ها روش یادگیری انتقال به خصوص دسته‌بندی تصاویر را به کار برده‌اند. چالش مهم در تحلیل تصاویر پزشکی کمبود تعداد تصاویر در آموزش مدل است. روش یادگیری انتقال با استفاده از مدل‌های از پیش آموزش دیده با مجموعه داده‌های بسیار حجیم، راه‌حلی برای رفع این مشکل می‌باشد. همچنین این روش عدم تطابق توزیع داده‌ها را بین داده‌های آموزش و آزمون کاهش می‌دهد که علت اصلی دقت پایین در روش‌های سنتی یادگیری ماشین است [۲۲]. همچنین این روش باعث کاهش آزمون و خطا برای دستیابی به بهترین معماری مدل می‌شود. از جمله مدل‌های آموزش دیده می‌توان AlexNet، GoogleNet، MobileNet، VGGNet، ResNet، DenseNet، Xception، NASNet، U-Net، V-Net، DMFNet را نام برد [۱۸، ۲۴، ۳۷].

### ارزیابی نتایج مدل

نتایج مدل‌ها در جدول ۴ برای مدل‌های بخش‌بندی و در جدول ۵ برای مدل‌های آشکارسازی و دسته‌بندی ذکر شده است. همه مدل‌ها نتایج تقریباً مشابه و قابل قبولی کسب کرده‌اند. در اکثر مدل‌های بخش‌بندی، معیار DSC برای سه ناحیه متفاوت تومور شامل TC، ET، WT به صورت جداگانه محاسبه شده است و مدل‌ها نتایج متفاوتی در نواحی مختلف به دست آورده‌اند. در اغلب مدل‌های آشکارسازی و دسته‌بندی از معیار صحت برای ارزیابی مدل استفاده شده است و در برخی موارد مدل بر روی مجموعه تصاویر مختلف نتایج متفاوتی کسب نموده است؛ بنابراین به طور قطعی نمی‌توان در مورد مدلی که بهترین نتیجه را کسب کرده است، نظر داد.

### زیرساخت

یافته‌ها حاکی از این است که اکثر پژوهش‌ها مدل‌هایشان را با GPU توسعه داده‌اند؛ زیرا GPUها توان محاسباتی را افزایش می‌دهند [۳۸] استفاده از یک (Central Processing Unit) CPU تک یا چند هسته‌ای و یا مجموعه‌ای از CPUها در محیط محاسباتی با کارایی بالا باعث می‌شود که در حالت اول زمان زیادی برای آموزش صرف شود و در حالت دوم نیاز به زیرساخت با هزینه بالا دارد. در صورتی که GPUها با قیمت مناسب‌تر، زمان کمتری را برای آموزش مدل‌های یادگیری عمیق صرف می‌کنند. علاوه بر کارایی بالای

## References

1. Işın A, Direkoğlu C, Şah M. Review of MRI-based brain tumor image segmentation using deep learning methods. *Procedia Computer Science* 2016;102:317-24. <https://doi.org/10.1016/j.procs.2016.09.407>
2. Van Meir EG, Hadjipanayis CG, Norden AD, Shu HK, Wen PY, Olson JJ. Exciting new advances in neuro-oncology: the avenue to a cure for malignant glioma. *CA Cancer J Clin* 2010;60(3):166-93. doi: 10.3322/caac.20069
3. Louis DN, Perry A, Reifenberger G, Von Deimling A, Figarella-Branger D, Cavenee WK, et al. The 2016 World Health Organization classification of tumors of the central nervous system: a summary. *Acta Neuropathol* 2016;131(6):803-20. doi: 10.1007/s00401-016-1545-1
4. Tabatabai G, Stupp R, Van Den Bent MJ, Hegi ME, Tonn JC, Wick W, et al. Molecular diagnostics of gliomas: the clinical perspective. *Acta Neuropathol* 2010;120(5):585-92. doi: 10.1007/s00401-010-0750-6
5. Coburger J, Merkel A, Scherer M, Schwartz F, Gessler F, Roder C, et al. Low-grade glioma surgery in intraoperative magnetic resonance imaging: results of a multicenter retrospective assessment of the German Study Group for Intraoperative Magnetic Resonance Imaging. *Neurosurgery* 2016;78(6):775-86. doi: 10.1227/NEU.0000000000001081
6. Yang T, Song J, Li L. A deep learning model integrating SK-TPCNN and random forests for brain tumor segmentation in MRI. *Biocybernetics and Biomedical Engineering* 2019;39(3):613-23.
7. Abd-Ellah MK, Awad AI, Khalaf AA, Hamed HF. A review on brain tumor diagnosis from MRI images: Practical implications, key achievements, and lessons learned. *Magn Reson Imaging* 2019;61:300-18. doi: 10.1016/j.mri.2019.05.028
8. Havaei M, Davy A, Warde-Farley D, Biard A, Courville A, Bengio Y, Pal C, Jodoin PM, Larochelle H. Brain tumor segmentation with deep neural networks. *Med Image Anal* 2017;35:18-31. doi: 10.1016/j.media.2016.05.004
9. Tandel GS, Biswas M, Kakde OG, Tiwari A, Suri HS, Turk M, et al. A review on a deep learning perspective in brain cancer classification. *Cancers* 2019;11(1):111. doi: 10.3390/cancers11010111
10. Razzak MI, Naz S, Zaib A. Deep learning for medical image processing: Overview, challenges and the future. *Classification in BioApps* 2018:323-50. doi:10.1007/978-3-319-65981-7\_12
11. Shen D, Wu G, Suk HI. Deep learning in medical image analysis. *Annu Rev Biomed Eng* 2017;19:221-48. doi: 10.1146/annurev-bioeng-071516-044442
12. Lotan E, Jain R, Razavian N, Fatterpekar GM, Lui YW. State of the art: machine learning applications in glioma imaging. *AJR Am J Roentgenol* 2019;212(1):26-37. doi: 10.2214/AJR.18.20218
13. Ebrahimighahnavieh MA, Luo S, Chiong R. Deep learning to detect Alzheimer's disease from neuroimaging: A systematic literature review. *Computer Methods and Programs in Biomedicine* 2020;187:105242. <https://doi.org/10.1016/j.cmpb.2019.105242>
14. Amin J, Sharif M, Anjum MA, Raza M, Bukhari SA. Convolutional neural network with batch normalization for glioma and stroke lesion detection using MRI. *Cognitive Systems Research* 2020;59:304-11. <https://doi.org/10.1016/j.cogsys.2019.10.002>
15. Amin J, Sharif M, Gul N, Raza M, Anjum MA, Nisar MW, Bukhari SA. Brain tumor detection by using stacked autoencoders in deep learning. *J Med Syst* 2019;44(2):32. doi: 10.1007/s10916-019-1483-2
16. Decuyper M, Van Holen R. Fully automatic binary glioma grading based on pre-therapy MRI using 3D convolutional neural networks. *arXiv preprint arXiv:1908.01506*. 2019.
17. Wadhwa A, Bhardwaj A, Verma VS. A review on brain tumor segmentation of MRI images. *Magn Reson Imaging* 2019;61:247-59.
18. Sahiner B, Pezeshk A, Hadjiiski LM, Wang X, Drukker K, Cha KH, et al. Deep learning in medical imaging and radiation therapy. *Med Phys* 2019;46(1):e1-e36.
19. Ge C, Gu IY, Jakola AS, Yang J. Deep learning and multi-sensor fusion for glioma classification using multistream 2D convolutional networks. *Annu Int Conf IEEE Eng Med Biol Soc* 2018;2018:5894-97.
20. Srinivas B, Sasibhushana Rao G. Segmentation of Multi-Modal MRI Brain Tumor Sub-Regions Using Deep Learning. *Journal of Electrical Engineering & Technology* 2020;15:1899-909.
21. KV AM, Rajendran VR. Glioma tumor grade identification using artificial intelligent techniques. *Journal of Medical Systems* 2019;43(5):1-2.
22. Yang Y, Yan LF, Zhang X, Han Y, Nan HY, Hu YC, et al. Glioma grading on conventional MR images: a deep learning study with transfer learning. *Front Neurosci*. 2018; 12: 804. doi: 10.3389/fnins.2018.00804
23. Anaraki AK, Ayati M, Kazemi F. Magnetic resonance imaging-based brain tumor grades classification and grading via convolutional neural networks and genetic algorithms. *Biocybernetics and Biomedical Engineering* 2019;39(1):63-74.
24. Zeineldin RA, Karar ME, Coburger J, Wirtz CR, Burgert O. DeepSeg: deep neural network framework for automatic brain tumor segmentation using magnetic resonance FLAIR images. *International Journal of Computer Assisted Radiology and Surgery* 2020;15(6):909-20.
25. Lachinov D, Vasiliev E, Turlapov V. Glioma Segmentation with Cascaded Unet. *arXiv:1810.04008*; 2018.
26. Mzoughi H, Njeh I, Wali A, Slima MB, BenHamida A, Mhiri C, Mahfoudhe KB. Deep multi-scale 3D convolutional neural network (CNN) for MRI gliomas brain tumor classification. *J Digit Imaging* 2020;33(4):903-15. doi: 10.1007/s10278-020-00347-9
27. Kumar GA, Sridevi PV. 3D deep learning for automatic brain MR tumor segmentation with T-spline intensity inhomogeneity correction. *Automatic Control and Computer Sciences* 2018;52(5):439-50.

28. Wacker J, Ladeira M, Nascimento JE. Transfer Learning for Brain Tumor Segmentation. arXiv preprint arXiv:1912.12452. 2019.
29. Sun J, Chen W, Peng S, Liu B. DRRNet: Dense residual refine networks for automatic brain tumor segmentation. *J Med Syst* 2019;43(7):221. doi: 10.1007/s10916-019-1358-6
30. Pérez-García F, Sparks R, Ourselin S. TorchIO: a Python library for efficient loading, preprocessing, augmentation and patch-based sampling of medical images in deep learning. arXiv preprint arXiv:2003.04696. 2020.
31. Hussain Z, Gimenez F, Yi D, Rubin D. Differential Data Augmentation Techniques for Medical Imaging Classification Tasks. *AMIA Annu Symp Proc* 2018;2017:979-84.
32. Perez L, Wang J. The effectiveness of data augmentation in image classification using deep learning. arXiv preprint arXiv:1712.04621. 2017.
33. Pereira S, Pinto A, Alves V, Silva CA. Brain tumor segmentation using convolutional neural networks in MRI images. *IEEE Trans Med Imaging* 2016;35(5):1240-51. doi: 10.1109/TMI.2016.2538465
34. Naser MA, Deen MJ. Brain tumor segmentation and grading of lower-grade glioma using deep learning in MRI images. *Computers in Biology and Medicine* 2020;121:103758.
35. Goodfellow I, Bengio Y, Courville A, Bengio Y. Deep learning. Cambridge: MIT Press; 2016.
36. Zhuge Y, Ning H, Mathen P, Cheng JY, Krauze AV, Camphausen K, Miller RW. Automated glioma grading on conventional MRI images using deep convolutional neural networks. *Med Phys* 2020;47(7):3044-53.
37. Sun L, Zhang S, Chen H, Luo L. Brain tumor segmentation and survival prediction using multimodal MRI scans with deep learning. *Front Neurosci.* 2019; 13: 810. doi: 10.3389/fnins.2019.00810
38. Lee JG, Jun S, Cho YW, Lee H, Kim GB, Seo JB, Kim N. Deep learning in medical imaging: general overview. *Korean J Radiol* 2017;18(4):570-84. doi: 10.3348/kjr.2017.18.4.570
39. Baid U, Talbar S, Rane S, et al. A Novel Approach for Fully Automatic Intra-Tumor Segmentation With 3D U-Net Architecture for Gliomas. *Front Comput Neurosci.* 2020;14:10. doi: 10.3389/fncom.2020.00010
40. Hasan SK, Linte CA. A modified U-Net convolutional network featuring a Nearest-neighbor Re-sampling-based Elastic-Transformation for brain tissue characterization and segmentation. *Proc IEEE West N Y Image Signal Process Workshop* 2018;2018:10.1109/WNYIPW.2018.8576421. doi: 10.1109/WNYIPW.2018.8576421
41. Cui S, Mao L, Jiang J, Liu C, Xiong S. Automatic semantic segmentation of brain gliomas from MRI images using a deep cascaded neural network. *J Healthc Eng* 2018;2018:4940593 doi: 10.1155/2018/4940593
42. Li H, Li A, Wang M. A novel end-to-end brain tumor segmentation method using improved fully convolutional networks. *Comput Biol Med* 2019;108:150-60. doi: 10.1016/j.compbiomed.2019.03.014
43. Feng X, Tustison NJ, Patel SH, Meyer CH. Brain tumor segmentation using an ensemble of 3d u-nets and overall survival prediction using radiomic features. *Front Comput Neurosci* 2020;14:25. doi: 10.3389/fncom.2020.00025
44. Wang G, Li W, Ourselin S, Vercauteren T. Automatic brain tumor segmentation using cascaded anisotropic convolutional neural networks. arXiv:1709.00382. doi: 10.1007/978-3-319-75238-9\_16
45. Khan H, Shah PM, Shah MA, ul Islam S, Rodrigues JJ. Cascading handcrafted features and convolutional neural network for IoT-enabled brain tumor segmentation. *Computer Communications* 2020;153:196-207. <https://doi.org/10.1016/j.comcom.2020.01.013>
46. Wang F, Biswal B. Neural architecture search for gliomas segmentation on multimodal magnetic resonance imaging. arXiv preprint arXiv:2005.06338. 2020.
47. Sultan HH, Salem NM, Al-Atabany W. Multi-classification of brain tumor images using deep neural network. *IEEE Access* 2019;7:69215-25. doi: 10.1109/ACCESS.2019.2919122
48. Wu S, Li H, Quang D, Guan Y. Three-Plane-assembled Deep Learning Segmentation of Gliomas. *Radiol Artif Intell* 2020; 2(2): e190011. doi: 10.1148/ryai.2020190011
49. Guo X, Yang C, Lam PL, Woo PY, Yuan Y. Domain Knowledge Based Brain Tumor Segmentation and Overall Survival Prediction. In book: *Brainlesion: Glioma, Multiple Sclerosis, Stroke and Traumatic Brain Injuries.* p. 285-95. doi:10.1007/978-3-030-46643-5\_28
50. Amian M, Soltaninejad M. Multi-Resolution 3D CNN for MRI Brain Tumor Segmentation and Survival Prediction. arXiv:1911.08388v1 2019.
51. Chen H, Qin Z, Ding Y, Tian L, Qin Z. Brain tumor segmentation with deep convolutional symmetric neural network. *Neurocomputing* 2020;392:305-13. doi: <https://doi.org/10.1016/j.neucom.2019.01.111>
52. Hussain S, Anwar SM, Majid M. Segmentation of glioma tumors in brain using deep convolutional neural network. *Neurocomputing* 2018;282:248-61. <https://doi.org/10.1016/j.neucom.2017.12.032>
53. Nema S, Dudhane A, Murala S, Naidu S. RescueNet: An unpaired GAN for brain tumor segmentation. *Biomedical Signal Processing and Control* 2020;55:101641. <https://doi.org/10.1016/j.bspc.2019.101641>

## Glioma Brain Tumor Identification Using Magnetic Resonance Imaging with Deep Learning Methods: A Systematic Review

Khazaei Zeinab<sup>1</sup>, Langarizadeh Mostafa<sup>2\*</sup>, Shiri Ahmad Abadi Mohammad Ebrahim<sup>3</sup>

• Received: 18 May 2021

• Accepted: 30 Jun 2021

**Introduction:** Glioma is one of the most common brain tumors, the early and accurate diagnosis of which leads to proper treatment and prolongs the patient's life. The studies conducted on glioma diagnosis using magnetic resonance imaging images with deep learning methods were reviewed and analyzed in this study.

**Method:** This study was a systematic review in which PubMed, ScienceDirect, Springer, IEEE, and Arxiv databases were searched between 2010 and 2020 in order to retrieve English language studies using keywords. Then, the articles were selected based on the inclusion and exclusion criteria and in line with the purpose of the research and the required information was extracted for review.

**Results:** Finally, 35 original research articles were selected. The review of the articles showed that they used a pipeline including collecting images, preprocessing, designing and implementing a model, and evaluating the results of the model for tumor detection, classification, and segmentation. The majority of the articles used public images and pre-trained models. In most articles, Dice similarity coefficient and accuracy criteria were used in segmentation and classification, respectively, as model evaluation criteria.

**Conclusion:** The results of this study revealed that in most articles, segmentation received more attention in comparison with detection and classification. Therefore, it is suggested that more studies be carried out on detection and especially grading glioma for being utilized in medical diagnostic assistance systems.

**Keywords:** Deep Learning, Glioma Brain Tumor, Magnetic Resonance Imaging

• **Citation:** Khazaei Z, Langarizadeh M, Shiri Ahmad Abadi ME. Glioma Brain Tumor Identification Using Magnetic Resonance Imaging with Deep Learning Methods: A Systematic Review. *Journal of Health and Biomedical Informatics* 2021; 8(2): 218-33. [In Persian]

1. Ph.D. Candidate in Information Technology Management, Department of Information Technology Management, Faculty of Management and Economics, Science and Research Branch, Islamic Azad University, Tehran, Iran

2. Ph.D. in Medical Informatics, Associate Professor, Department of Health Information Management, School of Health Management and Information Sciences, Iran University of Medical Sciences, Tehran, Iran

3. Ph.D. in Artificial Intelligence, Assistant Professor, Department of Computer Science, Faculty of Mathematics and Computer Science, Amirkabir University of Technology, Tehran, Iran

\***Corresponding Author:** Mostafa Langarizadeh

**Address:** Department of Health Information Management, School of Health Management and Information Sciences, Iran University of Medical Sciences, Rashid Yasami St., Vali-e-Asr Ave., Tehran, Iran

• **Tel:** 009821-88794301

• **Email:** langarizadeh.m@iums.ac.ir