

## طبقه‌بندی و تعیین درجه‌ی تومورهای گلیومای مغز با استفاده از تصاویر تشدید مغناطیسی و الگوریتم‌های یادگیری ماشین

زهرا پاپی<sup>۱</sup>، ایرج عابدی<sup>۱</sup>، فاطمه دالوند<sup>۲</sup>، علیرضا عموحیدری<sup>۳</sup>

### مقاله پژوهشی

### چکیده

**مقدمه:** گلیوما، متداول‌ترین تومور مغزی اولیه در بزرگسالان است. قابلیت‌های فراوان یادگیری ماشین با استفاده از تصویربرداری تشدید مغناطیسی (Magnetic resonance imaging) MRI می‌تواند آن را به عنوان ابزاری کاربردی در تشخیص دقیق و به موقع تومورها برای کمک به پزشکان در زمینه‌های مختلف تشخیصی و درمانی تبدیل کند. هدف از این پژوهش، طبقه‌بندی و تعیین درجه‌ی تومورهای گلیوما با انواع الگوریتم‌های یادگیری به صورت خودکار می‌باشد.

**روش‌ها:** این یک مطالعه‌ی بنیادی- کاربردی است که بر روی تصاویر مولتی‌مدالیته MRI، ۲۸۵ بیمار مبتلا به تومور گلیوما از مجموعه‌ی داده‌ی چالش BraTS 2018 انجام شد. جهت طبقه‌بندی تومورهای گلیوما درجه بالا (HGG (High grade glioma) و درجه پایین (LGG (Low grade glioma)، ابتدا قطعه‌بندی با شبکه‌ی U-Net صورت گرفت، سپس طبقه‌بندی بر مبنای شبکه‌ی VGG16 برای تعیین درجه‌ی تومور به کار گرفته شد.

**یافته‌ها:** میانگین ضریب دایس (Dice) قطعه‌بند طراحی شده برای نواحی کل تومور، هسته‌ی تومور و ناحیه‌ی افزایش یافته به ترتیب ۰/۷۶، ۰/۷۰ و ۰/۷۱ به دست آمد. صحت طبقه‌بند پیشنهادی بر مبنای شبکه‌ی VGG 16 به منظور تعیین درجه‌ی تومور در دو گروه HGG و LGG، ۹۹/۰۱ درصد حاصل شد.

**نتیجه‌گیری:** با استفاده از روش‌های یادگیری ماشین، می‌توان درجه‌ی تومور گلیوما را بدون استفاده از روش‌های تهاجمی همانند نمونه‌برداری مشخص و نرخ بقای این بیماران و کیفیت زندگی آن‌ها را بهبود بخشید.

**واژگان کلیدی:** یادگیری ماشین؛ قطعه‌بندی؛ طبقه‌بندی؛ گلیوما؛ تصاویر تشدید مغناطیسی

**ارجاع:** پاپی زهرا، عابدی ایرج، دالوند فاطمه، عموحیدری علیرضا. طبقه‌بندی و تعیین درجه‌ی تومورهای گلیومای مغز با استفاده از تصاویر تشدید

مغناطیسی و الگوریتم‌های یادگیری ماشین. مجله دانشکده پزشکی اصفهان ۱۴۰۱؛ ۴۰ (۶۶۵): ۱۹۳-۱۸۸

گسترش تومور به بافت‌های سالم اطراف، همچنین طبقه‌بندی دقیق‌تر به منظور تعیین درجه‌ی تومور را فراهم سازد.

Deen و Naser با هدف طبقه‌بندی خودکار تومورهای LGG (Low grade glioma)، از روش‌های پردازش تصویر و شبکه‌های عصبی بهره جستند. آن‌ها توانستند به دقت خوبی در تعیین درجه‌ی تومورهای LGG دست یابند (۴).

در مطالعه‌ی دیگری، Kollerathu و همکاران، با هدف طبقه‌بندی تومورهای HGG (High grade glioma) و LGG شبکه‌ی عصبی ResNet-50 را در مجموعه‌ی داده‌ی BraTS2017 به کار بردند (۵).

### مقدمه

گلیوماها، ۳۰ درصد تومورهای مغزی اولیه و ۸۰ درصد تومورهای بدخیم مغز را شامل می‌شوند (۱). تصویربرداری تشدید مغناطیسی (Magnetic resonance imaging) MRI، روش ارجح برای تشخیص تومورهای مغزی است (۲). با توجه به دسترسی فراوان به تصاویر پزشکی، می‌توان تکنیک‌های مختلف یادگیری را برای تجزیه و تحلیل این داده‌ها به کار گرفت. در حال حاضر، روش رایج جهت تعیین محل، شکل و اندازه‌ی تومور در تصاویر پزشکی، قطعه‌بندی دستی می‌باشد (۳). قطعه‌بندی تومور مغزی، می‌تواند امکان بررسی


۱- گروه فیزیک پزشکی، دانشکده‌ی پزشکی، دانشگاه علوم پزشکی اصفهان، اصفهان، ایران

۲- کارشناسی ارشد، مهندسی پرتو پزشکی، دانشگاه شهید بهشتی، تهران، ایران

۳- بخش رادیوتراپی، بیمارستان میلاد اصفهان، اصفهان، ایران

نویسنده‌ی مسؤول: ایرج عابدی؛ گروه فیزیک پزشکی، دانشکده‌ی پزشکی، دانشگاه علوم پزشکی اصفهان، اصفهان، ایران

انتهایی انجام شد. سپس، تصاویر هر مدالیته با کم کردن میانگین از شدت هر پیکسل و تقسیم بر انحراف معیار در هر برش نرمال‌سازی گردید. برای افزایش داده‌های آموزش و یادگیری بهتر، شبکه‌ی داده‌افزایی با روش مبتنی بر تکه (Patch-based) صورت گرفت. بنابراین، از هر برش تصویر چهار تکه حاوی تومور با اندازه‌ی  $16 \times 16$  به صورت تصادفی استخراج شد (شکل ۱).



شکل ۱. معماری U-Net ارائه شده برای طبقه‌بندی گلیوما

معماری و آموزش شبکه‌ی طبقه‌بندی: در این مقاله، طبقه‌بندی تومور گلیوما بر اساس اصلاح شبکه‌ی U-Net مشهور Ronneberger و همکاران آماده‌سازی گردید (۸). شمایی از شبکه‌ی طراحی شده، در شکل ۱ ترسیم شده است. این شبکه شامل مسیر رمزگذاری و رمزگشایی متقارن می‌باشد. هر کدام از مسیرها شامل پنج بلوک کانولوشنی است تا تقارن در هر دو مسیر حفظ شود. در مسیر رمزگذاری، هر بلوک دارای دو لایه‌ی کانولوشنی با ابعاد فیلتر  $3 \times 3$ ، طول گام یک و تابع فعال‌سازی Relu می‌باشد. در انتهای هر یک از چهار بلوک اول لایه حداکثر تجمع (Max-pooling) با ابعاد فیلتر و طول گام  $2 \times 2$  اعمال شده است. در مسیر رمزگشایی به منظور افزایش ابعاد نقشه‌ی ویژگی (Feature map) هر بلوک با یک لایه‌ی Up-convolutional با ابعاد فیلتر  $2 \times 2$  و طول گام دو، آغاز و با یک لایه‌ی اتصال مطابق با نقشه‌ی ویژگی آن در مسیر رمزگذاری و همچنین دو لایه‌ی کانولوشنی با ابعاد فیلتر  $3 \times 3$  دنبال می‌شود. در انتهای آخرین بلوک، یک لایه‌ی کانولوشنی با ابعاد  $1 \times 1$  به کار رفته است. لایه‌ی حذف تصادفی به منظور جلوگیری از بیش‌برازش و لایه‌گذاری مشابه (Same padding) به منظور حفظ ابعاد خروجی مشابه ورودی استفاده شد. جهت طراحی شبکه، از تابع هزینه‌ی هیبرید ارائه شده در مطالعه‌ی Kermi و همکاران استفاده گردید (۹).

Rehman و همکاران در پژوهشی، از شبکه‌های عصبی مختلف Alex net، Google net و VGG net برای طبقه‌بندی انواع متفاوت تومور مغزی شامل گلیوما، مننژیوما و هیپوفیز استفاده نمودند. شبکه‌ی VGG16 در تعیین نوع تومور به بالاترین صحت با مقدار  $98/69$  دست یافتند (۶).

هدف از مطالعه‌ی حاضر، ارائه‌ی روشی خودکار با استفاده از شبکه‌ی U-Net جهت طبقه‌بندی تومور و تعیین درجه‌ی تومور با استفاده از شبکه‌ی VGG16 و با استفاده‌ی مستقیم از تصاویر مولتی‌مدالیته MRI می‌باشد.

## روش‌ها

این مطالعه از نوع بنیادی-کاربردی می‌باشد. داده‌های استفاده شده از یک مرجع معتبر داده‌ای به نام چالش طبقه‌بندی تومور مغزی (Brain tumor segmentation) استخراج شده‌اند. مجموعه داده‌ی مورد استفاده در پژوهش حاضر، مربوط به چالش BraTS 2018 شامل تصاویر مولتی‌مدالیته‌ی MRI، ۲۱۰ و ۷۵ بیمار HGG و LGG بود (۷). در مرحله‌ی نخست، به منظور طبقه‌بندی نواحی توموری پیش‌پردازش تصاویر و طراحی شبکه جهت آموزش و ارزیابی با معیارهای ضریب تشابه دایس (Dice similarity coefficient)، حساسیت، اختصاصیت و فاصله‌ی هوسدروف در داده‌های آزمون صورت گرفت. سپس، طبقه‌بندی به منظور تعیین درجه‌ی تومور HGG و LGG با پیش‌پردازش مجدد تصاویر بر اساس یافته‌های مرحله‌ی طبقه‌بندی و طراحی شبکه جهت آموزش و ارزیابی با معیارهای صحت (Accuracy)، حساسیت، اختصاصیت، دقت موارد پیش‌بینی مثبت و منفی انجام شد. هر کدام از مراحل طبقه‌بندی و طبقه‌بندی در شبکه با بستر TensorFlow و کتابخانه‌ی کراس با استفاده از زبان برنامه‌نویسی پایتون (Python) نسخه‌ی ۳.۷.۲ پیاده‌سازی گردید. آموزش شبکه‌ها روی ابرکامپیوتر با ۵۶ هسته و پردازنده‌ی intel سری Xeon E5-2600 و پردازنده‌ی گرافیکی NVIDIA Tesla K80 از آزمایشگاه راهبردی فناوری‌های نوین در بازه‌ی زمانی آبان ماه سال ۱۳۹۹ تا خرداد ماه سال ۱۴۰۰ انجام شد. به طور مشخص، داده‌های آموزش در هر مرحله شامل ۶۰ درصد کل داده‌ها جهت یادگیری شبکه، ۲۰ درصد داده‌ها برای ارزیابی و تنظیم پارامترهای شبکه در طول فرایند یادگیری و در نهایت ۲۰ درصد داده‌های آزمون جهت ارزیابی نهایی به کار برده شد.

پیش‌پردازش داده‌ها در مرحله‌ی طبقه‌بندی: اندازه‌ی تصاویر در داده‌های BraTS2018،  $240 \times 240 \times 155$  می‌باشد. به منظور افزایش قدرت محاسباتی، کاهش ابعاد تصاویر به  $190 \times 190 \times 135$  با حذف مناطق حاشیه‌ی سیاه اطراف تصاویر و حذف برش‌های ابتدایی و



شکل ۲. معماری ارائه شده برای طبقه‌بندی گلیوماها

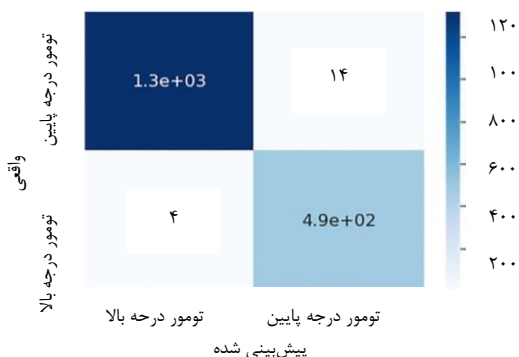
با نرخ یادگیری ۰/۰۰۱ و آنتروپی متقاطع دسته‌ای (Categorical cross entropy) به عنوان تابع هزینه استفاده شد. معیار مدل صحت، ساین دسته و تعداد دوره‌های اجرا به ترتیب ۱۶ و ۸ انتخاب شد.

این مطالعه با کد اخلاق در پژوهش (IR.MUI.MED.REC.1398.697) در دانشگاه علوم پزشکی اصفهان تأیید شده است.

### یافته‌ها

نتایج مربوط به قطعه‌بندی: نتایج مربوط به میانگین پارامترهای ضریب دایس (Dice)، حساسیت، اختصاصیت و فاصله‌ی هوسدروف برای نواحی مختلف تومور تعیین گردید. میانگین ضریب دایس (Dice) برای نواحی کل تومور، هسته‌ی تومور و افزایش یافته به ترتیب ۰/۷۶، ۰/۷۰، ۰/۷۱ و میانگین حساسیت برای این نواحی به ترتیب ۰/۹۱، ۰/۸۰، ۰/۸۶ به دست آمد. میانگین اختصاصیت برای نواحی مختلف یکسان و ۰/۹۹ برآورد شد. فاصله‌ی هوسدروف برای کل تومور ۸/۸۲ این فاصله در ناحیه‌ی هسته‌ی تومور و افزایش یافته به ترتیب ۴/۴۳ و ۷/۲۰ به دست آمد.

نتایج مربوط به طبقه‌بندی: نتایج «ماتریس درهم‌ریختگی» (Confusion matrix) از داده‌های آزمون در شکل ۳ آمده است. این نتایج عملکرد طبقه‌بند را نشان می‌دهد.



شکل ۳. نتایج ماتریکس درهم ریختگی

آموزش مدل با انتخاب تصادفی ۲۲۰ بیمار LGG، HGG از مجموعه‌ی داده‌ی BraTS 2018 صورت گرفت. سپس، از هر برش تصویر، چهار تکه حاوی تومور با اندازه‌ی ۱۶۰×۱۶۰×۱۶۰ به عنوان ورودی به شبکه داده شد. با توجه به تعداد ۱۳۵ برش برای هر مدالیت، ۱۱۸۸۰۰ تصویر برای آموزش انتخاب گردید. برای آموزش مدل، دسته (Batch) با اندازه‌ی ۱۶، تعداد دوره‌های اجرا پنج و الگوریتم بهینه‌ساز گرادیان تصادفی کاهشی (Stochastic gradient descent) انتخاب گردید. نرخ یادگیری اولیه، تکانه و ضریب فروپاشی به ترتیب ۰/۰۰۱، ۰/۹، ۰/۰۱ تنظیم شد.

پیش‌پردازش داده‌ها در مرحله‌ی طبقه‌بندی: در هر مدالیت، ۳۲ برش در ناحیه‌ی اطراف برش با بزرگترین اندازه‌ی تومور به منظور افزایش دقت و کم شدن بار محاسباتی استخراج شد. با بکارگیری نتایج حاصل از مرحله‌ی قطعه‌بندی تومور، پیکسل‌های حاوی مناطق تومور و پیکسل‌های غیرتوموری به ترتیب به عنوان پیکسل‌های اصلی و پیکسل‌های زمینه در نظر گرفته شد. سپس، شدت پیکسل‌های غیرتوموری در ۰/۲ ضرب گردید. آموزش شبکه‌ی طراحی شده با سه مدالیت‌ی تصویر با وزن FLAIR، T2W و TIWc به عنوان ۳ کانال ورودی صورت گرفت. با توجه به تعداد کمتر تصاویر LGG، داده‌افزایی بر روی تصاویر LGG با چرخش افقی آن‌ها انجام شد. تعداد برش‌های تصاویر جهت آموزش، ارزیابی و آزمون شبکه به ترتیب با ۶۸۹۰، ۹۱۲ و ۹۱۲ انتخاب گردید (شکل ۲).

معماری و آموزش شبکه‌ی طبقه‌بندی: روش یادگیری انتقالی بر مبنای شبکه‌ی VGG 16 (۱۰) به منظور طبقه‌بندی تومورهای HGG و LGG انتخاب گردید. دیاگرامی از شبکه‌ی طراحی شده در شکل ۲ ترسیم شده است. در به کارگیری شبکه‌ی VGG 16 به منظور طبقه‌بندی تومورهای گلیوما لایه‌های اولیه و میانی این شبکه به همان شکل باقی ماند. در ادامه، با جایگزینی یک لایه ادغام میانگین‌گیری کلی (Global average pooling)، یک لایه حذف تصادفی با فاکتور ۰/۷ و یک لایه متراکم با دو واحد به جای سه لایه‌ی تمام متصل شبکه‌ی VGG16 و همچنین، تابع فعال‌سازی سافت‌مکس در خروجی شبکه طبقه‌بند این مطالعه طراحی گردید. به منظور آموزش مدل از الگوریتم بهینه‌سازی (Stochastic gradient descent) SGD

به دقت بالای ۹۹/۰۱ در طبقه‌بندی HGG و LGG دست یافتیم. در این مطالعه، داده‌افزایی در مرحله‌ی قطعه‌بندی با استفاده از روش مبتنی بر تکه با استخراج چهار ناحیه‌ی تصادفی از هر برش تصویر و در مرحله‌ی طبقه‌بندی داده‌افزایی تنها با روش چرخش در داده‌های LGG انجام گردید. به کارگیری روش‌های دیگر داده‌افزایی منجر به افزایش تنوع داده‌ها جهت آموزش و کاهش خطاهای پیش‌بینی در داده‌های آزمون گردیده و با بهتر ساختن مدل در تعمیم، از واریانس مدل می‌کاهد. اما به کارگیری روش‌های دیگر داده‌افزایی، مستلزم زمان طولانی برای یادگیری شبکه و استفاده از GPU قدرتمندتر جهت تسریع فرایند یادگیری می‌باشد. در مطالعات آینده، از شبکه‌ی موجود برای قطعه‌بندی تومور و نواحی داخلی آن، همچنین طبقه‌بندی داده‌های بالینی بیماران مبتلا به تومور گلیوما، همچنین تومورهای دیگر استفاده خواهد شد. ارائه‌ی روش‌های خودکار قطعه‌بندی و طبقه‌بندی با استفاده‌ی مستقیم از تصاویر MRI، می‌تواند در قطعه‌بندی دقیق تومور، همچنین تشخیص غیرتهاجمی درجه‌ی تومور و درمان به موقع به پزشکان کمک‌کننده باشد.

### نتیجه‌گیری

در مطالعه‌ی حاضر، روشی خودکار جهت طبقه‌بندی تومورهای HGG و LGG بر مبنای تصاویر MRI بدون نیاز به نمونه‌برداری به روش تهاجمی استریوتاکتیک و صرف وقت ارائه گردید. طبقه‌بند طراحی شده بر مبنای شبکه‌ی از پیش آموزش دیده‌ی VGG 16، توانست تومورهای گلیوما HGG و LGG را با دقت بالای ۹۹/۰۱ درصد طبقه‌بندی کند.

### تشکر و قدردانی

این مقاله حاصل پایان‌نامه‌ی کارشناسی ارشد با شماره‌ی ۳۹۸۹۸۰ و کد اخلاق در پژوهش (IR.MUI.MED.REC.1398.697) در دانشگاه علوم پزشکی اصفهان می‌باشد. در پایان لازم است از معاونت محترم پژوهشی دانشگاه علوم پزشکی اصفهان، شبکه‌ی آزمایشگاهی فناوری‌های راهبردی، مراتب قدردانی صمیمانه خود را ابراز نماییم.

این ماتریس، اطلاعات ارزشمندی در مورد برجسب‌های واقعی و پیش‌بینی شده توسط طبقه‌بند را ارائه می‌دهد. در ارزیابی طبقه‌بند جهت تعیین درجه‌ی تومور در دو گروه HGG و LGG مقادیر پارامترهای صحت، حساسیت، اختصاصیت، دقت موارد پیش‌بینی مثبت و منفی در داده‌های آزمون به ترتیب ۹۹/۰۱، ۹۸/۹۴، ۹۹/۱۸، ۹۹/۶۹ و ۹۷/۲۰ درصد حاصل شد.

### بحث

در این مطالعه، یک الگوریتم جدید به منظور طبقه‌بندی خودکار تومورهای گلیوما در تصاویر MRI با استفاده از نتایج حاصل از مرحله‌ی قطعه‌بندی تومور معرفی شد.

در مطالعه‌ی Naser و Deen، مشابه مطالعه‌ی حاضر، از شبکه‌ی عصبی کانولوشنی بر مبنای U-Net و طبقه‌بندی بر مبنای شبکه‌ی VGG16؛ اما به منظور تعیین درجه LGG صورت گرفت. در مطالعه‌ی آن‌ها یک مرحله پیش‌پردازش قبل از قطعه‌بندی شامل حذف نواحی غیرضروری تومور و نرمال‌سازی انجام گردید. شبکه‌ی عصبی کانولوشنی بر مبنای U-Net شامل چهار بلوک کانولوشنی در قطعه‌بندی و با تغییر ۳ لایه‌ی آخر شبکه‌ی VGG16، به صورت لایه‌ی مسطح، حذف تصادفی با فاکتور ۰/۵ و لایه‌ی متراکم با یک واحد در تعیین درجه‌ی تومور LGG به کار بردند و دقت طبقه‌بندی ۰/۹۵ را گزارش کردند (۴).

در مطالعه‌ی Kollerathu و همکاران بدون مرحله‌ی قطعه‌بندی و با مرحله‌ی پیش‌پردازش شامل انتخاب برش با بزرگترین حجم تومور و انتخاب تنها دو برش بالایی و پایینی آن آموزش شبکه را انجام دادند. حساسیت، اختصاصیت، دقت این شبکه جهت طبقه‌بندی تومور به ترتیب ۹۰/۹، ۹۸/۲ و ۹۹/۴ درصد گزارش شد (۵).

با بررسی مطالعات دیگر، نتایج به دست آمده از آن‌ها و شبکه‌های از پیش آموزش دیده‌ی مختلف از شبکه‌ی VGG 16 در این مطالعه استفاده شد. سه لایه تمام متصل شبکه‌ی VGG16 را با یک لایه‌ی ادغام میانگین‌گیری کلی، یک لایه‌ی حذف تصادفی و یک لایه‌ی متراکم و تابع فعال‌سازی سافت‌مکس در خروجی مدل تنظیم و

### References

1. Goodenberger ML, Jenkins RB. Genetics of adult glioma. *Cancer Genet* 2012; 205(12): 613-21.
2. Işın A, Direkçoğlu C, Şah M. Review of MRI-based brain tumor image segmentation using deep learning methods. *Procedia Comput Sci* 2016;102: 317-24.
3. Bi WL, Hosny A, Schabath MB, Giger ML, Birkbak NJ, Mehrtash A, et al. Artificial intelligence in cancer imaging: clinical challenges and applications. *CA Cancer J Clin* 2019; 69(2): 127-57.
4. Naser MA, Deen MJ. Brain tumor segmentation and grading of lower-grade glioma using deep learning in MRI images. *Comput Biol Med* 2020; 121: 103758.
5. Kollerathu VA, Kesavadas C, Krishnamurthi G. A transfer learning based approach for automated grading of Gliomas using deep Residual Networks; 2018.
6. Rehman A, Naz S, Razzak MI, Akram F, Imran M. A deep learning-based framework for automatic brain

- tumors classification using transfer learning. *Circuits, Syst Signal Pro* 2020; 39(2): 757-75.
7. Bakas S, Reyes M, Jakab A, Bauer S, Rempfler M, Crimi A, et al. Identifying the best machine learning algorithms for brain tumor segmentation, progression assessment, and overall survival prediction in the BRATS challenge. arXiv preprint arXiv:181102629; 2018.
  8. Ronneberger O, Fischer P, Brox T. U-net: Convolutional networks for biomedical image segmentation. In: Navab N, Hornegger J, Wells W, Frangi A, editor. *Medical image computing and computer-assisted intervention – MICCAI*. Heidelberg, Germany: Springer; 2015.
  9. Kermi A, Mahmoudi I, Khadir MT. Deep convolutional neural networks using U-Net for automatic brain tumor segmentation in multimodal MRI volumes. In: Crimi A, Bakas S, Kuijf H, Keyvan F, Reyes M, van Walsum T, editor. *Brainlesion: Glioma, multiple sclerosis, stroke and traumatic brain injuries*. Heidelberg, Germany: Springer; 2018.
  10. Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition. arXiv preprint arXiv:14091556; 2014.

## Classification and Staging of Brain Glioma Tumors Using Magnetic Resonance Imaging and Machine Learning Algorithms

Zahra Papi<sup>1</sup>, Iraj Abedi<sup>1</sup>, Fatemeh Dalvand<sup>2</sup>, Alireza Amoheidari<sup>3</sup>

### Original Article

#### Abstract

**Background:** Glioma is the most common primary brain tumor in adults. Various machine learning tools via magnetic resonance imaging can make it a practical instrument in accurate and early diagnosis of tumors thereby assisting physicians in diverse diagnostic and therapeutic fields. The aim of this study is to automate the process of defining and determining the grade of glioma tumor with the use of a variety of learning algorithms.

**Methods:** This is a fundamental-applied study performed on multimodal MRI images of 285 patients with glioma tumors from the BraTS 2018 Challenge Database. In order to classify glioma tumors as high and low grade, first a was performed with U Net network for the definition purposes, then the results were incorporated for classification in VGG16 network to determine the exact grade of tumor.

**Findings:** The mean value of Dice Similarity Coefficient (DSC) for the classification designed for regions of the complete tumor, core of the tumor and the enhanced areas were 0.76, 0.70 and 0.71 respectively. The accuracy of the proposed classification based on VGG 16 network to determine the grade of tumor in both HGG and LGG groups was 99.01%.

**Conclusion:** Machine learning methods can be useful to determine the glioma tumor grade instead of using invasive procedures like biopsy which in turn improves overall survival rate of these patients and their quality of life.

**Keywords:** Machine learning; Segmentation; Classification; Glioma; Magnetic resonance imaging

**Citation:** Papi Z, Abedi I, Dalvand F, Amoheidari A. **Classification and Staging of Brain Glioma Tumors Using Magnetic Resonance Imaging and Machine Learning Algorithms.** J Isfahan Med Sch 2022; 40(665): 188-93.

1- Department of Medical Physics, School of Medicine, Isfahan University of Medical Sciences, Isfahan, Iran

2- MSc of Radiation Engineering, Shahid Beheshti University, Tehran, Iran

3- Department of Radiotherapy, Milad Hospital, Isfahan, Iran

**Corresponding Author:** Iraj Abedi, Department of Medical Physics, School of Medicine, Isfahan University of Medical Sciences, Isfahan, Iran; Email: i.abedi@med.mui.ac.ir