

بخش‌بندی ناحیه‌ی هدف درمانی در بیماران سرطانی گلیوما توسط یادگیری انتقالی

مریم هوشیاری آردکپان^۱، هادی اکبری زاده^۲، مهناز اتحاد توکل^۳، احمد شانه‌ی^۴

مقاله پژوهشی

چکیده

مقدمه: این مطالعه به منظور بررسی قدرت و کارایی یادگیری انتقالی در حل مشکل حجم داده‌های یادگیری عمیق به منظور بخش‌بندی خودکار ناحیه هدف درمانی در بیماران مبتلا به سرطان گلیوما انجام شده است.

روش‌ها: در این مطالعه از تصاویر T_1 ، T_2 و Flair، تعداد ۱۰۰ عدد از بیمارانی که سرطان گلیومای آن‌ها مسجل شده بود، استفاده شد. تمامی تصاویر پس از بازمینی کیفی، نرمالیزه شدند و به سبب مشخص درآمدند. سپس تصاویر به یک مدل در دو حالت با و بدون یادگیری انتقالی داده شدند و عملکرد آن‌ها با میزان تشابه، همپوشانی، حساسیت و دقت مورد بررسی قرار گرفت.

یافته‌ها: نتایج مطالعه‌ی ما نشان می‌دهد که یادگیری انتقالی می‌تواند باعث افزایش کارایی بخش‌بندی خودکار شده و در تصاویر Flair تا بیش از ۷۶ درصد تشابه در میزان بخش‌بندی خودکار با بخش‌بندی دستی شود. همچنین این روش در تصاویر T_2 که نتوانسته نتایج را بهبود بخشد، سرعت رسیدن به نتیجه مطلوب را افزایش داده است.

نتیجه‌گیری: یادگیری عمیق در بخش‌بندی خودکار می‌تواند بر محدودیت‌های ناشی از حجم داده در بیماران گلیوما غلبه کند و عملکرد آن‌ها را بهبود ببخشد.

واژگان کلیدی: یادگیری ماشین؛ طراحی درمان رادیوتراپی؛ گلیوما

ارجاع: هوشیاری آردکپان مریم، اکبری زاده هادی، اتحاد توکل مهناز، شانه‌ی احمد. بخش‌بندی ناحیه‌ی هدف درمانی در بیماران سرطانی گلیوما توسط

یادگیری انتقالی. مجله دانشکده پزشکی اصفهان ۱۴۰۲؛ ۴۱ (۷۰۸): ۹۶-۱۰۱

مقدمه

سرطان مغز، از علل اصلی مرگ و میر و معلولیت در سراسر جهان به شمار می‌رود، به گونه‌ای که بیش از ۱۴ میلیون مورد جدید از این نوع سرطان و بیش از ۸ میلیون مرگ را فقط در سال ۲۰۱۲ منجر شده که گلیوما، شایع‌ترین این نوع سرطان است (۱). در بعضی از انواع این نوع سرطان، به دلیل ماهیت تهاجمی بودن، درمان بسیار چالش‌برانگیز شده و باعث پیش‌آگهی ضعیف با بقای ۵ ساله در حدود ۵ درصد می‌شود (۲). پرتودرمانی و رادیوجراحی از جمله تکنیک‌های موجود برای درمان سرطان مغز به شمار می‌آیند. از آن‌جا که هر دو روش شامل انتقال دوز بسیار بالایی از اشعه است، تعیین دقیق تومور و

همچنین بافت‌های سالم اطراف بسیار با اهمیت می‌شود (۳).

یکی از خسته‌کننده‌ترین و وقت‌گیرترین کارها در برنامه‌ریزی رادیوتراپی، بخش‌بندی هدف و اندام در معرض خطر (Organ at risk) OAR است. این کار هنوز به صورت دستی و به صورت برش به برش انجام می‌شود. بنابراین انکولوژیست‌ها، فیزیست‌ها و سایر متخصصان پزشکی، بخش قابل توجهی از وقت خود را صرف بخش‌بندی این تصاویر پزشکی می‌کنند (۴). علاوه بر این، به دلیل خطاهای انسانی و همچنین اصول مختلف درمانی در پزشکان، معمولاً مشاهده می‌شود که بخش‌بندی دستی با تنوع گسترده‌ای و یکنواختی کم در بین متخصصین مختلف همراه می‌شود (۴). طراحی درمان در

۱- دانشجوی کارشناسی ارشد، گروه فیزیک پزشکی، دانشکده‌ی پزشکی، دانشگاه علوم پزشکی اصفهان، اصفهان، ایران

۲- دانشجوی دکترای فیزیک پزشکی، گروه فیزیک پزشکی، دانشکده‌ی پزشکی، دانشگاه علوم پزشکی مشهد، مشهد، ایران

۳- استادیار، گروه فیزیک پزشکی، دانشکده‌ی پزشکی، دانشگاه علوم پزشکی اصفهان، اصفهان، ایران

۴- استاد، گروه فیزیک پزشکی، دانشکده‌ی پزشکی، دانشگاه علوم پزشکی اصفهان، اصفهان، ایران

نویسنده‌ی مسؤول: احمد شانه‌ی؛ استاد، گروه فیزیک پزشکی، دانشکده‌ی پزشکی، دانشگاه علوم پزشکی اصفهان، اصفهان، ایران

وزن‌های T1، T2 و Flair بودند. این بیماران شامل ۵۶ عدد بیمار گلیوما با گرید بالا و ۴۴ عدد بیمار با گرید پایین می‌باشند. تمامی تصاویر مورد مطالعه، مورد بازبینی قرار گرفتند و تصاویری که کیفیت نامناسب داشتند از مطالعه حذف شدند. علاوه بر این، مقادیر پیکسل‌ها به یک نرمالیزه شده و اندازه‌ی تمامی تصاویر به 240×240 تبدیل شدند.

بخش بندی دستی: رسم نواحی تومور بیماران توسط یک فیزیست و آنکولوژیست پرتودرمانی (هر دو با بیش از ۱۰ سال تجربه) به صورت جداگانه انجام شد و در صورت عدم توافق در رسم بخش بندی‌های رسم شده، نظر متخصص سوم (با بیش از ۲۰ سال تجربه) گرفته شده است.

معماری شبکه‌ی عصبی کانولوشنی با استفاده از یادگیری انتقالی:

در این مطالعه از یک شبکه‌ی U-Net که یک شبکه‌ی رمزگذار-رمزگشا محبوب می‌باشد برای بخش بندی استفاده شده است. این شبکه دارای دو مسیر انقباضی و انبساطی متقارن و نظیر هم می‌باشد که هر آنچه در مسیر انقباضی حذف شده، در مسیر انبساطی بازبازی می‌شود. از این شبکه به طور گسترده در زمینه‌های بخش بندی استفاده می‌شود (۱۰، ۱۱). مسیر انقباضی شبکه‌ی ما با استفاده از معماری شبکه VGG-16 ساخته شده و ۵ قسمت رمزگذار این شبکه به شبکه‌ی مطالعه‌ی ما انتقال داده شده است. برای آموزش شبکه VGG-16 بیش از ۱۶ میلیون تصویر استفاده شده که این شبکه یکی از قدرتمندترین شبکه‌ها در کلاس بندی تصاویر می‌باشد. قسمت انبساطی شبکه‌ی ما نیز متناسب با قسمت انقباضی با ۵ رمزگشا ساخته شده است. در هر رمزگذار و رمزگشا، چند لایه کانولوشن با یک هسته کانولوشن 3×3 برای استخراج ویژگی تصویر استفاده گردید. شکل ۱، نمایی از ساختار شبکه را نشان می‌دهد.

ارزیابی مدل: در این مطالعه، یک بار مدل بدون استفاده از یادگیری انتقالی آموزش داده شده و سپس تحت شرایط یکسان با یادگیری انتقالی مورد آموزش قرار گرفت. تصاویر این مطالعه به ۵ قسمت تقسیم شدند که سه قسمت آن‌ها برای آموزش، یک قسمت برای اعتبارسنجی و یک قسمت برای تست مدل به کار گرفته شد. در این مطالعه حداکثر از ۳۰ دور با قابلیت توقف آموزش به شرط عدم تغییر در معیار تعیین شده برای داده‌های اعتبارسنجی در ۱۰ دوره استفاده شده است. نرخ یادگیری مدل 0.0001 و تصاویر با دسته‌های کوچک ۱۶ عددی برای آموزش استفاده شدند. پس از آموزش اول مدل یادگیری انتقالی، لایه‌های غیرقابل یادگیری مدل تغییر وضعیت داده شدند و مدل مجدد آموزش داده شد. برای ارزیابی عملکرد مدل، کمیت‌های Dice، IOU، حساسیت و دقت (Precision) استفاده شد. این کمیت‌ها بر اساس روابط ۴-۱ و بر اساس تعداد مثبت واقعی و کاذب و منفی واقعی و کاذب محاسبه می‌شوند (۱۲).

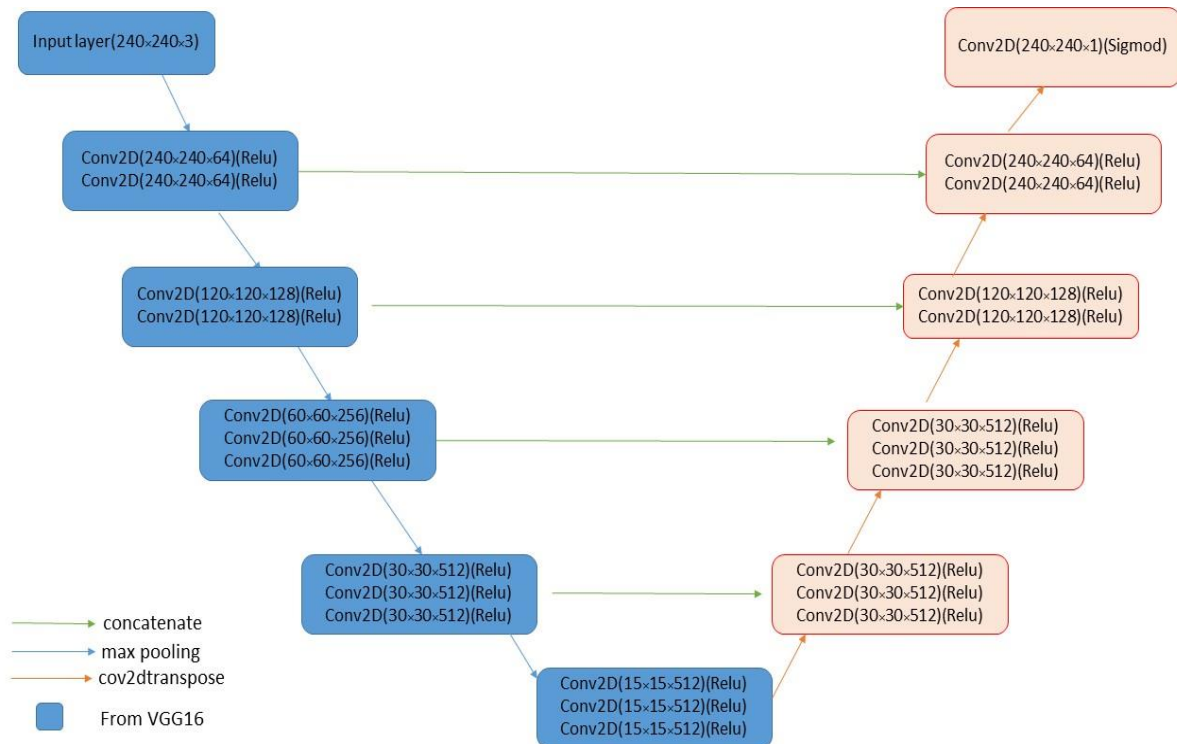
رادیوتراپی بر روی تصاویر سی‌تی انجام می‌گیرد ولی به دلیل کنتراست کم این مدالیته تصویربرداری، از توالی‌های تصویربرداری رزونانس مغناطیسی (MRI (Magnetic resonance imaging) به صورت روتین برای بخش بندی دقیق استفاده می‌شود. با خودکارسازی این فرایند، امکان دستیابی به بخش بندی‌هایی که به راحتی قابلیت تکرارپذیری دارند و مورد توافق اکثر متخصصان آنکولوژی است فراهم می‌شود. به علاوه، هر روشی که بتواند زمان انجام این مراحل را کاهش دهد، می‌تواند به روند درمان سرعت ببخشد و باعث پذیرش بیشتر و درمان بیماران بیشتری شود و یا با کاهش بار کاری بر عهده‌ی کادر درمانی (از جمله آنکولوژیست و فیزیست) منجر به استفاده‌ی مؤثرتر از مهارت‌های آن‌ها شود که در نهایت باعث افزایش کیفیت درمان خواهد شد (۵).

یادگیری عمیق، شاخه‌ای از یادگیری ماشین و هوش مصنوعی است که در سال‌های اخیر در زمینه‌های مختلفی از علوم، موفقیت‌های چشمگیری داشته است. این روش به منظور آموزش به ماشین، برای دستیابی به عملکردی معادل با عملکرد انسان در بعضی از وظایف انجام می‌گیرد، تا بتوان با افزایش سرعت، خودکار انجام شدن و تکرارپذیری، قدرت انجام آن عمل و یا وظیفه را افزایش داد (۶-۹). یکی از مهم‌ترین ویژگی‌های یادگیری عمیق، نیاز به داده‌های زیاد برای آموزش ماشین می‌باشد. با این حال، این مهم همیشه در دسترس نیست و در مواقعی که تعداد داده‌های در دسترس برای آموزش کم باشد از روش‌های یادگیری انتقالی و افزایش داده استفاده می‌کنند. یادگیری انتقالی، استفاده از دانش یک مدل از پیش آموزش دیده در یک مسأله‌ی متفاوت است. در این روش به جای شروع پروسه‌ی آموزش از صفر، از الگوهای بدست آمده در مسأله‌ای مشابه استفاده می‌شود و وزن‌هایی آموزش دیده و به دست آمده در شبکه، اول به شبکه داده می‌شود و شروع به ایجاد تغییرات در آن وزن‌ها می‌کند.

یکی از مهم‌ترین موانع مهم در پیشرفت علوم، یادگیری عمیق در شبکه‌های عصبی، کمبود داده‌های برجسب‌دار برای آموزش آن‌ها می‌باشد. با وجود تعداد زیاد مطالعات در این حوزه، مطالعات بسیار اندکی به بررسی روش و قدرت یادگیری انتقالی در بخش بندی خودکار پرداخته‌اند که با توجه به اهمیت این مسأله بخصوص در سرطان گلیوما، هدف از این مطالعه، بررسی اثر یادگیری انتقالی در بخش بندی خودکار گسترده‌ی حجم تومور گلیوما می‌باشد.

روش‌ها

جمع‌آوری تصاویر و آماده‌سازی آن‌ها: در این مطالعه از تصاویر ام‌آرآی ۱۰۰ بیماری که ابتلا به سرطان گلیوما در سوابق پزشکی آن‌ها (بیوپسی آن‌ها) ثبت شده بود استفاده شده است. تصاویر نیز شامل توالی‌هایی با



شکل ۱. نمایی از شبکه‌ی مورد استفاده در مطالعه

یافته‌ها

جدول ۱، نتایج عملکرد مدل با و بدون یادگیری انتقالی را در وزن‌های مختلف تصاویر نشان می‌دهد. همانطور که از این جدول می‌توان دریافت، در وزن‌های T_1 و Flair یادگیری انتقالی به طور چشمگیری عملکرد مدل را بهبود بخشیده است، به گونه‌ای که در تصاویر Falir می‌توان شاهد افزایش بیش از ۷۵ درصدی ضریب تشابه ماسک‌های پیش‌بینی شده توسط مدل با یادگیری انتقالی شد و برای این منظور، تصاویر با وزن Flair بهتر عمل می‌کنند. این بهبود در دیگر کمیت‌های مورد ارزیابی نیز مشاهده می‌شود. شکل ۲ نمونه ماسک‌های پیش‌بینی شده توسط مدل را در وزن Flair را نشان می‌دهد. با این حال، یادگیری انتقالی در تصاویر با وزن T_2 تفاوت معنی‌داری ایجاد نمی‌کند و تنها منجر به این می‌شود که در دوره‌های کوتاه‌تری به نتیجه مطلوب رسید.

کمیت Dice معیاری برای تشابه بین دو مجموعه داده، IOU معیاری برای سنجش میزان همپوشانی بخش‌بندی مدل و بخش‌بندی دستی است. دقت نیز معیاری برای سنجش میزان درست بودن و کسل‌های پیش‌بینی شده توسط مدل و حساسیت نسبت و کسل‌های درست پیش‌بینی شده به کل و کسل‌های درست اولیه می‌باشد.

$$\text{Dice coefficient} = \frac{2TP}{2TP+FN+FP} \quad \text{رابطه ۱}$$

$$\text{IOU} = \frac{TP}{TP+FP+FN} \quad \text{رابطه ۲}$$

$$\text{Sensitivity} = \frac{TP}{TP+FN} \quad \text{رابطه ۳}$$

$$\text{Precision} = \frac{TP}{TP+FP} \quad \text{رابطه ۴}$$

جدول ۱. مقایسه‌ی عملکرد مدل با و بدون یادگیری انتقالی در تصاویر با وزن‌های مختلف بر روی داده‌های تست (درصد)

حالت مدل	Flair		T_2		T_1		وزن تصاویر
	با یادگیری انتقالی	مدل ساده	با یادگیری انتقالی	مدل ساده	با یادگیری انتقالی	مدل ساده	
	۷۶/۴۸	۱/۰۷	۶۶/۴۲	۶۴/۷۷	۵۷/۷۴	۲/۳۵	Dice coefficient
	۶۵/۴۷	۱/۰۶	۵۶/۲۶	۵۴/۲۲	۴۵/۶۴	۲/۳۵	IOU
	۸۶/۸۴	صفر	۷۵/۹۸	۷۵/۵۰	۶۷/۸۷	صفر	Sensitivity
	۹۱/۸۰	صفر	۹۲/۸۷	۹۲/۳۰	۸۴/۳۳	صفر	Precision

می‌باشد به گونه‌ای که مدل‌های آموزش دیده با این روش می‌توانند تا ۷۵ درصد بهبود عملکرد داشته باشند و در مواردی هم که این روش نتوانسته نتایج را بهبود ببخشد، سرعت رسیدن به نتیجه‌ی مطلوب را افزایش داده است و از بین توالی‌های مختلف، تصاویر با وزن **Flair** عملکرد بهتری خواهند داشت. نتایج **Tian** و همکاران نیز مؤید این مطلب بود (۱۱). آن‌ها در مطالعه‌ی خود ابتدا مدل را برای بخش‌بندی خودکار هیپوکام آموزش دادند و سپس از این مدل آموزش دیده در بخش‌بندی نواحی سرطانی بهره بردند که نتایج آن‌ها مؤید ضریب شباهت ۸۴ درصدی بین بخش‌بندی‌های پیش‌بینی شده توسط مدل با بخش‌بندی‌های دستی می‌باشد. این تفاوت نتایج می‌تواند به علت تفاوت ساختار مدل‌ها و تفاوت یادگیری انتقالی باشد.

نتایج مطالعه‌ی **Flannery** و همکاران نیز بر روی بخش‌بندی خودکار رباط صلیبی قدامی درمان شده، نشان داد که با کمک یادگیری انتقالی می‌توان به ضریب شباهت ۷۰ درصد در قیاس با بخش‌بندی دستی رسید (۱۲).


بر اساس جستجوی ما در منابع معتبر، مطالعات بیان شده تنها مطالعات موجود برای بررسی یادگیری انتقالی در حوزه‌ی بخش‌بندی خودکار بوده‌اند که آن‌ها نیز از مدل‌های نزدیک به مدل خود برای آموزش شبکه‌ی خودشان بهره برده‌اند. با این حال، ما در مطالعه‌ی خود برای اولین بار از شبکه‌ی **VGG-16** که یک شبکه‌ی دسته‌بندی تصاویر عمومی است، استفاده کرده‌ایم. بررسی مطالعات مختلف نشان داد که بیشتر آن‌ها، برای اهداف کلاس‌بندی از این دسته از شبکه‌ها استفاده می‌کنند و نتایج تمامی آن‌ها نیز، حاکی از افزایش کارایی کلاس‌بندی بوده است (۱۳-۱۵). بنابراین نتایج ما حاکی از آن بود که یادگیری انتقالی حتی با مدل‌های آموزش دیده با قصد‌های غیر نزدیک نیز می‌تواند عملکرد یادگیری عمیق را افزایش دهد.

نتیجه‌گیری

با توجه به قدرت و کارایی یادگیری انتقالی در بهبود عملکرد مدل‌های یادگیری عمیق برای بخش‌بندی خودکار، نتایج این مطالعه می‌تواند نویدبخش محققین باشد که با استفاده از یادگیری انتقالی می‌توانند بر مشکلات ناشی از کمبود داده در یادگیری عمیق غلبه کرده و از مزایای این روش استفاده کنند.

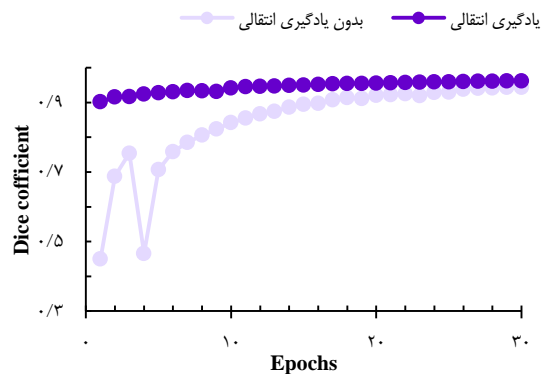
تشکر و قدردانی

این مقاله، حاصل از نتایج پایان‌نامه‌ی دوره‌ی کارشناسی ارشد با کد ۳۴۰۰۱۷۵ در دانشگاه علوم پزشکی اصفهان می‌باشد.



شکل ۲. نمایشی از ماسک پیش‌بینی شده توسط مدل آموزش دیده با یادگیری انتقالی در تصاویر با وزن **Flair**

شکل ۳ میزان تغییرات ضریب شباهت را در دوره‌های مختلف برای یادگیری ماشین در داده‌های آموزش در وزن T_2 را نشان می‌دهد و بیانگر آن است که یادگیری انتقالی باعث شده در همان دوره‌های ابتدایی، شبکه توانایی بیشتری در پیش‌بینی نتایج داشته باشد ولی برای حالت بدون یادگیری انتقالی نیاز به دوره‌های بیشتری بوده و حتی در دوره‌های ابتدایی نیز دچار اندکی نوسانات شده است.



شکل ۳. تغییرات **Dice coefficient** در دوره‌های مختلف در دو حالت با و بدون یادگیری انتقالی در تصاویر با وزن T_2

بحث

یکی از مهم‌ترین کارهای درمانی بیماران گلیوما، بخش‌بندی ناحیه‌ی سرطانی می‌باشد و از آنجایی که این کار نیازمند زمان قابل توجهی بوده و وابسته به تجربه‌ی کاری پزشک می‌باشد، خودکار کردن آن می‌تواند منجر به افزایش کارایی درمان این بیماران شود. یادگیری عمیق، شاخه از یادگیری ماشین است که قابلیت ایجاد انقلاب در رشته‌های دیگر را دارد. با این حال این روش نیازمند داده‌های بسیار برای آموزش بوده که یکی از راه‌های برون رفت از این مشکل استفاده از مدل‌های از پیش آموزش دیده و انتقال آن‌ها به مدل‌های خود است. نتایج مطالعه‌ی ما حاکی از اثبات قدرت یادگیری انتقالی در افزایش کارایی خودکار بخش‌بندی بیماران سرطانی گلیوما

References

1. Ilhan U, Ilhan A. Brain tumor segmentation based on a new threshold approach. *Procedia Comput Sci* 2017; 120: 580-7.
2. Tamimi AF, Juweid M. Epidemiology and outcome of glioblastoma. In: De Vleeschouwer S, Editor. *Glioblastoma*. Brisbane (AU): Codon Publications; 2017.
3. Mann J, Ramakrishna R, Magge R, Wernicke AG. Advances in radiotherapy for glioblastoma. *Front Neurol* 2018; 8: 748.
4. Deeley MA, Chen A, Datteri R, Noble JH, Cmelak AJ, Donnelly EF, et al. Comparison of manual and automatic segmentation methods for brain structures in the presence of space-occupying lesions: a multi-expert study. *Phys Med Biol* 2011; 56(14): 4557-77.
5. Meyer P, Noblet V, Mazzara C, Lallement A. Survey on deep learning for radiotherapy. *Comput Biol Med* 2018; 98: 126-46.
6. Christin S, Hervet É, Lecomte N. Applications for deep learning in ecology. *Methods Ecol Evol* 2019; 10(10): 1632-44.
7. Zhou L, Zhang C, Liu F, Qiu Z, He Y. Application of deep learning in food: a review. *Compr Rev Food Sci Food Saf* 2019; 18(6): 1793-811.
8. Khan S, Yairi T. A review on the application of deep learning in system health management. *Mech Syst Signal Process* 2018; 107: 241-65.
9. Ajmal H, Rehman S, Farooq U, Ain QU, Riaz F, Hassan A. Convolutional neural network based image segmentation: a review. In: Alam MS, Editor. *Pattern Recognition and tracking XXIX*. International Society for Optics and Photonics; 2018, Orlando, FL, United States. p. 106490N.
10. Isensee F, Jäger PF, Kohl SAA, Petersen J, Maier-Hein KH. Automated design of deep learning methods for biomedical image segmentation. *Nature Methods* 2020.
11. Tian S, Wang C, Zhang R, Dai Z, Jia L, Zhang W, et al. Transfer learning-based autosegmentation of primary tumor volumes of glioblastomas using preoperative MRI for radiotherapy treatment. *Front Oncol* 2022; 12: 856346.
12. Flannery SW, Kiapour AM, Edgar DJ, Murray MM, Beveridge JE, Fleming BC. A transfer learning approach for automatic segmentation of the surgically treated anterior cruciate ligament. *J Orthop Res* 2022; 40(1): 277-84.
13. Srinivas C, KS NP, Zakariah M, Alothaibi YA, Shaukat K, Partibane B, et al. Deep transfer learning approaches in performance analysis of brain tumor classification using MRI images. *J Healthc Eng* 2022; 2022: 3264367.
14. Ullah N, Khan JA, Khan MS, Khan W, Hassan I, Obayya M, et al. An Effective Approach to Detect and Identify Brain Tumors Using Transfer Learning. *Appl Sci* 2022; 12(11): 5645.
15. Amin J, Sharif M, Yasmin M, Saba T, Anjum MA, Fernandes SL. A new approach for brain tumor segmentation and classification based on score level fusion using transfer learning. *J Med Syst* 2019; 43(11): 326.

The Segmentation of Therapeutic Target Area in Glioma Cancer Patients by Transfer Learning

Maryam Hooshyari¹, Hadi Akbarizadeh², Mahanaz Etehadtavakol³, Ahmad Shanei⁴

Original Article

Abstract

Background: This study was conducted in order to investigate the power and efficiency of transfer learning in solving the problem of deep learning data volumes for automatic segmentation of the treatment target area in glioma cancer patients.

Methods: In this study, T₁, T₂ and Flair images of one hundred patients whose glioma cancer was confirmed were used. After quality review, all images were normalized and resized. Then the images were given to a model in two modes with and without transfer learning and their performance was evaluated with the degree of similarity, overlap, sensitivity and accuracy.

Findings: The results of our study show that transfer learning can increase the efficiency of automatic segmentation and increase the similarity of automatic segmentation with manual segmentation to more than 76% in Flair images. Also, this method has increased the speed of reaching the desired result in T₂ images that could not improve the results.

Conclusion: Deep learning in automatic segmentation can overcome the limitations caused by data volume in glioma patients and improve their performance.

Keywords: Machine learning; Radiotherapy planning; Glioma

Citation: Hooshyari M, Akbarizadeh H, Etehadtavakol M, Shanei A. **The Segmentation of Therapeutic Target Area in Glioma Cancer Patients by Transfer Learning.** J Isfahan Med Sch 2023; 41(708): 96-101.

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

2- PhD Student, Department of Medical Physics, School of Medicine, Mashhad University of Medical Sciences, Mashhad, Iran

3- Assistant Professor, Department of Medical Physics, School of Medicine, Isfahan University of Medical Sciences, Isfahan, Iran

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

Corresponding Author: Ahmad Shanei, Professor, Department of Medical Physics, School of Medicine, Isfahan University of Medical Sciences, Isfahan, Iran; Email: shanei@med.mui.ac.ir