

تشخیص تومورهای مغزی با استفاده از هوش مصنوعی و شبکه کانولوشنی از تصاویر MRI

عارفه عدنیان آرانی
کارشناسی
Arefehadnian82@gmail.com

سحر صابری منش
کارشناسی ارشد مهندسی پزشکی
saberimaneshsahar@gmail.com

چکیده - تومورهای سرطانی مغز انسان در دسته بیماری‌های خطرناک هستند که کیفیت زندگی انسان‌ها را تا سالیان دراز تحت تأثیر قرار می‌دهند و تشخیص آنها در مراحل اولیه، راه را برای درمان بسیار هموار می‌کند. هدف از این مقاله تشخیص هوشمند تومورهای مغزی با استفاده از یادگیری عمیق است. سیستم پیشنهادی شامل دو مرحله، استخراج ویژگی و طبقه‌بندی است. جهت استخراج ویژگی تصاویر، از یک شبکه کانولوشنی دوازده لایه استفاده شده است. در نهایت، جهت طبقه‌بندی ویژگی‌ها از تابع فعال‌ساز Softmax استفاده شده است. سیستم پیشنهادی بر روی پایگاه داده استاندارد و شامل سه کلاس گلیوما، مننژیوما و هیپوفیز اعمال شده است. پیاده‌سازی سیستم تشخیص روی پایگاه داده پیشنهادی، نشان‌دهنده برتری آن در مقایسه با روش‌های قبلی است. کلید واژه- تومور مغزی، تصاویر MRI، یادگیری عمیق، شبکه کانولوشنی دوبعدی

1. مقدمه

در نهایت جهت طبقه بندی از ماشین بردار پشتیبان (SVM) استفاده شد(3).

2. مواد و روش‌ها

در این مقاله پژوهشی مطالعات بر روی تصاویر سه نوع تومور مغزی استفاده شده است که از یک شبکه کانولوشنی عمیق دو بعدی استفاده می‌شود که در بخش‌های دوبعدی توضیحات کامل شبکه ارائه خواهد شد. پس از ارائه شبکه کانولوشنی عمیق، در بخش نهایی، روش مورد ارزیابی قرار می‌گیرد و پارامترهای دقت، حساسیت و اختصاصی محاسبه می‌شود.

2.1 دیتای ورودی

در روش پیشنهادی این مقاله به منظور تشخیص تومورهای مغزی از تصاویر MRI معمولی و استاندارد استفاده شده است. روش‌های تصویربرداری MRI دارای پروتکل‌های مختلفی هستند که معمولاً برای تحقیقات از پروتکل‌های T1، T2 و Flair استفاده می‌شود. به همین منظور از پایگاه داده استفاده شده که از تصاویر MRI با فرمت 1/5 تسلا هستند و در آن‌ها از پروتکل تصویربرداری MRI-T1 استفاده شده است. برای این تصاویر پایگاه داده از مرجع(4) استفاده شده است. در این تصویر شماره 1، سه تصویر از سه کلاس این پایگاه داده نمایش داده شده است. این پایگاه داده شامل تصاویر سه نوع کلاس مختلف مغزی در ابعاد ۵۱۲*۵۱۲ است که سه کلاس مربوط آن مربوط به تومورهای مننژیوما(۷۰۸ تصویر) گلیوما(۱۴۲۶ تصویر) و هیپوفیز(۹۳۰) تصویر است. ابعاد این تصاویر برای استفاده در روش پیشنهادی از ۵۱۲*۵۱۲ به ۱۲۸*۱۲۸ تغییر داده شده است(5).

رشد سلولی غیرعادی در هر بخش از بدن تومور نام دارد. تومورهای مغزی به دو نوع خوشخیم و بدخیم تقسیم می‌شوند. درواقع طرح درجه بندی تومورها که به طور گسترده استفاده می‌شود، توسط سازمان بهداشت جهانی صادر شده است (1). نرولوژیست‌ها نقش مهمی در ارزیابی تومورهای مغزی و درمان دارند. هنگامی که یک تومور مغزی از نظر بالینی تشخیص داده می‌شود نیاز به ارزیابی نرولوژیست برای تعیین موقعیت تومور و ارتباط آن با ساختارهای اطراف است. این اطلاعات بسیار مهم و حیاتی، برای انتخاب بهترین روش درمان از جمله جراحی و پرتودرمانی است، اما همواره پزشکان در تشخیص دقیق مکان به دلیل خستگی زیاد تصاویر با آرتیفکت بالا و سایر عوامل مشکل دارند. استفاده از سیستم‌های تشخیص پزشکی هوشمند در تشخیص بیماری‌های مغزی، به عنوان دستیاری در کنار پزشکان و رادیولوژیست‌ها علاوه بر کمک شایان به آنها، راه را برای شناسایی دقیق و عاری از خطا برای شناسایی و تفکیک این بیماری‌ها از سایر بیماری‌های مشابه، هموار می‌کند(2). در سالهای اخیر استفاده از سیستم‌های تشخیصی مبتنی بر یادگیری عمیق به دلیل کارایی بالای آن بسیار مورد استفاده قرار گرفته است. جهت تشخیص تومورهای سرطانی از تصاویر وزن دار T2 با استفاده از آستانه گیری اوتسو و روشهای طبقه بندی نظارتی شده ارائه شده است. جهت پیش پردازش تصاویر استفاده شده از روش‌های غیرهمگن استفاده شده است و در مرحله بعد بخش بندی تصاویر MRI با استفاده از آستانه گیری اوتسو انجام شده است. در گام بعد، روی تصاویر بخش بندی شده، تعدادی از روشهای استخراج ویژگی از قبیل تامورا LBP فیلترهای گابور GLCM و زرنیک اعمال شد سپس از روشهای استخراج ویژگی استفاده شد و دو نمونه برجسته از طریق اندازه گیری آنتروپی انتخاب شدند.

ماتریس فیلتر روی ارایه های پیکسل های تصویر قرار گرفته و ضرب می شوند. در نهایت حاصل تمام نقاط با یکدیگر جمع می شوند و به ازای هر قسمت فیلتر شده یک عدد بدست می آید. در مرحله بعد فیلتر یک واحد به سمت راست رفته و مجدد عملیات تکرار می شود. این عملیات تا زمانی پیش می رود که کل پیکسل های تصویر جارو شوند. در نهایت یک ماتریس جدید تولید می شود. این مقاله از ۳ لایه کانولوشنل با تابع فعالساز Relu که در هر لایه ۳۲ فیلتر با ابعاد ۳*۳ قرار دارد استفاده شده است (7).

2.4 لایه های کاهش اندازه


لایه های کاهش اندازه در فواصل معین و به صورت دوره ای در بین لایه های کانولوشن متوالی قرار دارند. قراردادن یک لایه pooling معمولاً بین چند لایه کانولوشنی پشت سرهم در یک معماری کانولوشنی امری بسیار رایج است (8) و از آن برای کاهش اندازه نگاشت ویژگی ها و پارامتر های شبکه می توان استفاده کرد. کارکرد این لایه کاهش اندازه مکانی تصویر به جهت کاهش تعداد پارامتر ها و محاسبات در داخل شبکه و بنابراین کنترل Overfit-ting است. رایج ترین شکل استفاده از این لایه به صورت استفاده این لایه با فیلتر هایی به اندازه و به صورت max pooling است (9).

2.5 Flatten لایه

این لایه یک لایه مهم است که بین لایه های استخراج ویژگی کانولوشنی و طبقه بندی خروجی قرار می گیرد. این لایه داده هایی که قصد ورود به مرحله طبقه بندی دارند را به بردار تبدیل می کند (10).

2.6 لایه های تمام متصل Dense


پس از لایه های کانولوشنی، لایه های آخر تمام متصل قرار دارند. لایه های تماماً متصل همانند همتایان خود در شبکه های عصبی مصنوعی سنتی عمل می کنند و تقریباً ۹۰ درصد پارامتر های یک شبکه کانولوشنی را شامل می شوند. لایه های تماماً متصل اجازه می دهند تا نتیجه شبکه را در قالب یک بردار با اندازه مشخص ارائه کنیم. ما می توانیم از این بردار برای دسته بندی تصاویر استفاده کنیم و یا اینکه از آن جهت ادامه پردازش های بعدی بهره ببریم (11) در این قسمت، از الگوریتم های طبقه بندی مختلفی استفاده می شود. اما در میان بیشتر از تابع فعال ساز softmax استفاده می شود. در ریاضیات تابع بیشینه هموار یا تابع نمایی نرمال سازی شده تعمیم تابع لجستیک است. این تابع یک بردار k بعدی از اعداد حقیقی مانند z را به عنوان ورودی دریافت می کند و بردار k بعدی از مقادیر حقیقی $(1/0)$ را به عنوان خروجی می دهد که جمع مولفه های آن ۱ می شود. سافت مکس با نام لجستیک رگرسیون چند جمله ای، عمدتاً در زمینه ریاضیات



شکل 1: تصویر به ترتیب از چپ به راست: تومور مننژیوما گیوما و تومور هیپوفیز

2.2 شبکه کانولوشنی پیشنهادی

آموزش شبکه در واقع حداقل کردن تابع خطا برحسب خروجی های واقعی شبکه در مقایسه با خروجی های مطلوب شبکه است. این کار از طریق اصلاح پارامترهای آزاد شبکه یعنی وزن ها و بایاس ها صورت می گیرد. روش آموزش مورد استفاده در ساختار پیشنهاد فعلی، روش آموزش همراه با ناظر است. در این روش یک سرپرست بر رفتار یادگیرنده نظارت می کند (6) و نحوه عملکرد صحیح را به او یادآور می شود. به بیان دیگر، سیستم یادگیرنده، مجموعه ای از زوج های داده متشکل از ورودی شبکه و خروجی مطلوب است. پس از اعمال ورودی شبکه، خروجی آن با خروجی مطلوب مقایسه شده و خطای یادگیری محاسبه و از آن برای اصلاح پارامتر شبکه به گونه ای استفاده می شود که اگر به طور مجدد به شبکه همان ورودی های داده شود، خروجی شبکه به خروجی مطلوب تر نزدیکتر وارد می شود. در این روش تصاویر به صورت دسته ای ۶۴ تایی به شبکه وارد می شود و با وجود اینکه نیازمند حافظه بالاتری است، اما پایداری بالاتری را خواهد داشت. معماری و روش پیشنهادی در تصویر شماره 2 نشان داده شده است و سپس در ادامه مهم ترین لایه این معماری به صورت خلاصه توضیح داده شده است.



شکل 2. شبکه کانولوشنی پیشنهادی

2.3 لایه های کانولوشنی

عملیات کانولوشن در تصویر بدین صورت است که فیلتر با سایز مورد نظر بر روی تصویر اصلی لغزانده می شود. بدین صورت که در هر لحظه ارایه های

عملکرد سیستم استفاده می شود. معیار دقت، بیان کننده تعداد (پیش بینی های صحیح انجام شده) توسط دسته بند، تقسیم بر، تعداد (کل پیش بینی های انجام شده) توسط همان دسته بند است (15).

1) معیار صحت، نسبت تعداد (پیش بینی های صحیح انجام شده) برای نمونه های یک کلاس خاص، به تعداد (کل پیش بینی ها) برای نمونه های همان کلاس خاص را (این تعداد، مجموع تمامی پیش بینی های صحیح و پیش بینی های نادرست را شامل می شود) ارزیابی میکند.

(فرمول شماره 1)


$$curacy = \frac{TP + TN}{TP + TN + FP + A}$$

2) معیار حساسیت، بیان کننده نسبت (تعداد داده های تصویری درست دسته بندی شده) در یک کلاس خاص، به تعداد کل داده هایی است که باید در همان کلاس خاص دسته بندی شوند.

(فرمول شماره 2)

$$Precision = \frac{TP}{TP + FP}$$

3) معیار امتیاز F1 پارامتر های دقت و حساسیت را با هم ترکیب می کند تا مشخص شود یک مدل دسته بند تا چه حد عملکرد خوبی از خود نشان می دهد.



(فرمول شماره 4)

$$F1 = 2 \times \frac{sensitivity \times Precision}{Sensitivity + Precision}$$

4. نتیجه گیری

مغز مهم ترین عضو بدن است که کنترل تمام قسمت های بدن را برعهده دارد. در صورت وجود بیماری در این قسمت از بدن، اختلال در سایر قسمت های بدن ممکن است ایجاد شود و گاهی این امر باعث مرگ فرد شود. در این پژوهش به منظور تشخیص و طبقه بندی تومور های مغزی، یک سیستم اتوماتیک بر مبنای یادگیری عمیق ارائه شد. به دلیل اینکه در روش

مخصوصا در تئوری احتمال و زمینه های مربوط به آن استفاده می شود. با این حال، طبقه بند softmax دارای یک مزیت منحصر به فرد در مقابله با بردارهای N بعدی است. در یادگیری عمیق برای طبقه بندی، بردار های استخراج شده، احتمال بردار استخراج شده را تعیین خواهد کرد و سپس طبقه بندی می کند. تابع فعال ساز softmax از طبقه بندی لجستیک رگرسیون در statistics گرفته شده است (12). ایده اصلی لجستیک رگرسیون استفاده از روش رگرسیون منطقی در طبقه بندی است که داده ورودی را قضاوت کرده و یک تک نتیجه گسسته خروجی می دهد (13). روش softmax فقط یک ایراد دارد و آن پیچیدگی محاسباتی بالاست. اما این مشکل با پیشرفت های سریع GPU حل شده است. با توجه به مزایای ذکر شده، در این مقاله در لایه تمام متصل از الگوریتم طبقه بندی softmax استفاده شده است.

2.2 لایه Dropout

این لایه، در قسمت لایه های تمام متصل و و بین آنها استفاده می شود و هدف استفاده از آن جلوگیری از overfitting شبکه است. همانطور که در تصویر شماره 3 مشاهده می شود این لایه از پیچیدگی های لایه های تمام متصل جلوگیری میکند که باعث جلوگیری از overfitting می شود. در این مقاله از دولایه Drop-out استفاده شده است و نرخ هرلایه برابر 0.5 تنظیم شده است (14).

شکل 3: نحوه عملکرد لایه Dropout

3. ارزیابی روش پیشنهادی

عملکرد یک سیستم دسته بندی، از طریق پارامتر های متفاوتی نظیر دقت، صحت، حساسیت و معیار امتیاز F1 سنجیده می شود. درک این معیار ها، به کاربران اجازه می دهد تا بفهمند یک مدل دسته بندی توسعه داده شده، تا چه حد در تحلیل داده های متنی خوب عمل میکند. برای ارزیابی عملکرد یک سیستم دسته بندی، می توان از یک مجموعه داده تست ثابت (مجموعه ایی از داده های متنی با اندازه پیش تعیین شده که کلاس (برچسب) هرکدام از نمونه های موجود در آن مشخص شده است) استفاده کرد. چنین فرایندی در مرحله ارزیابی، داده های آموزشی را به دو زیر مجموعه تقسیم میکند؛ زیرمجموعه اول برای آموزش مدل یادگیری ماشین و زیر مجموعه دوم برای تست

AT. Highdensity diffuse optical tomography for imaging human brain function. Review of Scientific Instruments. 2019; 90(5):051101.

[10] Chen J. Optical tomography in small animals with time-resolved Monte Carlo methods. Rensselaer Polytechnic Institute: New York, 2012.

[11] . Arridge SR, Schotland JC. Optical tomography: forward and inverse problems. Inverse problems. 2009; 25(12):123010.

[12] Karras DA, Reczko M, Mertzios V, GraveronDemilly D, van Ormondt D, Papademetriou RC. Neural network reconstruction of MR images from noisy and sparse k-space samples. In WCC 2000-ICSP 2000. 2000 5th International Conference on Signal Processing Proceedings. 16th World Computer Congress 2000 Aug 21 (Vol. 3, pp. 2115-2118). IEEE.

[13] Kang E, Min J, Ye JC. A deep convolutional neural network using directional wavelets for low-dose X-ray CT reconstruction. Medical physics. 2017 Oct;44(10): e360-75.

[14] Antholzer S, Haltmeier M, Schwab J. Deep learning for photoacoustic tomography from sparse data. Inverse problems in science and engineering. 2019 Jul 3;27(7):987-1005.

[15] Perdios D, Besson A, Arditi M, Thiran JP. A deep learning approach to ultrasound image recovery. In 2017 IEEE International Ultrasonics Symposium (IUS) 2017 Sep 6 (pp. 1-4). Ieee.

[16] سحر صابری منش، عارفه عدنیان آرانی " تشخیص تومورهای مغزی با استفاده از هوش مصنوعی و شبکه کانولوشنی از تصاویر MRI " نهمین کنفرانس دانشجویی مهندسی برق کشور، دانشگاه علامه فیض کاشانی

پیشنهادی، ویژگی های سطح بالا توسط یادگیری عمیق استخراج می شود، دقت طبقه بندی و تشخیص بسیار بالا بوده.

5. مراجع

[1] Powell S, Arridge SR, Leung T S. Gradient-based quantitative image reconstruction in ultrasoundmodulated optical tomography: first harmonic measurement type in a linearised diffusion formulation. IEEE transactions on medical imaging, 2015; 35(2):456-467.

[2] . Singer JR, Grünbaum FA, Kohn P, Zubelli JP. Image reconstruction of the interior of bodies that diffuse radiation. Science.1990; 248(4958): 990-993.

[3] Arridge SR, Schweiger M, Delpy DT. Iterative reconstruction of near-infrared absorption images. In Inverse Problems in Scattering and Imaging.1992; 1767:372-383..

[4] . BarbourRL, Graber HL, Lubowsky J, AronsonR, Das BB, Yoo KM, Alfano RR.Imaging of diffusing media by a progressive iterative backprojection method using time-domain data. Physiological Monitoring and Early Detection Diagnostic Methods. 1992 May; 1641: 21-34..

[5] Grosenick D, Rinneberg H, Cubeddu R, Taroni P. Review of optical breast imaging and spectroscopy. Journal of biomedical optics. 2016; 21(9): 091311.

[6] Cochran J M, Busch DR, Lin L, Minkoff DL, Schweiger M, Arridge S, Yodh AG. Hybrid timedomain and continuous-wave diffuse optical tomography instrument with concurrent, clinical magnetic resonance imaging for breast cancer imaging. Journal of biomedical optics. 2019; 24(5), 051409.

[7] Hebden JC, Gibson A, Yusof RM, Everdell N, Hillman EM, Delpy DT, Wyatt J S. Threedimensional optical tomography of the premature infant brain. Physics in Medicine & Biology.2002; 47(23): 4155..

[8] Hoshi Y, Yamada Y. Overview of diffuse optical tomography and its clinical applications. Journal of biomedical optics. 2016; 21(9):091312.

[9] Wheelock MD, Culver JP, Eggebrecht