



Islamic Azad University, Shiraz Branch

نشریه تحلیل مدارها، داده ها و سامانه ها
Journal of Circuits, Data and Systems Analysis



Cdsa.shiraz.iau.ir

ناحیه بندی تصاویر مغز نوزادان بر اساس شبکه های عصبی پیچشی

ایران سرافراز^۱، حامد آگاهی^{۲*}، آذر محمودزاده^۳

۱- دانشجوی دکتری، گروه مهندسی برق، واحد شیراز، دانشگاه آزاد اسلامی، شیراز، ایران

ideh.sarafraz@gmail.com

۲- دانشیار، گروه مهندسی برق، واحد شیراز، دانشگاه آزاد اسلامی، شیراز، ایران

hamed.agahi@iau.ac.ir

۳- استادیار، گروه مهندسی برق، واحد شیراز، دانشگاه آزاد اسلامی، شیراز، ایران

azar.mahmoodzadeh@iau.ac.ir

چکیده: در این مقاله، روشی مبتنی بر شبکه های عصبی پیچشی برای ناحیه بندی تصاویر مغز نوزادان ارائه می شود. یکی از چالش های مهم در این زمینه، همپوشانی توزیع شدت روشنایی بافت های ماده خاکستری و ماده سفید است، که منجر به کاهش دقت ناحیه بندی این نواحی می شود. برای افزایش تمایز سطوح خاکستری بین بافت های مغز، در این مقاله یک روش پیش پردازش مبتنی بر شبکه های عصبی پیچشی ارائه می شود که به طور موثری باعث افزایش دقت ناحیه بندی می گردد. برای به دست آوردن ناحیه بندی نهایی، یک شبکه پیچشی دیگر ارائه می شود که بر اساس تصاویر مدالیته T1-T2 ناحیه بندی را انجام می دهد. برای ارزیابی روش پیشنهادی، از دو پایگاه داده iseg2017 و iseg2019 که شامل تصاویر رزونانس مغناطیسی مغز نوزادان است استفاده می شود. نتایج به دست آمده نشان دهنده کارایی مناسب روش پیشنهادی در ناحیه بندی بافت های مغز است. **واژه های کلیدی:** ناحیه بندی، تصاویر رزونانس مغناطیسی، مغز نوزادان، شبکه های عصبی پیچشی، یادگیری عمیق.

Infant Brain Image Segmentation using the Convolutional Neural Networks

Iran Sarafraz¹, Hamed Agahi^{2*}, Azar Mahmoodzadeh³

¹ PhD Student, Department of Electrical Engineering, Shiraz Branch, Islamic Azad University, Shiraz, Iran

ideh.sarafraz@gmail.com

² Associate Professor, Department of Electrical Engineering, Shiraz Branch, Islamic Azad University, Shiraz, Iran

hamed.agahi@iau.ac.ir

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

azar.mahmoodzadeh@iau.ac.ir

Abstract:

In this paper, a method based on convolutional neural networks for segmenting neonatal brain images is presented. One of the major challenges in this field is the intensity distribution overlapping between gray matter and white matter tissues, which reduces the segmentation accuracy of these areas. To increase the intensity differentiation between brain tissues, this paper presents a pre-processing method based on convolutional neural networks that effectively increases the segmentation accuracy. To obtain the final segmentation result, another convolutional neural network is proposed which performs segmentation based on T1-T2 images. To evaluate the performance of the proposed method, two databases iseg2017, iseg2019 are used, which include magnetic resonance imaging of infants' brains. The results show the appropriate efficiency of the proposed method in segmenting brain tissues.

Keywords: Segmentation, magnetic resonance images, Infants' brain, Convolutional neural networks, Deep learning.

DOI: 00.00000/0000

نوع مقاله: پژوهشی

تاریخ چاپ مقاله: ۱۴۰۲/۰۳/۲۰


تاریخ پذیرش مقاله: ۱۴۰۲/۰۲/۲۴

تاریخ ارسال مقاله: ۱۴۰۲/۰۱/۱۱

۱ - مقدمه

کنتراست نسبی خوبی بین بافت‌های مغز در سنین شیرخوارگی و اوایل بزرگسالی وجود دارد. اما، در سنین پایین، توزیع شدت روشنایی در بافت‌های ماده خاکستری و ماده سفید (به ویژه در نواحی قشر مغز) تا حد زیادی با هم همپوشانی دارند. همین مسئله منجر به کاهش تمایز سطوح خاکستری بین بافت‌های مغز می‌شود. همچنین رشد مغز در نواحی مختلف، غیرخطی بوده و کنتراست در نواحی مختلف مغز متفاوت است [۶]. عوامل و مشکلات دیگری نیز در تصاویر مغز نوزادان وجود دارد. از جمله آن‌ها می‌توان به موارد زیر اشاره کرد: آثار حرکت مغز در حین تصویربرداری، اندازه حجمی کم تصاویر به دلیل کوچک بودن اندازه مغز نوزاد، وضوح محدود، نسبت سیگنال به نویز و نسبت کنتراست به نویز پایین و همچنین میلین‌سازی ناقص و سطح بالای آن در مغز نوزادان. تمامی موارد بیان شده، ناحیه‌بندی خودکار تصاویر مغز نوزادان را به یک کار بسیار چالش برانگیز تبدیل می‌کند. از این رو، ابزارهای محاسباتی که برای پردازش تصاویر مغز بزرگسالان استفاده می‌شوند (مانند SPM، FSL، BrainSuite، CIVET، FreeSurfer و HCP Pipeline) اغلب عملکرد ضعیفی را بر روی تصاویر MRI مغز نوزادان دارند [۷].

در سال‌های اخیر، روش‌ها و رویکردهای مختلفی برای ناحیه‌بندی نواحی مغز در تصاویر MRI ارائه شده است. یک رویکرد رایج برای ناحیه‌بندی خودکار، استفاده از اطلس‌ها برای مدل‌سازی آناتومیکی مغز و بهره گرفتن از آن برای ناحیه‌بندی است [۸، ۹، ۱۰]. در چنین رویکردی، یک اطلس (یا اطلس‌های متعدد) ابتدا در یک تصویر هدف ثبت می‌شود و سپس با تعمیم برچسب‌های دستی به این تصویر ثبت شده، ناحیه‌بندی تصویر هدف به دست می‌آیند. هنگامی که چندین اطلس در نظر گرفته می‌شود، برچسب‌ها از اطلس‌های مختلف را می‌توان از طریق یک استراتژی ترکیب برچسب [۱۱، ۱۲، ۱۳] ایجاد کرد و ناحیه‌بندی نهایی را به دست آورد. روش‌های مبتنی بر اطلس به‌طور گسترده در کاربردهای تقسیم‌بندی استفاده شده‌اند. اگرچه این روش‌ها در بسیاری از کاربردها عملکرد خوبی را ارائه کرده‌اند، اما معمولاً به فرآیند ثبت، بسیار حساس هستند و اگر تصویر، کنتراست پایینی داشته باشد یا تصویر ساختار مغز دارای تنوع زیادی باشد،



شکل (۱): تصاویر MR با وزن T1 (سطر اول) و T2 (سطر دوم) از یک نوزاد در سنین تازه دو هفته‌گی تا دوازده ماهگی به همراه توزیع نواحی مختلف مغزی در سنین مختلف (سطر سوم)

سال اول زندگی، پویاترین مرحله رشد مغز انسان پس از تولد بوده که با رشد سریع بافت و توسعه طیف وسیعی از عملکردهای شناختی و حرکتی همراه است [۱]. افزایش دسترسی به تصاویر رزونانس مغناطیسی چند وجهی مانند تصاویر T1w و T2w فرصت مناسبی را برای مطالعه دقیق و قابل اعتماد مراحل تکاملی مغز در اختیار ما قرار داده است. تصویربرداری T2w باعث می‌شود ساختارهایی با آب زیاد در تصاویر، روشن به نظر برسند و تصویربرداری T1w آب را تاریک و ساختارهای حاوی چربی را نسبتاً روشن نشان می‌دهد. بنابراین، تصویربرداری T1w برای ارزیابی ساختارهایی که دارای چربی بالا هستند (مانند مفاصل) مفید است. در حالی که تصویربرداری T2w برای ارزیابی ساختارهای غنی از آب مانند مایع مغزی و همچنین برای جستجوی التهاب موضعی مفید است. از اینرو، به کمک این تصاویر می‌توان ناهنجاری‌های رشد مغز را تشخیص داد. در سال‌های اخیر با ذخیره دیجیتال این تصاویر و بایگانی آن‌ها، مجموعه داده‌های مختلفی وجود دارد. این مجموعه داده‌ها بدون شک دانش ما را در مورد رشد طبیعی اولیه مغز افزایش می‌دهد و بینش‌های مهمی را در مورد منشاء و مسیرهای رشد غیرطبیعی، اختلالات رشد عصبی (مانند اوتیسم، اسکیزوفرنی، اختلال دوقطبی) و کمبود توجه و بیش‌فعالی ارائه می‌کند. این تصویر برداری در مطالعه مشکلات رشد مغز نوزادان بسیار کاربردی است و به محققان اجازه می‌دهد تا نقایص رشد مغز را ارزیابی، هنجار بودن مغز را اندازه‌گیری، و کودکان در معرض خطر بالای اختلالات رشد عصبی را شناسایی کنند.

یکی از گام‌های اساسی در مطالعه رشد طبیعی و غیرعادی اولیه مغز نوزادان، تقسیم‌بندی دقیق تصاویر MRI مغز نوزاد به مناطق مختلف مورد علاقه است [۲، ۳]. بافت مغز به طور کلی از سه ناحیه شامل ماده سفید، ماده خاکستری و مایع مغزی نخاعی تشکیل شده است. ناحیه‌بندی قسمت‌های مختلف مغز در ساخت اطلس مغز و همچنین بررسی رشد مغز، اهمیت زیادی دارد [۴، ۵]. در شکل (۱) تصاویر MRI مربوط به سنین مختلف از دو هفته‌گی تا یک سالگی نوزاد نشان داده شده است. در سنین کمتر از پنج ماهگی، بافت ماده خاکستری توزیع بیشتری نسبت به سنین بالاتر دارد و بخش زیادی از مغز را به خود اختصاص داده است. همانطور که در شکل مشاهده می‌شود، در بازه زمانی سنین شش تا نه ماهگی، بافت‌های مغز رشد سریع‌تری داشته که باعث افزایش شدت ماده سفید در تصاویر T1w شده و در نتیجه تمایز بیشتری با سایر نواحی ماده خاکستری و ماده سفید ایجاد می‌شود (که برای تصاویر T2w نیز صادق است). الگوی بافت مغز در سنین بیشتر از نه ماهگی شبیه به الگوی بزرگسالان بوده که در آن شدت ماده خاکستری در تصاویر T1w بسیار کمتر از ماده سفید است. توزیع شدت بافت مربوط به سنین مختلف در ردیف سوم شکل (۱) نشان داده شده است. همانطور که مشاهده می‌شود،

یکی از مشکلات عمده در اکثر روش‌های پیشنهادی، وجود عدم قطعیت سطوح خاکستری بین بافت‌های مختلف مغز نوزادان است که این موضوع ناشی از عدم رشد کامل مغز نوزادان است. این در حالی است که بافت مغز افراد بالغ به دلیل رشد کامل، امکان تفکیک مناسب‌تری دارد. این عامل باعث کاهش کارایی روش‌های ارائه شده در ناحیه‌بندی مغز نوزادان می‌شود. همگن نبودن سطوح خاکستری بافت‌های مختلف موجود در مغز نوزادان، یکی دیگر از چالش‌های مهم در شناسایی آن‌ها است. در این مقاله، یک روش مبتنی بر شبکه‌های عصبی پیچشی برای افزایش تمایز سطوح خاکستری بین بافت‌های مغز ارائه شده که از طریق انجام یک پیش‌پردازش مبتنی بر پیکسل به طور موثری باعث افزایش دقت ناحیه‌بندی می‌شود. روش پیش‌پردازش ارائه شده همچنین با افزایش یکنواختی و همگنی بافت‌های مختلف، منجر به بهبود دقت ناحیه‌بندی می‌شود. همچنین یک شبکه پیچشی دیگر برای ناحیه‌بندی مبتنی بر تصاویر T1 و T2 ارائه شده است.

ساختار ادامه مقاله به صورت زیر است: در بخش ۲، مراحل روش پیشنهادی به طور کامل توضیح داده خواهد شد. در بخش ۳، نتایج به دست آمده از شبیه‌سازی روش پیشنهادی ارائه می‌شود و در نهایت در بخش ۴، مقاله با یک نتیجه‌گیری به پایان می‌رسد.

۲- روش پیشنهادی

یکی از مهمترین چالش‌ها در طبقه‌بندی تصاویر مغز نوزادان، مشخص نبودن مرز بافت‌های مختلف موجود در مغز در مقایسه با مغز افراد بزرگسال است. در روش پیشنهادی، قبل از انجام ناحیه‌بندی، یک عملیات پیش‌پردازش بر روی تصویر ورودی MRI انجام می‌شود تا بتوان سطوح خاکستری بافت‌های مغزی را هر چه بیشتر از هم تفکیک کرد و متعاقباً ناحیه‌بندی دقیق‌تری انجام داد. بلوک دیاگرام روش پیشنهادی در شکل ۲ نشان داده شده است. همانطور که مشاهده می‌شود، روش پیشنهادی از دو بخش عمده پیش‌پردازش و ناحیه‌بندی تشکیل شده است. در ادامه این دو بخش توضیح داده می‌شود.

۲-۱- پیش‌پردازش عمیق

در اولین گام از روش پیشنهادی، یک روشی مبتنی بر شبکه‌های عصبی کانولوشنی برای تفکیک بیشتر بین بافت‌های مغز ارائه شده است. مدل پیشنهادی، یک شبکه U-Net بر اساس یک مدل رگرسیون است که ورودی آن تصویر MRI و خروجی، تصویر پیش‌پردازش شده است. این مدل U-Net شامل چندین لایه مشتمل بر لایه‌های کانولوشن، ماکس-پولینگ، آپ-کانولوشن و ترکیب است. به صورت کلی، مدل U-net دارای دو بخش رمزگذار و رمزگشا است. در بخش رمزگذار، تصویر توسط لایه‌هایی مانند کانولوشن و ماکس-پولینگ به یک فضای فشرده ویژگی منتقل می‌شود و در بخش رمزگشا، تصویر پیش‌پردازش به عنوان خروجی تولید می‌شود.

ممکن است با شکست مواجه شوند. این امر به ویژه در مورد تقسیم‌بندی مغز نوزاد، به دلیل تفاوت‌های زیاد و تنوع فضایی بالای مغز نوزادان مشکل ساز است. برای غلبه بر محدودیت‌های روش‌های مبتنی بر اطلس، از مدل‌های پارامتریک مانند مدل‌های تغییر شکل‌پذیر [۱۴، ۱۵، ۱۶] استفاده شده است. مدل‌های پارامتریک معمولاً تقسیم‌بندی را به‌عنوان یک مسئله بهینه‌سازی یک تابع انرژی بیان می‌کنند. چنین مدل‌هایی اغلب به تعداد زیادی تصاویر برچسب‌دار نیاز دارند، که در عمل به ندرت در دسترس هستند. مدل‌های تغییر شکل‌پذیر، نتایج به دست آمده توسط اطلس را به شیوه‌ای تکراری اصلاح می‌کنند تا بهتر با مرزهای نواحی مغز هماهنگ شوند. با این حال، این مدل‌ها معمولاً به ساختار مغز وابسته هستند.

اخیراً، روش‌های یادگیری عمیق مبتنی بر شبکه‌های عصبی پیچشی عملکرد فوق‌العاده‌ای را در طیف گسترده‌ای از کاربردهای بینایی ماشین و تحلیل تصویر نشان داده‌اند. به طور خاص، CNN ها برای مشکلات مختلف، از جمله تقسیم بندی MRI مغز نوزادان به نتایج پیشرفته‌ای دست یافته‌اند [۱۷-۲۲]. به عنوان نمونه، در [۱۷] یک ساختار دو بعدی CNN چند مقیاسی ارائه شده که با استفاده از مدالیته تصویر T2w تقسیم بندی دقیق و سازگاری انجام می‌دهد. برای به دست آوردن اطلاعات چند مقیاسی، نویسندگان فیلترهایی با اندازه‌های مختلف را در نظر گرفتند. در چندین مطالعه اخیر به منظور غلبه بر کنتراست بسیار کم بین بافت‌های ماده سفید و ماده خاکستری و افزایش دقت ناحیه‌بندی، از تصاویر با مدالیته‌های مختلف به عنوان ورودی استفاده شده است. به عنوان نمونه، در [۱۸] یک CNN عمیق با ترکیب تصاویر T1 و T2 و ناهمسانگردی کسری پیشنهاد شد. در تحقیقی دیگر، یک شبکه عصبی کاملاً پیچشی (FCNN) برای تقسیم‌بندی تصاویر MR مغز نوزادان پیشنهاد شده است [۱۹]. همچنین در [۲۰] یک روش جدید مبتنی بر شبکه سه بعدی U-Net مطرح گردیده است. در ساختار پیشنهادی آن‌ها، با این هدف که در مرحله رمزگذاری، اطلاعات معنایی کمی از دست برود از کانولوشن گسترش یافته استفاده شده است. در [۲۱]، از تطبیق هیستوگرام برای کم کردن تفاوت سطوح روشنایی پیکسل‌های تصاویر و یکسان‌سازی سطوح خاکستری استفاده شده است. در این روش همچنین یک شبکه سه بعدی U-Net ارائه شده که به ازای ورودی‌های با مدالیته‌های T1 و T2، ناحیه‌بندی انجام می‌شود. در [۲۲]، از ترکیب شبکه‌های عصبی عمیق VGG-16 و U-Net برای ناحیه‌بندی مغز استفاده شده است. در مطالعات انجام شده همچنین از اطلاعات فازی در شبکه‌های عمیق به منظور بخش بندی مغز نوزادان استفاده شده است [۲۳]. در [۲۴] ابتدا به پیش‌پردازش تصاویر پرداخته شده و سپس از شبکه عصبی کاملاً پیچشی (FCN) جهت تقسیم‌بندی نواحی مختلف مغز استفاده شده است. همچنین در [۲۵] تقسیم‌بندی با توجه به ویژگی‌های بافتی مغز انجام پذیرفته است و سپس از تصاویر چندوجهی به عنوان ورودی برای شبکه U-Net با چند مسیر، پیشنهاد شده است.



از آنجایی که در یک تصویر MRI، امکان دارد برخی از برش‌ها به نواحی خارج از مغز مربوط باشد، لذا در این بخش نیاز هست برش‌های دیگر که شامل اطلاعات مغزی نیست حذف شود تا آموزش مدل U-net بهتر انجام شود. برای انجام این کار از روش آستانه‌گذاری Otsu استفاده می‌شود که یک روش برای آستانه‌گذاری بهینه است و هدف آن، یافتن مقدار آستانه بهینه است به طوری که مجموع واریانس‌های پیش‌زمینه و پس‌زمینه حداقل باشد. در این روش همه پیکسل‌های تصویر با یک سطح آستانه مقایسه می‌شود و اگر مقدار سطح خاکستری پیکسل مورد نظر از آستانه بیشتر باشد آن پیکسل متعلق به یک بافت مغزی در نظر گرفته می‌شود و در غیر این صورت، به عنوان پیکسل پس‌زمینه لحاظ می‌شود.

$$Brain_{mask}(X_i) = \begin{cases} 1 & \text{if } im(X_i) \geq t^* \\ 0 & \text{if } im(X_i) < t^* \end{cases} \quad (1)$$

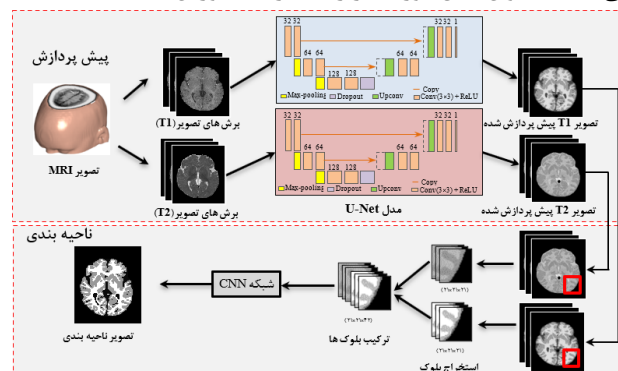
در این رابطه، $Brain_{mask}$ یک ماسک باینری حاصل از آستانه‌گذاری است که شامل ناحیه تقریبی بافت مغز است و t^* آستانه بهینه Otsu است. بعد از اعمال این آستانه‌گذاری ناحیه بافت مغز به دست می‌آید. در شکل (۳) برای چند تصویر نمونه نتیجه حاصل نشان داده شده است. بعد از شناسایی نواحی مغزی در هر برش، آن دسته از تصاویر برش که شامل هیچ ناحیه مغز نیست حذف می‌شود و در مراحل بعدی فقط از برش‌های حاوی ناحیه مغز برای آموزش مدل U-net استفاده می‌گردد. برای آموزش هر یک از مدل‌های U-net، از تمامی برش‌های تصویر MRI که در بخش قبل استخراج شدند به عنوان ورودی استفاده می‌شود. اما برای آموزش این مدل‌ها، علاوه بر داشتن تصاویر ورودی، تصاویر خروجی هدف (تصاویر پیش پردازش شده) نیز باید از روی داده‌های آموزش تولید شوند. لذا در این مرحله برای تمامی برش‌های به دست آمده از داده آموزش، باید تصاویر خروجی دلخواه تولید شود. همانطور که قبلاً ذکر شد، هدف کلی روش پیش‌پردازش عمیق پیشنهادی، افزایش اختلاف سطوح خاکستری بافت‌های مغز است. لذا برای تولید تصاویر خروجی، باید اختلاف سطوح خاکستری بافت‌های مغز افزایش یابد. برای انجام این کار طبق شکل (۴)، به صورت زیر عمل می‌شود:

۱- بر اساس برچسب‌هایی که برای بافت‌های مختلف مغزی در داده آموزش در اختیار است، سه بافت سفید، خاکستری و مایع مغزی از هم تفکیک می‌شود.

۲- مقدار سطح خاکستری هر پیکسل در هر بافت، معادل k برابر میانگین آن کلاس قرار داده می‌شود. به عنوان مثال، پیکسل‌هایی که به کلاس بافت سفید متعلق هستند، شناسایی می‌شود. سپس میانگین سطوح خاکستری تمامی آن پیکسل‌ها به دست می‌آید. اگر مقدار میانگین سطوح خاکستری بافت سفید تصویر، M در نظر گرفته شود، مقدار سطح خاکستری همه پیکسل‌های بافت سفید آن تصویر برابر $P_{ij} \times M \times k$ قرار داده می‌شود. این کار برای دو ناحیه بافت خاکستری و مایع مغزی نیز انجام می‌شود تا تصویر پیش-پردازش شده تولید شود. مقدار عدد k برای کلاس‌های پس‌زمینه،


بخش رمزگذار مدل U-net شامل سه مجموعه لایه کانولوشن است: مجموعه اول شامل دو لایه کانولوشن متوالی با تعداد ۳۲ فیلتر، مجموعه دوم شامل دو لایه کانولوشن متوالی با تعداد ۶۴ فیلتر و مجموعه سوم شامل دو لایه کانولوشن متوالی با تعداد ۱۲۸ فیلتر است. هرچه تعداد مجموعه لایه‌های کانولوشن شبکه U-net بیشتر شود عمق بخش رمزگذار بیشتر می‌شود و مدل می‌تواند ویژگی‌های فشرده‌تری را استخراج کند. بخش رمزگشای مدل ارائه شده نیز شامل دو مجموعه لایه کانولوشن است که هدف آن‌ها بازسازی تصویر خروجی از ویژگی‌های فشرده است. در این مدل، مجموعه لایه کانولوشن اول شامل دو لایه متوالی با تعداد ۶۴ فیلتر بوده در حالی که مجموعه لایه کانولوشن دوم شامل دو لایه متوالی با تعداد ۱۲۸ فیلتر است. در بخش رمزگشا، همچنین یک لایه آپ-کانولوشن وجود دارد که وظیفه آن افزایش دو برابری رزولوشن مکانی نقشه و ویژگی است. به عنوان مثال، اگر در خروجی لایه کانولوشن، نقشه ویژگی با ابعاد 10×10 و با عمق ۶۴ وجود داشته باشد (با اعمال لایه آپ-کانولوشن نقشه ویژگی با ابعاد 20×20 و با عمق ۶۴ $20 \times 20 \times 64$) به دست می‌آید.

مدل U-net همچنین شامل یک لایه dropout است که برای آموزش بهتر مدل و جلوگیری از بیش‌برازش^۱ استفاده شده است. وقتی یک مدل بیش از حد آموزش می‌بیند به این معنی است که بر روی داده‌های آموزش خوب عمل می‌کند در حالی که نتیجه مناسبی بر روی داده آزمایش به دست نمی‌آید. در واقع این لایه کمک می‌کند که مدل بتواند به خوبی ساختارهای مختلف تصویر را آموزش ببیند و صرفاً یک ناحیه یا نواحی از پیکسل‌های تصویر را یاد نگیرد. به دلیل اینکه تصاویر MRI شامل دو مدالیته T1 و T2 هستند، در این مقاله دو مدل U-net مجزا برای پیش پردازش این تصاویر ارائه شده است. برای آموزش هر یک از مدل‌های مذکور، در اولین گام، تمامی برش‌های تصویر MRI استخراج می‌شود و به صورت یک تصویر دو بعدی ذخیره می‌گردد. در واقع، به جای تحلیل تصویر سه بعدی MRI، آن تصاویر به تصاویر دو بعدی تجزیه می‌شود. این کار از بار پردازشی مدل U-net کاسته و این امکان را فراهم می‌کند که بتوان مدل مورد نظر را به سرعت آموزش داد.

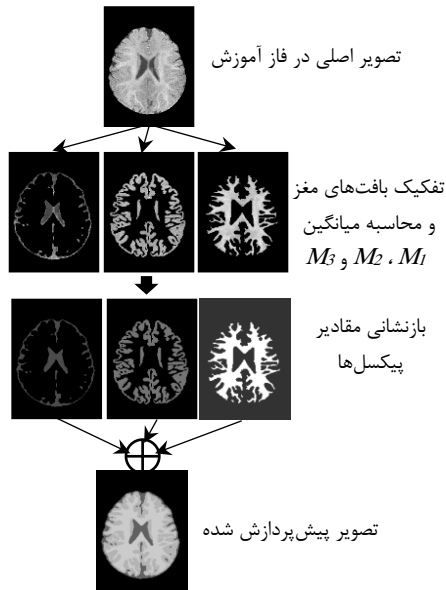


شکل (۲): بلوک دیاگرام روش پیشنهادی برای ناحیه بندی تصاویر مغز نوزادان


¹ Overfitting



شکل (۳): آستانه‌گذاری برای شناسایی ناحیه مغز در هر برش



شکل (۴): نحوه تولید تصویر پیش‌پردازش شده از یک تصویر برش نمونه برای آموزش مدل‌های U-net



شکل (۵): نحوه استخراج یک بلوک از تصویر MRI: (الف) تصویر T1، (ب) تصویر T2، (ج) بلوک استخراجی از تصویر T1 به اندازه $21 \times 21 \times 21$ به مرکزیت پیکسل (i,j)، (د) بلوک استخراجی از تصویر T2 به اندازه $21 \times 21 \times 21$ به مرکزیت پیکسل (i,j)، (ه) بلوک با ابعاد $21 \times 21 \times 42$ پیکسل حاصل از ترکیب بلوک‌های T1 و T2

مایع مغزی نخاعی، بافت ماده خاکستری و ماده سفید به صورت تجربی به ترتیب برابر ۱، ۲، ۳ و ۴ در نظر گرفته می‌شود. $P_{i,j}$ نیز سطح خاکستری پیکسل ستون i و سطر j از تصویر است. با تولید نواحی پیش‌پردازش شده بافت خاکستری، بافت سفید و مایع مغزی، این سه ناحیه با عملگر جمع با هم ترکیب می‌شوند تا تصویر پیش‌پردازش شده کل ناحیه مغز به دست آید. متعاقب دو مرحله ذکر شده، نسخه پیش‌پردازش شده برای هر یک از برش‌های داده آموزش به دست می‌آید که می‌توان آن‌ها را برای آموزش مدل‌های U-net استفاده نمود.

۲-۲- ناحیه بندی

در بخش قبل، تصاویر پیش‌پردازش شده توسط مدل‌های U-net به دست آمد. در این بخش، بر اساس این تصاویر، ناحیه‌بندی برش‌ها توسط مدل کانولوشنی عمیق پیشنهادی انجام می‌گیرد. برای انجام ناحیه‌بندی، از طبقه‌بندی مبتنی بر بلوک^۱ استفاده می‌شود. برای ناحیه‌بندی، ابتدا تصاویر سه بعدی MRI با ابعاد 192×144 پیکسل و تعداد برش‌های ۲۵۶، به بلوک‌های کوچک با ابعاد $21 \times 21 \times 21$ تقسیم می‌شود. این بدان معنی است که اندازه بلوک در راستای مختصات دو بعدی تصویر برابر 21×21 بوده و تعداد ۲۱ برش را شامل می‌شود. باید توجه داشت که بلوک‌های استخراج شده از تصویر، بلوک‌های همپوشان هستند. در واقع در این بخش، اطراف هر پیکسل تصویر، یک بلوک به اندازه $21 \times 21 \times 21$ پیکسل در نظر گرفته می‌شود. لذا اگر اندازه هر برش تصویر MRI، برابر N در M پیکسل باشد، در این صورت از آن تصویر به تعداد $M \times N$ بلوک استخراج می‌شود. حال اگر تصویر MRI، شامل C برش باشد در آن صورت به صورت کلی $M \times N \times C$ بلوک از آن تصویر استخراج می‌شود. از آنجایی که دو مدالیته T1 و T2 برای تصاویر سه بعدی MRI وجود دارد، این کار برای هر دو مدالیته انجام می‌شود و طبق شکل (۵) بلوک‌های متناظر استخراجی از دو مدالیته ذکر شده در راستای عمیق در کنار هم قرار داده می‌شود تا یک بلوک با اندازه $21 \times 21 \times 42$ پیکسل حاصل شود که شامل اطلاعات مربوط به هر دو مدالیته است. برچسب هر بلوک برابر با یک عدد خواهد بود که نشان‌دهنده کلاس پیکسل به مرکزیت آن بلوک است. هر بلوک می‌تواند به یکی از چهار کلاس بافت سفید (WM)، بافت خاکستری (GM)، مایع مغزی (CSF) و یا پس‌زمینه تعلق داشته باشد. ساختار مدل پیشنهادی پیچشی برای ناحیه‌بندی در جدول (۱) نشان داده شده که شامل چهار لایه کانولوشن، سه لایه ماکس-پولینگ و دو لایه تماماً متصل (FC)^۲ است. مدل پیشنهادی این امکان را می‌دهد که بتوان مسئله ناحیه‌بندی را به یک مسئله طبقه‌بندی تبدیل کرده و تصاویر حاصل از مرحله پیش‌پردازش را طبقه‌بندی کرد. برای آموزش هر چه بهتر مدل و جلوگیری از بیش‌برازش، از تکنیک افزایش داده استفاده می‌شود. این تکنیک در افزایش تنوع داده آموزش برای آموزش مدل‌های عمیق مورد استفاده قرار می‌گیرد.

² Fully-Connected (FC)

¹ Patch-based classification



جدول (۱): ساختار شبکه پیچشی روش پیشنهادی

لایه	تعداد فیلتر	اندازه فیلتر	استراید	خروجی
Input	-	-	-	21×21×42
Conv	32	3×3×3	1×1	21×21×32
BN + ReLU	-	-	-	21×21×32
Max-pool	1	2×2	2×2	10×10×32
Conv	64	3×3×3	1×1	10×10×64
BN + ReLU	-	-	-	10×10×64
Max-pool	1	2×2	2×2	5×5×64
Conv	128	3×3×3	1×1	5×5×128
BN + ReLU	-	-	-	5×5×128
Max-pool	1	2×2	2×2	2×2×128
Conv	256	3×3×3	1×1	2×2×256
BN + ReLU	-	-	-	2×2×256
FC	256	-	-	1×1×256
ReLU	-	-	-	1×1×256
FC	3	-	-	1×1×3
Softmax	-	-	-	1×1×3


جدول (۲): پروتکل تصویربرداری تصاویر آموزش

دو پایگاه داده iSeg 2017 و iSeg 2019

مدالیتی	تعداد برش	TR/TE	زاویه تلنگر	وضوح
T1	۱۴۴ (ساجیتال)	۱۹۰۰ / ۴۳۸ ms	۷ درجه	۱ × ۱ × ۱ میلی مترمربع
T2	۶۴ (آگزیتال)	۷۳۸۰ / ۱۱۹ ms	۱۵۰ درجه	۱.۹۵ × ۱.۲۵ × ۱.۲۵ میلی مترمربع

جدول (۳): پروتکل تصویربرداری تصاویر تست پایگاه داده iSeg 2019

داده	مدالیتی	TR/TE	زاویه تلنگر	وضوح
BCP	T1	۲۲۴ ms / ۲۴۰۰	۸ درجه	۰.۸ × ۰.۸ × ۰.۸ میلی مترمربع
	T2	۵۶۴ ms / ۳۲۰۰	۷ درجه	۰.۸ × ۰.۸ × ۰.۸ میلی مترمربع
دانشگاه استنفورد	T1	۲۰۹ ms / ۷۶	۱۱ درجه	۰.۸ × ۰.۸ × ۰.۸ میلی مترمربع
	T2	۹۱۴ ms / ۲۵۰۲	۹۰ درجه	۰.۸ × ۱ × ۱ میلی مترمربع
دانشگاه اموری	T1	۲۱۹ ms / ۲۴۰۰	۸ درجه	۱ × ۱ × ۱ میلی مترمربع
	T2	۵۶۱ ms / ۳۲۰۰ / ۱۲۰	۱۲۰ درجه	۱ × ۱ × ۱ میلی مترمربع



شکل (۶): اعمال روش‌های مختلف افزایش داده بر روی یک بلوک استخراج شده نمونه: (الف) تصویر نمونه، (ب) یک ناحیه از تصویر نمونه، (ج) تصاویر تولیدی توسط روش‌های مختلف افزایش داده

در روش پیشنهادی در این مقاله از چندین تکنیک افزایش داده از جمله چرخش، مقیاس، یکنواختی، تغییر سطح روشنایی و تغییر کنتراست استفاده شده که به شرح زیر هستند:

- چرخش: به اندازه مضربی از ۹۰ درجه
- مقیاس: به نسبت ۰/۸ تا ۱/۲
- یکنواختی: توسط فیلتر گوسی به ازای سیگما ۱/۲ تا ۳ و اندازه پنجره ۵×۵

در شکل (۶)، نمونه‌هایی از بلوک‌های به دست آمده توسط روش‌های مختلف افزایش داده، نشان داده شده است. بعد از آموزش مدل‌های U-net و مدل کانولوشنال ارائه شده، برای به دست آوردن نتیجه نهایی ناحیه‌بندی برای یک تصویر پیش‌پردازش شده آزمایشی، بدین صورت عمل می‌شود که ابتدا تصویر به بلوک‌های کوچک تقسیم می‌شود. سپس هر بلوک از مدل پیچشی پیشنهادی عبور داده شده تا برچسب آن تخمین زده شود. در نهایت مقدار پیکسل واقع در مرکز بلوک موردنظر، برابر کلاس تخمین زده شده توسط مدل پیچشی قرار داده می‌شود. این کار برای تمامی بلوک‌های تصویر انجام داده می‌شود تا تصویر ناحیه‌بندی شده نهایی به دست آید.

۳- ارزیابی نتایج

در این بخش، عملکرد روش پیشنهادی بررسی و نتایج آن با سایر روش‌های موجود مقایسه می‌شود. در این راستا، دو پایگاه داده مورد استفاده معرفی می‌شود. همچنین معیارهای ارزیابی نیز توضیح داده می‌شود.

۳-۱- پایگاه‌های داده

برای ارزیابی عملکرد روش‌های پیشنهادی، از دو پایگاه داده iSeg 2017 [۲۶] و iSeg 2019 [۲۷] استفاده می‌شود. این مجموعه داده‌ها شامل تصاویر مختلف MRI مغز نوزادان با ابعاد ۱۹۲×۱۴۴ پیکسل و تعداد برش‌های ۲۵۶ بوده که در دو پروتکل T1 و T2 تصویربرداری شده‌اند. مجموعه داده iSeg 2017 حاوی تصاویر اسکن‌های MR مختلف از نوزادان است. همه نوزادان مورد مطالعه در این پایگاه داده، سن بین ۵/۵±۰ ماه داشتند. اسکن‌های MR، توسط اسکن‌های زمینس سه تسلا انجام شده و در طول اسکن، نوزادان در خواب بوده و مجهز به محافظ گوش بودند و سر آن‌ها در دستگاه تثبیت خلاء، محکم شده بود. جزئیات مربوط به پروتکل تصویربرداری این پایگاه داده در جدول (۲) ذکر شده است [۲۶]. در این پایگاه داده، هر تصویر شامل یک تصویر دارای برچسب بوده که نشان‌دهنده نتیجه ناحیه‌بندی توسط یک رادیولوژیست است. تصویر برچسب نیز همانند تصاویر MRI، به صورت حجمی بوده و هم اندازه تصاویر MRI است. در تصویر برچسب، هر پیکسل به یکی از چهار کلاس پس‌زمینه، بافت خاکستری، بافت سفید و مایع مغز تعلق دارد. این پایگاه داده شامل ده تصویر MRI مغزی برای بخش آموزش و سیزده تصویر برای بخش تست و ارزیابی است.

۳-۳- پارامترهای آموزش و نتایج ارزیابی

برای آموزش مدل U-net، در این مقاله از برش‌های استخراج شده تمامی تصاویر MRI از داده آموزش استفاده می‌شود. به دلیل اینکه خروجی مدل پیشنهادی، یک تصویر سطح خاکستری پیش‌پردازش شده است، لذا این مدل، یک مدل رگرسیون بوده و برای آموزش آن از تابع هزینه میانگین مربعات خطا^۴ استفاده می‌شود. برای بهینه‌سازی این تابع هزینه در فرآیند آموزش مدل، از روش بهینه‌سازی آدام [۲۸] استفاده شده است. این روش در تکرارهای مختلف در مرحله آموزش، با حداقل‌سازی تابع هزینه، وزن‌های مدل را به روز رسانی می‌کند. سایر پارامترهای مدل U-net پیشنهادی در جدول (۴) نشان داده شده است. برای آموزش مدل، اندازه mini-batch برابر ۱۶ انتخاب شده است. انتخاب mini-batch های بزرگتر به همگرایی سریع‌تر کمک می‌کند اما بار محاسباتی نیز افزایش پیدا می‌کند. تعداد کل تکرار برای آموزش مدل، ۲۰۰ و همچنین نرخ یادگیری اولیه، ۰/۰۱ در نظر گرفته شده که مقدار آن به ازای هر ۳۰ تکرار با ضریب ۰/۸ کاهش پیدا می‌کند تا آموزش مدل بهتر انجام شود.

در مجموعه داده آموزش تنها ده تصویر MRI در اختیار است که از هر تصویر، برش‌هایی که شامل بافت مغز هستند استخراج و برای آموزش مدل U-net استفاده می‌شود. با این حال، تعداد برش‌های موجود برای آموزش مدل همچنان ناکافی است. لذا، قبل از آموزش مدل، از چندین روش افزایش داده به شرح زیر استفاده شده است:

- **جابجایی:** تصویر به اندازه ± 20 و ± 40 پیکسل جابجا می‌شود. در نتیجه، از هر تصویر برش چهار نسخه جدید به دست می‌آید. این عملیات، مدل را در برابر جابجایی پیکسل‌های نواحی مغز مقاوم می‌کند.

- **انعکاس:** در این روش، تصویر هر برش به صورت عمودی و افقی انعکاس داده می‌شود. لذا از هر برش دو نسخه جدید ایجاد می‌شود.
- **تغییر شدت روشنایی:** در این روش، شدت روشنایی هر برش تغییر داده می‌شود. برای اینکار از تابع گاما به ازای گام‌های ۰/۲۵، ۰/۵، ۱، ۱/۵ استفاده می‌شود. تابع گاما به ازای مقدار گامی کمتر از ۱، باعث تاریک‌تر شدن تصویر می‌شود، در حالی که به ازای گامی بزرگ‌تر از ۱ باعث روشن‌تر شدن تصویر می‌شود.

جدول ۴: پارامترهای آموزش مدل U-net

پارامتر	مقدار
نرخ یادگیری	۰/۰۱
تعداد تکرار	۲۰۰
mini-batch	۱۶
ضریب کاهش نرخ یادگیری	۰/۸
تابع هزینه	میانگین مربعات خطا

مجموعه داده دیگر مورد استفاده در این مقاله، iSeg 2019 است. این پایگاه داده نیز شامل تصاویر اسکن‌های MR مختلف از نوزادان شش ماهه است که در دو مدالیته T1 و T2 تهیه شده‌اند [۲۷]. این پایگاه داده شامل ده تصویر آموزش، سیزده تصویر ارزیابی و شانزده تصویر تست است که هر دو بخش آموزش و ارزیابی با دستگاه MRI سه تسلا با مشخصاتی مشابه با پایگاه داده iSeg 2017 تصویربرداری شده‌اند. تصاویر تست از مراکز مختلفی تهیه شده‌اند که مشخصات تصویربرداری متفاوتی با داده‌های آموزش دارند. در واقع، مجموعه داده تست از سه مرکز BCP، دانشگاه استنفورد و دانشگاه اموری تهیه شده است که مشخصات آن در جدول (۳) شده است.

۳-۲- معیارهای ارزیابی

برای ارزیابی نتایج روش پیشنهادی از معیارهای مختلفی استفاده می‌شود. هدف اصلی از معیارهای ارائه شده، مقایسه عملکرد و دقت ناحیه‌بندی توسط روش پیشنهادی با نواحی برچسب شده دستی است. سه معیار به نام های دایس، فاصله هاسدورف^۱ و فاصله متوسط سطح^۲ به کار گرفته شده، که طبق روابط زیر تعریف می‌شوند.

$$DICE = \frac{2|A \cap B|}{|A| + |B|} \quad (1)$$

$$HD(C, D) = \max(h(C, D), h(D, C)) \quad (2)$$

$$h(C, D) = \max_{c \in C} \max_{d \in D} \|c - d\| \quad (3)$$

$$ASD = \frac{1}{2} \left(\frac{\sum_{V_i \in S_A} \min_{V_j \in S_B} d(V_i, V_j)}{\sum_{V_i \in S_A} 1} + \frac{\sum_{V_j \in S_B} \min_{V_i \in S_A} d(V_j, V_i)}{\sum_{V_j \in S_B} 1} \right) \quad (4)$$

رابطه (۱)، مربوط به معیار دایس بوده و در آن، A و B نشان دهنده برچسب‌های باینری دستی و به دست آمده از روش پیشنهادی هستند. عملگر |.| تعداد پیکسل‌های مثبت در تصویر باینری را نشان می‌دهد و $|A \cap B|$ تعداد پیکسل‌های مثبت مشترک در دو تصویر برچسب و ناحیه‌بندی شده روش پیشنهادی است. در (۲)، C و D دو مجموعه رأس^۳ هستند که به ترتیب به صورت دستی و محاسباتی برای یک کلاس بافت مشخص شده‌اند. رأس به هر یک از نقاط زاویه‌ای روی مرز نواحی مغز اطلاق می‌گردد. در این رابطه، $h(C, D)$ طبق (۳) به دست می‌آید که معرف معیار هاسدورف است. رابطه (۴) نیز نشان‌دهنده فاصله متوسط سطح است. S_A سطح نقشه برچسب است و S_B سطح نقشه به دست آمده توسط روش پیشنهادی است. همچنین $d(V_i, V_j)$ فاصله اقلیدسی از رأس V_i تا V_j را نشان می‌دهد. بهترین روش، روشی است که حداکثر دایس و حداقل HD و ASD را نتیجه بدهد.

⁴ Mean Square Error (MSE)

¹ Hausdorff Distance (HD)

² Average Surface Distance (ASD)

³ Vertex



$$L = y_{true} \log(p) + (1 - y_{true}) \log(1 - p) \quad (5)$$

از روش بهینه سازی آدم برای بهینه کردن تابع هزینه استفاده شده است. پارامترهای آموزش مدل CNN پیشنهادی در جدول (5) نشان داده شده است. نتایج به دست آمده توسط روش پیشنهادی بر روی داده‌های تست پایگاه‌های داده iSeg 2017 و iSeg 2019 در جداول (6-7) به صورت مجزا برای هر تصویر ذکر شده‌اند. نتایج به دست آمده بر اساس معیارهای ارزیابی به طور مجزا برای هر یک از بافت‌های مغزی ذکر شده است. همچنین انحراف معیار مربوط به هر سه معیار نیز محاسبه شده است. همانطور که مشاهده می‌شود، روش پیشنهادی توانسته ناحیه سفید، خاکستری و مایع مغز را به ترتیب با دایس 0/1873، 0/898 و 0/937 و برای تصاویر iSeg-2017 و 0/767، 0/749 و 0/774 برای تصاویر iSeg-2019 ناحیه بندی کند. همچنین نتایج مربوط به معیار ارزیابی هاسدروف در نواحی سفید، خاکستری و مایع مغزی نخاعی به ترتیب برابر 7/16 و 7/44 و 10/0 در داده iSeg 2017 و 8/57 و 8/35 و 11/88 به ازای داده iSeg 2019 می‌باشد، که نشان از تفکیک خوب این نواحی است. معیار مربوط به فاصله متوسط سطح نیز با مقدار به دست آمده که در جداول (6-7) بیان شده است، نشان از کارایی مناسب این روش در ناحیه بندی تصاویر مغزی دارد.


در جداول (8-9) نتایج روش پیشنهادی با برخی از روش‌های موجود در [26 و 27] مقایسه شده است. ارزیابی‌ها نشان می‌دهد که روش پیشنهادی در مقایسه با روش‌های موجود با دقت خوبی توانسته ناحیه بندی را انجام دهد. در واقع پیش‌پردازش انجام شده بر روی تصاویر MRI و همچنین استفاده از روش‌های افزونی داده این امکان را به روش پیشنهادی داده که بتواند نتایج خوبی را حتی به ازای پایگاه داده تست iSeg-2019 که شامل تصاویری با پروتکل‌های تصویربرداری متنوع هست، به دست آورد.

4- نتیجه گیری


در این مقاله، یک روش خودکار برای ناحیه بندی تصاویر MRI مغز نوزادان مبتنی بر شبکه‌های پیچشی ارائه شد. در روش پیشنهادی برای غلبه بر چالش شباهت توزیع شدت روشنایی در بافت‌های ماده خاکستری و ماده سفید، یک روش پیش‌پردازش مبتنی بر شبکه پیچشی U-net ارائه شد که به طور مناسبی تفکیک مناسبی بین بافت‌های مغز ایجاد کرد. در ادامه یک شبکه عصبی پیچشی برای ناحیه بندی تصاویر پیش‌پردازش شده و به دست آوردن نواحی بافت‌های مغز ارائه شد. برای ناحیه بندی مقاوم در برابر تصاویر تهیه شده از روش‌های افزایش داده استفاده شد. نتایج به دست آمده نشان‌دهنده کارایی مناسب روش پیشنهادی در ناحیه بندی تصاویر مغز پایگاه‌های داده استاندارد است به طوری که برای پایگاه داده iSeg-2017 به ترتیب دایس 0/1873، 0/898 و 0/937 و برای پایگاه داده iSeg-2019 به ترتیب دایس 0/767، 0/749 و 0/774 برای نواحی سفید، خاکستری و مایع مغزی به دست آمده است.

- **افزایش کنتراست:** توسط این روش، یک نسخه از تصویر هر برش ایجاد می‌شود که در آن کنتراست تصویر بهبود یافته است. برای افزایش کنتراست از روش متعادل سازی کنتراست استفاده شده است. با انجام روش‌های ذکر شده، پایگاه داده آموزش به طور موثری بزرگتر می‌شود که این به آموزش بهتر مدل نیز کمک می‌کند. در شکل (7)، برخی از نسخه‌های به دست آمده از روش‌های مختلف افزایش داده نشان داده شده است.

از آنجا که دو مدالیته T1 و T2 در اختیار است، دو مدل U-net آموزش داده می‌شود تا پیش‌پردازش برای هر مدالیته به طور مجزا انجام شود. با آموزش مدل U-net توسط داده آموزش افزایش یافته، می‌توان از آن برای انجام پیش‌پردازش بر روی تصاویر تست استفاده کرد. در شکل (8)، چند نمونه از تصاویر پیش‌پردازش شده توسط روش پیشنهادی به ازای پایگاه داده iSeg 2017 و iSeg 2019 ارائه شده است.



شکل (7): روش‌های مختلف افزایش داده استفاده شده برای آموزش مدل u-net: (الف) تصویر برش اصلی، (ب) افزایش روشنایی توسط تابع گاما، (ج) کاهش شدت روشنایی توسط تابع گاما، (د) تصویر با کنتراست افزایش یافته، (ه) انعکاس افقی، (و) انعکاس عمودی، (ز) جابجایی به سمت بالا، (ح) جابجایی به سمت پایین و چپ



شکل (8): نتایج پیش‌پردازش به دست آمده توسط روش پیشنهادی: (الف) تصویر T2، (ب) تصویر پیش‌پردازش شده T2، (ج) تصویر پیش‌پردازش شده T1، (د) تصویر T1

جدول ۸: مقایسه نتایج به دست آمده توسط روش پیشنهادی با سایر

روش‌ها برای پایگاه داده iSeg 2017

روش	بافت سفید (WM)		بافت خاکستری (GM)		مایع مغز (CSF)	
	ASD	Dice	ASD	Dice	ASD	Dice
پیشنهادی	0.478	0.873	0.406	0.898	0.184	0.937
Uoff-Bioluming	0.517	0.870	0.429	0.895	0.162	0.94
BIGS2	0.496	0.871	0.409	0.893	0.144	0.949
LRDE	0.521	0.864	0.451	0.888	0.197	0.929
Authman	0.564	0.846	0.495	0.872	0.224	0.917

جدول ۹: مقایسه نتایج به دست آمده توسط روش پیشنهادی با سایر

روش‌ها برای پایگاه داده iSeg 2019

روش	بافت سفید (WM)		بافت خاکستری (GM)		مایع مغز (CSF)	
	ASD	Dice	ASD	Dice	ASD	Dice
پیشنهادی	0.803	0.767	0.704	0.749	0.696	0.774
MASI	1.33	0.67	0.429	0.895	0.162	0.94

مراجع

- [1] G. Li, et al., *Mapping Region-Specific Longitudinal Cortical Surface Expansion from Birth to 2 Years of Age, Cerebral Cortex*, vol. 23, pp. 2724-2733, Nov 2013.
- [2] L. Wang, et al., *Segmentation of Neonatal Brain MR Images Using Patch-Driven Level Sets*, NeuroImage, vol. 84, pp. 141-158, Jan 1, 2014.
- [3] L. Wang, et al., *Links: Learning-Based Multi-Source Integration Framework for Segmentation of Infant Brain Images*, NeuroImage, vol. 108, pp. 160-72, Mar 2015.
- [4] F. Shi, et al., *Neonatal Atlas Construction Using Sparse Representation*, Human Brain Mapping, vol. 35, pp. 4663-4677, Sep 2014.
- [5] F. Shi, et al., *Construction of Multi-Region-Multi-Reference Atlases for Neonatal Brain MRI Segmentation*, NeuroImage, vol. 51, pp. 684-693, Jun 2010.
- [6] Devi, C. N., et al., *Automatic segmentation of infant brain MR images: With special reference to myelinated white matter*, Biocybernetics and Biomedical Engineering, vol. 37, no. 1, pp. 143-158, 2017.
- [7] G. Li, et al., *Computational Neuroanatomy of Baby Brains: A Review*, NeuroImage, vol. 185, pp. 906-925, 2018.
- [8] George, M. M., et al., *A view on atlas-based neonatal brain MRI segmentation*. ICTMI 2017, pp. 199-214, 2019.
- [9] Mostapha, M. et al., *Role of deep learning in infant brain MRI analysis. Magnetic resonance imaging*, vol. 64, pp.171-189, 2019.
- [10] Wu, Z., et al, *Construction of 4D infant cortical surface atlases with sharp folding patterns via spherical patch-based group-wise sparse representation*, Human brain mapping, vol. 40, no. 13, pp. 3860-3880, 2019.
- [11] Iclănzan, D., et al., *The role of atlases and multi-atlases in brain tissue segmentation based on multispectral magnetic resonance image data*. In 2021 IEEE AFRICAN, pp. 1-6, 2021.
- [12] Wang, J., et al., *Multi-atlas segmentation of subcortical brain structures via the AutoSeg software pipeline*, Frontiers in neuroinformatics, vol. 8, pp. 7-15, 2014.
- [13] Dong, P., et al., *Multi-atlas and multi-modal hippocampus segmentation for infant MR brain images by propagating anatomical labels on hypergraph*, In International

جدول ۵: پارامترهای آموزش مدل CNN

پارامتر	مقدار
نرخ یادگیری	۰/۰۱
تعداد تکرار	۱۰۰
mini-batch	۲۵۶
ضریب کاهش نرخ یادگیری	۰/۸
تابع هزینه	آنتروپی باینری

جدول ۶: نتایج به دست آمده توسط روش پیشنهادی برای پایگاه داده

iSeg 2017

تصویر تست	بافت سفید (WM)			بافت خاکستری (GM)			مایع مغز (CSF)		
	ASD	MHD	Dice	ASD	MHD	Dice	ASD	MHD	Dice
11	0.411	7.87	0.887	0.339	6.40	0.912	0.139	6.48	0.948
12	0.535	5.38	0.840	0.440	5	0.882	0.169	7.07	0.936
13	0.467	8.12	0.885	0.394	8.06	0.907	0.172	11.9	0.943
14	0.457	6.16	0.878	0.417	8.24	0.898	0.199	9	0.925
15	0.443	6.32	0.884	0.369	6.40	0.912	0.137	7.874	0.948
16	0.473	8.77	0.884	0.403	7.87	0.896	0.168	11	0.94
17	0.412	6.48	0.887	0.353	7.21	0.904	0.152	8.124	0.943
18	0.460	7.68	0.879	0.379	8.06	0.900	0.149	9.48	0.948
19	0.465	7.21	0.885	0.385	7.34	0.900	0.151	9	0.944
20	0.610	8.30	0.832	0.506	7.28	0.879	0.244	13.9	0.927
21	0.464	6.16	0.876	0.384	6.70	0.902	0.1615	9.27	0.939
22	0.506	7.07	0.872	0.447	7	0.902	0.189	10.8	0.926
23	0.510	7.61	0.866	0.467	11.2	0.887	0.368	16.03	0.915
میانگین	0.478	7.16	0.873	0.406	7.44	0.898	0.184	10.00	0.937
انحراف معیار	0.053	1.00	0.018	0.047	1.43	0.010	0.062	2.722	0.010

جدول ۷: نتایج به دست آمده توسط روش پیشنهادی برای پایگاه داده

iSeg 2019

تصویر تست	بافت سفید (WM)			بافت خاکستری (GM)			مایع مغز (CSF)		
	ASD	MHD	Dice	ASD	MHD	Dice	ASD	MHD	Dice
24	0.772	7.810	0.780	0.674	7.07	0.775	0.595	10.77	0.813
25	0.762	8.774	0.773	0.661	6.32	0.772	0.556	11.66	0.799
26	0.735	7.141	0.804	0.674	7.34	0.782	0.672	11.53	0.728
27	0.702	6.70	0.797	0.635	7.81	0.778	0.571	10.24	0.801
28	0.699	8.36	0.807	0.635	9.27	0.791	0.559	12.36	0.813
29	0.708	8	0.820	0.653	8.48	0.778	0.601	9.848	0.799
30	1.067	9.43	0.675	0.917	9	0.646	1.421	19.26	0.620
31	0.854	8.60	0.766	0.758	9.16	0.728	0.817	13.56	0.778
32	0.869	9.64	0.735	0.787	8.18	0.698	1.015	13.03	0.701
33	0.730	9.69	0.797	0.714	7.87	0.739	0.868	13.30	0.746
34	0.835	10.72	0.760	0.781	8.77	0.710	1.039	14.17	0.707
35	0.865	9.53	0.735	0.698	8.06	0.757	0.453	10.05	0.845
36	0.898	8.77	0.727	0.725	8.12	0.749	0.458	10.81	0.845
37	0.783	7.87	0.758	0.652	8.06	0.765	0.485	10.19	0.782
38	0.807	11.18	0.765	0.665	13.60	0.742	0.544	9.38	0.786
39	0.767	7.81	0.769	0.634	6.55	0.767	0.471	9.9	0.825
میانگین	0.803	8.75	0.767	0.704	8.35	0.749	0.696	11.88	0.774
انحراف معیار	0.095	1.22	0.036	0.075	1.64	0.038	0.271	2.47	0.060



- [29] Good, I. J. *Rational Decisions*. Journal of the Royal Statistical Society. Series B (Methodological), vol. 14, no. 1, pp. 107–114, 1952.
- Workshop on Patch-based Techniques in Medical Imaging Springer, pp. 188-196, 2015.
- [14] Puonti, O., Iglesias, J.E. and Van Leemput, K., *Fast and sequence-adaptive whole-brain segmentation using parametric Bayesian modeling*. NeuroImage, Vol. 143, pp. 235-249, 2016.
- [15] Makropoulos, A., Counsell, S.J., Rueckert, D., *A review on automatic fetal and neonatal brain MRI segmentation*. NeuroImage, Vol. 170, pp. 231-248, 2018.
- [16] Guo, Y., Wu, Z. and Shen, D., *Learning longitudinal classification-regression model for infant hippocampus segmentation*. Neurocomputing, Vol. 391, pp.191-198, 2020.
- [17] Dolz, J., Desrosiers, C., Wang, L., Yuan, J., Shen, D. and Ayed, I.B., *Deep CNN ensembles and suggestive annotations for infant brain MRI segmentation*. Computerized Medical Imaging and Graphics, Vol. 79, p.101660, 2020.
- [18] Bui, T.D., Shin, J. and Moon, T., *Skip-connected 3D DenseNet for volumetric infant brain MRI segmentation*. Biomedical Signal Processing and Control, 54, p.101613, 2019.
- [19] Chen, Y., Qin, Y., Jin, Z., Fan, Z. and Cai, M., *A Triple Residual Multiscale Fully Convolutional Network Model for Multimodal Infant Brain MRI Segmentation*. KSII Transactions on Internet and Information Systems (TIIS), Vol. 14, pp.962-975, 2020.
- [20] Qamar, S., Jin, H., Zheng, R., Ahmad, P. and Usama, M., *A variant form of 3D-UNet for infant brain segmentation*. Future Generation Computer Systems, Vol. 108, pp.613-623, 2020.
- [21] Karayegen, G. and Aksahin, M.F., *Brain tumor prediction on MR images with semantic segmentation by using deep learning network and 3D imaging of tumor region*. Biomedical Signal Processing and Control, Vol. 66, p.102458, 2021.
- [22] Pasban, S., Mohamadzadeh, S., Zeraatkar-Moghaddam, J. and Shafiei, A.K., *Infant brain segmentation based on a combination of VGG-16 and U-Net deep neural networks*. IET Image Processing, Vol. 14, pp.4756-4765, 2021.
- [23] Ding, W., Abdel-Basset, M., Hawash, H., & Pedrycz, W. (2022). Multimodal infant brain segmentation by fuzzy-informed deep learning. *IEEE Transactions on Fuzzy Systems*, 30(4), 1088-1101
- [24] Saladi, S., Karuna, Y., Koppu, S., Reddy, G. R., Mohan, S., Mallik, S., & Qin, H. (2023). Segmentation and analysis emphasizing neonatal MRI brain images using machine learning techniques. *Mathematics*, 11(2), 285.
- [25] Chen, L., Wu, Z., Zhao, F., Wang, Y., Lin, W., Wang, L., & Li, G. (2023). An attention-based context-informed deep framework for infant brain subcortical segmentation. *Neuroimage*, 269, 119931.
- [26] Wang, L., Nie, D., Li, G., Puybureau, É., Dolz, J., Zhang, Q., Wang, F., Xia, J., Wu, Z., Chen, J.W. and Thung, K.H., *Benchmark on automatic six-month-old infant brain segmentation algorithms: the iSeg-2017 challenge*. IEEE transactions on medical imaging, Vol. 38, pp.2219-2230, 2019.
- [27] Sun, Yue, Kun Gao, Zhengwang Wu, Guannan Li, Xiaopeng Zong, Zhihao Lei, Ying Wei. *Multi-site infant brain segmentation algorithms: The iSeg-2019 Challenge*. IEEE Transactions on Medical Imaging Vol. 5, pp. 1363-1376, 2021.
- [28] Diederik P. Kingma and Jimmy Lei Ba. *Adam: A method for stochastic optimization*. arXiv:1412.6980v9, 2014.

