



Computational Intelligence in Electrical Engineering
Vol. 15, No. 3, 2024
pp. 99-116
Research Paper

Automatic Segmentation of Ischemic Stroke Lesions in CT Perfusion Maps Using Deep Learning Networks

Lida Zare Lahijan¹, Saeed Meshgini^{*2}, Reza Afrouzian³

¹ Phd Student, Department of Biomedical Engineering, Faculty of Electrical and Computer Engineering, University of Tabriz, Tabriz, Iran

² Associate Prof, Department of Biomedical Engineering, Faculty of Electrical and Computer Engineering, University of Tabriz, Tabriz, Iran

³ Assistant Professor, Department of Biomedical Engineering, Faculty of Electrical and Computer Engineering, University of Tabriz, Tabriz, Iran

Abstract:

Stroke is the third leading cause of death and the largest cause of acquired disability worldwide. Classification of stroke lesions is vital in recovery, diagnosis, outcome assessment, and treatment planning. The current standard approach for segmenting ischemic stroke lesions is based on thresholding of computed tomography perfusion (CTP) maps. However, this detection approach is inaccurate (the dice similarity coefficient is around 68%). Accordingly, several machine learning-based techniques have recently been proposed to improve the segmentation accuracy of ischemic stroke lesions. Although these studies have achieved significant results, they still need to be improved before being used in real practice. This research presents a new technique based on deep learning for the segmentation of ischemic stroke lesions in CTP maps. The proposed network architecture includes the 7 Graph Convolutional layer, which can automatically perform feature selection/extraction and classify the resulting feature vector. In this study, the ISLES 2018 database was used to train the proposed network. The indices of the Dice Similarity coefficient and Jaccard Index based on the proposed model are 75.41% and 74/52%, respectively, which is a significant improvement compared to recent studies. In addition, the performance of the proposed model in noisy environments is very promising; so, at SNR=-4, the accuracy of networks is still above 60%.

Keywords: Ischemic Stroke, CT Images, Deep Learning Networks, CNN.



This is an open access article under the CC BY-NC-ND/4.0/ License (<https://creativecommons.org/licenses/by-nc-nd/4.0/>).



<https://doi.org/10.22108/ISEE.2024.140996.1681>

تقسیم‌بندی خودکار ضایعات سکنه مغزی ایسکمیک در نقشه‌های پرفیوژن CT با استفاده

از شبکه‌های یادگیری عمیق

لیدا زارع لاهیجان^۱، سعید مشگینی^۲، رضا افروزیان^۳

۱- دانشجوی دکتری، دانشکده مهندسی برق و کامپیوتر، دانشگاه تبریز، تبریز، ایران

lidazare@tabrizu.ac.ir

۲- دانشیار، دانشکده مهندسی برق و کامپیوتر، دانشگاه تبریز، تبریز، ایران

meshgini@tabrizu.ac.ir

۳- استادیار، دانشکده مهندسی برق و کامپیوتر، دانشگاه تبریز، تبریز، ایران

afroiuzian@tabrizu.ac.ir

چکیده: سکنه مغزی را می‌توان سومین علت مرگ‌ومیر و بزرگ‌ترین عامل ناتوانی اکتسابی در سراسر جهان به شمار آورد. تقسیم‌بندی ضایعات سکنه مغزی نقشی حیاتی را در بهبود، تشخیص، ارزیابی نتیجه و برنامه‌ریزی برای درمان پ ایفا می‌کند. رویکرد استاندارد فعلی که برای تقسیم‌بندی ضایعات سکنه مغزی ایسکمیک وجود دارد بر اساس آستانه‌گذاری نقشه‌های پرفیوژن توموگرافی کامپیوتری (CTP) است؛ با این حال، این رویکرد تشخیص به اندازه کافی دقیق نیست (ضریب تشابه تاس (DSC) حدود ۶۸ درصد است). بر همین اساس، تکنیک‌های متعدد مبتنی بر یادگیری ماشین به‌تازگی برای بهبود صحت تقسیم‌بندی ضایعات سکنه مغزی ایسکمیک پیشنهاد شده‌اند. اگرچه این مطالعه‌ها به نتایجی جالب توجه دست یافته‌اند، هنوز باید قبل از استفاده در عمل بهبود یابند. این پژوهش تکنیکی جدید مبتنی بر یادگیری عمیق را برای تقسیم‌بندی ضایعات سکنه مغزی ایسکمیک در نقشه‌های CTP ارائه می‌کند. معماری شبکه پیشنهادی شامل پنج لایه کانولوشنال گراف است که می‌تواند عمل انتخاب/استخراج ویژگی را به صورت خودکار انجام دهد و بردار ویژگی حاصل را طبقه‌بندی کند. در این مطالعه، از پایگاه داده ISLES 2018 به منظور آموزش شبکه پیشنهادی استفاده شده است. شاخص‌های ضریب تشابه تاس و ضریب جاکارد بر اساس مدل پیشنهادی به ترتیب ۷۵/۴۱ و ۷۴/۵۲ درصد هستند که در مقایسه با مطالعه‌های گذشته بهبودی جالب توجه داشته‌اند. علاوه بر این، عملکرد مدل پیشنهادی در محیط‌های نویزی بسیار امیدوارکننده است؛ به طوری که در SNR=-4، صحت شبکه هنوز هم بیشتر از ۶۰ درصد است.

واژه‌های کلیدی: سکنه مغزی ایسکمیک، تصاویر سی‌تی، شبکه‌های یادگیری عمیق، شبکه‌های کانولوشنال عمیق.

۱- مقدمه

سکنه مغزی^۱ یکی از علل اصلی مرگ‌ومیر و ناتوانی در سراسر جهان است که سالانه ۱۵ میلیون نفر را تحت

تأثیر قرار می‌دهد [۱]. از این تعداد، نیمی از کسانی که پس از سکنه مغزی زنده می‌مانند، دچار ناتوانی مزمن می‌شوند [۲]. تقریباً ۹۰ درصد سکنه‌های مغزی از نوع ایسکمیک^۲ هستند که توسط یک شریان مسدود شده ایجاد می‌شوند و به کاهش جریان خون در مغز، ایسکمی بافتی و آنفارتکتوس^۳ منجر می‌شوند [۳]. سکنه مغزی ناشی از نوع دوم به دلیل ترکیب‌گی یا پارگی یک رگ خونی ضعیف شده به وجود می‌آید [۴]. مطابق گزارش سازمان غذا و دارو، ۸۷ درصد از سکنه‌های مغزی در ایالات متحده از نوع ایسکمیک و ۱۳ درصد از نوع هموراژیک^۴ هستند. از جمله

^۱ تاریخ ارسال مقاله: ۱۴۰۲/۱۲/۲۸

تاریخ پذیرش مقاله: ۱۴۰۳/۰۶/۰۳

نام نویسنده مسئول: سعید مشگینی

نشانی نویسنده مسئول: ایران، تبریز، دانشگاه تبریز، دانشکده مهندسی برق و کامپیوتر

پارامترهای مهم در عوامل عمده سکنه مغزی می‌توان به سن، جنسیت، نژاد و قومیت اشاره کرد. همچنین، از عوامل بالینی می‌توان به داشتن بیماری زمینه‌ای از جمله فشارخون بالا، بیماری‌های قلبی و دیابت اشاره کرد. علاوه بر این، برای پارامترهای سبک زندگی می‌توان کم‌تحركی، چاقی، تغذیه نامناسب، مصرف دخانیات و الکل را در نظر گرفت [۵]. تشخیص سکنه مغزی شامل یک تاریخچه پزشکی دقیق، معاینه فیزیکی، عصبی و یک آزمایش تصویربرداری مغزی مانند اسکن CT یا تصویربرداری رزونانس مغناطیسی (MRI) است که به منظور رد سایر احتمالات در تشخیص از جمله تومورهای مغزی، انتخاب نوع روش جراحی و تجویز دارو به منظور حل کردن لخته‌های خونی انجام می‌شود [۶].

تشخیص و بخش‌بندی خودکار ضایعه‌های سکنه مغزی ایسکمیک به صورت سنتی با به‌کارگیری روش سنتی و استفاده از رادیولوژیست عصبی انجام می‌شود. در روش سنتی، رادیولوژیست عصبی به صورت بصری ناحیه آنفارکتوس یا سایه را شناسایی و پزشک متخصص را از نوع عروق لخته‌شده مطلع می‌کند [۷]؛ با این حال، نوع ضایعه‌ها با یکدیگر همسان نیستند و از لحاظ شکل ظاهری، اندازه و محل قرارگیری متفاوت هستند. به این ترتیب، تفسیر و تشخیص از تصاویر تصویربرداری مغزی فرآیندی پیچیده است و به دانش تخصصی نیاز دارد [۸]. علاوه بر این، تفسیر سنتی ضایعه‌های سکنه مغزی توسط رادیولوژیست عصبی فرآیندی زمان‌بر، مستعد خطا و دارای دقت کم است [۹]. همچنین، در صورت تشخیص اشتباه ممکن است پیامدهایی جبران‌ناپذیر را به همراه داشته باشد. به علاوه، ممکن است کنتراست تصاویر اخذشده کم باشد و رادیولوژیست عصبی به دلیل وجود نویز در تصاویر نتواند تشخیصی درست از ناحیه ضایعه و عروق گرفته‌شده داشته باشد [۱۰]. به‌تازگی، پژوهش‌هایی بسیار در زمینه تشخیص خودکار سکنه مغزی ایسکمیک ارائه شده‌اند که در ادامه، هر یک از آن‌ها را بررسی خواهیم کرد.

سلطان‌پور و همکاران [۱۱] از چهار شبکه U-Net دوبعدی به منظور تقسیم‌بندی خودکار ضایعه سکنه مغزی ایسکمیک استفاده کرده‌اند. در مرحله پیش‌پردازش مدل

این پژوهشگران، نواحی پرت حذف شدند و مجموعه داده با استفاده از چرخش، مقیاس‌بندی و اضافه کردن نویز تقویت شد. در مرحله بعد، شبکه‌های U-Net موازی توسط نقشه‌های پرفیوژن توموگرافی کامپیوتری (CTP)^۶ آموزش داده شدند. عملکرد تقسیم‌بندی مدل این پژوهشگران با استفاده از معیارهای ضریب تشابه تاس (DSC)^۷ و شباهت حجمی ارزیابی شد و از مجموعه داده‌های چالش ISLES 2018 به منظور استفاده در مجموعه آموزش و ارزیابی شبکه استفاده شد. لیو^۸ و همکاران [۱۲] از تصاویر CTP به منظور بخش‌بندی خودکار ضایعه سکنه مغزی ایسکمیک استفاده کردند. این پژوهشگران در مدل پیشنهادی خود از شبکه‌های مولد تخصصی (GANs)^۹ به منظور تولید تصویربرداری بر وزن انتشار (DWI)^{۱۰} استفاده کردند. به طور کلی، ساختار شبکه کانولوشنال^{۱۱} این پژوهشگران شامل یک مولد، یک تفکیک‌کننده^{۱۲} و یک تقسیم‌کننده^{۱۳} است. DSC این پژوهشگران بر اساس اعتبارسنجی ۴-برابری^{۱۴} ۴۹ درصد گزارش شده است. دولز^{۱۵} و همکاران [۱۳] به منظور تقسیم‌بندی ضایعات سکنه مغزی ایسکمیک از شبکه‌های U-Net اصلاح‌شده استفاده کردند. معماری این پژوهشگران از سه جنبه مختلف دارای اهمیت بود. اول اینکه، به جای ترکیب مودالیت‌های تصویر موجود در یک ورودی، هر یک از آن‌ها در مسیری متفاوت پردازش شده‌اند تا از اطلاعات منحصربه‌فرد با عملکردی بهتر بهره‌برداری شود. دوم اینکه، شبکه پیشنهادی این پژوهشگران به طور متراکم متصل بود (هر لایه به تمام لایه‌های بعدی متصل است). سوم اینکه، این پژوهشگران با الهام از مدل شبکه Inception ماژول‌های استاندارد U-Net را با دو بلوک کانولوشن پیچشی در لایه‌های ورودی به منظور عملکرد بهتر در مقیاس‌های متفاوت بهبود داده‌اند. نتایج این پژوهش نشان داد اطلاعات چندوجهی می‌توانند در مقایسه با راهبردهای ساده‌تر، عملکردی بهتر را از خود به نمایش بگذارند. ونگ^{۱۶} و همکاران [۱۴] چارچوبی جدید مبتنی بر DWI از نقشه‌های CTP را برای به دست آوردن کیفیت بهتر به منظور تقسیم‌بندی دقیق‌تر ضایعه‌های مغزی ارائه کردند. مدل پیشنهادی این

مطابق بررسی‌های پژوهش‌های پیشین، هر کدام از این مطالعه‌ها دارای مزایا و معایبی بوده است؛ با این حال، مشکل اساسی در بخش‌بندی خودکار ضایعات سکنه مغزی، DSC کمتر از ۶۸ درصد است. علاوه بر این، تقریباً تمامی شبکه‌های پیشین بازدهی عملیاتی در محیط‌های نویزی را ندارند که این امر استفاده از الگوریتم پیشنهادی پژوهشگران را در کاربردهای بلادرنگ در حضور عدم قطعیت‌های مختلف همچون نویز به منظور بخش‌بندی تصاویر زیر سؤال می‌برد. روش پیشنهادی این پژوهش مبتنی بر شبکه‌های گراف کانولوشنال عمیق است که در نظر دارد از چالش‌های مربوط گذر کند تا بتوان از آن در کاربرد عملی به عنوان دستیار پزشکی برای بخش‌بندی خودکار سکنه مغزی ایسکمیک استفاده کرد. نوآوری مطالعه حاضر را می‌توان در موارد زیر جست‌وجو کرد:

الف) ارائه مدلی خودکار و پایان به پایان بر اساس ترکیب نظریه گراف و شبکه‌های کانولوشنال عمیق بدون نیاز به بلوک دیاگرام انتخاب/استخراج ویژگی.
ب) دستیابی به بیشترین مقادیر صحت^{۲۲} و DSC در مقایسه با پژوهش‌های گذشته به منظور بخش‌بندی خودکار ضایعه سکنه مغزی ایسکمیک با استفاده از تصاویر پرفیوژن CT.

پ) ارائه مدلی خودکار با قابلیت مقاومت زیاد در مقابل نویزهای محیطی تا محدوده $SNR=4$ dB.

ادامه مقاله به صورت زیر سازمان یافته است: بخش دوم پایگاه داده استفاده‌شده را به همراه نظریه ریاضی شبکه‌های گراف کانولوشنال بررسی می‌کند. بخش سوم روش پیشنهادی پژوهش حاضر را ارائه می‌دهد. بخش چهارم نتایج شبیه‌سازی را بر اساس روش پیشنهادی ارائه‌شده مشخص می‌کند و در نهایت، بخش پنجم مربوط به نتیجه‌گیری است.


۲- مواد و روش‌ها

در این بخش، ابتدا پایگاه داده مربوط به نقشه‌های سکنه مغزی ایسکمیک شرح داده می‌شود. سپس، پیش‌زمینه ریاضی مربوط به شبکه‌های گراف کانولوشنال بررسی خواهد شد.

پژوهشگران شامل سه مؤلفه مبتنی بر شبکه‌های عصبی کانولوشنال (CNN)^{۱۷} بود که به صورت سرتاسر و پایان به پایان آموزش داده می‌شد. این پژوهشگران در مسابقه چالش تصاویر ISLES 2018 رتبه اول را به دست آوردند. آلبرت^{۱۸} و همکاران [۱۵] با استفاده از تصاویر CTP و CT، سکنه مغزی ایسکمیک را به طور خودکار بخش‌بندی کرده‌اند. به این منظور، این پژوهشگران از مجموعه داده چالشی ISLES استفاده کرده‌اند. همچنین، آن‌ها به منظور بخش‌بندی تصاویر از یک شبکه U-Net بهبودیافته استفاده کردند. مجموعه ارزیابی نمونه‌ها شامل ۹۴ تصویر ضایعه برای آموزش شبکه و ۶۲ تصویر برای بخش آزمون شبکه بود. نحوه ارزیابی شبکه پیشنهادی آن‌ها بر اساس روش ۱۰-برابری انجام شده است و در نهایت، DSC حاصل شده برابر ۴۹ درصد به منظور بخش‌بندی تصاویر توسط این پژوهشگران گزارش شده است. می‌توان دقت کم در تشخیص ضایعات را از جمله معایب این پژوهش در نظر گرفت. غنمات^{۱۹} و همکاران [۱۶] مدلی جدید را بر اساس رویکردهای یادگیری عمیق^{۲۰} به منظور بخش‌بندی ضایعه سکنه مغزی ایسکمیک ارائه کردند. این پژوهشگران در این کار از فاصله اقلیدسی برای محاسبه میانگین فاصله هر پیکسل در جهت راست و پایین استفاده کردند. آن‌ها توانستند ضریب تشابه تاس را نسبت به پژوهش‌های اخیر ۲/۵ درصد بهبود ببخشند. راجو^{۲۱} و همکاران [۱۷] از شبکه‌های U-Net به منظور بخش‌بندی و تشخیص خودکار سکنه مغزی ایسکمیک استفاده کرده‌اند. آن‌ها یک مدل عمیق مشتق‌شده از U-Net را در پژوهش خود ارائه داده‌اند که می‌توانست تمامی نقشه‌های CTP را به طور موازی و مستقل پردازش کند. ضریب تشابه تاس گزارش شده توسط این پژوهشگران حدود ۴۲ درصد بود. سلطان‌پور و همکاران [۱۸] یک شبکه عصبی عمیق را به منظور بخش‌بندی خودکار ضایعه سکنه مغزی ایسکمیک ارائه کردند. به این منظور، در این پژوهش، از معماری اصلاح‌شده شبکه U-Net استفاده شد. در داخل این شبکه، از CNNهای چندمقیاسی و اتصالات میان‌بر مبتنی بر CNN استفاده شده بود. نتیجه نهایی گزارش شده توسط آن‌ها دارای شاخص تشابه تاس ۶۸ درصد بود.

۲-۱- پایگاه داده ISLES 2018

پایگاه داده ISLES 2018 به عنوان جامع‌ترین مجموعه داده به منظور بخش‌بندی خودکار سکته مغزی ایسکمیک شناخته می‌شود. می‌توان بقیه پایگاه‌های داده عمومی موجود را مشتقی از این مجموعه داده در نظر گرفت. این پایگاه داده شامل مجموعه داده‌های مربوط به ۱۰۳ بیمار است که با هدف تقسیم‌بندی هسته ضایعه سکته مغزی از تصاویر CTP اخذ شده است. همچنین، این مجموعه داده شامل اسکن‌های CTP چهاربعدی، نقشه‌های CTP سه‌بعدی شامل CBF، MTT، CBV و Tmax است. نمونه‌ای از این نقشه‌ها در شکل (۱) نمایش داده شده است. در این پایگاه، هر بیمار در عرض ۳ ساعت از تصویربرداری CTP پایه، تحت DW-MRI قرار گرفته است تا اعتبارسنجی توسط متخصص رادیولوژی انجام شود. تصاویر به صورت قطعه‌قطعه با تعداد برش محوری متغیر، از ۲ تا ۲۲ قطعه بسته به بیمار، با فاصله ۵ میلی‌متری و وضوح ۲۵۶×۲۵۶ اخذ شده‌اند [۱۹].



شکل (۱): نقشه‌های CTP به همراه تصویر طرف مقابل آن‌ها در پایگاه داده ISLES 2018 [۴۴].

۲-۲- شبکه کانولوشنال گراف

ایده اولیه شبکه کانولوشنال گراف^{۳۳} برای اولین بار توسط مایکل دفرارد^{۲۴} و همکاران در سال ۲۰۱۶ مطرح شد [۲۰]. این پژوهشگران برای اولین بار از پردازش سیگنال در حوزه گراف و نظریه طیفی گراف^{۲۵} در تعریف تابع کانولوشنی استفاده کرده‌اند که این موضوع امکان استفاده از شبکه‌های کانولوشنی را در قالب نظریه گراف فراهم می‌کند.

در نظریه گراف، داشتن ماتریس درجه و ماتریس مجاورت دارای اهمیتی ویژه است. اتصال هر یک از

رأس‌ها در گراف با استفاده از ماتریس مجاورت حاصل می‌شود. همچنین، با داشتن ماتریس مجاورت، می‌توان ماتریس درجه را نیز به دست آورد. این ماتریس، ماتریس قطری است که درایه‌های قطر آن با مجموع لبه‌های متصل به رأس متناظر با درایه برابر هستند. ماتریس درجه به صورت $D \in R^{N \times N}$ و ماتریس گراف به صورت $W \in R^{N \times N}$ نمایش داده می‌شود و Λ امین عنصر قطری ماتریس درجه به صورت زیر تعریف می‌شود [۲۱]:

$$D_{ii} = \sum_j W_{ij} \quad (1)$$

ماتریس لاپلاسین نیز به صورت رابطه زیر تعریف می‌شود:

$$L = D - W \in R^{N \times N} \quad (2)$$

$$L = U \Lambda U^T$$

مطابق رابطه بالا، همان‌طور که مشخص است، حاصل تفریق دو ماتریس درجه و ماتریس مجاورت ماتریس لاپلاسین را شکل می‌دهد. از این ماتریس به منظور محاسبه توابع پایه گراف استفاده می‌شود. توابع پایه گراف را می‌توان با استفاده از تجزیه به مقادیر تکین (SVD)^{۳۶} در ماتریس لاپلاسین به دست آورد. همچنین، ماتریس لاپلاسین را می‌توان با در نظر گرفتن ماتریس بردارهای ویژه و ماتریس مقادیر تکین به فرم رابطه (۲) تعریف کرد. بر اساس رابطه (۲)، ستون‌های ماتریس بردارهای ویژه با بردارهای ویژه ماتریس لاپلاسین متناظر هستند. تبدیل فوریه نیز بر اساس همین بردارهای ویژه امکان‌پذیر است و پایه‌های فوریه با داشتن مقادیر ویژه قطری شامل $\Lambda = \text{diag}([\lambda_0, \dots, \lambda_{N-1}])$ به صورت رابطه زیر تعریف می‌شوند:

$$U = [u_0, \dots, u_{N-1}] \in R^{N \times N} \quad (3)$$

برای درک بهتر، تبدیل فوریه و عکس تبدیل فوریه یک سیگنال مانند $q \in R^N$ به ترتیب در روابط (۴) و (۵) تعریف می‌شوند:

$$\hat{q} = U^T q \quad (4)$$

$$q = U U^T q = U \hat{q} \quad (5)$$

مشخص می‌شود که از ناحیهٔ مربوطه به دست آمده است. میانگین شدت برای منطقه R_i با میانگین شدت پیکسل در نظر گرفته شد. لبه‌های وزندار گره‌هایی را به یکدیگر مرتبط می‌کنند که نواحی مجاور را نشان می‌دادند. فرمول زیر یک تابع وزندهی گاوسی را نشان می‌دهد که وزن‌ها به واسطهٔ آن به دست می‌آیند:

$$w_{ij} = e^{-\beta d(f_i - f_j)} \quad (9)$$

که در آن:

$$d(f_i - f_j) = \sum_{k=1}^C (f_i^k - f_j^k)^2 \quad (10)$$

و β در اینجا یک پارامتر آزاد است.

یک ماتریس مجاورت ناحیه^{۲۹} $A = [a_{ij}] \in \mathbb{R}^{N \times N}$

مطابق رابطهٔ زیر است:

$$a_{ij} = \begin{cases} 1 & \text{if regions } R_i \text{ and } R_j \text{ are adjacent} \\ 0 & \text{otherwise} \end{cases} \quad (11)$$

پهمنین، یک ماتریس ویژگی ناحیه^{۳۰} $X \in \mathbb{R}^{N \times I}$ وجود دارد که نشان‌دهندهٔ N رأس است که هر کدام دارای ویژگی‌هایی در $\mathbb{R}^{1 \times I}$ است.

۳- روش پیشنهادی

روش پیشنهادی در این مقاله در این بخش ارائه خواهد شد. ساختار اصلی مدل پیشنهادی در شکل (۲) نمایش داده شده است.

۳-۱- پیش‌پردازش داده‌ها

ابتدا، عملیات پیش‌پردازش برای هر تصویر با در نظر گرفتن واحد ضریب هانسفیلد^{۳۱} انجام و شدت پیکسل‌های بیشتر از ۱۵۰ و زیر صفر حذف و با صفر جایگزین می‌شود. سپس، اندازهٔ تصاویر 256×256 با تمرکز بر بخش یادشده در نظر گرفته می‌شود. سپس، به منظور جلوگیری از پدیدهٔ بیش‌برازش، عملیات افزایش دادگان بر روی تصاویر انجام شد. به این منظور، تصاویر $0-20$ درجه به چپ - راست و راست - چپ چرخانده شدند.

بر اساس رابطهٔ (۴)، \hat{q} نمایش‌دهندهٔ تبدیل فوریهٔ گراف است. همچنین، بر اساس رابطهٔ (۵)، بردار ویژگی برای سیگنالی همچون q با داشتن پایه‌های فوریه و تبدیل فوریهٔ گراف امکان‌پذیر است.

عملگر کانولوشن گراف نیز با داشتن کانولوشن دو سیگنال در حوزهٔ گراف توسط تبدیل فوریهٔ هر سیگنال محاسبه می‌شود. برای درک بهتر، کانولوشن دو سیگنال z و y به همراه اپراتور $*$ به صورت رابطهٔ زیر تعریف می‌شود:

$$z *_g = U((U^T z) \square (U^T y)) \quad (6)$$

در رابطهٔ بالا، از تابع فیلترکنندهٔ $g(0)$ برای توصیف یک عملگر کانولوشن گراف در ترکیب با شبکه‌های عصبی استفاده شده است. بر اساس رابطهٔ بالا، Z ورژن فیلترشده توسط $g(L)$ است:

$$y = g(L)z \quad (7)$$

با جای‌گذاری ماتریس لاپلاسین و تجزیه به مقادیر تکین و بردارهای ویژه، کانولوشن گراف به صورت زیر تعریف می‌شود [۲۲]:

$$\begin{aligned} y &= g(L)z = Ug(\Lambda)U^T z \\ &= U(g(\Lambda)) \square (U^T z) \\ &= U(U^T (U *_g(\Lambda))) \square (U^T z) \\ &= z *_g (Ug(\Lambda)) \end{aligned} \quad (8)$$

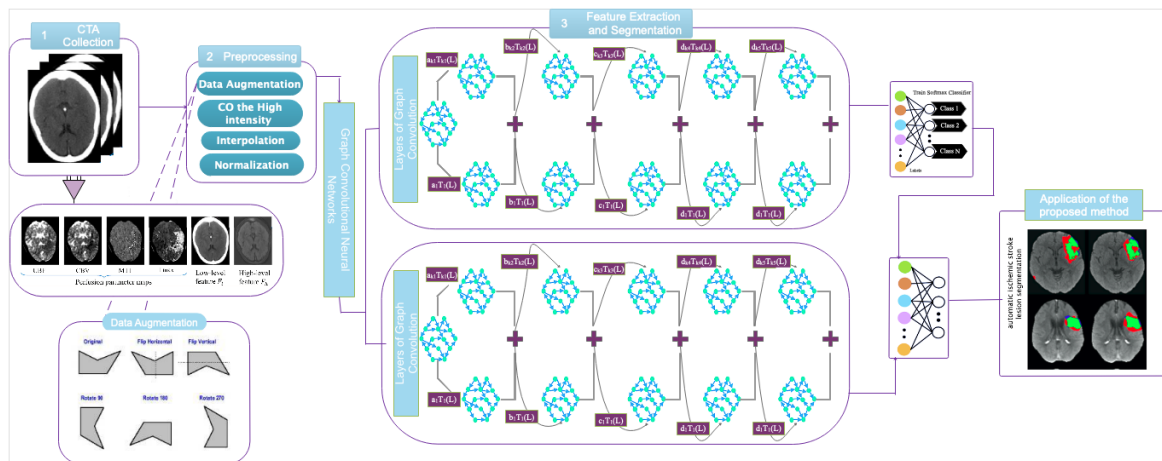
۳-۲- الگوریتم خوشه‌بندی تکراری ساده

تصویر ورودی I با استفاده از تکنیک سوپریکسل الگوریتم خوشه‌بندی تکراری ساده (SLIC)^{۳۲} برای تولید نمودار مجاورت منطقهٔ G به چندین بخش مجزا $\{R_i\}_{i=1}^N$ تقسیم شد [۲۳]. $N = P \times Q / 1000$ تعداد مناطق ارائه‌دهنده، به صورت تصادفی انتخاب شد که $P \times Q$ در اینجا خلاصه‌شدهٔ وضوح فضایی^{۳۸} است. با تقسیم هر کانال بر $2B-1$ که در آن B عمق بیت هر کانال را نشان می‌دهد [۲۳] و مطابق آن ویژگی‌های تصویر در محدودهٔ [۰ و ۱] نرمال می‌شوند، سوپریکسل‌های R_i با رئوس vi در شبکهٔ مجاورت منطقه حاصل مشخص می‌شوند که هر کدام با یک بردار ویژگی یک‌بعدی fi

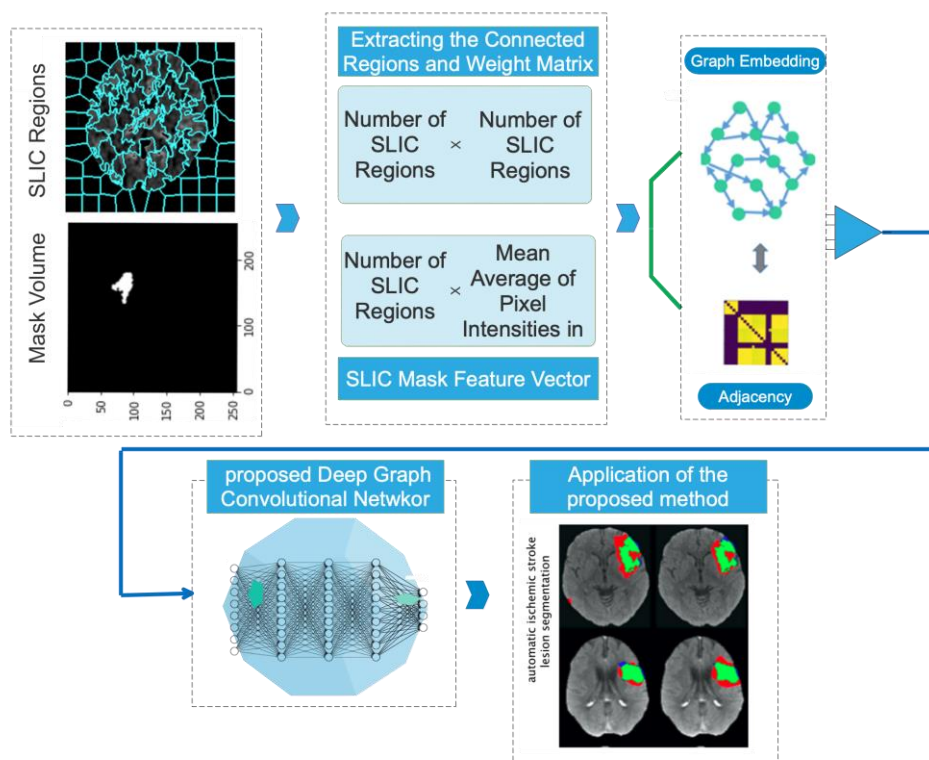
۲-۳- نحوه تشکیل گراف

نمایش گراف از طریق روش خوشه‌بندی تکراری خطی ساده به دست می‌آید. این رویکرد تصاویر را خوشه‌بندی می‌کند و دنباله‌ای از سوپرپیکسل‌ها را به عنوان مناطق مختلف تصویر استخراج می‌کند. شکل (۳) نحوه ایجاد یک گراف را با استفاده از این رویکرد نشان می‌دهد.

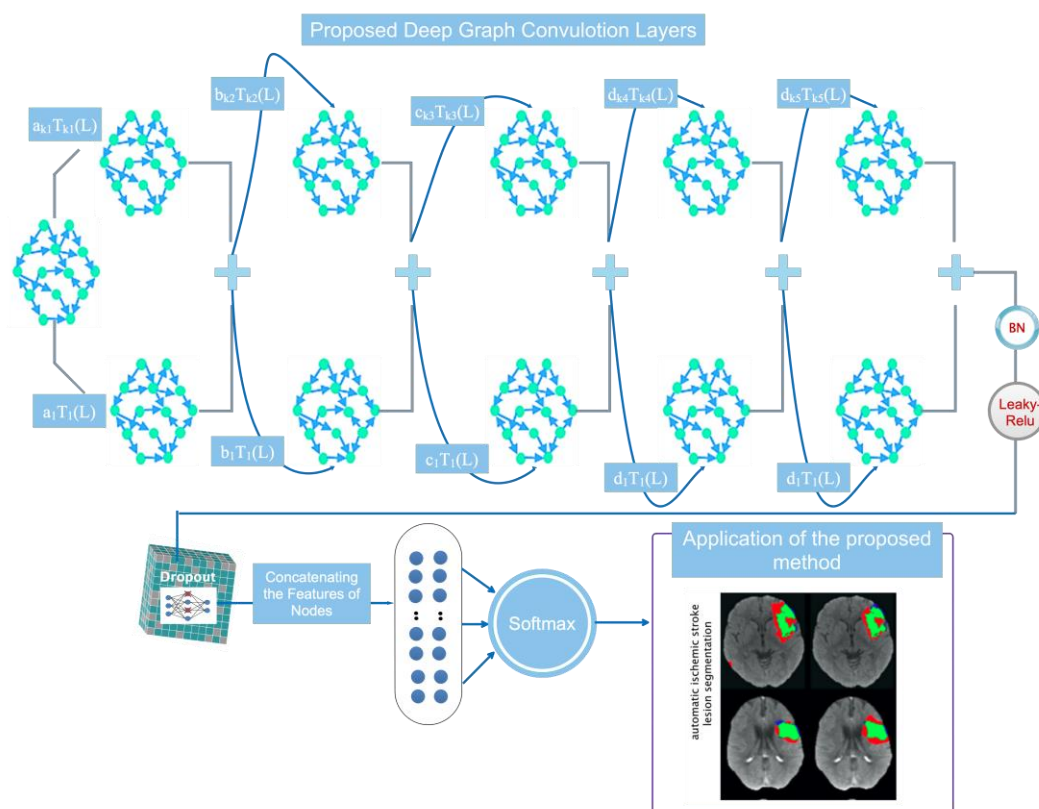
شکل (۳) نشان می‌دهد هر گره از این شبکه با ناحیه‌های سوپرپیکسلی بازیابی شده با استفاده از روش خوشه‌بندی تکراری خطی ساده مطابقت دارد. علاوه بر این، میانگین شدت پیکسل‌ها در هر منطقه به عنوان بردار ویژگی مربوط به هر ناحیه و گره شبکه در نظر گرفته می‌شود. علاوه بر این، لبه‌های نمودار بسته به فاصله و همسایگی هر ناحیه



شکل (۲): بلوک دیاگرام مدل عمیق پیشنهادی به منظور طبقه‌بندی خودکار ضایعه سکنه مغزی ایسکمیک



شکل (۳): نحوه تشکیل گراف از تصاویر CT



شکل (۴): شمای گرافیکی از معماری شبکه پیشنهاد شده

گرفته می‌شود. مستقل از گره‌های شبکه، ابعاد ورودی لایه کانولوشن گراف در معماری پیشنهادی ۱۶ پیکسل است. بعد خروجی لایه اول نیز برابر ۱۶ است که بر اساس آن، گراف در نظر گرفته شده دارای رئوس A و ۱۶ نمونه در هر گره است.

مطابق شکل (۵)، گراف‌های ایجاد شده از مرحله قبل به عنوان ورودی مرحله رمزگذار ویژگی^{۴۰} استفاده می‌شوند و با گره A نمایش داده شده‌اند. لایه کانولوشن گراف دوم یک گراف A -node با ۱۶ نمونه را در هر رأس ایجاد می‌کند. عملیات یاد شده تا زمانی ادامه می‌یابد که گراف پنجم یک گراف A -node با ابعاد ۲ را ایجاد کند. سپس، خروجی استخراج شده از مرحله رمزگذاری ویژگی به یک لایه حذف تصادفی فرستاده می‌شود و گراف A -node حاصل با دو نمونه در هر گره مسطح می‌شود تا بردار عناصر A ایجاد شود. پس از مسطح شدن، بردار وارد یک لایه سافت مکس می‌شود. همچنین، شکل (۵) نشان می‌دهد که ترتیب

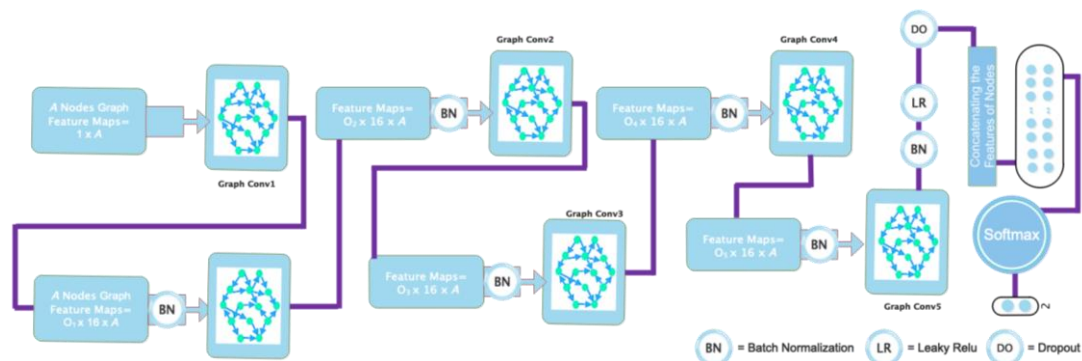
در حین ایجاد یک ماتریس مجاورت گراف بررسی می‌شوند. در تشکیل گراف، مکان‌های همسایه به هم مرتبط هستند؛ اما مناطق غیر همسایه به هم مرتبط نیستند.

۳-۳- معماری شبکه عمیق پیشنهادی

معماری شبکه پیشنهادی در شکل (۴) نمایش داده شده است. مطابق این شکل، مدل پیشنهادی به صورت زیر سازمان یافته است: الف) یک لایه کانولوشن روی یک گراف چیشیف^{۳۳} به همراه نرمال‌ساز دسته‌ای^{۳۳}، تابع فعال‌سازی لیکی-رلو^{۳۴} و فیلتر کردن دسته‌ای^{۳۵}؛ ب) معماری مرحله قبل چهار دفعه دیگر تکرار می‌شود؛ پ) یک لایه حذف تصادفی^{۳۶} به منظور جلوگیری از پدیده بیش‌برازش^{۳۷} (ت) امتیازها در لایه تماماً متصل^{۳۸} با استفاده از تابع سافت مکس^{۳۹} محاسبه می‌شوند. تفاوت در لایه‌های مختلف در شکل (۵) نمایش داده شده است. هر گره در گراف ساخته شده دارای یک نمونه است؛ زیرا بردار ویژگی هر گره میانگین شدت پیکسل در هر ناحیه در نظر

جدول (۱): جزئیات لایه‌های مختلف در معماری پیشنهادی

Layer	Shape of Weight Tensor	Shape of Bias	Number of Parameters
First graph convolution	$(O_1, 16, 16)$	16	$256 \times O_1 + 16$
Batch normalization	(16)	16	32
Second graph convolution	$([O_2, 16, 16)$	16	$256 \times O_2 + 16$
Batch normalization	(16)	16	32
Third graph convolution	$(O_3, 16, 16)$	16	$256 \times O_3 + 16$
Batch normalization	(16)	16	32
Fourth graph convolution	$(O_4, 16, 16)$	16	$256 \times O_4 + 16$
Batch normalization	(16)	16	32
Fifth graph convolution	$(O_5, 16, 2)$	2	$32 \times O_4 + 2$
Batch normalization	(16)	16	32
Softmax layer	-	2	$2 \times A \times O_4$



شکل (۵): معماری شبکه عمیق پیشنهادی به همراه جزئیات لایه‌ها

جدول (۲): پارامترهای بهینه انتخاب شده در معماری شبکه پیشنهادی

مقدار بهینه	فضای جست‌وجو	پارامتر
Adadelata	RMSProp, Adam, Sgd, Adamax, Adadelata	بهینه‌ساز
Cross Entropy	MSE, Cross Entropy	تابع خطا
۵	۱۰ ۷ ۵ ۳	تعداد لایه‌های گراف کانولوشنال
۱۶	۱۲۸ ۶۴ ۳۲ ۱۶	اندازه خروجی در لایه اول
۱۶	۱۲۸ ۶۴ ۳۲ ۱۶	اندازه خروجی در لایه دوم
۱۶	۱۲۸ ۶۴ ۳۲ ۱۶	اندازه خروجی در لایه سوم
۱۶	۱۲۸ ۶۴ ۳۲ ۱۶	اندازه خروجی در لایه چهارم
6×10^{-4}	6×10^{-5} 6×10^{-4}	اندازه بهینه ساز
۰/۳	۰/۵ ۰/۴ ۰/۳ ۰/۲ ۰	مقدار لایه حذف تصادفی
۰/۰۰۰۱	۰/۰۰۰۱ ۰/۰۰۱ ۰/۰۱	نرخ آموزش

آزمون و خطا بر اساس اعتبارسنجی متقاطع ۱۰ برابری آموزش داده شده و ارزیابی شده است. شکل (۶) نحوه تخصیص دادگان را به صورت ساده‌تر نمایش می‌دهد. مطابق این شکل، کل داده‌ها (۱۰۰ درصد) به ۱۰ بازه مساوی (۱۰ درصد) تقسیم می‌شوند. در مرحله اول، بازه ۱ تا ۹ به عنوان مجموعه آموزش انتخاب و بازه باقی‌مانده به عنوان مجموعه آزمون استفاده می‌شود. این تکنیک با

هر لایه کانولوشنال گراف از بسط چندجمله‌ای چیبیشف منحصر به فرد است و توسط ضرایب O_1, O_2, O_3 و O_4 برای پنج لایه کانولوشنال گراف مشخص شده تعیین می‌شود. مشخصات شبکه پیشنهادی به همراه جزئیات لایه‌ها در جدول (۱) نمایش داده شده است.

۳-۴- مجموعه آموزش، ارزیابی و آزمون

شبکه پیشنهادی در این مطالعه با استفاده از رویکرد

پژوهش برای ارزیابی مدل پیشنهادی استفاده شده‌اند که فرمول محاسبه آن‌ها به شرح روابط زیر است:

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (14)$$

$$Precision = \frac{TP}{TP+FP} \quad (15)$$

$$Sensitivity = \frac{TP}{TP+FN} \quad (16)$$

$$kappa = \frac{Pr(a) - Pr(e)}{1 - Pr(e)} \quad (17)$$

مطابق روابط (۱۶-۱۴)، TP مثبت حقیقی، TN منفی حقیقی، FP مثبت کاذب و FN نشان‌دهنده منفی کاذب نمونه‌ها در کلاس‌های طبقه‌بندی است. رابطه (۱۷) نیز نحوه محاسبه کاپا کوهن را نمایش می‌دهد. این ضریب یک شاخص محاسبه آماری است که در آن $Pr(a)$ بیانگر قرارداد نسبی مشاهده شده بین ارزیاب‌ها است و $Pr(e)$ احتمال فرضی قرارداد شانس را نمایش می‌دهد.

شکل (۷) صحت و خطای تاس^{۴۴} روش پیشنهادی را برای تقسیم‌بندی خودکار ضایعه سکنه مغزی ایسکمیک نشان می‌دهد. مطابق همین شکل، همان‌طور که مشاهده می‌شود، ۱۵۰ تکرار برای آموزش و ارزیابی شبکه در نظر گرفته شده‌اند که با افزایش تعداد تکرارها، صحت افزایش و خطا کاهش می‌یابد. بر اساس همین شکل، صحت شبکه در نهایت برای مجموعه آزمون به ۸۳ درصد می‌رسد. شکل (۸) نمونه‌های اصلی تصاویر CT، ماسک باینری و تصویر پیش‌بینی شده از شبکه آموزش دیده را برای بخش‌بندی خودکار سکنه مغزی ایسکمیک به ترتیب از چپ به راست نمایش می‌دهد. ارزیابی مدل پیشنهادی از لحاظ معیارهای صحت، ضریب تشابه تاس، حساسیت، شاخص جاکارد و کاپا کوهن در جدول (۳) ارائه شده است. مطابق این جدول، همان‌طور که مشخص است، معیارهای ارزیابی عملکرد مطلوب شبکه پیشنهادی را تأیید می‌کنند. به علاوه، شاخص آماری کاپا کوهن در محدوده ۰/۸۲ است که نشانگر کارایی مطلوب مدل عمیق پیشنهادی است. به منظور ارزیابی مدل پیشنهادی، تجزیه و تحلیل منحنی مشخصه (ROC)^{۴۵} در شبکه پیشنهادی انجام شد. نتایج این تجزیه و تحلیل در شکل (۹) نشان داده شده

شیت یک‌بازه‌ای تا ۹ مرحله ادامه می‌یابد. بر اساس این روش، همه نمونه‌ها در ارزیابی شرکت می‌کنند و پدیده بیش‌برازش در فرآیند آموزش رخ نمی‌دهد.

جدول (۲) پارامترهای بهینه انتخاب شده برای طراحی معماری پیشنهادی را نشان می‌دهد. همان‌طور که از این جدول مشخص است، از تعداد لایه‌های مختلف، الگوریتم‌های بهینه‌سازی مختلف و غیره استفاده و بهترین مقدار برای معماری پیشنهادی انتخاب شده است.



شکل (۶): نحوه تخصیص دادگان برای مجموعه آموزش و آزمون

۴- یافته‌ها

نتایج مربوط به روش پیشنهادی در این بخش ارائه شده است.

کلیه شبیه‌سازی‌ها در این مطالعه با استفاده از پلت‌فرم کلاب^{۴۱} انجام شده‌اند که مشخصات آن به شرح زیر است: رم ۲۵ گیگابایت و Tesla k90 GPU. نتایج تقسیم‌بندی با استفاده از معیارهای ضریب تشابه تاس و شاخص جاکارد^{۴۲} ارزیابی شد. روابط معیارهای در نظر گرفته شده به صورت زیر هستند:

$$DSC = 2|S \cap T| / (|S| + |T|) \quad (12)$$

$$IoU = |S \cap T| / |S \cup T| \quad (13)$$

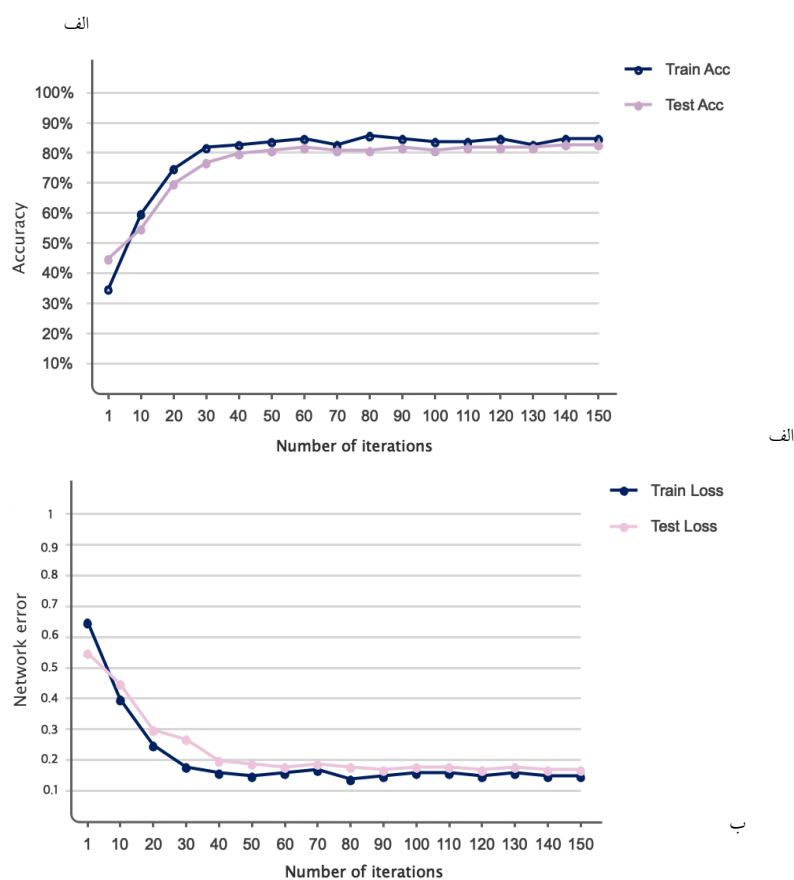
که در آن‌ها S و T به ترتیب نتیجه تقسیم‌بندی و حقیقت عینی را نمایش می‌دهند. همچنین، معیارهایی دیگر از جمله صحت، دقت، حساسیت و کاپا کوهن^{۴۳} در این

شد [۲۴]. این دو شبکه مقایسه‌شده به طور گسترده در مطالعه‌های گذشته در رابطه با تقسیم‌بندی سکنه مغزی ایسکمیک استفاده شده‌اند. نتایج عملکرد از نظر صحت شکل (۱۱) نشان داده شده است. مطابق شکل (۱۱)، همان‌طور که مشاهده می‌شود، شبکه پیشنهادی توانسته است بیشترین صحت را برای تقسیم‌بندی سکنه مغزی ایسکمیک به دست آورد. همچنین، همان‌طور که نشان داده شده است، نرخ نوسان مدل پیشنهادی بسیار کمتر از دو شبکه مقایسه‌شده است که به معماری سفارشی‌شده بر اساس شبکه پیشنهادی مربوط است.


ما اثربخشی روش پیشنهادی خود را با مطالعه‌های گذشته مقایسه کرده‌ایم. نتایج به‌دست‌آمده در جدول (۵) ارائه شده است. بر اساس نتایج به‌دست‌آمده، DSC روش پیشنهادی برای تقسیم‌بندی خودکار سکنه مغزی ایسکمیک ۷۵/۴۱ درصد است؛ در حالی که همین شاخص برای مطالعه‌های [۱۸] و [۱۷] به ترتیب ۶۸ و ۴۲ درصد است.

است. همان‌طور که مشخص است، نمودار به‌دست‌آمده برای تقسیم‌بندی در محدوده ۰/۷ تا ۰/۹ قرار دارد که اثربخشی بهینه شبکه پیشنهادی را نمایش می‌دهد. شکل (۱۰) خوشه‌بندی تصاویر CT را با در نظر گرفتن تعدادی متفاوت از مناطق نشان می‌دهد. برای مقایسه بصری، خوشه‌بندی بر اساس ۲۵، ۵۰، ۱۰۰ و ۱۵۰ ناحیه به طور جداگانه نشان داده شده است. با در نظر گرفتن مصالحه بین نواحی الگوریتم خوشه‌بندی تکراری خطی ساده و صحت تقسیم‌بندی، تعداد ۱۵۰ ناحیه برای به دست آوردن نمودار مربوط انتخاب شد. جزئیات پارامترهای ارزیابی در جدول (۴) نشان داده شده است که به این سه منطقه مختلف مربوط می‌شود. انتخاب ۱۰۰ ناحیه بهترین اثربخشی را از نظر معیارهای صحت، ضریب تشابه تاس و شاخص جاکارد تأیید می‌کند.

به منظور تعیین اثربخشی بهتر مدل پیشنهادی برای تقسیم‌بندی سکنه مغزی ایسکمیک، مدل پیشنهادی با شبکه‌های Modified U-Net و Shortcut CNN مقایسه




شکل (۷): الف. صحت و ب. خطای شبکه پیشنهادی در ۱۵۰ تکرار







شکل (۸): مقایسه الف. تصویر CT، ب. ماسک متناظر و پ. عملکرد مدل پیشنهادی در تشخیص سکنه مغزی ایسکمیک

جدول (۳): عملکرد شبکه پیشنهادی بر اساس شاخص‌های ارزیابی مختلف

عملکرد (%)	شاخص اندازه‌گیری
۸۳/۱	صحت
۷۵/۴۱	ضریب تشابه تاس
۷۴/۵۲	ضریب جاکارد
۷۸	حساسیت
۸۰/۸۹	دقت
۰/۸۲	کاپا کوهن



شکل (۹): تجزیه و تحلیل منحنی ROC




شکل (۱۰): نواحی انتخابی با الگوریتم خوشه‌بندی تکراری ساده
 الف. ۲۵ ناحیه انتخابی، ب. ۵۰ ناحیه انتخابی، پ. ۱۰۰ ناحیه انتخابی و ت. ۱۵۰ ناحیه انتخابی

جدول (۴): نتایج حاصل بر اساس تعداد نواحی انتخاب‌شده مختلف

تعداد ناحیه انتخابی با الگوریتم خوشه‌بندی تکراری ساده				شاخص اندازه‌گیری
۱۵۰	۱۰۰	۵۰	۲۵	
۸۲/۸۵	۸۳/۱	۷۹/۷۴	۷۲/۲۷	صحت
۷۱/۲۵	۷۵/۴۱	۹۱/۶۷	۶۴/۹۴	DSC
۷۲/۴۲	۷۴/۵۲	۷۰/۰۱	۶۲/۲۵	ضریب جاکارد
۷۸/۹۲	۸۰/۸۹	۷۵/۲۵	۶۸/۸۷	دقت

جدول (۵): مقایسه مدل پیشنهادی با پژوهش‌های گذشته

DSC (%)	روش استفاده شده	مطالعه
۵۵	Multi-scale U-Net	ونگ و همکاران [۱۴]
۵۷	FCN	کلجیوس و همکاران [۱۵]
۴۳/۲۲	Mutation Model	غنمات و همکاران [۱۶]
۴۲	U-Net with Group Convolutions	راجو و همکاران [۱۷]
۶۸/۱	MultiRes U-Net	سلطان پور و همکاران [۱۸]
۷۵/۴۱	Graph Convolution	روش پیشنهادی



شکل (۱۱): عملکرد شبکه پیشنهادی در حضور سایر شبکه‌های مورد مقایسه

جدول (۶): پیچیدگی محاسباتی مدل پیشنهادی در مقایسه با سایر شبکه‌های مورد مقایسه

روش	زمان آموزش (ثانیه)	زمان آزمون (ثانیه)
Modified U-Net	۲۲۰۱	۴
Shortcut CNN	۲۷۰۵	۷
مدل پیشنهادی	۳۲۰۸	۹

روش‌های مورد مقایسه، با در نظر گرفتن صحت بیشتر، برتری دارد و می‌توان از آن در کاربردهای بلادرنگ هم استفاده کرد.


همان‌طور که می‌دانیم، تصاویر CTP به‌شدت به حرکت بیمار وابسته هستند و در صورت حرکت جزئی بیمار، خروجی تصویر CTP نویزدار خواهد بود و پزشک معالج در تشخیص محل، اندازه و شدت ضایعه با مشکل روبه‌رو خواهد بود. متأسفانه، هیچ یک از مطالعه‌های گذشته به دلیل کاهش عملکرد الگوریتم، مدل پیشنهادی خود را در محیط‌های نویزی ارزیابی نکرده‌اند. همان‌طور که مشخص است، برای راه‌یابی پژوهش حاضر به حوزه کاربردی درمانی، لازم است تا مدل پیشنهادی در مقابل

طبق این جدول، همان‌طور که نشان داده شده است، روش پیشنهادی بر اساس مستندات ارائه شده در نمودارها و منحنی‌های قبلی برای اولین بار در پژوهش حاضر به صحت بیشتر از ۸۰ درصد برای تقسیم‌بندی سکنه مغزی ایسکمیک دست یافته است. پیچیدگی محاسباتی الگوریتم پیشنهادی با شبکه‌های مورد مقایسه Modified U-Net و Shortcut CNN در جدول (۶) ارائه شده است. همان‌طور که مشخص است، روش پیشنهادی زمان آموزش بیشتری نسبت به شبکه‌های مقایسه شده دارد که این مشکل را با ظهور واحدهای گرافیکی قدرتمند می‌توان برطرف کرد. همچنین، همان‌طور که مشخص است، زمان آزمون بر اساس مدل پیشنهادی حدود ۹ ثانیه است که از سایر

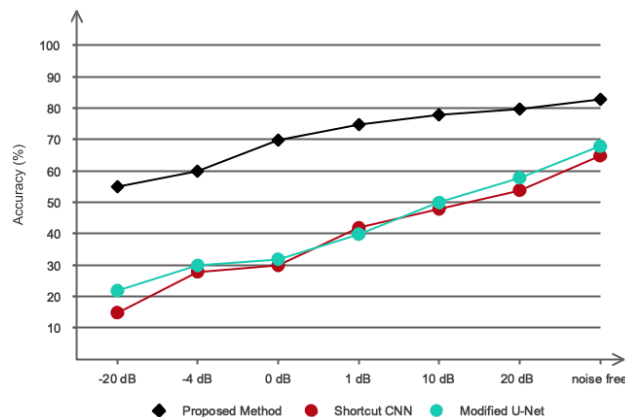
معایبی است. از جمله مزایایی این پژوهش می‌توان دست‌یابی به بهترین عملکرد بخش‌بندی را بیان کرد. همچنین، ارائه روش مطمئن بر اساس شبکه‌های کانولوشنال گراف ممکن است بستری بسیار مناسب برای طبقه‌بندی سکنه مغزی ایسکمیک باشد؛ با این حال، ابعاد پایگاه داده استفاده‌شده باید افزایش یابند. بر همین اساس، ما در مطالعه‌های آینده قصد داریم تا پایگاه داده‌ای جامع‌تر را برای تقسیم‌بندی خودکار سکنه مغزی ایسکمیک ارائه دهیم. با توجه به عملکرد مطلوب مدل پیشنهادی، می‌توان از آن در آینده برای کمک به پزشکان و رادیولوژیست‌ها در شناسایی ابعاد و محل دقیق ضایعه سکنه مغزی ایسکمیک استفاده کرد.

عدم قطعیت‌های مختلف همچون نویز آزمایش و ارزیابی شود. به این ترتیب، برای شبیه‌سازی نویزهای حرکتی بیمار، نویز سفید گاوسی به تصاویر در طیفی مختلف از سیگنال-به-نویز (SNR)^{۴۶} مختلف افزوده شد. نویز اضافه‌شده به تصاویر در طیفی مختلف از SNRهای مختلف در شکل (۱۲) نمایش داده شده است. همچنین، نتایج بخش‌بندی بر اساس مدل پیشنهادی و شبکه‌های قابل مقایسه Modified U-Net و Shortcut CNN در شکل (۱۳) ارائه شده است. مطابق همین شکل، همان‌طور که مشخص است، شبکه پیشنهادی به خوبی توانسته است در بازه‌ای وسیع از SNRهای مختلف، مقاومتی خوب را از خود به نمایش بگذارد.

این مطالعه همانند سایر مطالعه‌ها دارای مزایا و



شکل (۱۲): نویز اضافه‌شده به تصاویر در طیف SNRهای مختلف



شکل (۱۳): نحوه عملکرد مدل پیشنهادی در محیط نویزی در حضور سایر شبکه‌های مورد مقایسه

۵- نتیجه گیری

در این مطالعه، روشی جدید بر اساس شبکه‌های یادگیری عمیق به منظور بخش‌بندی خودکار سکنه مغزی ایسکمیک با استفاده از تصاویر CTP ارائه شده است. به این منظور، معماری شبکه پیشنهادی از پنج لایه گراف کانولوشنال به همراه یک لایه سافت مکس تشکیل شده است که می‌تواند انتخاب/استخراج ویژگی و بخش‌بندی را به صورت خودکار انجام دهد. معماری پیشنهادی در این مطالعه با سایر روش‌های محبوب و مطالعه‌های مرتبط مقایسه قرار شده و عملکردی امیدوارکننده را از خود به نمایش گذاشته است؛ به طوری که DSC روش پیشنهادی برای بخش‌بندی ضایعه سکنه مغزی ایسکمیک بر اساس پایگاه داده ISLES 2018، بیشتر از ۷۵ درصد گزارش شده است. با توجه به عملکرد مطلوب روش پیشنهادی، می‌توان از آن برای تشخیص خودکار ضایعه سکنه مغزی ایسکمیک بدون نیاز به تشخیص بصری استفاده کرد.

۶- مراجع

- Conference on Image Processing (ICIP), pp. 111-115, 2016.
- [6] J. Mitra Pierrick Bourgeat, Jurgen Fripp, S. Ghose, S. Rose, O. Salvado, A. Connelly, B. Campbell; "Lesion segmentation from multimodal MRI using random forest following ischemic stroke", *NeuroImage*, Vol. 98, pp. 324-335, 2014.
- [7] O. Maier, M. Wilms, J. von der Gablentz, U. M. Krämer, T. F. Münte, H. Handels, "Extra tree forests for sub-acute ischemic stroke lesion segmentation in MR sequences", *Journal of neuroscience methods*, Vol. 240, pp. 89-100, 2015.
- [8] Y. Zhang, S. Liu, C. Li, J. Wang, "Application of deep learning method on ischemic stroke lesion segmentation", *Journal of Shanghai Jiaotong University (Science)*, Vol. 27, No. 1, pp. 99-111, 2022.
- [9] K. Qi, Hao Yang, Cheng Li, Zaiyi Liu, Meiyun Wang, Qiegen Liu and Shanshan Wang, "X-net: Brain stroke lesion segmentation based on depthwise separable convolution and long-range dependencies", *International conference on medical image computing and computer-assisted intervention*, pp. 247-255, Springer, 2019
- [10] R. Guerrero, C. Qin, O. Oktay, C. Bowles, L. Chen, R. Joules, R. Wolz, M. C. Valdés-Hernández, "White matter hyperintensity and stroke lesion segmentation and differentiation using convolutional neural networks", *NeuroImage: Clinical*, Vol. 17, pp. 918-934, 2018.
- [11] M. Soltanpour, R. Greiner, P. Boulanger, B. Buck, "Ischemic stroke lesion prediction in CT perfusion scans using multiple parallel u-nets following by a pixel-level classifier", *IEEE 19th International Conference on Bioinformatics and Bioengineering (BIBE)*, pp. 957-963, 2019.
- [12] P. Liu, "Stroke lesion segmentation with 2D novel CNN pipeline and novel loss function", *International MICCAI Brainlesion Workshop*, pp. 253-262: Springer, 2018.
- [13] J. Dolz, I. Ben Ayed, C. Desrosiers, "Dense multi-path U-Net for ischemic stroke lesion segmentation in multiple image modalities", *International MICCAI Brainlesion Workshop*, pp. 271-282, Springer, 2018.
- [14] G. Wang, T. Song, Q. Dong, M. Cui, N. Huang, S. Zhang, "Automatic ischemic stroke lesion segmentation from computed tomography perfusion images by image synthesis and attention-based deep neural networks", *Medical Image Analysis*, Vol. 65, p. 101787, 2020.
- [15] A. Clèrigues, S. Valverde, J. Bernal, J. O. Maier, C. Schröder, N. D. Forkert, T. Martinetz, H. Handels, "Classifiers for ischemic stroke lesion segmentation: a comparison study", *PloS one*, Vol. 10, No. 12, p. e0145118, 2015.
- [2] R. Guerrero, O. Oktay, C. Bowles a, L. Chen a, R. Joules b, R. Wolz b a, M.C. Valdés-Hernández c, "White matter hyperintensity and stroke lesion segmentation and differentiation using convolutional neural networks", *NeuroImage: Clinical*, Vol. 10, pp. 978-934, 2019.
- [3] S. Rekik, T. K. Allasonnière, J. M. Carpenter, Wardlaw, "Medical image analysis methods in MR/CT-imaged acute-subacute ischemic stroke lesion: Segmentation, prediction and insights into dynamic evolution simulation models. A critical appraisal", *NeuroImage: Clinical*, Vol. 1, No. 1, pp. 164-178, 2012.
- [4] Y. Zhou, W. Huang, P. Dong, Y. Xia, S. Wang, "D-UNet: a dimension-fusion U shape network for chronic stroke lesion segmentation", *IEEE/ACM transactions on computational biology and bioinformatics*, Vol. 18, No. 3, pp. 940-950, 2019.
- [5] Y. Wang, A. K. Katsaggelos, X. Wang, T. B. Parrish, "A deep symmetry convnet for stroke lesion segmentation", *IEEE International*

- [20] M. Defferrard, X. Bresson, P. Vandergheynst, "Convolutional neural networks on graphs with fast localized spectral filtering", *Advances in neural information processing systems*, Vol. 29, 2016.
- [21] A. Lazcano, P. J. Herrera, M. Monge, "A Combined Model Based on Recurrent Neural Networks and Graph Convolutional Networks for Financial Time Series Forecasting", *Mathematics*, Vol. 11, No. 1, p. 224, 2023.
- [22] A. Fabijanska, "Graph Convolutional Networks for Semi-Supervised Image Segmentation", *IEEE Access*, Vol. 10, pp. 104144-104155, 2022.
- [23] J. Zhang, Y. Zhang, Y. Jin, J. Xu, X. Xu, "MDU-Net: multi-scale densely connected U-Net for biomedical image segmentation", *Health Information Science and Systems*, Vol. 11, No. 1, p. 13, 2023.
- [24] W. Weng, X. Zhu, L. Jing, M. Dong, "Attention Mechanism Trained with Small Datasets for Biomedical Image Segmentation", *Electronics*, Vol. 12, No. 3, p. 682, 2023.
- Freixenet, A. Oliver, X. Lladó, "Acute ischemic stroke lesion core segmentation in CT perfusion images using fully convolutional neural networks", *Computers in Biology and Medicine*, Vol. 115, p. 103487, 2019.
- [16] R. Ghnemat, A. Khalil, and Q. Abu Al-Haija, "Ischemic stroke lesion segmentation using mutation model and generative adversarial network," *Electronics*, vol. 12, no. 3, p. 590, 2023.
- [17] C. S. P. Raju, A. M. Kirupakaran, B. C. Neelapu, R. H. Laskar, "Ischemic Stroke Lesion Segmentation in CT Perfusion Images Using U-Net with Group Convolutions", *International Conference on Computer Vision and Image Processing*, pp. 276-288, Springer, 2022.
- [18] M. Soltanpour, R. Greiner, P. Boulanger, B. Buck, "Improvement of automatic ischemic stroke lesion segmentation in CT perfusion maps using a learned deep neural network", *Computers in Biology and Medicine*, Vol. 137, p. 104849, 2021.
- [19] Isles challenge 2018 ischemic stroke lesion segmentation. www.isles-challenge.org.

¹ Brain Stroke

² Ischemic

³ Anfractuous

⁴ Hemorrhagic

⁵ Magnetic Resonance Imaging

⁶ Computed Tomography Perfusion

⁷ Dice Similarity Coefficient

⁸ Liu

⁹ Generative Adversarial Networks

¹⁰ Diffusion Weighted Imaging

¹¹ Convolutional Network

¹² Generator

¹³ Discriminator

¹⁴ 4-Fold Cross Validation

¹⁵ Dolz

¹⁶ Wang

¹⁷ Convolutional Neural Network

¹⁸ Albert

¹⁹ Ghnemat

²⁰ Deep Learning

²¹ Raju

²² Accuracy

²³ Graph Convolutional

²⁴ Michael Radford

²⁵ Graph Spectral Theory

²⁶ Singular Value Decomposition

- ²⁷ Simple Linear Iterative Clustering algorithm
- ²⁸ Spatial Resolution
- ²⁹ Region Adjacency Matrix
- ³⁰ Region Feature Matrix
- ³¹ Hounsfield Unit Coefficient
- ³² Chebyshev Graph
- ³³ Batch Normalization
- ³⁴ Leaky-Relu
- ³⁵ Batch Filtering
- ³⁶ Dropout
- ³⁷ Over Fitting
- ³⁸ Fully Connected
- ³⁹ Softmax
- ⁴⁰ Feature-Encoding
- ⁴¹ Google Colab
- ⁴² Jaccard Index
- ⁴³ Kappa Coefficient
- ⁴⁴ Dice Loss
- ⁴⁵ Receiver Operating Characteristic (ROC)
- ⁴⁶ Signal Noise Ratio

