

Fuzzy Inference System in Pre-Processing to Improve Stroke Lesion Segmentation using U-Net Deep Neural Network

Alimoradi, Mohammad Mahdi¹ / Khodabakhshi, Mohammad Bagher^{2*} / Jamasb, Shahriar³

¹ - M.Sc., Biomedical Engineering Department, Hamedan University of Technology, Hamedan, Iran

² - Assistant Professor, Biomedical Engineering Department, Hamedan University of Technology, Hamedan, Iran

³ - Associate Professor, Biomedical Engineering Department, Hamedan University of Technology, Hamedan, Iran

ARTICLE INFO

DOI: 10.22041/ijbme.2023.2008324.1856

Received: 4 August 2023

Revised: 10/10/2023 – 9/11/2023

Accepted: 9 November 2023

KEYWORDS

Stroke Lesion
Magnetic Resonance Images
Deep Learning
U-Net Network
Fuzzy Inference System

ABSTRACT

Stroke is one of the causes of death and the main cause of disability in developed countries. Normally, identification of stroke lesions is done by magnetic imaging, and its analysis requires the continuous presence of a doctor in the treatment center. Therefore, intelligent processing of medical images will be an effective approach for automatic diagnosis of brain lesions. In this paper, a new integrated framework based on fuzzy inference system and deep neural network for automatic segmentation of brain lesions is introduced. In this regard, firstly, an improved U-Net deep network (U-Net) has been introduced for lesion detection and segmentation, which includes increasing the number of encoder and decoder layers along with changing the activation functions. Then, by using a fuzzy inference system based on if-then rules used by membership functions, the proposed approach of this study, which is based on the pre-processing of input images and the use of the unit network, has been introduced. The results showed that the integration of the fuzzy inference system in the pre-processing with the improved deep network could increase the DICE coefficient up to 0.84. In addition, improving the contrast of the input images by the fuzzy system compared to the usual pre-processing methods such as histogram equalization showed a much better performance in the detection of lesions with small dimensions, which is due to the ability to control the amount of contrast increase in the fuzzy systems compared to the usual methods.

*Corresponding Author

Address: Biomedical Engineering Department, Hamedan University of Technology, Hamedan, Iran

Postal Code: 65155-579

E-Mail: mb.khodabakhshi@hut.ac.ir

Tel: +98-81-28311507





به کارگیری سیستم استنتاج فازی در پیش‌پردازش جهت بهبود بخش‌بندی ضایعات سکتی مغزی با استفاده از شبکه‌ی عصبی عمیق U-Net

علی‌مرادی^۱، محمدمهدی^۱ / خدابخشی^۲، محمدباقر^{۳*} / جاماسب^۳، شهریار^۳

^۱ - کارشناسی ارشد، گروه مهندسی پزشکی، دانشگاه صنعتی همدان، همدان، ایران

^۲ - استادیار، گروه مهندسی پزشکی، دانشگاه صنعتی همدان، همدان، ایران

^۳ - دانشیار، گروه مهندسی پزشکی، دانشگاه صنعتی همدان، همدان، ایران

مشخصات مقاله

شناسه‌ی دیجیتال: 10.22041/ijbme.2023.2008324.1856

پذیرش: ۱۸ آبان ۱۴۰۲

بازنگری: ۱۴۰۲/۷/۱۸ - ۱۴۰۲/۸/۱۸

ثبت در سامانه: ۱۳ مرداد ۱۴۰۲

چکیده

سکتی مغزی یکی از علل مرگ و میر و عامل اصلی ایجاد ناتوانی بیماران در کشورهای توسعه یافته است. به طور معمول شناسایی ضایعات سکتی مغزی به وسیله‌ی تصویربرداری مغناطیسی صورت گرفته و تحلیل آن نیازمند حضور مستمر پزشک در مرکز درمانی است. لذا پردازش هوشمند تصاویر پزشکی رویکردی موثر برای تشخیص خودکار ضایعات مغزی می‌باشد. در این مقاله یک چارچوب تلفیقی جدید بر مبنای سیستم استنتاج فازی و شبکه‌ی عصبی عمیق برای بخش‌بندی خودکار ضایعات مغزی معرفی شده است. در این راستا ابتدا به معرفی یک شبکه‌ی عمیق U-Net بهبود یافته برای تشخیص و بخش‌بندی ضایعه پرداخته شده که شامل افزایش تعداد لایه‌های بخش‌های رمزگذار و رمزگشا به همراه تغییر توابع فعال‌سازی است. سپس با به کارگیری یک سیستم استنتاج فازی مبتنی بر قواعد اگر-آن‌گاه، رویکرد پیشنهادی این مطالعه که بر مبنای پیش‌پردازش تصاویر ورودی و به کارگیری شبکه‌ی یونت بوده معرفی شده است. نتایج نشان داده که تلفیق سیستم استنتاج فازی در پیش‌پردازش با شبکه‌ی عمیق یونت توانسته است ضریب دایس را تا میزان ۰/۸۴ افزایش دهد. به علاوه بهبود کنتراست تصاویر ورودی توسط سیستم فازی نسبت به روش یکسان‌سازی هیستوگرام، باعث عمل‌کرد بسیار بهتری در تشخیص ضایعات با ابعاد کوچک شده که دلیل آن توانمندی بیش‌تر کنترل کنتراست در قواعد فازی است.

واژه‌های کلیدی

ضایعه‌ی سکتی مغزی
تصاویر رزونانس مغناطیسی
یادگیری عمیق
شبکه‌ی U-Net
سیستم استنتاج فازی

*نویسنده‌ی مسئول

نشانی: استادیار، گروه مهندسی پزشکی، دانشگاه صنعتی همدان، همدان، ایران

تلفن: ۰۲۸۳۱۱۵۰۷-۸۱-۹۸+

پست الکترونیکی: mb.khodabakhshi@hut.ac.ir

کد پستی: ۶۵۱۵۵-۵۷۹



۱- مقدمه

در حال حاضر یکی از دلایل عمده‌ی مرگ و میر در جهان سکت‌های مغزی بوده و محققان در سراسر جهان به بررسی سکت‌های ایسکمیک که یکی از مهم‌ترین و پرتکرارترین انواع سکت‌های مغزی است می‌پردازند [۱]. بیمار مبتلا به سکت‌های مغزی ایسکمیک می‌تواند از اولین تشخیص قطعی ممکن بیش‌ترین بهره‌ی درمانی را ببرد که در این امر تصویربرداری مغز نقشی اساسی دارد.

به دلیل کنتراست بالای بافت نرم، تصویربرداری رزونانس مغناطیسی^۱ (MRI) به یک روش قابل اعتنا برای ارزیابی بالینی ضایعات مرتبط با ایسکمیک تبدیل شده است [۲]. برای تجزیه و تحلیل کمی ضایعه‌ی سکت‌های مغزی در تصاویر رزونانس مغناطیسی، بخش‌بندی دستی توسط متخصص هم‌چنان یک رویکرد رایج برای محاسبه‌ی اندازه، شکل و حجم ضایعات سکت‌های مغزی است [۲]. با این حال تشخیص بلادرنگ ضایعات نیازمند حضور دائمی پزشک متخصص در مراکز درمانی است. به علاوه بخش‌بندی خودکار می‌تواند یک ابزار مفید برای پیش‌آگهی پزشک از وجود ضایعه باشد. بنابراین توسعه‌ی روش‌های کاملاً خودکار و دقیق بخش‌بندی ضایعات سکت‌های مغزی به یک زمینه‌ی تحقیقاتی مهم تبدیل شده است [۳].

پس از ظهور الگوریتم‌های تشخیص هوشمند در این زمینه پژوهش‌های بسیاری صورت گرفته که سبب سرعت بخشیدن هر چه بیش‌تر به روند تشخیص، درمان و حتی پیش‌گیری از وقوع هر چه بیش‌تر صدمات ناشی از ضایعات سکت‌های مغزی شده است. این پژوهش‌ها از نظر معماری به کار رفته یا مجموعه‌ی داده‌های استفاده شده دارای وجه تمایز با یک‌دیگر هستند. در این میان شبکه‌های عصبی عمیق که دارای قدرت بسیار بالا در ایجاد وجه تمایز بین بافت دارای ضایعه و بافت سالم هستند بیش‌تر مورد توجه قرار دارند [۴].

یکی از معماری‌های شناخته شده در این حوزه، شبکه‌ی عمیق U-Net بوده که از آن برای مسائل مختلف پردازش تصویر شامل تشخیص اشیا در تصاویر [۵] و بخش‌بندی استفاده شده است. اگر چه به نظر می‌رسد که طبقه‌بندی نمونه‌های غیرطبیعی با ظهور شبکه‌ی عصبی کانولوشنی^۲ (CNN) بسیار موفق بوده، اما این رویکرد برای ارزیابی دقیق ابعاد ضایعه به تنهایی قابل استفاده نیست [۶]. روش پیشنهاد شده در مقاله‌ی [۳] ترکیبی از شبکه‌ی U-Net و یک شبکه‌ی چندمسیری است که به مدل، انعطاف بیش‌تری نسبت به مدل پایه می‌دهد. در یک مطالعه‌ی

دیگر از ورودی سه‌بعدی در شبکه‌ی U-Net استفاده شده است [۱]. در این کار برش‌های تصاویر دوبعدی مربوط به مقاطع مختلف مغز به همراه برچسب‌های متناظر هر یک روی هم انباشته شده تا یک مجموعه‌ی ورودی سه‌بعدی ایجاد شود و سپس نتایج پیش‌بینی شده‌ی دوبعدی طبق ترتیب قبل از برش، روی هم قرار داده شده است تا نتایج نهایی پیش‌بینی سه‌بعدی به دست آید. در یک پژوهش دیگر یک شبکه با نام U-ISLES معرفی شده است [۷]. دقت بالای این شبکه نیازمند پارامترها و عوامل مختلفی بوده که یکی از این عوامل، پیش‌پردازش تصویر است. در این کار برای بهبود تصاویر از تکنیک یکسان‌سازی هیستوگرام ساده استفاده شده است. در این راستا یک شبکه‌ی U-Net کارآمد به نام E-Unet پیشنهاد شده است [۵]. این مدل عملیات کانولوشن ساختار U-Net اصلی را با یک بلوک (e) مبتنی بر کانولوشن جایگزین کرده تا به طور موثر تعداد پارامترهای قابل آموزش را کاهش دهد.

به طور کلی در مطالعات گوناگون تایید شده است که معماری‌های کانولوشنی مبتنی بر U-Net عمل‌کرد مطلوبی در کاربرد پردازش تصاویر پزشکی دارند [۵]. به عنوان مثال شبکه‌ی عصبی تمام کانولوشنی (FCN) پتانسیل بالایی در بخش‌بندی تصاویر پزشکی از خود نشان داده است [۸]. در این راستا در یک مطالعه از یک شبکه‌ی رزنت برای بخش‌بندی ضایعه‌ی سکت‌های ایسکمیک استفاده شده است [۹]. الگوریتم FCN به دلیل استفاده از تعداد پارامتر کم‌تر، سریع‌تر از شبکه‌ی رزنت عمل می‌کند اما چون رزنت دارای قابلیت بازفراخوانی اطلاعات از لایه‌های قبل است، دقت بالاتری دارد [۹، ۱۰].

در مقاله‌ی [۱۱] شبکه‌ی عمیق پیش‌رفته‌ی DRA-Net^۳ برای بخش‌بندی هم‌زمان سکت‌های مغزی ایسکمیک و ضایعات شدت ماده‌ی سفید از تصاویر رزونانس مغناطیسی پیشنهاد شده است. این شبکه از ماژول جدیدی استفاده کرده که ویژگی‌های با کیفیت بالا را از تصاویر ورودی استخراج می‌کند. هم‌چنین در مقاله‌ی [۱۲] شبکه‌ی DSN^۴ برای حل عدم تعادل داده معرفی شده است. هم‌چنین از یک معماری سه‌مسیره برای استخراج ویژگی در صفحه‌های مختلف استفاده شده که در نهایت پیش‌بینی نهایی دقیق‌تر انجام شود.

با نگاهی به مطالعات اشاره شده می‌توان گفت که چالش اصلی آن‌ها بزرگ بودن ساختار شبکه‌ها بوده که باعث زیاد شدن تعداد پارامترهای مدل و هزینه‌ی بالای محاسباتی شده است. در مواردی که ضایعات دارای ابعاد کوچک هستند، توانایی

^۳ Deep Residual Attention Network

^۴ Detection And Segmentation Network

^۱ Magnetic Resonance Imaging

^۲ Convolutional Neural Network

بیان شده و در ادامه نتایج پیاده‌سازی چارچوب پیشنهادی و مقایسه‌ی نتایج به دست آمده با سایر روش‌ها ارائه شده است.

۲- مواد و روش‌ها

در این بخش رویکرد مورد نظر این پژوهش برای مساله‌ی بخش‌بندی تصاویر رزونانس مغناطیسی به تفصیل شرح داده شده است. به علاوه تاثیر افزایش کنتراست تصاویر در بهبود نتایج بخش‌بندی ضایعات بررسی شده است. این روش مبتنی بر سیستم استنتاج فازی است که باعث بهبود کیفیت بصری تصویر و هم‌چنین کمک به استخراج ویژگی‌های فضایی موجود در تصویر می‌شود. این روش در مقایسه با سایر الگوریتم‌های بهبود مانند یکسان‌سازی هیستوگرام کارا تر بوده و دارای قدرت تنظیم کنتراست از طریق تغییر در تعداد متغیرهای زبانی است.

۲-۱- مجموعه‌ی داده

پایگاه داده‌ی ISLES شامل مجموعه‌ای از تصاویر رزونانس مغناطیسی بوده که در این مطالعه از نسخه‌ی ISLES 2017 در بر گیرنده‌ی ۷۵ بیمار سکته‌ی مغزی ایسکمیک استفاده شده که به دو مجموعه‌ی آموزش (۴۳ نفر) و آزمایش (۳۲ نفر) تقسیم‌بندی شده است.

این مجموعه‌ی داده‌ی عمومی شامل تصاویر رزونانس مغناطیسی با ابعاد 256×256 بوده که دارای حقیقت زمینی متناظر ۶ است. برای تولید اسکن‌های رزونانس مغناطیسی از اسکن‌های دوبعدی جدید استفاده شده است. بنابراین مجموعه‌ی داده‌های چندطیفی از ۷۵ بیمار سکته‌ی مغزی که ماسک‌های آن به صورت دستی از اسکن‌های پیگیری شده تشریح شده، ارائه گردیده است. هر دو مجموعه شامل بیماران مبتلا به سکته‌ی مغزی ایسکمیک و نیز افراد سالمی که در آن‌ها ضایعه مشاهده نشده می‌باشند. در مجموع در این مطالعه تعداد ۱۳۰۱ تصویر برای آموزش، ۳۲۶ تصویر برای اعتبارسنجی و ۱۸۱ تصویر برای آزمایش به کار رفته است [۱۲، ۱۴]. در کنار هر تصویر ماسک مرتبط با آن که نمایش دهنده‌ی محل قرارگیری ضایعات مغزی بوده وجود دارد که از آن‌ها در فرایند آموزش و ارزیابی بهره‌برداری شده است.

در شکل (۱) نمونه‌ای از مجموعه‌ی داده‌ی مورد نظر نشان داده شده است. ستون اول و دوم به ترتیب حاوی تصاویر مربوط به افراد سالم و ماسک متناظر با تصاویر مربوطه است. در ستون سوم و چهارم نیز به ترتیب تصاویر افراد مبتلا به سکته‌ی ایسکمیک به همراه ماسک مورد نظر ارائه شده است.

شبکه در تشخیص ضایعه تا حد قابل توجهی کاهش می‌یابد. پیش‌پردازش تصاویر که یک عامل حیاتی در بحث پردازش تصاویر پزشکی بوده نیز کم‌تر مورد توجه قرار گرفته است [۱۳]. در این پژوهش تشخیص و بخش‌بندی ضایعه‌ی سکته‌ی ایسکمیک با استفاده از سیستم استنتاج فازی در بحث پیش‌پردازش تصاویر انجام شده که باعث توانمندی شبکه در بخش‌بندی ضایعات در ابعاد کوچک شده است. به عبارت دیگر افزایش کنتراست تصاویر توسط سیستم فازی منجر به افزایش ایجاد وجه تمایز بین بافت‌های سالم و بیمار شده که این امر به نوبه خود عمل کرد مدل هوشمند را بهبود خواهد داد. هم‌چنین با استفاده از شبکه‌ی U-Net که مدلی کارا برای بخش‌بندی تصاویر پزشکی بوده میزان بهبود عمل کرد چارچوب تلفیقی پیشنهادی مورد بررسی قرار گرفته است. نتایج حاصل از به کارگیری این رویکرد بر مبنای تشخیص تعداد پیکسل‌های مرتبط با ضایعات در مقابل بافت سالم با ضریب دایس بیان شده است. این نتایج بیان کننده‌ی بهبود عمل کرد چارچوب پیشنهادی در مقایسه با روش‌های مرسوم است.

مجموعه‌ی داده‌ی مورد استفاده در این مطالعه از پایگاه داده‌ی ISLES2017^۱ بارگیری شده است [۹]. این مجموعه‌ی داده شامل چهار مدالیته‌ی مختلف از تصاویر رزونانس مغناطیسی است. در این مطالعه از دادگان شامل ۱۵۳ مقطع دوبعدی در صفحه‌ی آگزیکال استفاده شده است.

برای پیاده‌سازی الگوریتم پیشنهادی، داده‌های مورد نظر توسط نرم‌افزار پایتون در محیط کگل و کولب بهره‌برداری شده است. دلیل اصلی استفاده از سکوه‌های اشاره شده، به کارگیری منابع سخت‌افزاری پردازشی و گرافیکی رایگان بوده که موجب بالا رفتن سرعت اجرای الگوریتم‌های پیاده شده گردیده است. از جمله نوآوری‌های این پژوهش می‌توان به موارد زیر اشاره کرد. ۱- بهبود ساختار شبکه‌ی U-Net از طریق تغییر تعداد لایه‌های بخش‌های رمزگذار و رمزگشا به همراه جایگزینی تابع فعال‌سازی لایه‌ی انتهایی با یک تابع سیگموئید تا ساختار نرم‌تری برای لایه‌ی تصمیم‌گیری ایجاد شود.

۲- افزودن ساختاری بر پایه‌ی مدل‌های فازی برای تبدیل چارچوب کلی به یک مدل با توصیف زبانی برای بهبود کنتراست تصاویر ورودی که نتیجه‌ی آن بهبود عمل کرد شبکه است.

در ادامه در بخش ۲ پس از معرفی مختصر مجموعه‌ی داده‌ی مورد استفاده، مدل پایه‌ای و بهبود یافته‌ی شبکه‌ی U-Net معرفی شده است. پس از آن چارچوب کلی روش به کار رفته شامل تلفیق سیستم استنتاج فازی با شبکه‌ی عصبی عمیق

^۱ Ischemic Stroke Lesion Segmentation

مدل پایه‌ای دارد، مربوط به استفاده از تابع فعال‌سازی سیگموئید در لایه‌ی خروجی آن است. از آن‌جا که تابع سیگموئید نسبت به ReLU دارای تغییرات نرم‌تری است انتظار می‌رود که مقادیر تشخیصی لایه‌ی خروجی نسبت به شبکه‌ی U-Net وضعیت بهتری ایجاد نماید [۱۸]. این تفاوت در لایه‌ی خروجی در شکل (۳) قابل مشاهده است.


تصاویر رزونانس مغناطیسی برای سکنه‌ی مغزی از تابع دایس^۲ در تقسیم‌بندی تصویر پزشکی استفاده می‌کند زیرا تعداد پیکسل‌ها برای ضایعه و نواحی طبیعی (بدون احتساب ضایعه) بسیار نامتعادل است [۱۹]. بنابراین به منظور ارزیابی عمل کرد الگوریتم‌های پیشنهادی از ضریب دایس به عنوان تابع هزینه استفاده شده که بیان‌کننده‌ی میزان شباهت بین شکل پیکسل‌های خروجی الگوریتم و تصویر ماسک واقعی بوده و به صورت زیر قابل تعریف است.

$$Dice\ Score = 2 \times \frac{size\ of\ the\ intersection}{union\ of\ the\ sizes\ of\ the\ 2\ sets} \quad (1)$$

در این رابطه صورت و مخرج کسر به ترتیب بیان‌کننده‌ی اشتراک و اجتماع تصاویر ماسک واقعی و خروجی تخمین زده شده است. هم‌چنین برای آموزش شبکه از بهینه‌ساز Adam استفاده شده است.

۲-۴- پیش‌پردازش تصاویر با استفاده از سیستم استنتاج فازی

نظریه‌ی فازی یک روش استنتاج سیستم‌ها بر اساس متغیرهای زبانی و انجام محاسبات عددی با استفاده از برجسب‌های مرتبط با آن‌ها است که در قالب توابع عضویت ارائه می‌شود. سیستم استنتاج فازی قادر است تخصص انسان خبره را به صورت ساختارمندی در قالب محاسبات ریاضی دخیل نماید [۲۰]. در این مطالعه از یک سیستم استنتاج فازی استفاده شده است که می‌تواند کنتراست تصاویر با وضوح پایین را به طور موثر افزایش دهد. سپس این نتایج با یکسان‌سازی هیستوگرام مقایسه شده است. به طور کلی دو نوع سیستم فازی با نام‌های سیستم فازی TSK^۳ و سیستم فازی ممدانی^۴ برای مدل‌سازی پدیده‌ها معرفی شده است. به دلیل ماهیت الگوریتم بهبود کنتراست و لزوم به کارگیری متغیرهای زبانی در بخش تالی قواعد فازی، در این مطالعه از سیستم استنتاج فازی ممدانی استفاده شده است [۲۱].



شکل (۱) - نمونه‌ای از مجموعه‌ی داده‌ی ISLES2017.

ستون اول و دوم مربوط به افراد سالم و ستون سوم و چهارم مربوط به افراد دارای ضایعه است، ستون‌های زوج حاوی ماسک مربوط به مکان قرارگیری ضایعات است.

۲-۲- مدل پایه بر مبنای U-Net

شبکه‌ی مورد استفاده در این مقاله عمومی‌ترین نوع شبکه‌ی عمیق از نوع U-Net بوده که مطابق شکل (۲) معماری آن در کل شامل ۱۱ لایه است. هر یک از این لایه‌ها از عمل‌گرهای کانولوشن با اندازه‌های به ترتیب ۱۶×۱۶، ۳۲×۳۲، ۶۴×۶۴، ۱۲۸×۱۲۸ و ۲۵۶×۲۵۶ تشکیل شده که در بخش رمزگذار به کار گرفته شده و در بخش رمزگشای این شبکه تصاویر با همان ابعاد اولیه‌ی ورودی دریافت شده است [۱۶]. در این بخش تصاویر بدون هیچ‌گونه تغییر یا پیش‌پردازشی وارد شبکه‌ی عمیق شده و سپس تشخیص اولیه‌ی ضایعه صورت می‌گیرد.

۲-۳- شبکه‌ی U-Net بهبود یافته

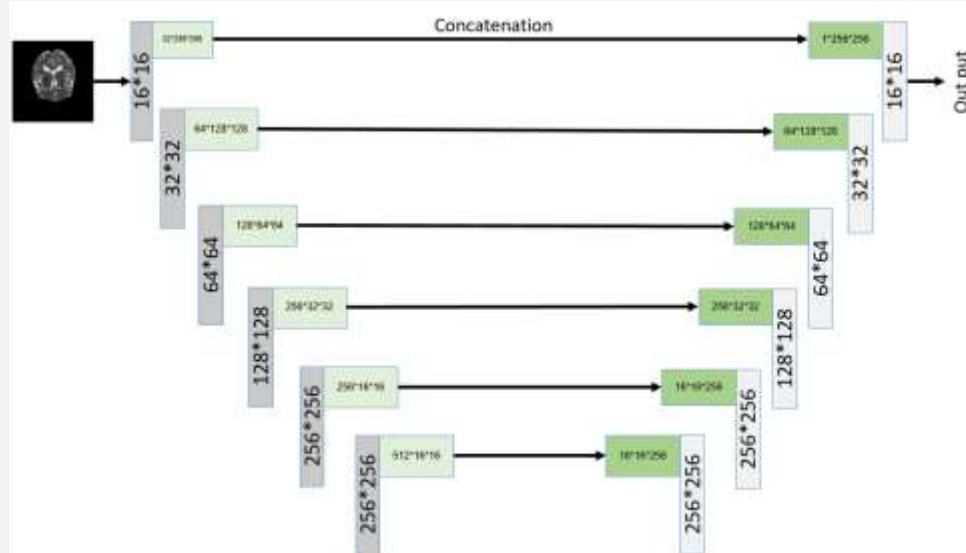
عوامل مختلفی بر افزایش دقت تشخیص ضایعات با ابعاد مختلف توسط شبکه‌ی عمیق موثر است که از آن جمله می‌توان به تعداد لایه‌های شبکه‌ی عمیق اشاره کرد [۱۷]. در این مطالعه برای بهبود هر چه بیشتر عمل‌کرد شبکه تعداد لایه‌های آن افزایش داده شده است. شبکه در کل از ۱۹ لایه کانولوشن^۱ تشکیل شده که نسبت به شبکه‌ی معمول، دارای عمل‌کرد بهتری است. معماری شبکه‌ی U-Net بهبود یافته در شکل (۳) نشان داده شده است. ورودی شبکه، تصاویر با ابعاد ۲۵۶×۲۵۶×۳ است. سپس از هر یک از این تصاویر توسط لایه‌های کانولوشن نگاشت‌هایی استخراج شده که در نهایت با به کارگیری توابع فعال‌ساز خروجی شبکه شکل گرفته است. تفاوت دیگری که شبکه‌ی بهبود یافته‌ی این مطالعه نسبت به

^۲ Takagi Sugeno Kang

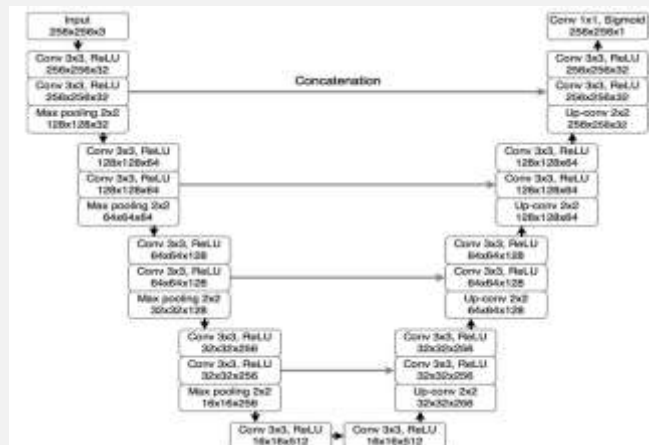
^۴ Mamdani FIS

^۱ Convolution

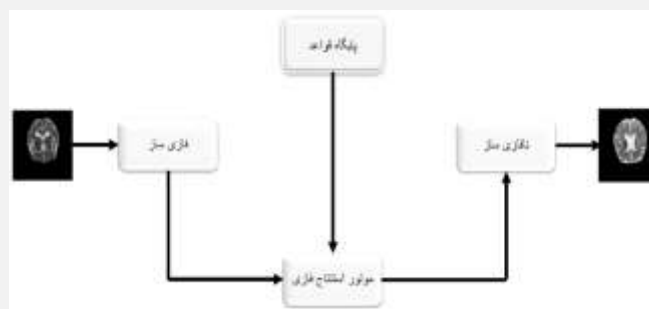
^۲ Dice Score



شکل (۲) - شبکه‌ی U-Net، در این شبکه در کل از ۱۱ لایه‌ی کانولوشن استفاده شده و از هیچ‌گونه فرایند پیش‌پردازشی برای تشخیص بهتر ضایعات سکنه‌ی مغزی ایسکمیک استفاده نشده است



شکل (۳) - شبکه‌ی U-Net بهبود یافته، این شبکه از ۱۹ لایه‌ی کانولوشن تشکیل شده که در بخش رمزگذار و رمزگشا توزیع شده است، در تابع فعال‌ساز لایه‌ی آخر به جای ReLU از سیگموئید استفاده شده است



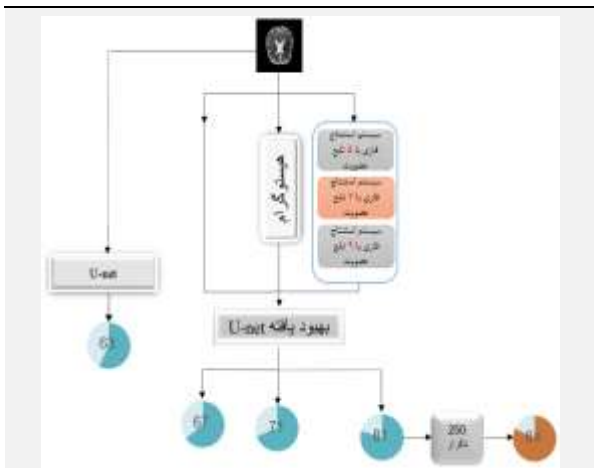
شکل (۴) - بلوک دیاگرام سیستم استنتاج فازی، تصویر به عنوان ورودی به بلوک فازی‌ساز وارد شده، توسط قواعد اگر-آن‌گاه در بلوک موتور استنتاج فازی به بخش نافازی‌ساز نگاشت شده و در نهایت تصویر با افزایش کنتراست کیفی مد نظر به عنوان خروجی سیستم حاصل می‌شود

اصلی شامل بخش‌های فازی‌ساز، پایگاه قواعد، موتور استنتاج فازی و نافازی‌ساز تقسیم‌بندی شده است. در این سیستم استنتاج فازی مقدار گسسته‌ی شدت یک پیکسل به عنوان ورودی یک‌بعدی در نظر گرفته شده که از طریق توابع عضویت ورودی به مقادیر فازی تبدیل شده است.

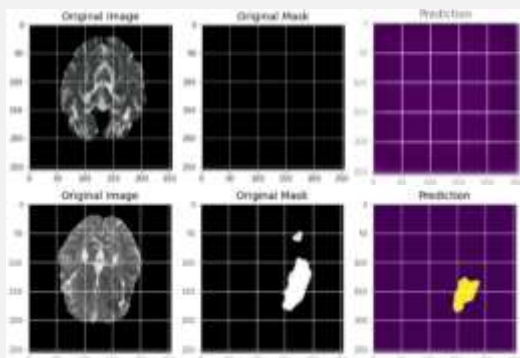
سیستم استنتاج فازی در بر گیرنده‌ی یک پایگاه دانش شامل قواعد اگر-آن‌گاه است. این قواعد ورودی‌های عددی را از طریق توابع عضویت فازی به خروجی‌های فازی نگاشت می‌کنند. بلوک دیاگرام این سیستم در شکل (۴) نشان داده شده است. با توجه به این بلوک دیاگرام می‌توان گفت که سیستم فازی به ۴ بخش

تصاویر به عنوان ورودی به شبکه اعمال شده و سپس نتایج حاصل در شکل (۶) نشان داده شده است.

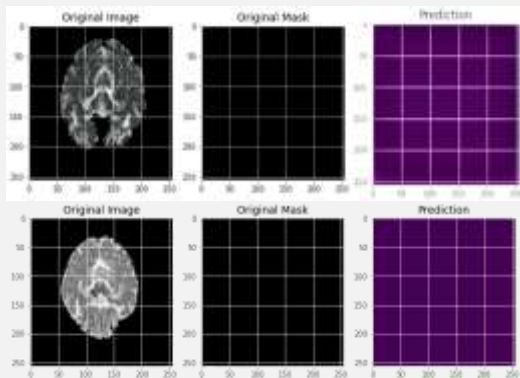
نمونه‌ای دیگر از نتیجه‌ی حاصل توسط شبکه در شکل (۷) قابل مشاهده بوده که توانایی شبکه در تشخیص افراد سالم را به خوبی نشان داده اما در برخی از بخش‌بندی‌ها عدم توانایی شبکه در تشخیص ضایعه حتی با ابعاد متوسط نیز مشخص است.



شکل (۵) - بلوک دیاگرام پیاده‌سازی شبکه‌ی U-Net و U-Net بهبود یافته و به کارگیری تکنیک یکسان‌سازی هیستوگرام و سیستم استنتاج فازی با تعداد قواعد ۵، ۷ و ۹



شکل (۶) - خروجی شبکه‌ی U-Net، ردیف اول: نمونه‌ای فاقد ضایعات، ردیف دوم: نمونه‌ای حاوی ضایعات با ابعاد نسبتاً بزرگ



شکل (۷) - خروجی شبکه‌ی U-Net برای دو نمونه از افراد سالم

سپس بر اساس قواعد اگر-آن‌گاه^۱ ورودی به خروجی نگاشت شده است [۲۲]. در نهایت با استفاده از توابع عضویت خروجی، یک مقدار غیرفازی شده به دست آمده و تصاویر بهبود یافته به شبکه‌ی عمیق بهبود یافته وارد شده است. نحوه‌ی شکل‌گیری قواعد فازی بدین گونه بوده که اگر ورودی بسیار تاریک^۲ باشد آن‌گاه تصویر خروجی کمی تیره^۳ شده و اگر ورودی خاکستری^۴ باشد آن‌گاه تصویر خروجی به ازای تمام پیکسل‌های خاکستری خود کمی تاریک شده است. در صورتی که ورودی روشن^۵ باشد، خروجی کمی روشن^۶ شده و این روند به ازای تمام پیکسل‌های تصویر ادامه یافته که در نهایت به یک تصویر با میزان افزایش کنتراست انتخابی ختم شده است. قواعد اگر-آن‌گاه موجود در الگوریتم پیشنهادی با ۷ تابع عضویت به صورت زیر است.

۱- اگر ورودی بسیار تاریک (VD) باشد آن‌گاه خروجی کمی تاریک (SD) است. ۲- اگر ورودی خاکستری تیره (DG) باشد آن‌گاه خروجی کمی تیره (SD) است. ۳- اگر ورودی خاکستری (G) باشد آن‌گاه خروجی کمی تاریک (SD) است. ۴- اگر ورودی روشن (B) باشد آن‌گاه خروجی کمی روشن (SB) است. ۵- اگر ورودی تیره (D) باشد آن‌گاه خروجی بسیار تاریک (VD) است. ۶- اگر ورودی بسیار روشن (VB) باشد آن‌گاه خروجی بدون تغییر (NC) است. ۷- اگر ورودی خاکستری روشن (LG) باشد آن‌گاه خروجی کمی تیره (SD) است.

۳- یافته‌ها و بحث

در این بخش به بیان نتایج پیاده‌سازی رویکرد معرفی شده پرداخته شده است. بلوک دیاگرام پیاده‌سازی روش پیشنهادی روی دادگان ISLES در شکل (۵) نشان داده شده است. مشاهده می‌شود که در ابتدا نتایج به وسیله‌ی شبکه‌ی U-Net بدون پیش‌پردازش ارائه شده است. پس از آن عمل کرد شبکه‌ی U-Net بهبود یافته بیان شده است. در ادامه تاثیر به کارگیری الگوریتم پیش‌پردازش در نتایج بررسی شده که شامل استفاده از سیستم استنتاج فازی با تعداد قواعد فازی گوناگون است.

۳-۱- نتایج پیاده‌سازی شبکه‌ی U-Net

شبکه‌ی U-Net معمولی این مقاله شامل ۱۱ لایه‌ی کانولوشنی بوده که به ترتیب دارای ابعاد ۲۵۶×۲۵۶، ۱۲۸×۱۲۸، ۶۴×۶۴، ۳۲×۳۲ و ۱۶×۱۶ در بخش رمزگذار و معادل آن در بخش رمزگشا است. عمل کرد این شبکه با تعداد تکرار به ترتیب ۱۰۰، ۱۵۰ و ۲۵۰ مورد آزمایش قرار گرفته است. در این کار ابتدا

^۱ Gray

^۵ Bright

^۶ Slightly Bright

^۱ IF-THEN

^۲ Very Dark

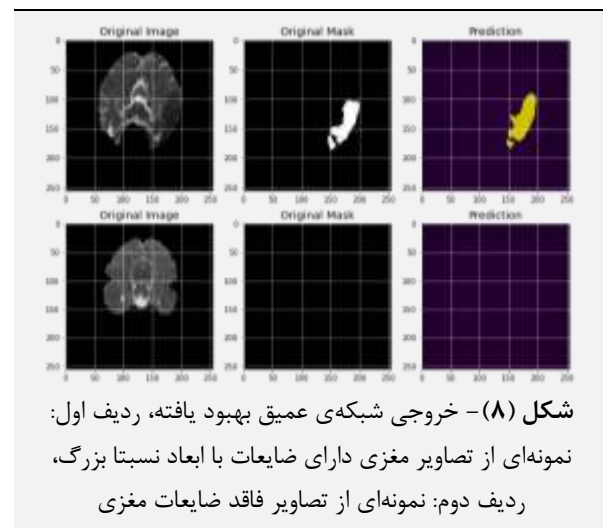
^۳ Slightly Dark

۲-۳- شبکه‌ی U-Net بهبود یافته

جهت افزایش عمل‌کرد شبکه‌ی پایه‌ای بخش قبل، در این بخش نتایج مربوط به شبکه‌ی عمیق U-Net بهبود یافته بررسی شده است. استفاده از شبکه‌ی عمیق بهبود یافته توانسته است ضریب دایس را به میزان $0/68$ بهبود دهد که تاثیر تغییرات اعمالی بر شبکه را تایید می‌کند.

نمونه‌ای از عمل‌کرد شبکه‌ی بهبود یافته‌ی این مطالعه در شکل (۸) نشان داده شده است. مشاهده می‌شود که شبکه در بخش‌بندی ضایعه بهتر از شبکه‌ی U-Net معمولی عمل کرده و به خوبی در تشخیص ضایعه با ابعاد متوسط توانمند است.

در تشخیص اولیه، ویژگی‌های بارز شبکه‌ی U-Net به خوبی قابل مشاهده است. مطابق شکل (۶) شبکه قادر است تا افراد فاقد ضایعه را از افراد دارای ضایعات با ابعاد متوسط و بزرگ شناسایی کند اما عدم توانایی شبکه در تشخیص ضایعات حتی با ابعاد متوسط و بزرگ از ایرادهای بارز این شبکه به حساب می‌آید. این ایراد در ردیف پایین شکل (۶) قابل مشاهده است.




شکل (۸) - خروجی شبکه‌ی عمیق بهبود یافته، ردیف اول: نمونه‌ای از تصاویر مغزی دارای ضایعات با ابعاد نسبتاً بزرگ، ردیف دوم: نمونه‌ای از تصاویر فاقد ضایعات مغزی

۳-۳- بهبود کنتراست تصاویر توسط سیستم فازی

معرفی شده

در این بخش به بیان نتایج عمل‌کرد مدل در حالت تلفیق پیش‌پردازش فازی با شبکه‌ی U-Net پرداخته شده است. برای سنجش تاثیر تعداد توابع عضویت ورودی در عمل‌کرد سیستم فازی در این مطالعه از مقادیر ۵، ۷ و ۹ تابع عضویت ورودی استفاده شده است. مجموعه‌ای از مقادیر شدت پیکسل به عنوان ورودی به متغیرهای زبانی گوسی شکل با نام‌های تیره، خاکستری، روشن و غیره اعمال شده است. نحوه‌ی افزایش فضای ورودی در حالتی که ۷ مجموعه‌ی فازی برای فضای ورودی در نظر گرفته شده در شکل (۹) قابل مشاهده است.

به طور خلاصه می‌توان بیان کرد که برای پیش‌پردازش تصاویر از سیستم استنتاج فازی با ۷ تابع عضویت ورودی و پایگاه قواعد اگر-آن‌گاه مناسب که به دفعات مورد بررسی و آزمایش قرار گرفته و بهترین سیستم ممکن برای مجموعه‌ی داده‌ی انتخابی بوده استفاده شده است تا بتوان به وسیله‌ی آن یک نتیجه‌ی دقیق در تشخیص ضایعات توسط شبکه‌ی U-Net بهینه به دست آورد. از آن‌جا که سیستم استنتاج فازی به کار رفته از نوع ممدانی است، برای بیان هر یک از قواعد فازی باید از توابع عضویت در خروجی استفاده شود [۲۳]. در این مطالعه توابع عضویت تالی قواعد نیز از نوع گوسی انتخاب شده است. در نهایت مقدار اصلاح شدت پیکسل خروجی از طریق فرایند نافازی‌سازی به دست آمده است [۲۴]. با توجه به شکل (۱۰) پایگاه قواعد فازی در نظر گرفته شده تعیین می‌کند که اگر پیکسلی تیره باشد تاریک‌تر شده و اگر پیکسلی روشن باشد آن پیکسل مقداری روشن‌تر به خود بگیرد. در این شکل نتایج اعمال سیستم فازی برای افزایش کنتراست تصاویر در حالت استفاده از ۵، ۷ و ۹ قاعده‌ی فازی قابل مشاهده است.



شکل (۹) - سیستم استنتاج فازی با ۷ تابع عضویت گوسی در فضای ورودی

است. برای مقایسه‌ی میزان تاثیر روش پیش‌پردازش در بهبود نتایج نهایی از روش یکسان‌سازی هیستوگرام استفاده شده است. برای این کار ابتدا تصویر وارد بلوک بهینه‌سازی کنتراست از طریق هیستوگرام شده و سپس به عنوان ورودی شبکه‌ی

مشاهده‌ی بصری تصاویر نشان می‌دهد که تمایز بین بافت روشن و تیره در حالت استفاده از ۷ قاعده‌ی فازی نسبت به حالات دیگر وضعیت مطلوب‌تری دارد. در ادامه تصاویر پیش‌پردازش شده به شبکه‌ی U-Net بهبود یافته اعمال شده

از متغیر زبانی برای افراز فضای ورودی، ضریب دایس شبکه تا مقدار ۰/۸۱ افزایش یافته است. این به نوبه خود موید میزان تاثیرگذاری قدرت تشخیص رویکرد تلفیقی معرفی شده در بهبود فرایند تشخیص ضایعات است.


۳-۴- افزایش داده‌های تصویری

در این بخش به منظور بهبود عمل‌کرد رویکرد معرفی شده، اقدام به افزایش تعداد داده به طور مصنوعی از تصاویر اصلی شده است [۲۶]. به بیان دیگر، تصاویری از میان مجموعه‌ی داده به طور تصادفی انتخاب شده و با اعمال برخی تکنیک‌ها از جمله چرخش تصادفی^۱، تنظیم روشنایی^۲، جابه‌جایی افقی تصادفی^۳ و جابه‌جایی عمودی تصادفی^۴ تصاویر جدیدی برای اعمال به شبکه ایجاد شده است [۲۷]. در نهایت با اعمال این روش ۱۹۵۲ تصویر آموزش، ۴۸۹ تصویر اعتبارسنجی و ۲۷۲ تصویر آزمون به دست آمده است. با توجه به شکل (۱۲) عمل‌کرد مدل تلفیقی ارائه شده روی مجموعه‌ی داده‌ی جدید با مقدار تکرار ۲۵۰ منجر به ایجاد ضریب دایس ۰/۸۴ شده است. در منحنی‌های یادگیری مشاهده می‌شود که مدل در این حالت برای رسیدن به پاسخ مطلوب با چالش انتخاب هم‌زمان گام یادگیری و افزایش مدت زمان آموزش مواجه است. به بیان دیگر افزایش تعداد دادگان به این شیوه موجب شده است که شبکه در نهایت پاسخ مطلوب‌تری ارائه دهد اما به زمان آموزش طولانی‌تری (تعداد بیش‌تر تکرار الگوریتم آموزشی) نیاز دارد. در نتیجه با انتخاب گام یادگیری بزرگ‌تر سعی در کاهش نسبی هزینه‌ی محاسباتی شده که این کار جهش‌های موضعی در منحنی‌های عمل‌کرد شبکه ایجاد کرده است.


به طور خلاصه مطابق جدول (۱) شبکه‌ی U-Net بهبود یافته همراه با سیستم استنتاج فازی در بحث پیش‌پردازش تصاویر توانسته است نتیجه‌ی مطلوبی از خود نشان دهد. با نگاهی دقیق به این جدول می‌توان دریافت که گنجاندن سیستم فازی به عنوان پیش‌پردازش توانسته است بهبود معناداری از منظر ضریب دایس ایجاد نماید. این بهبود هنگام استفاده از ۷ قاعده‌ی فازی به بیش‌ترین حد خود رسیده و افزایش بیش‌تر قواعد فازی منجر به نتیجه‌ی مطلوب‌تر نشده است.

برای ارزیابی نتایج به دست آمده، مدل به کار رفته با ۷ قاعده‌ی فازی با برخی از مطالعات پیشین مقایسه شده است. مقایسه‌ی اعداد مندرج در جدول (۲) نشان می‌دهد که این شبکه می‌تواند در مقایسه با شبکه‌ی U-Net معمولی و شبکه‌های به کار گرفته شده در مطالعات قبلی از ضریب دایس و دقت بسیار خوبی در

بهبود یافته در نظر گرفته شده است. تفاوت عمل‌کرد دو تکنیک مورد استفاده در این مطالعه برای بهبود کنتراست تصاویر در شکل (۱۱) ارائه شده است. در روش یکسان‌سازی هیستوگرام امکان تنظیم کنتراست به میزان دل‌خواه وجود ندارد که این امر در سیستم فازی با بهینه‌سازی توابع عضویت میسر است.



شکل (۱۰) - خروجی سیستم استنتاج فازی، سطر اول، دوم و سوم به ترتیب نتایج مربوط به اعمال الگوریتم بهبود کنتراست فازی با تعداد ۵، ۷ و ۹ قاعده‌ی فازی



شکل (۱۱) - مقایسه‌ی بصری روش هیستوگرام با سیستم استنتاج فازی با ۷ تابع عضویت ورودی، تصویر بالا: خروجی حاصل از تکنیک یکسان‌سازی هیستوگرام، تصویر پایین: خروجی حاصل از سیستم استنتاج فازی

پس از اعمال فرایند پیش‌پردازش، تصاویر به دست آمده به شبکه‌ی U-Net بهبود یافته اعمال شده است [۲۵]. ضریب دایس در حالت استفاده از تکنیک یکسان‌سازی هیستوگرام برابر با ۰/۷۳ به دست آمده که نسبت به تصاویر بدون پیش‌پردازش میزان بالاتری است. پس از آن از تلفیق سیستم فازی و مدل U-Net بهره‌برداری شده است. نتایج نشان داده هنگام استفاده

^۱ Random Horizontal Shift

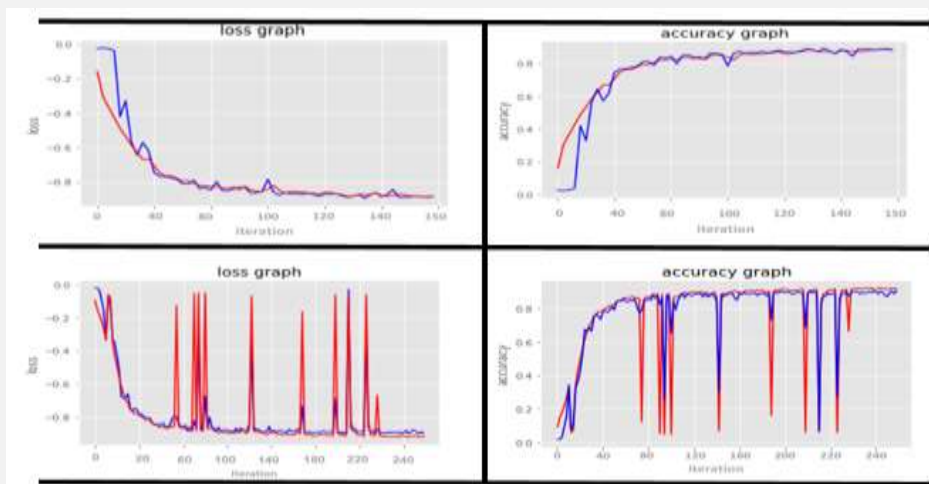
^۲ Random Vertical Shift

^۳ Random Rotation

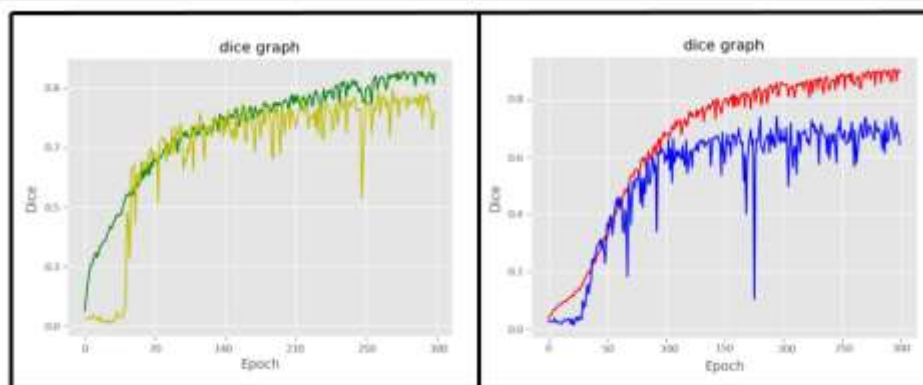
^۴ Brightness Adjustment

شده که کیفیت تصاویر جمع‌آوری شده توسط این دو مرجع بالاتر از مجموعه‌ی جمع‌آوری شده در این پژوهش بوده اما میزان ضریب دایس آن پایین‌تر است. مطابق این جدول در برخی از الگوریتم‌ها با وجود درصد صحت بالا، میزان حساسیت پایینی به دست آمده که دلیل آن تعداد بسیار زیادتر پیکسل‌های سالم در برابر پیکسل‌های مربوط به ضایعات بوده و مجموعه‌ی داده از این دیدگاه دچار عدم توازن است.

تشخیص ضایعه برخوردار باشد. به منظور مقایسه‌ی صحیح کار حاضر با سایر مطالعات، مراجعی که در این جدول مورد مقایسه قرار گرفته با مجموعه‌ی دادگان این مطالعه یکسان است. با این وجود انتخاب دادگان از مجموعه‌ی داده‌ی اصلی به صورت تصادفی صورت گرفته است. به علاوه در روش پیشنهادی مقاله‌ی [۵] از مجموعه‌ی داده‌ی جمع‌آوری شده در بیمارستان توسط افراد متخصص و نیز مجموعه‌ی داده‌ی ATLAS استفاده



شکل (۱۲) - ردیف بالا: خروجی شبکه‌ی عمیق بهبود یافته، ردیف پایین: خروجی مدل ارائه شده‌ی تلفیقی به همراه افزایش داده، نمودار راست: دقت، نمودار چپ: میزان تابع زیان، خط قرمز: دادگان آزمون، خط آبی: دادگان آموزش (در ردیف بالا تعداد تکرار به ۱۵۰ و در ردیف پایین تعداد تکرار به ۲۵۰ می‌رسد)



شکل (۱۳) - تصویر مربوط به منحنی یادگیری در شبکه‌های مختلف، سمت چپ: شبکه‌ی FCN [۸] با مجموعه‌ی داده‌ی مشابه در این پژوهش (رنگ قرمز: دادگان آموزش، رنگ آبی: دادگان آزمون)، سمت راست: شبکه‌ی U-ISLES [۱۴] با مجموعه‌ی داده‌ی مشابه (رنگ سبز: دادگان آموزش، رنگ زرد: دادگان آزمون)

جدول (۱) - مقایسه‌ی ضریب دایس روش‌های مختلف

ضریب دایس	روش پیشنهادی
۰/۶۳	U-Net [۱۹]
۰/۶۸	U-Net بهبود یافته
۰/۷۳	تلفیق U-Net بهبود یافته و یکسان‌سازی هیستوگرام
۰/۷۵	تلفیق U-Net بهبود یافته و سیستم فازی (۵ قاعده‌ی فازی)
۰/۸۴	تلفیق U-Net بهبود یافته و سیستم فازی (۷ قاعده‌ی فازی)
۰/۷۷	تلفیق U-Net بهبود یافته و سیستم فازی (۹ قاعده‌ی فازی)

جدول (۲) - مقایسه‌ی عمل‌کرد رویکرد پیشنهادی با سایر مطالعات

روش	ضریب دایس	دقت (/.)	حساسیت (/.)	تشخص (/.)	شبکه‌ی مورد آزمایش با مجموعه‌ی داده‌ی مشابه در این پژوهش (ضریب دایس)
[۳] 3D U-Net	۰/۵۴	۶۹/۱۱	۴۰/۱	۹۹/۹۸	-
[۱۴] U-ISLES	۰/۶۴	۸۶/۱۲	-	-	۰/۶۶
[۵] eU-Net	۰/۶۷	۸۷/۷۰	-	۸۹/۳۷	-
[۸] FCN	۰/۶۵	۷۰/۰۰	-	۹۹/۲۰	۰/۷۴
[۹] RES	۰/۷۰	۹۹/۱۲	-	۹۹/۱۴	-
[۱۲] DSN	۰/۶۲	۹۸/۳۶	۷۳/۲۲	۹۹/۴۸	-
مدل این مطالعه	۰/۸۴	۹۹/۹۱	۴۷/۲۱	۹۹/۹۸	-

۴- جمع‌بندی

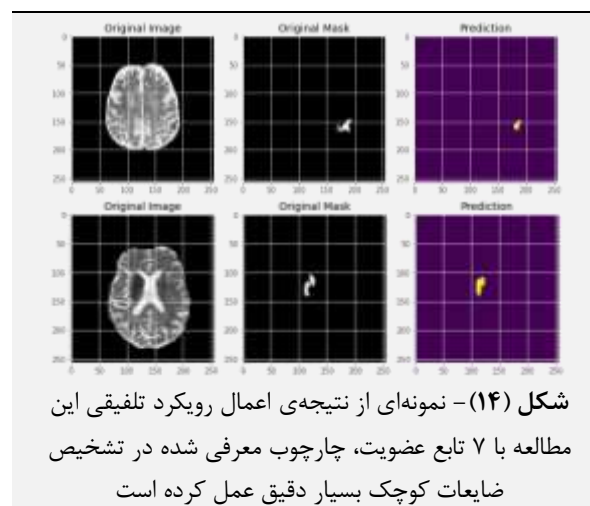
در این مطالعه یک چارچوب کلی بر مبنای تلفیق سیستم استنتاج فازی به عنوان پیش‌پردازش و شبکه‌ی U-Net برای بخش‌بندی تصاویر تشدید رزونانس مغناطیسی بیماران دارای ضایعات ناشی از سکته‌ی مزمن ارائه شده است. برای بخش‌بندی نهایی تصاویر، استفاده از یک شبکه‌ی U-Net بهبود یافته مطرح شده است. برای ارزیابی نهایی این شبکه از ضریب دایس استفاده شده که مقدار ۰/۸۴ را به خود اختصاص داده است. به کارگیری این روش در آینده می‌تواند جایگزین مناسبی برای بخش‌بندی ضایعات سکته‌ی مغزی ایسکمیک به روش دستی توسط متخصصین باشد و خطای موجود توسط انسان را به حداقل برساند. به طور خلاصه در این پژوهش یک روش خودکار بخش‌بندی ضایعه‌ی سکته‌ی مغزی معرفی شده که قادر است ضایعات مختلف سکته‌ی مغزی را در ابعاد مختلف به خوبی تشخیص دهد. استفاده از تکنیک پیش‌پردازش فازی مبتنی بر متغیرهای زبانی عمل‌کرد مطلوبی در کنترل میزان بهبود کنتراست نسبت به روش‌های سنتی داشته که در نتیجه‌ی نهایی بخش‌بندی نیز اثر مطلوب خود را نمایان کرده است.

در ادامه برای مقایسه‌ی یکسان چارچوب پیشنهادی با برخی از مطالعات پیشین، مدل معرفی شده در مقالات [۸، ۱۴] با دادگان کاملا مشابه با همین مطالعه مورد بهره‌برداری قرار گرفته که نتایج آن در ستون سمت چپ جدول (۲) ارائه شده است. مشاهده می‌شود که نتایج جدید به دست آمده به طور نسبی با آنچه در متن اصلی مقالات مربوطه گزارش شده منطبق است. شکل (۱۳) نیز به همین مقایسه اختصاص دارد. در هر دو بخش این شکل مشاهده می‌شود که با افزایش تعداد تکرار فرایند آموزش، ضریب دایس مدل‌ها افزایش یافته است تا به مقدار نهایی برسد. این موارد تایید کننده‌ی برتری مدل ترکیبی معرفی شده نسبت به مطالعات پیشین است.

در مجموع می‌توان گفت که ضریب دایس می‌تواند بهترین معیار برای مقایسه‌ی عمل‌کرد شبکه‌ها باشد و این معیار نشان می‌دهد که سیستم تلفیقی ارائه شده در این مطالعه عمل‌کرد بسیار خوبی در مقایسه با سایر روش‌ها داشته است. نمونه‌ای از خروجی مدل تلفیقی در شکل (۱۴) نشان داده شده است. مشاهده می‌شود که چارچوب پیشنهادی به دلیل وجود سیستم استنتاج فازی در بخش پیش‌پردازش قادر است تا ضایعات با ابعاد بسیار کوچک را نیز به خوبی تشخیص دهد.

۵- مراجع

- [1] H. Hui, X. Zhang, F. Li, X. Mei, and Y. Guo, "A Partitioning-Stacking Prediction Fusion Network Based on an Improved Attention U-Net for Stroke Lesion Segmentation," IEEE Access, vol. 8, pp. 47419-47432, 2020, doi: 10.1109/ACCESS.2020.2977946.
- [2] S. Winzeck et al., "Ensemble of Convolutional Neural Networks Improves Automated Segmentation of Acute Ischemic Lesions Using Multiparametric Diffusion-Weighted MRI," AJNR. Am. J. Neuroradiol., vol. 40, no. 6, pp. 938-945, Jun. 2019, doi: 10.3174/ajnr.A6077.
- [3] S. Khezrpour, H. Seyedarabi, S. N. Razavi, and M. Farhoudi, "Automatic segmentation of the



- U-ISLES: Ischemic Stroke Lesion Segmentation Using TensorFlow U-Net. 2020.
- [15] A. Pinto, J. Amorim, A. Hakim, V. Alves, M. Reyes, and C. A. Silva, "Prediction of Stroke Lesion at 90-Day Follow-Up by Fusing Raw DSC-MRI With Parametric Maps Using Deep Learning," *IEEE Access*, vol. 9, pp. 26260–26270, 2021, doi: 10.1109/ACCESS.2021.3058297.
- [16] X.-L. Liao et al., "Implementation and outcome of thrombolysis with alteplase 3 to 4.5 h after acute stroke in Chinese patients.," *CNS Neurosci. Ther.*, vol. 19, no. 1, pp. 43–47, Jan. 2013, doi: 10.1111/cns.12031.
- [17] M. B. Khodabakhshi, N. Eslamyeh, S. Z. Sadredini, and M. Ghamari, "Cuffless blood pressure estimation using chaotic features of photoplethysmograms and parallel convolutional neural network.," *Comput. Methods Programs Biomed.*, vol. 226, p. 107131, Nov. 2022, doi: 10.1016/j.cmpb.2022.107131.
- [18] R. Sathish, R. Rajan, A. Vupputuri, N. Ghosh, and D. Sheet, "Adversarially Trained Convolutional Neural Networks for Semantic Segmentation of Ischaemic Stroke Lesion using Multisequence Magnetic Resonance Imaging.," *Annu. Int. Conf. IEEE Eng. Med. Biol. Soc. IEEE Eng. Med. Biol. Soc. Annu. Int. Conf.*, vol. 2019, pp. 1010–1013, Jul. 2019, doi: 10.1109/EMBC.2019.8857527.
- [19] T. Kooi et al., "Large scale deep learning for computer aided detection of mammographic lesions.," *Med. Image Anal.*, vol. 35, pp. 303–312, Jan. 2017, doi: 10.1016/j.media.2016.07.007.
- [20] M. Kirichev, T. Slavov, and G. Momcheva, "Fuzzy U-Net Neural Network Design for Image Segmentation BT - Contemporary Methods in Bioinformatics and Biomedicine and Their Applications," 2022, pp. 177–184.
- [21] S. Joshi and S. Kumar, Image contrast enhancement using fuzzy logic. 2018.
- [22] J. Ni, J. Wu, J. Tong, Z. Chen, and J. Zhao, "GC-Net: Global context network for medical image segmentation.," *Comput. Methods Programs Biomed.*, vol. 190, p. 105121, Jul. 2020, doi: 10.1016/j.cmpb.2019.105121.
- [23] M. B. Khodabakhshi, M. H. Moradi, Z. M. Sanat, and P. Jafari Moghadam Fard, "Lung sound decomposition using recurrent fuzzy wavelet network.," *J. Intell. Fuzzy Syst.*, vol. 33, pp. 2497–2508, 2017, doi: 10.3233/JIFS-17684.
- [24] A. Salami, M. B. Khodabakhshi, and M. H. Moradi, "Fuzzy transfer learning approach for analysing imagery BCI tasks," in *2017 Artificial Intelligence and Signal Processing Conference (AISP)*, 2017, pp. 300–305, doi: 10.1109/AISP.2017.8324101.
- [25] D. C. Sullivan et al., "Metrology Standards for Quantitative Imaging Biomarkers.," *Radiology*, vol. 277, no. 3, pp. 813–825, Dec. 2015, doi: 10.1148/radiol.2015142202.
- brain stroke lesions from MR flair scans using improved U-Net framework," *Biomed. Signal Process. Control*, vol. 78, p. 103978, 2022, doi: <https://doi.org/10.1016/j.bspc.2022.103978>.
- [4] V. Badrinarayanan, A. Kendall, and R. Cipolla, "SegNet: A Deep Convolutional Encoder-Decoder Architecture for Image Segmentation.," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 39, no. 12, pp. 2481–2495, Dec. 2017, doi: 10.1109/TPAMI.2016.2644615.
- [5] H. Shin, R. Agyeman, M. Rafiq, M. C. Chang, and G. S. Choi, "Automated segmentation of chronic stroke lesion using efficient U-Net architecture," *Biocybern. Biomed. Eng.*, vol. 42, no. 1, pp. 285–294, 2022, doi: <https://doi.org/10.1016/j.bbe.2022.01.002>.
- [6] K. He, G. Gkioxari, P. Dollár, and R. Girshick, "Mask R-CNN," in *2017 IEEE International Conference on Computer Vision (ICCV)*, 2017, pp. 2980–2988, doi: 10.1109/ICCV.2017.322.
- [7] N. Stier, N. Vincent, D. Liebeskind, and F. Scalzo, "Deep Learning of Tissue Fate Features in Acute Ischemic Stroke.," *Proceedings. (IEEE. Int. Conf. Bioinformatics Biomed.)*, vol. 2015, pp. 1316–1321, Nov. 2015, doi: 10.1109/BIBM.2015.7359869.
- [8] R. Karthik, U. Gupta, A. Jha, R. Rajalakshmi, and R. Menaka, "A deep supervised approach for ischemic lesion segmentation from multimodal MRI using Fully Convolutional Network," *Appl. Soft Comput.*, vol. 84, p. 105685, 2019, doi: <https://doi.org/10.1016/j.asoc.2019.105685>.
- [9] S. Zhang, S. Xu, L. Tan, H. Wang, and J. Meng, "Stroke Lesion Detection and Analysis in MRI Images Based on Deep Learning," *J. Healthc. Eng.*, vol. 2021, p. 5524769, 2021, doi: 10.1155/2021/5524769.
- [10] N. Tomita, S. Jiang, M. E. Maeder, and S. Hassanpour, "Automatic post-stroke lesion segmentation on MR images using 3D residual convolutional neural network," *NeuroImage Clin.*, vol. 27, p. 102276, 2020, doi: <https://doi.org/10.1016/j.nicl.2020.102276>.
- [11] T. Brosch, L. Y. W. Tang, Y. Yoo, D. K. B. Li, A. Traboulsee, and R. Tam, "Deep 3D Convolutional Encoder Networks With Shortcuts for Multiscale Feature Integration Applied to Multiple Sclerosis Lesion Segmentation.," *IEEE Trans. Med. Imaging*, vol. 35, no. 5, pp. 1229–1239, May 2016, doi: 10.1109/TMI.2016.2528821.
- [12] L. Zhang et al., "Ischemic Stroke Lesion Segmentation Using Multi-Plane Information Fusion," *IEEE Access*, vol. 8, pp. 45715–45725, 2020, doi: 10.1109/ACCESS.2020.2977415.
- [13] L. Liu, L. Kurgan, F.-X. Wu, and J. Wang, "Attention convolutional neural network for accurate segmentation and quantification of lesions in ischemic stroke disease," *Med. Image Anal.*, vol. 65, p. 101791, 2020, doi: <https://doi.org/10.1016/j.media.2020.101791>.
- [14] L. K. Cornelio, M. A. Del Castillo, and P. Naval,



[27] L. Chen, P. Bentley, and D. Rueckert, "Fully automatic acute ischemic lesion segmentation in DWI using convolutional neural networks," *NeuroImage Clin.*, vol. 15, pp. 633–643, 2017, doi: <https://doi.org/10.1016/j.nicl.2017.06.016>.

[26] R. Karthik, R. Menaka, M. Hariharan, and D. Won, "Ischemic Lesion Segmentation using Ensemble of Multi-Scale Region Aligned CNN," *Comput. Methods Programs Biomed.*, vol. 200, p. 105831, 2021, doi: <https://doi.org/10.1016/j.cmpb.2020.105831>.