

Enhancing medical image segmentation accuracy using a hybrid U-Net and ResNet18 architecture for improved treatment planning

Hajar Ahmadi¹, Azimeh NV Dehkordi², Farhad Azimifar³, Seied Rabi Mehdi Mahdavi^{4,5}, Mahnaz Roayaei⁶

¹ Department of Biomedical Engineering, Isf.C., Islamic Azad University, Isfahan, Iran ² Department of Physics, Na.C., Islamic Azad University, Najafabad, Iran

³ Assistant Professor, Department of Biomedical Engineering, Isf.C., Islamic Azad University, Isfahan, Iran,

⁴ Department of Medical Physics and Radio-Oncology, Faculty of Medicine, Iran University of Medical Science, Tehran, Iran

⁵ Radiation Biology Research Center, Iran University of Medical Science, Tehran, Iran

⁶ Department of Radiation Oncology, Omid Hospital, Esfahan University of Medical Sciences, Isfahan, Iran

Abstract

Background: Improving segmentation accuracy in CT images of patients with breast cancer plays a crucial role in designing effective treatment plans. This study aimed to evaluate the performance of two deep neural network models, including a U-Net architecture and a combined U-Net with ResNet-18, in this domain.

Materials and methods: Data from 120 patients, comprising 6,890 CT slices, were annotated by expert oncologists and used as the reference standard. These annotations included the heart, left lung, planning target volume (PTV), gross tumor volume (GTV), background, and skin. After data preprocessing, hyperparameters were optimized using a random search method. The models were trained and evaluated based on various performance metrics. Results indicated that the combined model outperformed the U-Net alone in identifying tumor volumes and sensitive structures.

Results: The Dice score reached to 60.35% for GTV and 76.94% for PTV, whereas the U-Net model achieved 39.22% and 39.47%, respectively. These findings demonstrated that the integrated architecture provided significant improvements in classification and detection accuracy, affirmed that combining these architectures enhanced segmentation performance.

Conclusion: Utilizing this approach can significantly improve treatment planning processes and reduce targeting errors. The results clearly show that the combined U-Net and ResNet-18 architecture performs better than the U-Net alone. However, further validation with larger datasets is necessary to establish its clinical applicability.

Keywords: Breast cancer, Radiotherapy, Inverse treatment planning, Deep neural networks, U-Net, Resnet18.

Cited as: Ahmadi H, NV Dehkordi A, Azimifar F, Rabi Mahdavi S, Roayaei M. Enhancing medical image segmentation accuracy using a hybrid U-Net and ResNet18 architecture for improved treatment planning. Medical Science Journal of Islamic Azad University, Tehran Medical Branch 2026; 36(3): 289-301.

Correspondence to: Azimeh NV Dehkordi

Tel: +98 9133847617

E-mail: nourizadeh@iau.ac.ir

ORCID ID: 0000-0001-6824-2944

Received: 22 Sep 2025; **Accepted:** 2 Jan 2026

افزایش دقت تقسیم‌بندی تصاویر پزشکی با استفاده از معماری هیبریدی U-Net و ResNet18 و نقش آن در بهبود برنامه ریزی درمان

هاجر احمدی^۱، عظیمه نوری زاده واحد دهکردی^۲، فرهاد عظیمی فر^۳، سید ربیع مهدی مهدوی^۴، مهناز روعایانی^۶

^۱ گروه مهندسی پزشکی، واحد اصفهان (خوراسگان)، دانشگاه آزاد اسلامی، اصفهان، ایران

^۲ گروه فیزیک، واحد نجف‌آباد، دانشگاه آزاد اسلامی، نجف‌آباد، ایران

^۳ استادیار، گروه مهندسی پزشکی، واحد اصفهان (خوراسگان)، دانشگاه آزاد اسلامی، اصفهان، ایران

^۴ گروه فیزیک پزشکی و رادیونکولوژی، دانشکده پزشکی، دانشگاه علوم پزشکی ایران، تهران، ایران

^۵ مرکز تحقیقات بیولوژی پرتو، دانشگاه علوم پزشکی ایران، تهران، ایران

^۶ گروه رادیونکولوژی، بیمارستان امید، دانشگاه علوم پزشکی اصفهان، اصفهان، ایران

چکیده

سابقه و هدف: بهبود دقت در تقسیم‌بندی تصاویر سی‌تی‌اسکن بیماران مبتلا به سرطان پستان، اهمیت زیادی در طراحی درمان‌های مؤثر دارد. هدف این مطالعه، بررسی عملکرد دو مدل شبکه عصبی عمیق، شامل معماری یونت و ترکیب آن با رزنت ۱۸، در این حوزه بود. **روش بررسی:** داده‌های ۱۲۰ بیمار، شامل ۶۸۹۰ اسلایس، با کانتورینگ متخصصان صورت گرفت و به عنوان مرجع استفاده شد. این کانتورینگ‌ها شامل نواحی قلب، ریه، حجم هدف و تومور بودند. پس از پیش‌پردازش داده‌ها، برای بهینه‌سازی پارامترها از روش جستجوی تصادفی استفاده شد. مدل‌ها آموزش یافته و با معیارهای مختلف ارزیابی شدند. مدل ترکیبی در تشخیص حجم تومور و ساختارهای حساس، عملکرد بهتری نسبت به مدل یونت تنها داشت.

یافته‌ها: امتیاز دایس برای حجم خالص تومور تا ۶۰/۳۵ درصد و برای حجم تومور طراحی شده تا ۹۴/۷۶ درصد رسید، در حالی که این مقادیر در مدل یونت به ترتیب ۳۹/۲۲ درصد و ۳۹/۴۷ درصد بودند. این نتایج، نشان‌دهنده برتری مدل ترکیبی در رتبه‌بندی و تشخیص نواحی هدف در تصویر بود و اثبات کرد که ترکیب معماری‌ها می‌تواند بهبود قابل‌توجهی در دقت تشخیص ایجاد کند.

نتیجه‌گیری: استفاده از این فناوری، می‌تواند در ارتقاء فرآیندهای برنامه‌ریزی درمان و کاهش خطاهای هدف‌گیری نقش مهمی ایفا کند. نتایج نشان می‌دهند که معماری ترکیبی یونت و رزنت ۱۸ نسبت به یونت تنها، عملکرد بهتری دارد. با این حال، نیازمند بررسی گسترده‌تر با نمونه‌های بزرگ‌تر است تا قابلیت‌های عملیاتی آن در حوزه بالینی تثبیت شود.

واژگان کلیدی: سرطان پستان، پرتودرمانی، طراحی درمان معکوس، شبکه‌های عصبی عمیق، یونت، رزنت ۱۸.

مقدمه

سرطان پستان (Breast Cancer: BC) یکی از شایع‌ترین انواع سرطان در میان زنان در سرتاسر جهان است. طبق آمار سازمان

بهداشت جهانی، این بیماری هر ساله جان میلیون‌ها زن را در سراسر دنیا می‌گیرد و به عنوان یکی از اصلی‌ترین علل مرگ و میر ناشی از سرطان در این گروه سنی شناخته می‌شود. عوامل مختلفی از جمله ژنتیک، هورمون‌ها، سبک زندگی و محیط زیست می‌توانند در بروز این بیماری تأثیرگذار باشند. لذا، بهبود روش‌های تشخیص، درمان و مدیریت سرطان پستان اهمیت ویژه‌ای دارد، که این امر نیازمند درک بهتر از خصوصیات

آدرس نویسنده مسئول: نجف‌آباد، دانشگاه آزاد اسلامی واحد نجف‌آباد، گروه فیزیک، عظیمه نوری زاده

واحد دهکردی (email: nourizadeh@iau.ac.ir)

ORCID ID: 0000-0001-6824-2944

تاریخ دریافت مقاله: ۱۴۰۴/۶/۳۱

تاریخ پذیرش مقاله: ۱۴۰۴/۱۰/۱۲

پستان این امکان را فراهم می‌کند که تقسیم‌بندی بافت‌های هدف و حساس به دقت بالاتری انجام شود و در نتیجه طراحی برنامه‌های رادیوتراپی بهبود یابد (۱۲-۸). U-Net، به علت معماری خاص خود که شامل لایه‌های رمزگذار و رمزگشا (Encoder and Decoder) است، قادر به حفظ جزئیات در مقیاس‌های مختلف و همچنین تولید خروجی‌های با کیفیت بالا است (۱۳). از سوی دیگر، ResNet-18 با استفاده از تکنیک بلوک‌های باقیمانده (Residual Blocks)، امکان یادگیری عمیق‌تری از داده‌ها را فراهم می‌سازد و به بهبود دقت تقسیم‌بندی کمک می‌کند (۱۴).

این مطالعه به بررسی و مقایسه عملکرد U-Net و ترکیب آن با ResNet-18 در تقسیم‌بندی خودکار بافت‌های مختلف در بیماران مبتلا به سرطان پستان چپ پرداخت. هدف اصلی این پژوهش، ارزیابی دقت و کارایی این مدل‌ها در حمایت از طراحی بهینه پروتکل‌های درمان رادیوتراپی بود. با به‌کارگیری این تکنیک‌های نوین هوش مصنوعی، نه تنها می‌توان به بهبود نتایج درمانی دست یافت، بلکه می‌توان عوارض جانبی ناشی از درمان را نیز کاهش داد و به این ترتیب گامی مؤثر در راستای افزایش کیفیت زندگی بیماران مبتلا به سرطان پستان برداشت.

مواد و روشها

معماری شبکه‌ها

در این بخش، به بررسی دو معماری مهم شبکه‌های عصبی عمیق منتخب، یعنی یونت (U-Net) و رزنت ۱۸ (ResNet-18) خواهیم پرداخت. این دو معماری در کاربردهای تقسیم‌بندی تصاویر، به‌ویژه در زمینه‌های پزشکی، بسیار موفق و مورد توجه هستند.


معماری U-Net

U-Net، نوعی معماری شبکه عصبی برای تقسیم‌بندی تصاویر است. این شبکه به طور ویژه برای تجزیه و تحلیل تصاویر پزشکی طراحی شده است که شامل دو بخش اصلی است: بخش رمزگذار (بخش جمع‌آوری ویژگی‌ها)، که این بخش به تدریج ابعاد تصویر ورودی را کاهش داده و ویژگی‌های سطح بالا را استخراج می‌کند. لایه‌های همگرا (Convolutional Layers) و لایه‌های کمکی (Pooling Layers) در این بخش استفاده می‌شوند؛ و بخش رمزگشا (بخش بازیابی) که این بخش با استفاده از لایه‌های معکوس (Transposed Convolutional Layers) مقیاس تصویر را افزایش می‌دهد و ویژگی‌ها را بازسازی می‌کند (شکل ۱). در اینجا به دقت بالایی تجزیه و تحلیل بافت کمک می‌شود. یکی از جنبه‌های منحصر به فرد U-Net استفاده از ارتباطات جزئی


بیولوژیک و بالینی تومورهای پستان و طراحی درمان (Treatment Planning) هدفمند و مؤثر است. درمان‌های متداول برای سرطان پستان شامل جراحی، شیمی‌درمانی، هورمون‌درمانی و رادیوتراپی هستند. این درمان‌ها به‌طور مستقل یا به صورت ترکیبی استفاده می‌شوند تا به حداکثر اثر درمانی برسند (۳-۱).

از میان درمان‌های معاصر، رادیوتراپی یکی از اصلی‌ترین روش‌های مؤثر در مدیریت سرطان پستان به شمار می‌رود. این روش درمانی با استفاده از پرتوهای یونیزه‌کننده به تخریب سلول‌های سرطانی می‌پردازد و می‌تواند به‌عنوان درمان اولیه یا روش تکمیلی پس از جراحی یا شیمی‌درمانی به کار برود. هدف رادیوتراپی، به حداقل رساندن آسیب به بافت‌های سالم در معرض خطر (Organs At Risk: OAR) و به حداکثر رساندن تأثیر بر بافت‌های سرطانی است. مدیریت مناسب دز تابش و طراحی دقیق پروتکل‌های درمانی به‌ویژه با توجه به پیچیدگی و تنوع آناتومی بیماران، یک چالش کلیدی در این زمینه محسوب می‌شود. این موضوع نیازمند دقت بالا در شناسایی و تقسیم‌بندی (Segmentation) بافت‌های سرطانی است (۴). تشخیص و تفکیک بافت هدف (Target Volume: TV) که باید تحت درمان قرار گیرد و بافت‌های حساس که باید محافظت شوند، نقش اساسی در نتیجه درمان دارد. نادرستی در این تقسیم‌بندی می‌تواند به عوارض ناخواسته همچون آسیب به بافت‌های سالم یا کاهش اثربخشی درمان منجر شود. بنابراین، نیاز به تکنیک‌های خودکار و دقیق برای تقسیم‌بندی این بافت‌ها در حال افزایش است (۶-۴). بنابراین تقسیم‌بندی دقیق بافت‌ها اهمیت زیادی در طراحی درمان رادیوتراپی دارد، زیرا هرگونه خطا در شناسایی یا برآورد حجم این بافت‌ها می‌تواند منجر به عوارض جانبی شدید و یا کاهش اثر درمان شود. استفاده از روش‌های سنتی تقسیم‌بندی به صورت دستی، علاوه بر زمان‌بر بودن، مستعد خطاهای انسانی است. به همین دلیل، استفاده از تکنیک‌های خودکار و هوش مصنوعی در این زمینه به یک نیاز اساسی تبدیل شده است (۷).

در سال‌های اخیر، شبکه‌های عصبی عمیق (Deep DLNs: Learning Networks) به عنوان یکی از پیشرفته‌ترین ابزارها در حوزه پردازش تصاویر پزشکی ظهور کرده‌اند. این شبکه‌ها به‌ویژه برای تحلیل و تقسیم‌بندی تصاویر پیچیده بافت‌های انسانی بسیار کارآمد هستند. مدل‌هایی مانند U-Net و ResNet-18 به‌خاطر ساختار خاص و ویژگی‌های منحصر به فردشان، در این زمینه به شهرت رسیده‌اند. این مدل‌ها توانایی پردازش و تحلیل حجم بالای داده‌ها را دارند و می‌توانند با یادگیری ویژگی‌های پیچیده از داده‌های آموزشی، کیفیت تقسیم‌بندی را به طور قابل توجهی بهبود بخشند. استفاده از این تکنیک‌ها در فرآیند درمان سرطان



شکل ۱. نمایی از معماری شبکه یونت



شکل ۲. نمایی از معماری شبکه رزنت ۱۸

ورودی، یادگیری بهتری انجام دهد. این ویژگی به کاهش مشکل ناپدید شدن گرادیان (vanishing gradient) کمک می‌کند و امکان آموزش عمیق‌تری را فراهم می‌آورد. این معماری به عنوان یک چارچوب قوی و پایدار برای کارهای بینایی ماشین و به‌ویژه تقسیم‌بندی تصویری شناخته شده است. این مدل به خاطر خودآموزختگی و قابلیت یادگیری از ویژگی‌های عمیق، بسیار موثر است. با ترکیب ResNet-18 با روش‌های تقسیم‌بندی، به مدل کمک می‌شود تا ویژگی‌های سطح بالا به همراه اطلاعات مکانی را به‌خوبی پردازش کند (۱۹، ۲۰).

جمع‌آوری داده‌ها

تعداد ۱۲۰ بیمار مبتلا به سرطان پستان، شامل ۶۸۹۰ اسلایس CT از مراکز رادیوتراپی امید تهران و بیمارستان تخصصی رادیوتراپی سید الشهداء اصفهان جمع‌آوری شدند. در این مطالعه، حریم خصوصی بیماران حفظ شد و تمامی مراحل تحقیق تحت

(Skip Connections) است که اجازه می‌دهد اطلاعات تصاویری با ابعاد پایین‌تر به لایه‌های بالاتر منتقل شود. این ویژگی به حفظ اطلاعات مکانی و جزئیات مهم کمک کرده و باعث بهبود دقیق‌تر تقسیم‌بندی در نواحی کوچک می‌شود و به خاطر دقت بالای آن در تقسیم‌بندی نواحی با مقیاس‌های کوچک و نیز توانایی آن در کار با تعداد کم داده‌ها بسیار مهم است. این شبکه به طور گسترده‌ای در کاربردهای پزشکی، مثل تقسیم‌بندی بافت‌های سرطانی و ناهنجاری‌ها مورد استفاده قرار می‌گیرد (۱۸-۱۵).

معماری ResNet-18

رزنت (Residual Networks) نوعی معماری پیشرفته برای یادگیری عمیق است که رزنت ۱۸ یکی از نسخه‌های ابتدایی این معماری است و از ۱۸ لایه تشکیل شده است. ساختار اصلی ResNet به استفاده از بلوک‌های باقیمانده معروف است (شکل ۲). این طراحی به مدل اجازه می‌دهد تا با هر بار اتصال یک لایه به

شناسایی بافت‌های مورد نظر کمک می‌کند. با حذف نواحی غیرمرتبط، مدل می‌تواند عملکرد بهتری داشته باشد و انرژی محاسباتی را صرف محتوای مهم‌تر کند.

ب. استانداردسازی (Normalization): استانداردسازی داده‌ها به مقیاس مشخصی (معمولاً بین ۰ تا ۱) انجام می‌شود. استانداردسازی باعث کاهش اثرات ناخواسته ناشی از تفاوت‌های مقیاس داده‌ها می‌شود و به مدل اجازه می‌دهد که سریع‌تر و با دقت بیشتری یاد بگیرد. این اقدام به تنظیم بهتری از وزن‌ها کمک می‌کند و می‌تواند به جلوگیری از مشکل ناپدید شدن گرادیان کمک کند.

ج. حذف نویز (Denoising): حذف نویزهای ناخواسته از تصاویر برای بهبود کیفیت داده‌ها و افزایش دقت تقسیم‌بندی مفید است. نویز می‌تواند تأثیر منفی بر عملکرد مدل بگذارد و منجر به شناسایی نادرست نقاط کلیدی شود. با کاهش نویز، اطلاعات مفید بیشتری به مدل ارائه می‌شود.

د. بهبود کنتراست (Contrast Enhancement): افزایش وضوح و تمایز در ساختارهای موجود در تصویر است. این کار به مدل کمک می‌کند تا الگوهای مهم در تصاویر را بهتر شناسایی کند. بهبود کنتراست به‌ویژه در تصاویر پزشکی اهمیت زیادی دارد، زیرا معمولاً بافت‌ها می‌توانند با هم تداخل کنند.

ه. تغییر اندازه ورودی (Input Resizing): تغییر اندازه تصاویر برای تطبیق با ورودی‌های شبکه. مدل‌های یادگیری عمیق معمولاً نیاز به ورودی‌های با اندازه مشخص دارند و این کار به بهینه‌سازی استفاده از حافظه و افزایش سرعت پردازش کمک می‌کند.

و. حذف لایه‌های فاقد اطلاعات (Removal of Empty Slices): حذف لایه‌هایی که اطلاعات کافی ندارند (مانند لایه‌های با محتوای ناواضح یا غیرضروری) می‌تواند به جلوگیری از تحلیل‌های نادرست کمک کند. داده‌های نادرست می‌توانند به مدل آسیب بزنند و نتایج غیرقابل اعتمادی تولید کنند.

این پیش‌پردازش‌ها برای اطمینان از کیفیت داده‌های ورودی و بهینه‌سازی عملکرد مدل انجام شدند. هدف از این مراحل، تضمین دقت و درستی نتایج مدل در فرآیند تقسیم‌بندی تصاویر پزشکی است. سپس هر ارگان با رنگ خاص مشخص شد (شکل ۳) و داده‌ها به سه دسته تقسیم شدند: ۷۰٪ یعنی ۸۴ داده برای آموزش (Training)، ۱۵٪ یعنی ۱۸ داده برای اعتبارسنجی (Validation) و ۱۵٪ یعنی ۱۸ داده برای تست انتخاب شدند. این تقسیم‌بندی به منظور ارزیابی دقیق و کارایی مدل در تست نهایی بدون ایجاد سوگیری در داده‌ها انجام شد. در این پژوهش برای آموزش داده‌ها از تابع فعال‌سازی ReLU و بهینه‌ساز Adam استفاده شد. ReLU به دلیل سرعت بالا در یادگیری و جلوگیری

کد اخلاق مناسب انجام شد. سپس تمامی داده‌ها با استفاده از نرم‌افزار 3D Slicer نمونه برداری شدند. ابعاد تصاویر از (۳ ۵۱۲ ۵۱۲) به (۳ ۲۲۴ ۲۲۴) کاهش یافت تا با شبکه‌های انتخابی مطابقت داشته باشد و همچنین فاصله گذاری (Spacing) تصاویر به (۱ ۱ ۱) تغییر یافت. داده‌ها توسط چند متخصص انکولوژی کانتور شده و این کانتورینگ‌ها به عنوان مرجع اصلی (Ground Truth) استفاده شدند. این داده‌های کانتور شده شامل قلب، ریه چپ، حجم هدف طراحی شده (PTV: Planning Target Volume)، حجم خالص تومور (GTV: Gross Tumor Volume)، پس زمینه (Back Ground) و پوست (Skin) بودند.

این تحقیق مورد تأیید کمیته اخلاق در پژوهش دانشگاه آزاد اسلامی واحد اصفهان (خوراسگان) با شناسه اخلاق IR.IAU.KHUISF.REC.1402.100 قرار گرفته است.

پیش‌پردازش داده‌ها

پیش‌پردازش داده‌ها مرحله‌ای حیاتی در فرایند یادگیری ماشین و به‌ویژه در تشخیص و تقسیم‌بندی (Segmentation) تصاویر پزشکی است. این مرحله اطمینان می‌دهد که داده‌های ورودی با کیفیت بالا و در قالب مناسب برای آموزش مدل‌های یادگیری عمیق فراهم شوند. اهمیت پیش‌پردازش به دلایل زیر است:

- بهبود کیفیت داده‌ها: داده‌های خام معمولاً شامل نویز، نقاط غیرمعمول و اطلاعات غیرضروری هستند که می‌توانند به دقت مدل آسیب برسانند. پیش‌پردازش به حذف یا اصلاح این مشکلات کمک می‌کند.

- افزایش دقت و کارایی مدل: با آماده‌سازی داده‌ها، مدل می‌تواند بهتر و سریع‌تر یاد بگیرد. استانداردسازی و بهبود کیفیت تصاویر به کاهش هزینه محاسباتی و افزایش دقت مدل کمک می‌کند.


- جلوگیری از بیش‌برازش (Overfitting) و کم‌برازش (Underfitting): داده‌های با کیفیت پایین یا غیر مرتبط می‌توانند منجر به یادگیری نادرست و ناکارآمد شوند. پیش‌پردازش به ایجاد یک پایه محکم برای آموزش مدل کمک می‌کند.

- تطبیق نیازهای شبکه‌های عمیق: مدل‌های یادگیری عمیق معمولاً نیاز به ورودی‌هایی با اندازه و شکل خاص دارند. پیش‌پردازش می‌تواند ویژگی‌های داده را به گونه‌ای تغییر دهد که با این نیازها سازگار شود.

در نتیجه، پیش‌پردازش داده‌ها مرحله‌ای کلیدی است که کیفیت و قابلیت اطمینان نتایج مدل‌های یادگیری عمیق را به شدت افزایش می‌دهد. در ادامه، مراحل مختلف پیش‌پردازش را بررسی خواهیم کرد:

الف. برش (Crop): حذف نواحی غیرضروری تصویر برای تمرکز بر بافت هدف است. این کار به کاهش نویز و افزایش کارایی مدل در

از مشکل مشتق صفر یا همان ناپدید شدن گرادیان انتخاب شد و Adam با ترکیب یادگیری تطبیقی و میانگین متحرک، به بهبود قابلیت اطمینان و کارایی مدل کمک می‌کند (۲۲،۲۱).



شکل ۳. لیبل گذاری ارگان های مورد نظر

بهینه‌سازی

بهینه‌سازی داده‌ها (Optimizing Hyperparameters) یکی از مراحل کلیدی در فرآیند آموزش مدل‌های یادگیری عمیق است، چرا که این مرحله تأثیر مستقیم بر کارایی، دقت و قابلیت تعمیم مدل دارد. بهینه‌سازی مجموعه‌های آموزشی با تنظیم دقیق پارامترها و ویژگی‌ها، به مدل کمک می‌کند که با الگوهای داده‌ها بهتر سازگار شود و در نتیجه عملکرد بهتری در وظایف پیش‌بینی داشته باشد (۲۴،۲۳). در این مرحله، از چندین پارامتر کلیدی (هایپرپارامتر) برای بهینه‌سازی عملکرد مدل استفاده شد:

- نرخ یادگیری اولیه (Initial Learning Rate :LR): نرخ یادگیری یک پارامتر حیاتی است که نشان می‌دهد مدل با چه سرعتی باید وزن‌های خود را به‌روزرسانی کند. نرخ یادگیری بیش از حد بالا می‌تواند منجر به ناپایداری و واگرایی مدل شود، در حالی که نرخ یادگیری بسیار پایین ممکن است به یادگیری کند و ناکافی منجر شود. تعیین نرخ یادگیری بهینه به مدل کمک می‌کند تا به نحو مطلوبی به حداقل مقدار تابع هزینه نزدیک شود. در این مطالعه محدوده $0.0001 - 0.0013$ مورد بررسی قرار گرفتند، تا بهترین مقدار انتخاب شود.

- فاکتور کاهش نرخ یادگیری (Learning Rate Drop :LRDF): این پارامتر در طول آموزش استفاده می‌شود تا نرخ یادگیری را در نقاط خاص یا پس از تعداد مشخصی از دوره‌ها کاهش دهد. این اقدام به مدل کمک می‌کند که در مراحل پایانی آموزش، به تغییرات کوچک حساس‌تر باشد و در نتیجه حداکثر دقت ممکن را به دست آورد. به همین منظور ما نرخ تغییرات را بین $0.01 - 0.95$ قرار دادیم، تا بتوانیم بهترین نقطه را که بالا ترین دقت را میدهد به عنوان نقطه بهینه انتخاب کنیم.

- تعداد دوره‌ها (Number of Epochs): تعداد دوره‌ها نشان‌دهنده این است که مدل چند بار بر روی کل مجموعه آموزشی آموزش می‌بیند. انتخاب تعداد دوره‌های مناسب به مدل کمک می‌کند تا به آموزش کامل برسد بدون این که دچار بیش‌برازش شود. در همین راستا ما نرخ تغییرات را برای دست‌یابی به بهترین مقدار ممکن، بین $220 - 80$ قرار دادیم.

- اندازه دسته (Batch Size :BS): اندازه دسته به تعداد نمونه‌هایی اشاره دارد که در هر مرحله از آموزش به مدل داده می‌شود. انتخاب حجم دسته مناسب می‌تواند تأثیر زیادی بر زمان یادگیری و پایداری فرآیند آموزش داشته باشد. حجم‌های بسیار کوچک ممکن است به نوسانات زیاد در گرادیان منجر شوند، در حالی که حجم‌های بسیار بزرگ می‌توانند به افزایش زمان آموزش منجر شوند. بهترین محدوده برای تغییرات $1 - 256$ است.

- اندازه حرکت (Momentum): این پارامتر به شروع سریع‌تر و ناپایداری کمتر در فرایند به‌روزرسانی وزن‌ها کمک می‌کند. با ذخیره‌سازی اندکی از تغییرات قبلی، مدل می‌تواند به سمت سمت‌های کمینه‌های محلی با سرعت بیشتری حرکت کند. محدوده تغییرات را در این مورد برای رسیدن به نقطه بهینه، بین $0.5 - 1$ قرار دادیم.

- منظم‌سازی (L2 Regularization :L2R): این تکنیک به کنترل پیچیدگی مدل کمک می‌کند و از بیش‌برازش جلوگیری می‌کند. با اضافه کردن یک جریمه به تابع هزینه (Loss Function) متناسب با مقادیر وزن‌ها، باعث می‌شود که وزن‌ها به سمت مقادیر کوچک‌تر تمایل داشته باشند و در نتیجه مدلی با توانایی تعمیم بهتر به دست آید. برای این‌ها بهیپرپارامتر محدوده تغییرات را بین $0.0001 - 0.001$ در نظر گرفتیم، تا بتوانیم در این محدوده نقطه‌ای را که بالاترین دقت را می‌دهد به عنوان نقطه بهینه معرفی کنیم.

بهینه‌سازی هایپرپارامترها از جوانب مختلف اهمیت دارد:

✓ بهبود دقت و کارایی: تنظیم صحیح هایپرپارامترها می‌تواند به کاهش خطا در پیش‌بینی‌ها و افزایش دقت تقسیم‌بندی منجر شود.

✓ افزایش قابلیت تعمیم: یک مدل بهینه‌شده می‌تواند بهتر روی داده‌های جدید اجرا شود و از این رو عملکرد بهتری در شرایط غیرمانند داده‌های آموزش یافته داشته باشد.

✓ کاهش زمان آموزش: با انتخاب مناسب هایپرپارامترها، می‌توان زمان آموزش را کاهش داد و در عین حال دقت و کیفیت نتایج را حفظ کرد.

• ماتریس سردرگمی (Confusion Matrix): این ابزار تجزیه و تحلیل دقیقی از عملکرد طبقه‌بندی را فراهم می‌آورد و به ما اجازه می‌دهد تا خطاهای پیش‌بینی را به‌طور دقیق شناسایی کنیم. ماتریس سردرگمی به ما کمک می‌کند تا تشخیص دهیم که کدام کلاس‌ها بیشتر با خطا مواجه شده و نیاز به بهبود بیشتری دارند. معیارهای انتخاب‌شده به‌دلیل زیر اهمیت دارند:

- تنوع ارزیابی: استفاده از معیارهای مختلف به ما این امکان را می‌دهد که اندازه‌گیری جامع‌تری از عملکرد مدل داشته باشیم. هر معیار از جنبه‌های مختلف عملکرد مدل را بررسی می‌کند.

- تمرکز بر دقت‌های پزشکی: در کاربردهای پزشکی، دقت و صحت در شناسایی بافت‌ها و ساختارهای مهم بسیار حیاتی است. معیارهایی مانند DSC و IoU به‌ویژه در تشخیص و تقسیم‌بندی بافت‌های کوچک بسیار حساس و مؤثر هستند.

- تحلیل دقیق‌تر عملکرد: استفاده از ماتریس سردرگمی و دقت میانگین به ما این امکان را می‌دهد که به‌طور دقیق‌تری درباره نقص‌ها و ضعف‌های مدل در تقسیم‌بندی بافت‌های خاص آگاه شویم.

- بازخورد برای بهبود مدل: این معیارها به ما در شناسایی و تحلیل نواقص مختلف کمک می‌کنند و می‌توانند به عنوان ابزاری برای بهینه‌سازی و بهبود عملکرد مدل در مراحل بعدی استفاده شوند.

در این صورت ما می‌توانیم به ارزیابی دقیق‌تری از عملکرد مدل‌ها دست یابیم و روندهای بهبود را در تقسیم‌بندی تصاویر پزشکی شناسایی کنیم.

یافته‌ها

در این تحقیق، به بررسی عملکرد دو معماری شبکه عصبی عمیق، یعنی یونت و ترکیب یونت و رزنت ۱۸، در زمینه تقسیم‌بندی تصاویر CT مربوط به بیماران با سرطان پستان چپ در فرآیند طراحی درمان معکوس پرتودرمانی پرداخته شد. با توجه به جدول ۱، برای بهینه‌سازی عملکرد مدل‌ها، هایپرپارامترهای مختلفی همانطور که در بخش قبل نام برده شد، مورد ارزیابی قرار گرفت. مقدار بهینه هر کدام به روش جستجوی تصادفی تعیین شدند که این موضوع به افزایش کارایی مدل‌ها کمک کرد.

بر اساس جدول ۲ و داده‌های ارائه شده، می‌توان نتایج تجزیه و تحلیل عملکرد این دو مدل را به‌صورت زیر خلاصه کرد:

✓ جلوگیری از مشکلات یادگیری: بهینه‌سازی هایپرپارامترها می‌تواند به جلوگیری از مشکلاتی مانند بیش‌برازش و کم‌برازش کمک کند، که می‌تواند تأثیر منفی بر عملکرد مدل داشته باشد. در نهایت، بهینه‌سازی داده‌ها و تنظیم هایپرپارامترها یک فرآیند پویا و تکراری است که نیازمند آزمایش و ارزیابی مکرر است تا به بهترین مدل ممکن دست یابیم.

ارزیابی مدل‌ها (Models Evaluation)

برای ارزیابی عملکرد مدل‌ها از معیارهای مختلفی استفاده شد که هر کدام به روش‌های خاص به اندازه‌گیری دقت و کارایی تقسیم‌بندی کمک می‌کنند. معیارهای انتخاب‌شده شامل موارد زیر هستند:

• معیار همپوشانی دایس (Dice Similarity Coefficient: DSC): این معیار همپوشانی بین ماسک‌های پیش‌بینی‌شده و زمینه حقیقی (GT) را اندازه‌گیری می‌کند. به دلیل حساسیت بالای آن در شناسایی بافت‌های کوچک، به‌ویژه برای کاربردهای پزشکی که دقت در شناسایی ساختارها اهمیت زیادی دارد، انتخاب شده است.

• همپوشانی و اتحاد (Intersection over Union: IoU): این معیار میزان همپوشانی بین نواحی پیش‌بینی‌شده و زمینه حقیقی را محاسبه می‌کند و به‌ویژه در تقسیم‌بندی چندکلاسه مفید است. انتخاب این معیار به دلیل قابلیت خوبی که در ارزیابی عملکرد برای چندین کلاس مختلف دارد، بوده است.

• میانگین IOU (IoU Mean): این معیار به محاسبه میانگین IoU برای تمامی کلاس‌ها می‌پردازد و توانایی مدل را در شناسایی نواحی مختلف تجزیه و تحلیل می‌کند. استفاده از میانگین IoU به ما امکان می‌دهد تا یک دید کلی از عملکرد مدل کل در تمامی کلاس‌ها داشته باشیم.

• دقت کل (Global Accuracy): این معیار همان میزان دقت کل پیش‌بینی‌ها را نسبت به کل داده‌ها نشان می‌دهد. این معیار به ما کمک می‌کند تا تخمین دقیقی از عملکرد کلی مدل به‌دست آوریم.

• دقت میانگین (Mean Accuracy): این معیار دقت را برای هر کلاس به‌طور جداگانه محاسبه کرده و میانگین آن‌ها را نمایش می‌دهد. این کار به ما اجازه می‌دهد تا نحوه عملکرد مدل را در هر کلاس به‌طور جداگانه بررسی کنیم و تشخیص دهیم که آیا برخی کلاس‌ها نیاز به بهبود بیشتری دارند.

• میانگین امتیاز BF (Mean BF Score): این معیار بر عملکرد تشخیص مرز تأکید می‌کند و به ما کمک می‌کند تا نحوه شناسایی دقیق مرزها را در بافت‌های مختلف بررسی کنیم.

جدول ۱. بهینه سازی هایپر پارامتر های کلیدی

هایپر پارامتر	محدوده پیشنهادی	بهترین مقدار پیشنهادی
نرخ یادگیری اولیه	۰/۰۰۰۱ - ۰/۰۰۱۳	۰/۰۰۳
عامل کاهش نرخ یادگیری	۰/۹۵ - ۰/۱	۰/۹
تعداد دوره ها	۸۰ - ۲۲۰	۲۰۰
اندازه دسته	۲۵۶-۱۶	۶۴
اندازه حرکت	۰/۱-۵/۲	۰/۹۹
تنظیم L2	۰/۰-۰۰۰۱/۰۱	۰/۰۰۵

جدول ۲. مقایسه شبکه های آموزشی بر اساس امتیازهای دایس

امتیاز دایس*	قلب	ریه چپ	حجم تومور خالص	حجم تومور طراحی شده	پوست	پس زمینه
U-Net	۸۲/۵	۹۷/۳	۳۹/۲	۳۹/۴	۹۰/۲	۹۷/۰۳
Combining U-Net & Resnet 18	۹۰/۵	۹۰/۵	۶۰/۳	۷۶/۹	۹۵/۰	۹۸/۷

* تمامی اعداد به درصد هستند.

- مدل یونت دارای ضریب Dice میانگین ۷۴/۳۴ درصد بود، که نشان دهنده دقت خوبی در تقسیم بندی است. در مورد ارگان ها، یونت برای تقسیم بندی قلب و ریه چپ عملکرد قابل قبولی از خود نشان داد، به طوری که ضریب Dice برای قلب ۸۲/۵۸ درصد و برای ریه چپ ۹۷/۳۰ درصد ثبت شد.
- مدل ترکیبی یونت و رزنت ۱۸ به خصوص در تقسیم بندی ارگان ها با توجه به نتایج دایس برای هر ارگان، دارای عملکرد بهتری نسبت به یونت بود. به گونه ای که برای قلب، به دقت ۹۰/۵۵ رسید و بهترین دقت را نسبت به یونت برای GTV و PTV به ترتیب ۶۰/۳۵ درصد و ۷۶/۹۴ درصد ثبت کرده است، در حالی که شبکه یونت برای این اندام ها به ترتیب دارای دقت ۳۹/۲۲ درصد و ۳۹/۴۷ درصد است. این نتایج نشان دهنده ضعف یونت در تقسیم بندی برخی مناطق خاص از جمله GTV و PTV، نسبت به شبکه ترکیبی یونت و رزنت ۱۸ است.

در جدول ۳ نتایج ارزیابی شبکه ها با ارزیاب های منتخب که در بخش قبل ذکر شد، آورده شده است. با توجه به این نتایج، دقت کلی برای یونت، ۹۵/۱۱ درصد و برای ترکیب یونت و رزنت ۱۸، ۹۶/۸۲ درصد است. این نشان می دهد که به کارگیری رزنت ۱۸ به شبکه کمک کرده تا بیشتر به نسبت برچسب های صحیح دست یابد. این دقت بالاتر می تواند به ویژه در زمینه های حساس مانند پزشکی از اهمیت بالایی برخوردار باشد، جایی که تشخیص صحیح

می تواند تأثیر زیادی بر نتایج درمانی داشته باشد. در زمینه میانگین دقت، ترکیب یونت و رزنت ۱۸ با ۹۴/۳۵ درصد عملکرد قابل توجهی دارد و از یونت با ۶۳/۵۹ درصد فاصله دارد. این نشان دهنده بهبود در شناسایی کلاس های مختلف است و به ما این امکان را می دهد که بگوییم با استفاده از رزنت ۱۸، شبکه به طور موثرتری قادر به درک ویژگی های موجود در داده های آموزشی شده است و به همین دلیل در تشخیص نواحی کوچک تر و مهم مانند PTV و GTV عملکرد بسیار بالاتری را از خود نشان داده است. میانگین IoU نیز به نفع شبکه ترکیبی یونت و رزنت ۱۸ است، به طوری که ۷۷/۰۳ درصد را در مقابل ۶۱/۱۶ درصد از یونت نشان می دهد. این معیار نشان دهنده درصد نواحی پیش بینی شده درست با نواحی واقعی است. لذا، ترکیب یونت و رزنت ۱۸ در درک نواحی صحیح و جلوگیری از خطاهای شناسایی در تصویر بهتر عمل کرده است.

در نهایت، IOU وزنی نیز برای مدل ترکیبی یونت و رزنت ۱۸، ۹۳/۴۸ درصد و برای یونت، ۸۹/۶۲ درصد است. این معیار به ما نشان می دهد که مدل با ترکیب کلاس ها بهتر عمل کرده و در شناسایی نواحی بحرانی توانسته موفق تر باشد و در نهایت در نمودار میانگین امتیاز BF، مدل ترکیبی یونت و رزنت ۱۸ با ۸۳/۶۵ درصد نسبت به یونت با ۷۸/۰۷ درصد نمایانگر عملکردی بهتر است. این نشان دهنده توازن بین دقت و ضریب فراخوانی است؛ در واقع بالا بودن میانگین امتیاز BF نشان دهنده دقت بالای مدل در شناسایی و تعیین مرزهای تومور و اندام های در

جدول ۳. ارزیابی شبکه ها با ارزیابی های منتخب*

شبکه های آموزشی	دقت کلی	میانگین دقت	میانگین IoU	وزنی IoU	امتیاز میانگین BF
U-Net	۹۵/۱۱	۶۳/۵۹	۶۱/۱۶	۸۹/۶۲	۷۸/۰۷
Combining U-Net with ResNet-18	۹۶/۸۲	۹۴/۳۵	۷۷/۰۳	۹۳/۴۸	۸۳/۶۵

* تمامی اعداد به درصد هستند.

جدول ۴. ماتریس سردرگمی شبکه یونت

کلاس ها	قلب	ریه چپ	حجم خالص تومور	حجم تومور طراحی شده	پوست	پس زمینه
قلب	۳۳/۳۱	۰/۱۰	۰/۰۰	۰/۰۰	۶۶/۵۹	۰/۰۵
ریه چپ	۰/۱۰	۴۷/۳۱	۰/۰۰	۰/۰۰	۵۲/۲۲	۰/۴۸
GTV	۲/۶۵	۰/۰۱	۴۱/۵۰	۴۶/۰۸	۹/۷۴	۰/۰۲
PTV	۰/۰۸	۰/۰۵	۰/۶۲	۶۰/۳۲	۳۸/۹۰	۰/۰۲
پوست	۰/۰۳	۰/۰۴	۰/۰۰	۰/۰۹	۹۹/۴۴	۰/۴۰
پس زمینه	۰/۰۰	۰/۰۰	۰/۰۰	۰/۰۰	۰/۳۲	۹۹/۶۸

* تمامی اعداد به درصد هستند.

جدول ۵. ماتریس سردرگمی شبکه یونت (رزت ۱۸)


کلاس ها	قلب	ریه چپ	حجم خالص تومور	حجم تومور طراحی شده	پوست	پس زمینه
قلب	۹۶/۵۷	۰/۱۰	۰/۱۲	۰/۰۸	۳/۱۲	۰/۰۰
ریه چپ	۰/۰۲	۹۷/۳۲	۰/۰۰	۰/۱۳	۲/۵۳	۰/۰۰
GTV	۰/۲۱	۰/۰۰۵	۸۵/۵۲	۱۴/۲۵	۰/۰۱	۰/۰۰
PTV	۰/۰۵	۰/۰۹	۳/۸۶	۹۳/۹۷	۱/۱۵	۰/۰۰۰۶
پوست	۰/۸۳	۱/۵۸	۰/۰۲	۱/۸۱	۹۵/۱۲	۰/۶۳
پس زمینه	۰/۰۰۰۹	۰/۰۰۰۵	۰/۰۰	۰/۰۰	۰/۵۸	۹۹/۴۱

* تمامی اعداد به درصد هستند.

معرض خطر است، که به بهبود تصمیم‌گیری‌های بالینی و طراحی درمان‌های هدفمند کمک می‌کند.

در جدول ۴، ماتریس سردرگمی مدل U-Net آورده شده است. مدل با دقت ۳۳/۳۱ درصد از نمونه‌های واقعی قلب را به درستی طبقه‌بندی کرد، در حالی که حدود ۶۶/۵۹ درصد از آن‌ها را به اشتباه به عنوان پوست طبقه‌بندی کرد. این نشان‌دهنده یک چالش مهم در تشخیص دقیق ساختارهای قلب است. نرخ پیش‌بینی صحیح ریه چپ ۴۷/۳۱ درصد است. قابل توجه است که ۵۲/۲۲ درصد از نمونه‌های تقسیم بندی ریه به اشتباه به عنوان پوست طبقه‌بندی شدند، که نشان‌دهنده دشواری در تمایز این ناحیه از مناطق غیر ساختاری است. کلاس GTV عملکرد متفاوتی را نشان می‌دهد و ۴۱/۵ درصد از نمونه‌ها به درستی شناسایی شده‌اند. اشتباه قابل توجه ۴۶/۰۸ درصد

به PTV نشان‌دهنده چالش‌ها در تقسیم بندی موثر ناحیه تومور است. برای کلاس PTV، مدل به ۶۰/۳۲ درصد طبقه‌بندی‌های صحیح برای PTV دست یافت، در حالی که حدود ۳۸/۹ درصد به اشتباه به عنوان پوست طبقه‌بندی شدند. این نشان‌دهنده عملکرد قابل قبول است، اما همچنان حاکی از وجود فضای بهبود است. کلاس پوست با دقت ۹۹/۴۴ درصد بالاترین دقت را دارد که نشان‌دهنده توانایی بالای مدل در تقسیم بندی این ساختار است (با حداقل طبقه‌بندی اشتباه). مدل با دقت ۹۹/۶۸ درصد پس‌زمینه را به درستی شناسایی کرد، که نشان‌دهنده عملکرد قوی در تشخیص پس‌زمینه از ساختارهای آناتومیکی است. این موضوع قابل انتظار است، زیرا پس‌زمینه معمولاً شامل نواحی غیر مرتبط در تصویربرداری پزشکی است. بنابراین، ماتریس درهم‌ریختگی نقاط قوت و ضعف مدل یونت را در



شکل ۴. مقایسه نتایج بصری شبکه های آموزشی

تقسیم بندی مناطق مختلف آناتومیکي برجسته می‌کند. در حالی که مدل در طبقه‌بندی پوست و پس‌زمینه عالی عمل می‌کند، اما با تقسیم بندی دقیق مناطق پیچیده‌تر مانند قلب و GTV دست و پنجه نرم می‌کند. این بینش‌ها ممکن است به بهسازی‌های آتی مدل، مانند استراتژی‌های آموزشی هدفمند یا تکنیک‌های افزایش داده، برای بهبود عملکرد در کلاس‌های ضعیف کمک کند.

همچنین در جدول ۵ ماتریس سردرگمی برای مدل ترکیبی یونت و رزنت ۱۸ آورده شده است. مدل، دقت کلی بالایی را در بین دسته‌های مختلف نشان می‌دهد. مقادیر قطری ماتریس سردرگمی، نشان‌دهنده نسبت نمونه‌های به‌درستی طبقه‌بندی‌شده برای هر دسته هستند. نرخ‌های طبقه‌بندی دقیق برای دسته‌های اصلی به این شرح است: قلب ۹۶/۵۷ درصد، ریه چپ ۹۷/۳۲ درصد، حجم خالص تومور ۸۵/۵۲ درصد، حجم تومور طراحی شده ۹۳/۹۷ درصد، پوست ۹۵/۱۲ درصد، و پس‌زمینه ۹۴/۴۱ درصد. این مقادیر نشان می‌دهند که مدل به ویژه در تمایز بین دسته‌های قلب، ریه و پس‌زمینه عملکرد خوبی دارد. تقسیم‌بندی دقیق بافت‌های سرطان سینه برای برنامه‌ریزی موثر درمان، به ویژه در پرتودرمانی، بسیار مهم است. نرخ‌های دقت بالا در اکثر دسته‌ها نشان می‌دهد که مدل ترکیبی یونت و رزنت ۱۸ ابزاری امیدوارکننده نسبت به یونت برای تقسیم‌بندی

خودکار بافت‌های سرطان سینه است و به طور بالقوه به رادیولوژیست‌ها در تعیین حدود دقیق کمک می‌کند. شکل ۴ مجموعه‌ای از برش‌های تصویری CT را به‌عنوان ورودی‌های شبکه به همراه پیش‌بینی‌های تولید شده توسط مدل‌های مختلف نمایش می‌دهد. ستون اول تصاویر ورودی CT را نشان می‌دهد، ستون دوم تقسیم‌بندی‌های دستی که توسط کارشناسان تأیید شده است (GT) را نشان می‌دهد. ستون سوم همپوشانی بین تصاویر ورودی و GT را نشان می‌دهد، در حالی که ستون چهارم تقسیم‌بندی‌های پیش‌بینی‌شده مدل‌ها را ارائه می‌دهد. ستون آخر همپوشانی بین نقشه‌های تقسیم‌بندی پیش‌بینی‌شده و GT را تأکید می‌کند. در این ستون، نواحی سیاه و خاکستری نشان‌دهنده توافق کامل بین تقسیم‌بندی‌های پیش‌بینی‌شده و GT است، در حالی که نواحی بنفش اختلافات را نشان می‌دهد. ردیف اول نتایج تقسیم‌بندی شده با مدل یونت را نشان می‌دهند و ردیف دوم نتایج پیش‌بینی مدل ترکیبی یونت و رزنت ۱۸ را نشان می‌دهند. معماری یونت در وظایف بخش‌بندی تصاویر پزشکی نویدبخش بوده است. با این حال، یافته‌های اولیه نشان می‌دهد که یک مدل یونت استاندارد دقت کافی در شناسایی و بخش‌بندی نواحی حجم هدف برنامه‌ریزی (PTV) و حجم خالص تومور (GTV) از خود نشان نمی‌دهد

مثبتی بر عملکرد کلی تقسیم‌بندی داشته باشد و میزان خطا را به حداقل برساند.

در چند سال اخیر، تحقیقات متعددی در حوزه خودکارسازی فرآیندهای تقسیم‌بندی نواحی هدف در درمان سرطان پستان انجام شده است. به عنوان مثال، یافته‌های مطالعه چانگ و همکارانش (۲۰۲۱) نشان دادند که استفاده از روش‌های مبتنی بر یادگیری عمیق، امکان خودکارسازی ترسیم حجم هدف و ارگان‌های در معرض خطر پس از جراحی محافظت‌کننده پستان را فراهم می‌کند، که این رویکرد در بهبود دقت و کاهش زمان مورد نیاز، اثربخش است (۱۵). در پژوهش دیگری که در سال ۲۰۲۳ انجام شد، توانستند با تلفیق یونت ۳ بعدی و پیچ‌های بعدی شبکه گان، فرآیند تقسیم‌بندی نواحی درمان را در تصاویر CT بیماران مبتلا به سرطان پستان بهبود بخشند، که نشان‌دهنده اثر مثبت استفاده از معماری‌های پیچیده و ترکیبی در این حوزه است (۲۰).

همچنین، در مطالعه کاظم مقدم و همکارانش (۲۰۲۴) موفق به توسعه رویکردهای مبتنی بر یادگیری عمیق برای تقسیم‌بندی خودکار حجم هدف در درمان پرتودرمانی بخش پستان شدند که نتایج قابل توجهی در دقت و سرعت ارائه می‌دهد (۲۵).

مطالعه حاضر، بر پایه تجربیات این پژوهش‌ها، با تمرکز بر تقسیم‌بندی چندنقشه‌ای جامع شامل پس‌زمینه، پوست، حجم تومور، ریه چپ و قلب، توانست با بهره‌گیری از ترکیب معماری‌های قوی و به‌روز، U-Net و ResNet-18، سطح عملکرد مدل را به میزان قابل توجهی ارتقاء دهد. استفاده هم‌زمان و ترکیب این معماری‌ها، امکان استخراج ویژگی‌های غنی‌تر و جامع‌تر از تصاویر پزشکی را فراهم می‌کند، که در نتیجه به بهبود دقت در تقسیم‌بندی نواحی هدف می‌انجامد. به‌کارگیری روش بهینه‌سازی هایپرپارامترها و ادغام این معماری‌ها، منجر به ساختن یک مدل دقیق‌تر، سریع‌تر و مقاوم‌تر شده است. این رویکرد در مقایسه با به کار گیری شبکه‌های منتخب U-Net یا ResNet-18، به صورت مجزا، مزیت‌هایی نظیر کاهش خطا، بهبود شناسایی جزئیات، و صرفه‌جویی در زمان پردازش را دارد که اهمیت قابل توجهی در کاربردهای بالینی مانند برنامه‌ریزی رادیوتراپی دارد. در نتیجه، عملکرد این مدل ارتقاء یافته، نسبت به نمونه‌های قبلی، باعث افزایش دقت و کارایی در تشخیص و تقسیم‌بندی نواحی مختلف در تصاویر پزشکی شده است.

با توجه به نتایج به‌دست‌آمده، می‌توان نتیجه‌گیری کرد که استفاده از شبکه‌های عصبی عمیق، به‌خصوص معماری مدل ترکیبی یونت و رزنت ۱۸، قادر است در تقسیم‌بندی خودکار

و اغلب اندازه آن‌ها را بیش از حد تخمین می‌زند. در مقابل، معماری مدل ترکیبی یونت و رزنت ۱۸ است، که عملکرد به مراتب بهتری در همین وظیفه از خود نشان می‌دهد. این یونت بهبود داده شده با رزنت ۱۸، در شناسایی ساختارهایی مانند قلب و ریه‌ها به خوبی عمل می‌کند و دقت به طور قابل توجهی بالاتری در بخش‌بندی PTV و GTV نشان می‌دهد. علاوه بر این، مرزهای مشخص‌شده برای نواحی PTV و GTV تولید شده توسط مدل ترکیبی یونت و رزنت ۱۸، به خوبی با تقسیم‌بندی متخصصان مطابقت دارد، که نشان‌دهنده یک نتیجه بخش‌بندی قابل اعتمادتر و از نظر بالینی مرتبط‌تر است. این نتایج بر اهمیت اصلاحات معماری، مانند گنجانیدن ساختارهای رزنت، برای بهبود عملکرد مدل‌های یونت در وظایف خاص بخش‌بندی تصاویر پزشکی تأکید می‌کند.

بحث

در این پژوهش، به بررسی تقسیم‌بندی خودکار حجم هدف و اندام‌های در معرض خطر در سرطان پستان با استفاده از تصاویر سی‌تی پرداخته شد. دو مدل پیشرفته شبکه‌های عصبی عمیق، یونت و مدل ترکیبی یونت و رزنت ۱۸، به‌منظور ارزیابی دقت تقسیم‌بندی و عملکردهای آن‌ها در شناسایی نواحی حیاتی مورد استفاده قرار گرفتند. تحلیل امتیازهای دایس و ارزیابی‌های انجام شده نشان داد که هر دو مدل توانسته‌اند به عملکرد قابل توجهی دست یابند. یونت در تقسیم‌بندی نواحی مانند پس‌زمینه و پوست به نتایج خوبی دست یافته، در حالی که مدل ترکیبی یونت و رزنت ۱۸ به لطف معماری پیشرفته‌تری که دارد، بهبود عملکرد قابل توجهی در شناسایی نواحی پراهمیت‌تر در بحث پرتودرمانی مانند حجم خالص تومور و حجم تومور طراحی‌شده ارائه داد. یونت با توانایی بالای خود در شناسایی نواحی مختلف، به‌ویژه در شناسایی پوست و پس‌زمینه، امتیازهای دایس بالایی را به خود اختصاص داد. با این حال، مدل ترکیبی یونت و رزنت ۱۸ در مقایسه با مدل یونت دستاوردهای بهتری در تقسیم‌بندی تومورها نشان داد. به‌طور خاص، امتیاز BF و میانگین دقت در مدل ترکیبی یونت و رزنت ۱۸ به‌وضوح بالاتر از یونت بود. این تفاوت‌ها ناشی از ساختار پیچیده‌تر و عمیق‌تر رزنت ۱۸ است که امکان یادگیری ویژگی‌های پیچیده‌تر و استخراج بهتر اطلاعات از تصاویر سی‌تی را فراهم می‌کند. نتایج نشان می‌دهند که مدل ترکیبی یونت و رزنت ۱۸ توانسته است تأثیر

به همین دلیل، تلاش برای توسعه و بهینه‌سازی مدل‌های یادگیری عمیق در آینده ضروری است تا بتوانیم به نتایج بهتری در زمینه درمان معکوس رادیوتراپی دست یابیم و در نهایت کیفیت درمان و نتایج بالینی را برای بیماران مبتلا به سرطان پستان بهبود بخشیم.

حجم هدف و اندام‌های در معرض خطر در سرطان پستان به خوبی عمل کند. این امر نه تنها در بهبود دقت تشخیص نواحی حیاتی کمک می‌کند، بلکه می‌تواند به طراحی درمان‌های شخصی‌سازی شده و هدفمند برای بیماران نیز منجر شود. پژوهش حاضر نشان می‌دهد که بهینه‌سازی هایپرپارامترها همچنین نقش کلیدی در افزایش کارایی مدل‌ها ایفا می‌کند.

REFERENCES

1. Shaaban SM, Nawaz M, Said Y, Barr M. An Efficient Breast Cancer Segmentation System based on Deep Learning Techniques. *Engineering, Technology & Applied Science Research* 2023;13:12415–22.
2. Yerramilli D, Xu AJ, Gillespie EF, Shepherd AF, Beal K, Gomez D, et al. Palliative Radiation Therapy for Oncologic Emergencies in the Setting of COVID-19: Approaches to Balancing Risks and Benefits. *Adv Radiat Oncol* 2020;5:589-94.
3. Trapani D, Ginsburg O, Fadelu T, Lin NU, Hassett M, Ilbawi AM, et al. Global challenges and policy solutions in breast cancer control. *Cancer Treat Rev* 2022;104:102339.
4. Van de Steene J, Linthout N, de Mey J, Vinh-Hung V, Claassens C, Noppen M, et al. Definition of gross tumor volume in lung cancer: inter-observer variability. *Radiother Oncol* 2002;62:37-49.
5. Chung Y, Kim JW, Shin KH, Kim SS, Ahn SJ, Park W, et al. Dummy Run of Quality Assurance Program in a Phase 3 Randomized Trial Investigating the Role of Internal Mammary Lymph Node Irradiation in Breast Cancer Patients: Korean Radiation Oncology Group 08-06 Study. *Int J Radiat Oncol Biol Phys* 2015;91:419-26.
6. Khodadadi Shoushtari F, Sina S, Dehkordi ANV. Automatic segmentation of glioblastoma multiform brain tumor in MRI images: Using Deeplabv3+ with pre-trained Resnet18 weights. *Phys Med* 2022;100:51-63.
7. Ciardo D, Argenone A, Boboc GI, Cucciarelli F, De Rose F, De Santis MC, et al. Variability in axillary lymph node delineation for breast cancer radiotherapy in presence of guidelines on a multi-institutional platform. *Acta Oncol* 2017;56:1081–88.
8. Yu Y, Wang C, Fu Q, Kou R, Huang F, Yang B, et al. Techniques and Challenges of Image Segmentation: A Review. *Electronics*. 2023;12:1199.
9. LeCun Y, Bengio Y, Hinton G. Deep learning. *Nature* 2015;521:436-44.
10. Schmidhuber, J. Deep learning in neural networks: An overview. *Neural Netw* 2015;61:85–117.
11. Shamshirband S, Fathi M, Dehzangi A, Chronopoulos AT, Alinejad-Rokny H. A review on deep learning approaches in healthcare systems: Taxonomies, challenges, and open issues. *J Biomed Inform* 2021;113:103627.
12. Miotto R, Wang F, Wang S, Jiang X, Dudley JT. Deep learning for healthcare: review, opportunities and challenges. *Brief Bioinform* 2018;19:1236-46.
13. Ling DC, Moppins BL, Champ CE, Gorantla VC, Beriwal S. Quality of Regional Nodal Irradiation Plans in Breast Cancer Patients Across a Large Network-Can We Translate Results From Randomized Trials Into the Clinic? *Pract Radiat Oncol* 2021;11:e30-e35.
14. Dehkordi AN, Kamali-Asl A, Ewing JR, Wen N, Chetty IJ, Bagher-Ebadian H. An adaptive model for rapid and direct estimation of extravascular extracellular space in dynamic contrast enhanced MRI studies. *NMR Biomed* 2017;30.
15. Chung SY, Chang JS, Choi MS, Chang Y, Choi BS, Chun J, et al. Clinical feasibility of deep learning-based auto-segmentation of target volumes and organs-at-risk in breast cancer patients after breast-conserving surgery. *Radiat Oncol* 2021;16:44.
16. Zhang J, Yang J, An T, Wu P, Ma C, Zhang C, et al. AFC-ResNet18: A Novel Real-Time Image Semantic Segmentation Network for Orchard Scene Understanding. *Journal of the ASABE* 2024;67:493-500.
17. Shelhamer E, Long J, Darrell T. Fully Convolutional Networks for Semantic Segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence* 2017;39:640651.
18. Ronneberger O, Fischer P, Brox T. U-net: Convolutional networks for biomedical image segmentation. In: *International Conference on Medical image computing and computer-assisted intervention* 2015 Oct 5 (pp. 234-241). Cham: Springer international publishing.

19. Caballo M, Pangallo DR, Mann RM, Sechopoulos I. Deep learning-based segmentation of breast masses in dedicated breast CT imaging: Radiomic feature stability between radiologists and artificial intelligence. *Comput Biol Med* 2020;118:103629.
20. Colbert ZM, Ramachandran P. Auto-segmentation of thoracic organs in CT scans of breast cancer patients using a 3D U-net cascaded into 2D patchGANs. *Biomed Phys Eng Express* 2023;9.
21. Jiang X, Zhang R, Nie S. Image Segmentation Based on Level Set Method. *Physics Procedia* 2012;33:840-84.
22. He K, Zhang X, Ren S, Sun J. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas, NV, USA, 2016, pp. 770-78.
23. Kingma DP, Ba J. Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*. 2014 Dec 22.
24. Khodadadi Shoushtari F, Dehkordi ANV, Sina S. Quantitative and Visual Analysis of Data Augmentation and Hyperparameter Optimization in Deep Learning-Based Segmentation of Low-Grade Glioma Tumors Using Grad-CAM. *Ann Biomed Eng* 2024;52:1359-77.
25. Kazemimoghadam M, Yang Z, Chen M, Rahimi A, Kim N, Alluri P, et al. A deep learning approach for automatic delineation of clinical target volume in stereotactic partial breast irradiation (S-PBI). *Phys Med Biol* 2023;68:10.1088/1361-6560/accf5e.