مجله علوم، مهندسی و فناوری هستهای، دوره ۴۶، شماره ۲، جلد ۱۱۲، تابستان ۱۴۰۴

Journal of Nuclear Science, Engineering and Technology Vol. 46 (2), Serial Number 112, 2025

# بررسي الگوريتمهاي يادگيري عميق بهعنوان ابزار خودكار قطعهبندي تصاوير سيتياسكن لگني

الناز قائدی\*'، علی اسدی'، سیدابوالفضل حسینی' 回، حسین عربی' دانشکده مهندسی انرژی، دانشگاه صنعتی شریف، صندوق پستی: ۱۴۵۶۵-۱۱۱۴، تهران - ایران ۲. بخش پزشکی هستهای و تصویربرداری مولکولی، گروه تصویربرداری پزشکی، بیمارستان ژنو، ژنو- سوئیس

\*Email: Elnaz.ghaedi74@sharif.edu

مقالة يژوهشي تاریخ دریافت مقاله: ۱۴۰۳/۰۳/۰۹ تاریخ بازنگری مقاله: ۱۴۰۳/۰۶/۲۵ تاریخ پذیرش مقاله: ۱۴۰۳/۰۷/۱۸

### چکندہ

طراحی پرتودرمانی نیازمند شناسایی و قطعهبندی دقیق اندامهای در معرض خطر (OAR) است، که بهطور معمول عملیاتی دستی و زمان بر می،اشد. هدف از این پژوهش، بررسی امکان استفاده از الگوریتمهای یادگیری عمیق بهعنوان ابزاری خودکار برای قطعهبندی تصاویر سی تی اسکن است. از این رو عملکرد چند شبکه عصبی کانولوشنال (CNN) شامل Residual U-Net ،U-Net و SegResNet به عنوان ابزارهای قطعهبندی خودکار اندامهای در معرض خطر در تصاویر سیتی اسکن لگنی (مثانه، پروستات، رکتوم، استخوان فمورال چپ و استخوان فمورال راست) با قطعهبندی دستی توسط متخصص مقایسه شد. این مطالعه، شامل ۲۳۸ بیمار برای قطعهبندی یروستات و ۲۱۸ بیمار برای چهار اعضای دیگر بود. عملکرد مدلها با استفاده از معیارهایی نظیر ضریب شباهت دایس، شاخص ژاکارد و معیار فاصله هاسدورف ارزیابی شد. مدل SegResNet با ارائه بهترین عملکرد، توانست به ضریب دایس ۹۵۶،۰۰، ۲۸۳٬۰۰، ۸۶۴،۰۰، ۰۹۸۷ و ۰٫۹۸۵ بهتر تیب برای مثانه، پروستات، رکتوم، فمورال چپ و فمورال راست دست یابد. بهطور خلاصه، نتایج حاصله نشانمیدهد که شبکههای عصبی کانولوشنال در عین حال که می توانند قطعهبندی اعضای در معرض خطر در طراحی پرتودرمانی را با دقت بالایی انجام دهند (استخوانها و مثانه بالاتر از ۹۵درصد و رکتوم و پروستات بالای ۸۳درصد)، فرایند قطعهبندی را نیز تسریع می بخشند.

کلیدواژ دها: قطعهبندی، اندامهای در معرض خطر، شبکههای عصبی کانولوشنال، سی تی اسکن، یروستات

# An investigation of deep learning techniques for automatic pelvic **CT** scan segmentation

#### E. Ghaedi<sup>\*1</sup>, A. Asadi<sup>1</sup>, S.A. Hosseini<sup>1</sup>, H. Arabi<sup>2</sup>

1. Department of Energy Engineering, Sharif University of Technology, P.O.BOX: 1114-14565, Tehran - Iran 2. Department of Nuclear Medicine and Molecular Imaging, Department of Medical Imaging Geneva University Hospital, Geneva - Switzerland

> **Research Article** Received: 29.05.2024, Revised: 15.09.2024, Accepted: 09.10.2024

#### Abstract

Radiotherapy treatment planning requires accurate delineation of organs at risk (OAR), which is typically a manual and time-consuming process. This research aims to explore the feasibility of using deep learning algorithms as an automatic tool for segmenting CT scan images. Accordingly, the performance of several convolutional neural networks (CNNs), including U-Net, Residual U-Net, and SegResNet, was compared as tools for automatic segmentation of OARs in pelvic CT scans (bladder, prostate, rectum, left femoral head, and right femoral head) against manual segmentation by specialists. This study involved 238 patients for prostate segmentation and 218 patients for the other four organs. The models' performance was assessed using metrics such as the Dice similarity coefficient, Jaccard index, and Hausdorff distance. The SegResNet model, providing the best performance, achieved Dice coefficients of 0.956, 0.832, 0.864, 0.980, and 0.985 for the bladder, prostate, rectum, left femoral head, and right femoral head, respectively. In summary, the results indicate that convolutional neural networks can accurately segment organs at risk in radiotherapy planning, with accuracies above 95% for bones and bladder, and over 83% for the rectum and prostate, while also speeding up the segmentation process.

Keywords: Segmentation, Organs at risk, Convolutional neural networks, CT scan, Prostate

Journal of Nuclear Science, Engineering and Technology

Vol. 46 (2), Serial Number 112, 2025, P 98-108

مجله علوم، مهندسی و فناوری هستهای دوره ۴۶، شماره ۲، جلد ۱۱۲، تابستان ۱۴۰۴، ص ۹۸–۱۰۸



#### ۱. مقدمه

سرطان پروستات رتبه دوم در عوامل مرگومیر ناشی از سرطان را در بین آقایان به خود اختصاص داده است [۱]. پرتودرمانی یکی از روشهای متداول و اثرگذار در درمان این سرطان است [۲]. در طراحی پرتودرمانی، قطعهبندی و تعیین دقیق مرزهای بافتهای سالم اطراف تومور بهمنظور انتقال بهینه دز به تومور و اجتناب از پرتوگیری اضافه و مسمومیت ثانویه این بافتها، امری حیاتی است.

در حال حاضر، قطعهبندی ارگانها در مراکز درمانی و تشخیصی، عمدتاً بهصورت دستی انجام میشود و بسته به در دسترس بودن افراد متخصص، فرایندی زمانبر بوده و بهطور میانگین حدود ۳۰ تا ۱۲۰ دقیقه به طول می انجامد [۳-۶]. بهعلاوه ترجيح فردى و سطح تجربه افراد نيز در اين روش تأثیر گذار بوده و می تواند باعث کاهش دقت و ایجاد عدم قطعیت در مرزها شود. با توجه به اینکه امروزه مراکز محدودی چه در سطح جهانی و چه در ایران، از یک سیستم مشخص و کاملاً خودکار برای قطعهبندی در بخش طراحی پرتودرمانی استفاده می کنند؛ وجود یک روش خودکار و قابل اعتماد برای قطعهبندی اندامهای در معرض خطر (OAR<sup>1</sup>) اطراف پروستات در تصاویر سی تی اسکن لگنی به طوری که فشار کاری انکولوژیستها و فیزیسیستها را کاهش دهد، امری ضروری است. پژوهشهای اخیر نشان دادهاند روشهای خودکار مبتنی بر یادگیری عمیق نسبت به سایر روشها از جمله روشهای مبتنی بر اطلس، عمل قطعهبندی را با دقت بیشتر و صرف زمان کمتری انجام میدهند [۹-۷]. این روشها با ارائه مدلها و شبکههای چندلایه قابلیت یردازش خودکار مجموعهدادههای بزرگ را بدون نیاز به دخالت انسان دارند.

قطعهبندی خودکار اندامهای ناحیه لگنی فرایندی چالش برانگیز و دشوار است. از جمله عواملی که باعث این امر می شوند عبارتند از: الف) کنتراست پایین تصاویر سی تی اسکن که موجب عدم وضوح مرز بین ارگانهای مجاور می شود. ب) عمده اندامها در این ناحیه از بافت نرم تشکیل شدهاند؛ این اندامها بهویژه پروستات و رکتوم، شکلی مشخص نداشته و شکل و سایز آنها از بیماری به بیمار دیگر متفاوت است [۴، ۱۰]. ج) در مورد سایر اعضا نیز عواملی همچون پربودن مثانه، وجود گاز در روده و رکتوم و درصد چربی اطراف شکم و لگن باعث تغییر شکل این اندامها می شود [۱۰، ۱۲]. در سال های اخیر شبکههای عصبی و مدل های عمیق متعددی برای مقابله با این

چالشها ارائه شده است [۱۴، ۱۳]. Kilijunen و همکاران [۱۵] با استفاده از مدل MVision که ساختاری رمزگذار-رمزگشا و مشابه مدل مرجع U-Net داشته اما از تعداد بیشتری بلوک residual استفاده می کند، توانستند به مقادیر متوسط ضریب شباهت دایس (DSC<sup>۲</sup>)، ۰۰٬۸۲، ۰۰٬۸۴، ۰٬۶۸ و ۰٬۶۹ برای اندامهای مثانه، پروستات، رکتوم، فمورال چپ و فمورال راست دست یابند. Balagopal و همکاران [۱۶] توانستند به مقادیر متوسط DSC برابر ۰٫۹۶، ۰٫۹۰، ۲٫۸۴، ۰٬۹۵ و ۰٬۹۵ بهترتیب برای مثانه، پروستات، رکتوم، فمورال چپ و فمورال راست برسند. آنها با استفاده یک شبکه U-Net دوبعدی برای مکانیابی اولیه اندامها و سپس U-Net سەبعدى اصلاح شدە با بلوكھاى Vet براى قطعهبندی نهایی، دقت قطعهبندی را بهبود دادند. Yang و همکاران [۱۷] بهمنظور غلبه بر مشکل کنتراست پایین بافت نرم در تصاویر سی تی اسکن، با استفاده از یک شبکه CycleGan ابتدا به کمک ۱۴۰ تصویر سی تی اسکن جمع آوری شده، ۱۴۰ تصویر MRI با کنتراست بافت نرم بالا تولید کردند و سپس به کمک یکی از مشتقات U-Net به مقادیر متوسط DSC برابر با ۰٬۹۵، ۰٬۹۸، ۰٬۹۰، ۹۵٬۹۰ و ۰٬۹۵ بهترتیب برابر مثانه، پروستات، رکتوم، فمورال چپ و فمورال راست رسیدند. Gibbons و همکاران [۱۸] با بهکارگیری یک مدل تجاری به نام DLCExpert اندامهای در معرض خطر در تصاویر سر و گردن، قفسه سینه و لگن (هر کدام شامل ۳۰ سیتی اسکن) را قطعهبندی کرده و مزایای روش مبتنی بر یادگیری عمیق را با روش مبتنی بر اطلس مقایسه کردند. آنها توانستند برای چهار ارگان مثانه، رکتوم، فمورال چپ و راست به ترتیب به مقادیر متوسط DCS برابر با ۰٬۹۶، ۰۰٬۸۷، ۰٬۹۴ و ۰٬۹۸ درصد برسند. دقت روش مبتنی بر یادگیری عمیق برای بافت نرم بیش از ٨درصد بالاتر بوده و زمان مورد نياز براى اصلاحات ثانويه ماسکهای تولید شده در این روش ۶۱درصد کمتر از روش مبتنی بر اطلس بود. Mofid و همکاران [۱۹] با استفاده از ۱۱۸ تصویر از بیماران مبتلا به سرطان پروستات که تحت IMRT قرار گرفته بودند مدل nnU-Net (یک مشتق پویا از U-Net، این مدل نیاز به مقداردهی اولیه نداشته و در روند آموزش بهترین پارامترها را انتخاب میکند) را آموزش دادند. مقادیر متوسط DSC بهدستآمده برای مثانه، پروستات، رکتوم، فمورال چپ و راست به ترتیب برابر ۰۰٬۹۷ ۰٬۹۲، ۰۰٬۹۰ و ۹۶٫۰ بود.



<sup>1.</sup> Organs at Risk

<sup>2.</sup> Dice Similarity Coefficient Journal of Nuclear Science, Engineering and Technology Vol. 46 (2), Serial Number 112, 2025, P 98-108

با وجود قابلیتهای یادگیری عمیق، همچنان از این روش به صورت گسترده در مراکز پرتودرمانی استفاده نمی شود [۲۰]. از اینرو در این پژوهش، عملکرد قطعهبندی سه شبکه عصبی عمیق کانولوشنال (CNN<sup>1</sup>) به نامهای U-Net]، و همچنين [٢٢] Residual U-Net و همچنين قابلیت جایگزینی آنها با روشهای دستی بهعنوان ابزارهای خودکار قطعهبندی بررسی شد. U-Net مدلی مرجع با ساختاری رمزگذار-رمزگشا بوده و مختص به تصاویر زیست پزشکی طراحی شده است و دو مدل دیگر از مشتقات U-Net میباشند. این مقایسه از این جهت اهمیت دارد که درک کاملی از عملکرد و دقت شبکهها برای وظایف مشابه در اختیار پژوهشگران قرار میدهد. در نتیجه، آنها میتوانند از فرایند زمانبر و پرهزینهٔ ایجاد و آزمایش شبکههایی که عملکرد ضعیفتری دارند و احتمال شکست آنها بالاتر است، جلوگیری کنند. با شناسایی شبکههای مؤثرتر در مراحل اولیه، پژوهشگران میتوانند تلاشهای خود را بر بهبود و بهینهسازی آنها متمرکز كنند. این كار نهتنها به حفظ زمان و هزینه می انجامد، بلكه توسعه شبکههای قوی و دقیق را در حوزههای مختلف سرعت مى بخشد.

# ۲. مواد و روشها

فرایند قطعهبندی خودکار تصاویر پزشکی به سه مرحله کلی جمعآوری و آمادهسازی تصاویر، طراحی و آموزش مدل عمیق و ارزیابی تقسیم میشود.

## ۱.۲ جمع آوری و آمادهسازی تصاویر

تصاویر از سه مجموعه جمع آوری شدند؛ دو بیمارستان در تهران شامل تصاویر سی تی اسکن لگنی و دیتاست WORD<sup>2</sup> [۲۴] شامل تصاویر سی تی اسکن شکم و لگن. و به منظور تقویت داده ها برای بخش بندی پروستات از دیتاست Amos۲۰۲۲ [۲۵] استفاده شد. پنج اندام مثانه، پروستات، رکتوم، فمورال چپ و فمورال راست توسط انکولوژیستهای مجرب قطعه بندی شد و فمورال راست توسط انکولوژیستهای مجرب قطعه بندی شد و و بی اثر به ویژه در داده های جمع آوری شده از بیمارستان، روی هم رفته ۲۳۸ تصویر برای پروستات و ۲۱۸ تصویر برای سایر اندام ها باقی ماند و مورد استفاده قرار گرفت. تصاویر دارای ابعاد اندام ها باقی ماند و مورد استفاده قرار گرفت. تصاویر دارای ابعاد

بودند. به منظور جلوگیری از بایاس و سوگیری مدل ها، با استفاده از الگوریتمی کاملاً تصادفی ۸۰ درصد تصاویر برای آموزش و ارزیابی انتخاب شد و مورد استفاده قرار گرفت و ۲۰ درصد باقی مانده برای آزمایش کنار گذاشته شد. برای مقابله با محدودیت حافظه تعداد ۶۴ مقطع از هر تصویر که شامل هر پنج اندام مورد نظر بود، استخراج شده و در نهایت ابعاد تمام تصاویر برای ورود به شبکه یکدست و برابر ۶۴×۲۵۶×۲۵۶ انتخاب شد. به منظور آماده سازی تصاویر برای ورود به شبکه، تبدیلاتی همچون spacing برای یکدست کردن ابعاد وکسل به اندازه عملیات نرمال سازی شدت پیکسل ها به بازه ۰ تا ۱ به تصاویر اعمال شد. همچنین به منظور تقویت داده ها از دو تبدیل affine و flip استفاده شد.

# ۲.۲ طراحی و آموزش مدل عمیق

در این پژوهش، سه مدل Residual U-Net ،U-Net و SegResNet مورد بررسی قرار گرفتند. U-Net که از مدلهای مرجع برای تصاویر پزشکی است، چینشی مشابه به حرف لاتین دارد و از دو مسیر رمزگذار و رمزگشا تشکیل شده است. در  ${
m U}$ مسیر اول، تصاویر پس از ورود به شبکه کوچک و کوچکتر شده و تمام ویژگیهای موردنظر توسط شبکه استخراج میشود؛ و سپس در مسیر دوم با استفاده از ویژگیهای بهدستآمده، تصوير قطعهبندى شده بازيابى مىشود. نقطه قوت اين مدل نسبت به مدلهای پیشین، وجود اتصالات پرشی<sup>۴</sup> برای انتقال مستقیم ویژگیهای استخراج شده در مسیر رمزگذار به لایه همسطح در مسیر رمزگشا است. به این ترتیب مدل هنگام بازسازی تصویر نهایی، علاوه بر ویژگیهای سطح بالا، به ویژگیهای سطح پایین (همچون لبه) نیز دسترسی دارد. مدل Residual U-Net از اضافه کردن واحدهای Residual به U-Net بهدست می آید. در این مدل، علاوه بر اتصالات پرشی بین دو مسیر رمزگذار و رمزگشا، اتصالات برای انتقال مستقیم نقشه ویژگیها از ابتدای هر واحد به انتهای آن تعبیه شده است که از ناپدید شدن سیگنال گرادیان جلوگیری و روند آموزش را تسریع می کند. مدل SegResNet یکی دیگر از مشتقات U-Net بوده و مختص به قطعهبندی معنایی تصاویر پزشکی طراحی شده است. این شبکه از نقاط قوت دو مدل U-Net و ResNet [۲۷، ۲۶] استفاده می کند؛ به عبارتی هم معماری لشکل بههمراه اتصالات پرشی بین دو مسیر رمزگذار و رمزگشا ${
m U}$ 

<sup>1.</sup> Convolutional Neural Network

<sup>2.</sup> Whole Abdominal Organ Dataset

<sup>3.</sup> Voxel

<sup>4.</sup> Skip Connections Journal of Nuclear Science, Engineering and Technology Vol. 46 (2), Serial Number 112, 2025, P 98-108

داشته و هم از بلوکهای residual تشکیل شده است. ویژگی منحصربهفرد این شبکه وجود عدم تقارن بین دو مسیر است؛ بهطوریکه مسیر رمزگذار بزرگتر و مسیر رمزگشا کوچکتر است. این عدم تقارن ناشی از وجود بلوکهای الاعام تکرارشونده در مسیر رمزگذار است. وجود این بلوکها مدل را قادر میسازد با دقت بیشتری به استخراج ویژگیهای تصویر بپردازد. در نتیجه تصاویر بازیابی شده در مسیر رمزگشا، بیشترین شباهت را به تصاویر اولیه ورودی به شبکه خواهند داشت. این بلوکها کمک میکنند مدل ویژگیهای معنادار تصویر ورودی را به خوبی فرا گیرد و از به حافظه سپردن آنها جلوگیری میکند.

برای طراحی، آموزش و آزمایش مدلها از کتابخانه MONAI<sup>1</sup> استفاده شد. این کتابخانه محیطی برای کاربردهای هوش مصنوعی در زمینه پزشکی در اختیار کاربر قرار می دهد. از BegResNet مدل می اوملار مدل SegResNet استفاده شد و برای دو مدل دیگر تابع PReLU به عنوان فعال سازی شد و برای دو مدل دیگر تابع preLU به عنوان فعال سازی شد و پس از ۱۱۰ تا ۲۰۰ تکرار (epoch) به ازای هر اندام به هم گرایی رسید. از AdamW به عنوان الگوریتم بهینه ساز، از هم گرایی رسید. از Cosine Annealing اندازه گام فرایند آموزش و از تابع Dice که رابطه آن در معادله ۱ نشان داده شده است، به عنوان تابع هزینه استفاده شد.

$$DL = 1 - \frac{\sum_{n=1}^{N} p_n r_{n+\varepsilon}}{\sum_{n=1}^{N} p_n + r_n + \varepsilon} - \frac{\sum_{n=1}^{N} (1 - p_n)(1 - r_n) + \varepsilon}{\sum_{n=1}^{N} (1 - p_n) - r_n + \varepsilon}$$
(1)

در رابطه ۱،  $p_n$  مقادیر پیشبینی شده،  $r_n$  مقادیر واقعی، N تعداد کل پیکسل های تصویر بوده و  $\mathfrak{F}$  برای جلوگیری از ناپایدار شدن تابع و صفر شدن مخرج میباشد.

## ۳.۲ ارزیابی و آزمایش مدل

پس از آموزش مدلها، نوبت به ارزیابی عملکرد آنها با استفاده از ۲۰درصد تصاویر کنار گذاشته شده رسید. برای سنجش عملکرد مدلها و مقایسه خروجی آنها با ماسکهای واقعی از معیارهای متداولی چون ضریب شباهت دایس (DSC<sup>2</sup>)، معیارهای متداولی چون ضریب شباهت دایس (DSC<sup>2</sup>)، شاخص ژاکار (II) و ۹۵ امین صدک معیار فاصله هاسدورف (۹۵HD) استفاده شد. رابطه هر کدام از معیارها بهترتیب در روابط ۲ تا ۶ تعریف شده است. II پیکسلهایی که بهدرستی

پیشبینی شدهاند را در نظر می گیرد و برای اشیایی با مرزهای مربعی و مشخص مناسب است [۲۸]. DSC متداول ترین و پرتکرارترین معیار اعتبارسنجی قطعهبندی تصاویر پزشکی میباشد [۱۶]. این معیار علاوهبر سنجش میزان شباهت ماسک تولید شده توسط مدل و ماسک واقعی، انطباق مرز دو ماسک را نیز مورد بررسی قرار میدهد [۲۹]. فاصله هاسدورف، معیاری است که برای سنجش شباهت یا عدم شباهت مجموعه نقاط دو ماسک مورد استفاده قرار می گیرد.

$$DSC = \frac{\tau TP}{\tau TP + FP + FN} \tag{7}$$

$$JI = \frac{TP}{TP + FP + FN} \tag{(7)}$$

$$H(Y,X) = \max(h(Y.X).h(X.Y)) \tag{(f)}$$

$$h(Y.X) = \max_{y \in Y} \min_{x \in Y} \left\| y - x \right\| \tag{\Delta}$$

$$A \Delta HD = percentile(h(Y.X) \cup h(X.Y).Ath)$$
 (5)

در روابط ۲ تا P، TP به معنای مثبت صحیح، FP به معنای مثبت کاذب و Y مجموعه مثبت کاذب و X و X مجموعه نقاط ماسک واقعی و ماسک پیش بینی شده هستند و  $\|$ .  $\|$  بیانگر نرم یا فاصله اقلیدسی است.

#### ۳. بحث و نتایج

پس از انجام آموزش، خروجیهای تولید شده با هر سه مدل و ماسکهای واقعی با استفاده از معیارهای ذکر شده مقایسه شد. پس از بررسی و مقایسه خروجیهای تولید شده توسط U-Net، میانگین و انحراف معیار مقادیر DSC به دست آمده، به تر تیب برای مثانه، پروستات، رکتوم، فمورال چپ و فمورال راست برابر ۰٬۰۲۴ ± ۰٬۹۴۱ و ۰٬۰۰۴ ± ۰٬۹۴۵ بهدست آمد. این مقادیر برای مدل Residual U-Net بهترتیب برای مثانه، پروستات، رکتوم، فمورال چپ و فمورال راست برابر ۰٬۰۵۱ ± ۰٬۰۵۴،  $9^{-1}$ ,  $9^{-1}$ ,  $9^{-1}$ ,  $9^{-1}$ ,  $9^{-1}$ ,  $9^{-1}$ ,  $9^{-1}$ ,  $10^{-1}$ ,  $10^{-1}$ ,  $10^{-1}$ SegResNet ... و برای ۰٫۹۴۰ + ۰٫۰۰۴  $(\cdot)_{\Lambda}$   $(\cdot)_$ ۰٬۰۲۱ ± ۰٬۹۸۰ و ۰٬۰۱۶ ± ۰٬۰۲۱ برآورد شد. این مقادیر بههمراه بازه اطمینان ۹۵درصد در جدول ۱ گزارش شده است. همچنین، نمودار جعبهای توزیع مقادیر بهدست آمده در شکل ۱ رسم شده است.

Journal of Nuclear Science, Engineering and Technology Vol. 46 (2), Serial Number 112, 2025, P 98-108



<sup>1.</sup> Medical Open Network for AI

<sup>2.</sup> Dice Similarity Coefficient

<sup>3.</sup> Jaccard Index

جدول ۱. میانگین و انحراف معیار DSC بهدست آمده بر روی مجموعه آزمایش به همراه فاصله اطمینان ۹۵درصد آن ها

SegResNet		Residual U-Net		U-Net		
%۹۵CI	$DSC\pm SD$	٩ΔCI	$DSC \pm SD$	۶.۹۵CI	$DSC\pm SD$	اندام
۰,۹۴۴ — ۰,۹۶۹	$\bullet, PDF \pm \bullet, \bullet TF$	•,9•V — •,9۴•	۰,۹۲۴±۰,۰۵۱	$1_{\mathbf{A}}1_{A$	$\boldsymbol{\cdot}_{\boldsymbol{\cdot}} \boldsymbol{\cdot} \boldsymbol{\cdot} \boldsymbol{\cdot}_{\boldsymbol{\cdot}} \boldsymbol{\cdot} \boldsymbol{\cdot}_{\boldsymbol{\cdot}} \boldsymbol{\cdot} \boldsymbol{\cdot}_{\boldsymbol{\cdot}} \boldsymbol{\cdot} \boldsymbol{\cdot}_{\boldsymbol{\cdot}}$	مثانه
$\cdot_{\lambda}$ $()$ $ \cdot_{\lambda}$ $()$	$\boldsymbol{\cdot}_{\prime}\boldsymbol{\cdot}\boldsymbol{\cdot} \pm \boldsymbol{\cdot}_{\prime}\boldsymbol{\cdot}\boldsymbol{\cdot}\boldsymbol{\cdot}$	·/۶۶۱ — ·/۷۹·	$\boldsymbol{\cdot}_{\boldsymbol{\beta}}\boldsymbol{\mathbf{\gamma}}\boldsymbol{\boldsymbol{\delta}}\pm\boldsymbol{\cdot}_{\boldsymbol{\beta}}\boldsymbol{\boldsymbol{\delta}}\boldsymbol{\boldsymbol{\gamma}}\boldsymbol{\boldsymbol{\delta}}$	•,87X — •,77m	$\cdot$ , $\mathcal{F}$ $\Lambda$ $\Lambda$ $\pm$ $\cdot$ , $\cdot$ $\mathfrak{A}$ $\Delta$	پروستات
$\cdot _{\lambda} \wedge \cdot - \cdot _{\lambda} \wedge \cdot$	$oldsymbol{\cdot}_{_{/}}oldsymbol{\lambda}$ ۶۴ ± $oldsymbol{\cdot}_{_{/}}oldsymbol{\cdot}$ ۰ ۸	·,٧۴٩ - ·,٧٧٩	$\boldsymbol{\cdot}_{/}\boldsymbol{\forall}\boldsymbol{\forall}\boldsymbol{\xi}\pm\boldsymbol{\cdot}_{/}\boldsymbol{\cdot}\boldsymbol{\forall}\boldsymbol{q}$	•, <i>۶۶</i> ۳ – •,۷۲۹	$\boldsymbol{\cdot}_{/}$ ۶۹۸ ± $\boldsymbol{\cdot}_{/}$ ۱۰۱	ركتوم
$\cdot$	$\boldsymbol{\cdot}_{/}\boldsymbol{\cdot}\boldsymbol{\lambda}\boldsymbol{\cdot}\pm\boldsymbol{\cdot}_{/}\boldsymbol{\cdot}\boldsymbol{\cdot}\boldsymbol{1}$	۰,۹۵۱ — ۰,۹۶۶	$\boldsymbol{\cdot}_{/}\boldsymbol{9\Delta}\boldsymbol{9}\pm\boldsymbol{\cdot}_{/}\boldsymbol{\boldsymbol{\cdot}}\boldsymbol{7}\boldsymbol{9}$	۰,۹۳۳ — ۰,۹۴۸	•,941 ± •,•74	فمورال چپ
+,9XD - +,994	$\boldsymbol{\cdot}_{/}\boldsymbol{RAS}\pm\boldsymbol{\cdot}_{/}\boldsymbol{\boldsymbol{\cdot}}\boldsymbol{NS}$	۰,۹۳۲ — ۰,۹۴۷	$\bullet, PF \bullet \pm \bullet, \bullet \bullet F$	۰,۹۳۶ — ۰,۹۵۴	$\bullet, PFD \pm \bullet, \bullet \bullet F$	فمورال راست



**شکل ۱.** نمودار جعبهای مقادیر DSC بهدست آمده توسط مدلهای Residual U-Net ،U-Net و SegResNet بهازای هر اندام.

پروستات مشهود است. واحدهای residual تکرارشونده مدل را قادر میسازد ویژگیهای عمیقتر و پیچیدهتر تصویر را در مقیاسهای متفاوت استخراج کند. در نتیجه، مدل قادر خواهد بود تصاویر را در مسیر رمزگشا، با دقت بیشتری بازیابی کند. طبق جدول ۱، SegResNet توانسته است بیشترین دقت برای قطعهبندی OARها در تصاویر سیتیاسکن لگنی را ارائه کند؛ بهطوریکه دقت قطعهبندی استخوانها و مثانه بالاتر از ۹۵درصد و رکتوم و پروستات بالای ۸۰درصد میباشد. فاصله اطمينان ٩٥درصد براساس توزيع مقادير موجود مشخص مي كند پیشبینیهای مدل تا احتمال ۹۵درصد در چه بازهای قرار مى گيرند. قابل توجه است كه هر سه مدل فواصل اطمينان بسیار کوتاهی داشته و بهجز در مورد پروستات، بازهای کمتر از ۰٫۱ ارائه دادند. طبق گزارش ثبت شده در جدول ۱، مدل SegResNet بهترین عملکرد را داشته و فواصل اطمینانی کوتاهتر از ۰٬۰۵ ارائه کرده است که نشان از قابل اطمینان بودن و استحكام نتايج اين مدل دارد.

بهمنظور سنجش بهتر SegResNet، نتایج تولیدی با تعدادی از پژوهشهای قبلی صورت گرفته در این زمینه مقایسه شد. در مطالعهای که توسط Kilijunen و همکاران [۱۵] انجام شد، مقادیر متوسط DSC برای مثانه، پروستات، رکتوم، فمورال چپ و راست بهترتیب ۵۲/۲۰، ۲۰/۸۴ و ۶۹/۰ گزارش شد و مقادیر متوسط ۹۵HD بهترتیب ۳/۳، ۱/۶، ۶/۱۱، ۲۵/۰ و

Journal of Nuclear Science, Engineering and Technology Vol. 46 (2), Serial Number 112, 2025, P 98-108

در زمینه قطعهبندی تصاویر پزشکی همچون تصاویر لگنی سیتی که پیچیدگی خاصی دارند، انتخاب معماری مدل نقشی اساسی در تعیین دقت قطعهبندی نهایی دارد. طبق گزارشات ثبتشده در جدول ۱ و شکل ۱، در مورد عملکرد سه مدل -U SegResNet , Residual U-Net ،Net ،Net قابل توجهی وجود دارد. مدل U-Net با وجود محدودیتهایی که برای جمعآوری جزئیات پیچیده دارد به کمک ساختار رمزگذار-رمزگشای متقارن خود، بهجز برای دو اندام رکتوم و پروستات، قطعهبندی را بهنحوی معقول و با دقتی بیش از ۸۰درصد انجام داده است. از طرفی دیگر، با اضافه کردن بلوکهای residual به این ساختار رمزگذار-رمزگشا و پیادەسازى Residual U-Net، دقت قطعەبندى بافت نرم بیش از ۴درصد افزایش یافته و تمام ارگانها را با دقتی بالاتر از ۷۰درصد قطعهبندی کرده است. وجود واحدهای residual در هر دو مسیر رمزگذار و رمزگشا، از ناپدیدشدن سیگنال گرادیان جلوگیری میکند. به این ترتیب اتصالات پرشی بین دو مسیر رمزگذار و رمزگشا و همچنین از ورودی به خروجی هر واحد residual مانع از بینرفتن گرادیان و باعث تسریع انتشار دادهها در شبکه می شود و مدل با سرعت و دقت بالاتری همگرا می شود. از میان هر سه مدل، SegResNet بهترین عملکرد را داشته و تمام مقادیر DSC بهدست آمده توسط این مدل بالاتر از ۸۰درصد است. این افزایش دقت بهویژه در دو اندام رکتوم و ۹/۲ و ۲۰٫۱ و ۲۰٫۸۲۹ و ۸۰٬۸۲۹ و ۲۰٫۱ ۹۰٬۱۱ و ۲۰٫۱۹ و ۹/۲ میلیمتر بهدست آمد. Wang و همکاران [۳] با استفاده از مدلی مشتق از U-Net با واحدهای residual اما متفاوت با مدل ما توانستند برای ۱۲۵ تصویر سیتیاسکن دهانه رحمی بانوان، به مقادیر DSC برابر با ۲۰٫۱۰، ۸۸٬۰۰ و ۸۱٬۱۰ و مقادیر ۹۵/۲۹ برابر با ۲۰٫۱۲، ۲۰٫۹۶ و ۲۰٫۷ میلیمتر مقادیر ۲۰۲۵ برابر با ۲۰٫۱۲، ۲۰٫۹۶ و ۲۰٫۷ میلیمتر بهترتیب برای مثانه، فمورال راست، فمورال چپ و رکتوم دست یابند. Zhikai و همکاران [۳] با استفاده از ۲۰۱ تصویر دهانه رحمی و با کمک یکی از مشتقات U-Net توانستند برای مثانه، برابر با ۲۹۲۶، ۲۰٫۹۰۶ و ۲۰۹۱ و مقادیر DSC برابر با فمورال چپ، فمورال راست و رکتوم بهترتیب به مقادیر DSC برابر با ۹۵/۲۲ و ۲۰٫۹۰۴، ۲۰٫۹۰۹ و ۱۹٬۲۰ و مقادیر DSC برابر با ۹۵/۲۲ و ۹۹٫۵۹ میلیمتر دست یابند. با اینکه هر سه پژوهش تک مدالیته بودند، اما همچنان بهجز رکتوم، مقدار پژوهش ما بالاتر بود.

در یکی از پژوهشهای اخیر، Mofid و همکاران [۱۹] با استفاده از ۱۱۸ تصویر از بیماران مبتلا به سرطان پروستات که تحت IMRT قرار گرفته بودند مدل nnU-Net (یک مشتق پویا از U-Net) را آموزش دادند. این پژوهش نیز تک مدالیته بوده و تمام تصاویر بین سالهای ۲۰۲۱ تا ۲۰۲۳ جمع آوری شده و توسط یک انکولوژیست قطعهبندی شده بودند. مقادیر متوسط DSC بهدستآمده برای مثانه، پروستات، رکتوم، فمورال چپ و راست بهترتیب برابر ۰٫۹۷، ۰٫۸۲، ۰٫۹۰، ۰٫۹۶ و ۰٫۹۶ بهدست آمد. به همان دلایل قبل این مدل نسبت به مدل ما، برای قطعهبندی بافت نرم بهتر عمل کرده و توانست رکتوم را با اختلاف دقتی بیش از ۴درصد قطعهبندی کند. در حالی که برای بافت سخت، مدل ما همچنان برتری داشته و با دقتی بیش از ۲درصد هر دو فمورال را مشخص کرد. مدل استفاده شده در پژوهش Gibbons و همکاران [۱۸]، DLCExpert نام داشت. آنها اندامهای در معرض خطر در تصاویر سر و گردن، قفسه سینه و لگن (هر کدام شامل ۳۰ سیتیاسکن) را قطعهبندی کرده و مزایای روش مبتنی بر یادگیری عمیق را با روش مبتنی بر اطلس مقایسه کردند. آنها توانستند برای چهار ارگان مثانه، رکتوم، فمورال چپ و راست بهترتیب به مقادیر متوسط DCS برابر با ۰٫۹۶، ۰٫۸۷، ۰٫۹۸ و ۰٫۹۸ درصد برسند. این پژوهش نیز تک مدالیته بوده و حتی در آن از تصاویر کمتری استفاده شد و در نتیجه نتایج بهدست آمده برای بافت نرم ۱درصد بالاتر و برای بافت سخت برابر با پژوهش ما بهدست آمد. یک برتری پژوهش ما، این است که مدل با طیف وسیعتری از تصاویر آشنا شده و تعیم پذیری بالاتری دارد و در کاربردهای کیلینی قابل اتكاتر است. ۲۴٫۷ بود. آنها از مدل MVision که یک مدل یادگیری عمیق تجاری از MVision AI و دارای ساختاری مشابه با U-Net است، استفاده کردند. مدل با استفاده از ۸۷۶ اسکن سیتیاسکن سرطان پروستات آموزش داده شد. با وجود اینکه تصاویر استفاده شده در این پژوهش بیش از حدوداً ۴ برابر تصاویر پژوهش ما بود، مدل ما برای تمام ارگانها بهتر عمل کرده و دقت قطعهبندی بافت نرم را بیش از ۱درصد و بافت سخت را بیش از ۲۰ درصد افزایش داد. در نهایت، در مطالعه Kilijunen، ليبلهاى مثانه، ركتوم و پروستات توسط چندين انكولوژيست اصلاح شد که DSC برای این نواحی بهترتیب به ۱۰۰درصد، بیش از ۹۷درصد و بیش از ۹۲درصد افزایش یافت. Balagopal و همکاران [۱۶] به کمک یک شبکه U-Net اصلاح شده با یک شبکه residual به نام ResNext به مقادیر متوسط DSC برابر ۰٫۹۶، ۰٫۹۰، ۲٫۹۴، ۱٫۹۵ و ۰٫۹۵ بهترتیب برای مثانه، پروستات، رکتوم، فمورال چپ و فمورال راست رسیدند. مدل آنها برای دو اندام مثانه و پروستات دقت بالاتری نسبت به مدل ما ارائه کرد. اما باید توجه داشت که این پژوهش تک مدالیته بوده و تصاویر با استفاده از یک دستگاه سیتیاسکن یکسان گرفته شده و توسط یک انکولوژیست بررسی و قطعهبندی دستی شده بود. این در حالی است که در پژوهش ما تصاویر از سه مجموعه متفاوت تشکیل شده و توسط چندین انکولوژیست متفاوت قطعهبندی شدهاند. در پژوهشهای تک مدالیته، معیارها عدد بالاتری را نشان میدهند اما نتایج جامعیت کمتری نسبت به سایر پژوهشها دارند. هرچه تصاویر جمعآوری شده متنوعتر باشند، مدل با تصاویر بیشتری آشنا شده و نسبت به تصاویر جدید بهتر عمل میکند و در نتیجه تعمیم پذیری آن بالاتر میرود. در پژوهش دیگری که توسط Schreier و همکاران [۱۱] صورت گرفت، مدل BibNet (یکی از مشتقات U-Net) با استفاده از ۶۰۰ تصویر سیتیاسکن آموزش داده شد. آنها توانستند به مقادیر متوسط DSC برابر ۰٬۹۳۲، ۰٬۸۴۰ و ۰٬۸۷۱ بهترتیب برای مثانه، پروستات و رکتوم برسند. با اینکه در این پژوهش تک مدالیته تعداد تصاویر استفاده شده بیش از ۲٫۵ برابر تصاویر ما بود، باز هم اختلاف DSC برای دو اندام پروستات و رکتوم کمتر از ۱درصد بود. حتی در مورد مثانه، مدل ما بهتر عمل کرد و حدود ۲درصد افزایش دقت ارائه داد.

در پژوهش انجام شده توسط Zhang و همکاران [۳۰]، از مدل DSD-UNet برای آموزش ۹۱ تصویر دهانه رحمی بانوان استفاده شد. DSD-UNet بر مبنای U-Net بوده و علاوه بر اضافه کردن واحدهای residual، در مسیر رمزگذار به رمزگشا، از لایهٔ کانولوشن منبسطشده (متشکل از چندین لایه کانولوشن موازی) استفاده می کند. در نهایت مقادیر DSC و ۹۵HD برای

نمودار جعبهای دو معیار II و ۹۵HD نیز برای هر سه مدل و بهازای تکتک اندامها محاسبه و در شکلهای ۲ و ۳ گزارش شده است. بهدلایل ذکر شده، SegResNet بالاترین II و کمترین ۹۵HD را ارائه کرده است. همچنین پراکندگی کمتر مقادیر هر دو معیار برای این مدل مشهود است. بهعبارت دیگر، مقادیر هر دو معیار برای این مدل مشهود است. بهعبارت دیگر، در مقایسه با دو مدل دیگر، ماسکهای تولید شده توسط SegResNet بیشترین شباهت را با ماسکهای متخصص داشته و قادر به مقابله با چالش دخالت سلیقه شخص بوده و مشکل عدم قطعیت بین مرز OARها را برطرف میکند.

یکی از نقاط ضعف سیتیاسکن، کنتراست پایین بافت نرم است. بنابراین در عملیات قطعهبندی، چه توسط فرد و چه توسط ماشین، تعین کردن بافتهای نرم امری چالش برانگیز بوده و در اکثر مواقع، انکولوژیستها تنها براساس دانش قبلی آناتومیک خود مرز اندامها را مشخص میکنند. از میان CARها، رکتوم و پروستات کمترین دقت را به خود اختصاص دادهاند. از جمله عوامل این کمبود دقت، کنتراست پایین سیتی و مشخص نبودن مرز این دو عضو است. بخشی از رکتوم و بیشتر بخش های پروستات واضح نبوده و در نتیجه احتمال عدم قطعیت ماسکهای تولید شده برای این دو عضو بیشتر است. نداشته و از فرد به فرد متفاوت هستند. از میان بافتهای نرم، قطعهبندی مثانه دقت بالاتری دارد. به دلیل شکل مشخص مثانه، تعیین دقیق مرز آن به نسبت رکتوم و پروستات کاری ساده تر است.

طبق نتایج حاصله، بافتهای استخوانی شامل فمورال چپ و راست، بالاترین دقت قطعهبندی را به خود اختصاص دادهاند. از آنجایی که سیتی اسکن توانایی بالایی برای به تصویر کشیدن بافت سخت دارد و همچنین استخوان شکل معین و ثابتی دارد و نسبت به سایر بافتهای اطراف ناحیه لگنی که عمدتاً از نوع بافت نرم هستند کنتراست بالایی دارد، تعیین مرز دقیق آن بهراحتی انجام می شود. همچنین پر بودن رکتوم و مثانه، حرکت رودهها و درصد چربی شکمی متفاوت بین افراد از سایر عوامل كمتر بودن دقت قطعهبندی بافت نرم نسبت به استخوانها است. بهمنظور درک بهتر عملکرد مدلها، خروجی تولید شده توسط هر کدام از آنها بهازای سه بیمار متفاوت در شکل ۴ رسم شده است. طبق انتظار، ماسکهای تولید شده توسط SegResNet، بیشترین هم پوشانی و شباهت را با ماسکهای رفرنس داشته و ماسکهای U-Net، بیشترین اختلاف را با ماسکهای رفرنس دارد. بهطور کلی تمام مدلها، بهویژه SegResNet، ماسکهای قابل قبولي توليد كردند. بخش عمده آنها دقيق، بخشي نياز به اصلاحات جزئی و بخشی دیگر نیاز به اصلاحات کلی داشتند. هرچه تعداد تصاویر استفاده شده در پژوهش افزایش یابد، تصاویر از دستگاههای سیتی مختلفی جمعآوری شوند و ماسکهای رفرنس به کمک انکولوژیستهای متعددی تولید شوند، مدل با مجموعه داده گستردهتری آشنا می شود. در نتیجه تعميم پذيرى و استحكام مدل افزايش يافته و نتايج دقيق تر و قابل استنادتری تولید می کند.







شکل ۳. نمودار جعبهای مقادیر II بهدست آمده توسط مدلهای Residual U-Net ،U-Net و SegResNet بهازای هر اندام. مجله علوم، مهندسی و فناوری هستهای Vol. 46 (2), Serial Number 112, 2025, P 98-108



**شکل ۴.** مقایسه خروجی مدلها بر روی مجموعه تست بهازای هر اندام برای سه بیمار مختلف. الف) مثانه، ب) پروستات، ج) رکتوم، د) فمورال چپ و ه) فمورال راست. خطوط زرد خروجی مدل U-Net، خطوط قرمز خروجی مدل Residual U-Net، خطوط آبی کم<sub>ا</sub>رنگ خروجی مدل SegResNet و خطوط آبی پررنگ ماسک واقعی را نشان میدهند.

#### ۴. نتیجه گیری

قطعهبندی OARها در تصاویر سی تی اسکن پیش از اقدامات طراحی پرتودرمانی، امری ضروری بوده و نقشی اساسی در دقت درمان انجام گرفته دارد. هرچه قطعهبندی دقیقتر باشد، دز رسیده به اندامهای سالم اطراف تومور کاهش یافته و از مسمومیت آنها جلوگیری می شود. قطعهبندی معمولاً به صورت دستی توسط انکولوژیست انجام می شود. بسته به تعداد اندامهای موردنظر و تجربه فرد، این کار حدود ۳۰ تا ۱۲۰ دقیقه به طول میانجامد که زمان زیادی به حساب می آید. از طرفی، عواملی همچون کنتراست یایین سی تی اسکن و سطح تجربه متفاوت افراد بر تعیین مرز اندامها اثر گذاشته و باعث ایجاد عدم قطعیت می شود. بنابر عدم وجود یک سیستم مشخص، نیاز به وجود یک ابزار خودکار برای قطعهبندی OARها پیش از پرتودرمانی به شدت احساس می شود. در این مطالعه، امکان به کارگیری الگوریتمهای یادگیری عمیق بهعنوان جایگزینی برای قطعهبندی دستی پنج OAR در تصاویر سیتیاسکن لگنی (مثانه، پروستات، رکتوم، استخوان فمورال چپ و راست) بررسی شد. طبق نتايج بهدست آمده، با انتخاب معماري مناسب مي توان با دقت بسیار بالایی (استخوانها و مثانه بالاتر از ۹۵درصد و رکتوم و پروستات بالای ۸۳درصد) در زمانی کمتر از یک دقیقه قطعهبندی هر پنج اندام را انجام داد. براساس مقایسات انجامشده در بخش قبل، مدل SegResNet توانست ماسکهایی با هم یوشانی بالا نسبت به ماسکهای مرجع تولید کند و با دقتی بالاتر از پژوهشهای مشابه در گذشته بهویژه برای بافت سخت، قطعهبندی را انجام دهد. همچنین حتی در حالتی که نتیجه قطعهبندی از دقت دلخواه برخوردار نباشد، نیاز به قطعهبندی از ابتدا نیست و انکولوژیست میتواند بازبینی و اصلاح ماسک را در مدت زمان ۱۰ تا ۲۰ دقیقه انجام دهد و زمان خود را بهصورت بهینه صرف استخراج و طراحی یارامترهای پرتودرمانی کند. بنابر دلایل ذکر شده، در صورت انتخاب مدل مناسب و بالا بودن تعداد و تنوع مناسب دادهها برای آموزش، الگوریتمهای یادگیری عمیق میتوانند جایگزین مناسبی نسبت به روشهای دستی باشند. اهمیت دیگر این یژوهش مقایسهای، جلوگیری از آزمایش شبکههایی که عملکرد ضعیفتری دارند و شناسایی مدلهای مؤثرتر و قویتر همچون SegResNet است. با شناسایی شبکههای مؤثرتر در مراحل اولیه، توسعه الگوریتمهای سریع و دقیق در تمام حوزهها تسریع مىشود.

## ۵. پیشنهاد برای ادامه پژوهش

هرچه تعداد تصاویر بیشتر و تنوع مراکز بیشتر باشد، مدل تعمیم پذیری بیشتری داشته و در برابر دادههای جدید آمادگی بیشتری خواهد داشت. بنابراین با افزایش حجم مجموعهداده مورد استفاده میتوان به کاربردی شدن مدل تا حد زیادی کمک کرد. یکی دیگر از اقداماتی که کمک میکند پژوهش گسترش یابد، بررسی پژوهش انجامشده به صورت تجربی است. با کمک گرفتن از یک انکولوژیست و فیزیسیست مجرب و ارزیابی بالینی ماسکهای تولید شده و بررسی امکان اعمال آنها در کاربردهای بالینی همچون طراحی پرتودرمانی (با استفاده از دزیمتری و اندازه گیری پارامترهای پرتودرمانی) میتوان دقت روش خودکار را در کاربردهای واقعی محک زد و به آن اعتبار بخشید.

## مراجع

- Sung H, et al., Global cancer statistics 2020: GLOBOCAN estimates of incidence and mortality worldwide for 36 cancers in 185 countries. CA: a cancer journal for clinicians. 2021;71(3):209-249.
- Delaney G, Jacob S, Featherstone C, Barton M. The role of radiotherapy in cancer treatment: estimating optimal utilization from a review of evidence-based clinical guidelines. Cancer: Interdisciplinary International Journal of the American Cancer Society. 2005;104(6):1129-1137.
- Liu Z, Liu X, Xiao B, Wang S, Miao Z, Sun Y, Zhang F. Segmentation of organs-at-risk in cervical cancer CT images with a convolutional neural network. Physica Medica. 2020;69:184-191.
- 4. Wang S, He K, Nie D, Zhou S, Gao Y, Shen D. CT male pelvic organ segmentation using fully convolutional networks with boundary sensitive representation. Medical image analysis. 2019;54:168-178.
- 5. Yazdanpanah F, Houshi S, Hosseini M, Bagherieh S, Ebrahimian Sadabad F, Nejati S.F, Arabi H, Zangiabadian M, Subtirelu R, Teichner E, Werner Th, Alavi A, Revheim M.E. Machine learning based radiomics features of theranostics PET features in detection of Prostate cancer (PCa): A systematic review of 1703 patients. ed: Soc Nuclear Med. 2023.
- Bagheri H. Mahdavi S.R, Geramifar P, Neshasteh-Riz A, Sajadi Rad M, Dadgar H, Arabi H, Zaidi H. An Update on the Role of mpMRI and 68Ga-PSMA PET Imaging in Primary and Recurrent Prostate Cancer. Clinical genitourinary cancer. 2024;102076.
- Ibragimov B, Xing L. Segmentation of organs-atrisks in head and neck CT images using convolutional neural networks. Medical physics. 2017;44(2):547-557.

Journal of Nuclear Science, Engineering and Technology Vol. 46 (2), Serial Number 112, 2025, P 98-108

- 8. Men K, Dai J, Li Y. Automatic segmentation of the clinical target volume and organs at risk in the planning CT for rectal cancer using deep dilated convolutional neural networks. Medical physics. 2017;44(12):6377-6389.
- Wang J, Lu J, Qin G, Shen L, Sun Y, Ying H, Zhang Z, Hu W. A deep learning-based autosegmentation of rectal tumors in MR images. Medical physics. 2018;45(6):2560-2564.
- Arabi H, Dowling J.A, Burgos N, Han X, Greer P.B, Koutsouvelis N, Zaidi H. Comparative study of algorithms for synthetic CT generation from MRI: consequences for MRI-guided radiation planning in the pelvic region. Medical physics. 2018;45(11):5218-5233.
- Schreier J, Genghi A, Laaksonen H, Morgas T, Haas B. Clinical evaluation of a full-image deep segmentation algorithm for the male pelvis on conebeam CT and CT. Radiotherapy and Oncology. 2020;145:1-6.
- 12. Arabi H, Koutsouvelis N, Rouzaud M, Miralbell R, Zaidi H. Atlas-guided generation of pseudo-CT images for MRI-only and hybrid PET–MRI-guided radiotherapy treatment planning. Physics in Medicine & Biology. 2016;61(17):6531.
- 13. Arabi H, Zaidi H. Applications of artificial intelligence and deep learning in molecular imaging and radiotherapy. European Journal of Hybrid Imaging. 2020;4(1):17.
- 14. Karimzadeh R, Fatemizadeh E, Arabi H. Attentionbased deep learning segmentation: Application to brain tumor delineation. in 2021 28th National and 6th International Iranian Conference on Biomedical Engineering (ICBME). IEEE. 2021;248-252.
- 15. Kiljunen T, Akram S, Niemelä J, Löyttyniemi E, Seppälä J, Heikkilä J, Vuolukka K, Kääriäinen O.S, Heikkilä V.P, Lehtiö K, Nikkinen J, Gershkevitsh E, Borkvel A, Adamson M, Zolotuhhin D, Kolk K, Pei Ping Pang E, Tuan J.K.L, Master Z, Chua M.L.K, Joensuu T, Kononen J, Myllykangas M, Riener M, Mokka M, Keyriläinen J. A deep learning-based automated CT segmentation of prostate cancer anatomy for radiation therapy planning-a retrospective multicenter study. Diagnostics. 2020;10(11):959.
- 16. Balagopal A, Kazemifar S, Nguyen D, Lin M.H, Hannan R, Owrangi A, Jiang S. Fully automated organ segmentation in male pelvic CT images. <u>Physics in Medicine & Biology</u>. 2018;63(24):245015.
- 17. Lei Y, Wang T, Tian S, Fu Y, Patel P, Jani A.B, Curran W.J, Liu T, Yang X. Male pelvic CT multiorgan segmentation using synthetic MRI-aided dual pyramid networks. Physics in Medicine & Biology. 2021;66(8):085007.
- 18. Gibbons E, Hoffmann M, Westhuyzen J, Hodgson A, Chick B, Last A. Clinical evaluation of deep learning and atlas-based auto-segmentation for critical organs at risk in radiation therapy. Journal of Medical Radiation Sciences. 2023;70:15-25.

Journal of Nuclear Science, Engineering and Technology

- 19. Mofid B, Mosalla S.M.M, Goodarzi M, Tavakoli H. Deep CNN-based Fully Automated Segmentation of Pelvic Multi-Organ on CT Images for Prostate Cancer Radiotherapy. Journal of Biomedical Physics and Engineering. 2024.
- 20. Wong J, Huang V, Wells D, Giambattista J, Giambattista J, Kolbeck C, Otto K, Implementation of deep learning-based auto-segmentation for radiotherapy planning structures: a workflow study at two cancer centers. Radiation Oncology. 2021;16(1):101.
- 21. Ronneberger O, Fischer P, Brox T. U-net: Convolutional networks for biomedical image segmentation. in Medical image computing and computer-assisted intervention-MICCAI 2015: 18th international conference, Munich, Germany, October 5-9, 2015, proceedings, part III 18, 2015;234-241. Springer.
- 22. Zhang Z, Liu Q, Wang Y. Road extraction by deep residual u-net. IEEE Geoscience and Remote Sensing Letters. 2018;15(5):749-753.
- Myronenko A. 3D MRI brain tumor segmentation using autoencoder regularization. in Brainlesion: Glioma, Multiple Sclerosis, Stroke and Traumatic Brain Injuries: 4th International Workshop, BrainLes 2018, Held in Conjunction with MICCAI 2018, Granada, Spain, September 16, 2018, Revised Selected Papers, Part II 4, 2019;311-320. Springer.
- 24. Luo X, Liao W, Xiao J, Chen J, Song J, Zhang X, Li K, Metaxas D.N, Wang G, Zhang S. WORD: A large scale dataset, benchmark and clinical applicable study for abdominal organ segmentation from CT image. arXiv preprint arXiv:2111.02403. 2021.
- 25. Ji Y, Bai H, Ge C, Yang J, Zhu Y, Zhang R, Li Z, Zhanng L, Ma W, Wan X, Luo P. Amos: A largescale abdominal multi-organ benchmark for versatile medical image segmentation. Advances in Neural Information Processing Systems. 2022;35:36722-36732.
- 26. He K, Zhang X, Ren S, Sun J. Deep residual learning for image recognition. in Proceedings of the IEEE conference on computer vision and pattern recognition. 2016;770-778.
- 27. Gholamiankhah F, Mostafapour S, Arabi H. Deep learning-based synthetic CT generation from MR images: comparison of generative adversarial and residual neural networks. arXiv preprint arXiv:2103.01609. 2021.
- Abdelhafiz D, Bi J, Ammar R, Yang C, Nabavi S. Convolutional neural network for automated mass segmentation in mammography. BMC bioinformatics. 2020;21:1-19.
- 29. Bertels J, Eelbode T, Berman M, Vandermeulen D, Maes F, Bisschops R, Blaschko M.B. Optimizing the dice score and jaccard index for medical image segmentation: Theory and practice. in Medical Image Computing and Computer Assisted Intervention– MICCAI 2019: 22nd International Conference, Shenzhen, China, October 13–17 2019, Proceedings, Part II 22, 2019;92-100. Springer.



- 30. Zhang D, Yang Z, Jiang S, Zhou Z, Meng M, Wang W. Automatic segmentation and applicator reconstruction for CT-based brachytherapy of cervical cancer using 3D convolutional neural networks. Journal of Applied Clinical Medical Physics. 2020;21(10):158-169.
- 31. Wang Z, Chang Y, Peng Z, Lv Y, Shi W, Wang F, Pei X, Xu X.G. Evaluation of deep learning-based auto-segmentation algorithms for delineating clinical target volume and organs at risk involving data for 125 cervical cancer patients. Journal of Applied Clinical Medical Physics. 2020;21(12):272-279.

# **COPYRIGHTS** ©2021 The author(s). This is an open access article distributed under the terms of the Creative Commons Attribution (CC BY 4.0), which permits unrestricted use, distribution, and reproduction in any medium, as long as the original authors and source are cited. No permission is required from the authors or the publishers.

استناد به این مقاله

قائدی، الناز، اسدی، علی، حسینی، سیدابوالفضل، عربی، حسین. (۱۴۰۴)، بررسی الگوریتمهای یادگیری عمیق بهعنوان ابزار خودکار قطعهبندی تصاویر سیتیاسکن لگنی. مجله علوم، مهندسی و فناوری هستهای، ۱۱۲(۲)، ۹۸–۱۰۸. Url: https://jonsat.nstri.ir/article\_1682.html .DOI: https://doi.org/10.24200/nst.2024.1585.2026.

