

Automatic Detection and Segmentation of Bone, lung, and soft tissue Based on Computed Tomography Scan Using Deep learning

Mohammad Mohammadian¹, Maryam Khazae Moghadam^{2*}, Elham Saniei²

1. Master's degree Medical Radiation, Department of Nuclear Engineering, CT.C., Islamic Azad University, Tehran, Iran.
2. Assistant Professor, Department of Nuclear Engineering, CT.C., Islamic Azad University, Tehran, Iran.

ARTICLE INFO:

Article History:

Received: 7 Dec 2024

Accepted: 6 Mar 2025

Published: 18 Mar 2025

*Corresponding Author:

Maryam Khazae Moghadam

Email:

m.khazae@iau.ac.ir

Citation: Mohammadian M, Khazae Moghadam M, Saniei E. Automatic Detection and Segmentation of Bone, lung, and soft tissue Based on Computed Tomography Scan Using Deep learning. Journal of Health and Biomedical Informatics 2025; 11(4): 323-35. [In Persian]

Introduction: In the field of radiation therapy and dosimetry, identifying and segmenting different regions and structures of the body in medical images is crucial for calculating radiation dose distribution for optimization, protecting sensitive organs, and improving treatment planning. In this regard, the application of automatic segmentation algorithms and the advancement of deep learning models in the field of medical image analysis enhance both accuracy and speed. This study aims to evaluate two convolutional neural networks (CNNs) and introduce an effective and efficient model for high-accuracy segmentation of bone, lung, and soft tissue based on CT images.

Method: This study utilized deep neural networks based on DeepLabV3+, ResNet-18, and MobileNet-v2 pre-trained architectures as the backbone for segmentation. To preprocess the CT scan images and prepare the input data for the neural network algorithms, 3D Slicer was employed to generate mask images for organs, including soft tissues, bones, and lungs. The development process and fine-tuning of the aforementioned deep learning models were carried out in the MATLAB environment, with accuracy and Intersection over Union (IoU) measured to evaluate the performance of the segmentation algorithms.

Results: The results indicated that the accuracy of semantic segmentation of bone for the ResNet-18 and MobileNet-v2 neural networks was 97% and 96%, respectively. For lung and soft tissue segmentation, the accuracy of the aforementioned networks was reported as 96.9% and 96.7% (for lung), and 99.2% and 99% (for soft tissue), respectively.

Furthermore, the IoU criterion for semantic segmentation of bone by the ResNet-18 and MobileNet-v2 networks was measured at 85% and 84%, respectively. For lung and soft tissue segmentation, this criterion was 90.8% and 91.2% (for lung), and 99% and 99% (for soft tissue) for both networks, respectively.

Conclusion: Various evaluation metrics indicate that the MobileNet-v2 neural network demonstrates superior performance and speed compared to the ResNet-18 network in analyzing CT scan images and segmenting the target tissues.

Keywords: Semantic segmentation, medical images, computed tomography images, convolutional neural networks (CNN)



CrossMark

مقاله پژوهشی

تشخیص و تقسیم بندی استخوان، ریه و بافت نرم به روش خودکار براساس تصاویر توموگرافی کامپیوتری CT با استفاده از شبکه‌های یادگیری عمیق

محمد محمدیان^۱، مریم خزاعی مقدم^{۲*}، الهام صنیعی^۲

۱. کارشناسی ارشد پرتو پزشکی، گروه مهندسی پرتو پزشکی، دانشکده فنی و مهندسی، دانشکده تهران مرکزی، تهران، ایران

۲. دکترا پرتو پزشکی، استادیار گروه مهندسی پرتو پزشکی، دانشکده فنی و مهندسی، دانشکده تهران مرکزی، تهران، ایران

اطلاعات مقاله

سابقه مقاله

دریافت: ۱۴۰۳/۹/۱۷

پذیرش: ۱۴۰۳/۱۲/۱۶

انتشار برخط: ۱۴۰۳/۱۲/۲۸

*نویسنده مسئول:

مریم خزاعی مقدم

ایمیل:

m.khazae@iau.ac.ir

ارجاع:

محمدیان محمد، خزاعی مقدم مریم، صنیعی الهام. تشخیص و تقسیم بندی استخوان، ریه و بافت نرم به روش خودکار براساس تصاویر توموگرافی کامپیوتری CT با استفاده از شبکه‌های یادگیری عمیق. مجله انفورماتیک سلامت و زیست پزشکی ۱۴۰۳؛ ۱۱(۴): ۳۳۵-۳۳۳.

مقدمه: در حوزه پرتودرمانی و محاسبات دزیمتری، شناسایی و تفکیک مناطق و ساختارهای مختلف بدن در تصاویر پزشکی از جمله استخوان، ریه و بافت نرم براساس تصاویر سی تی اسکن نقش مهمی در محاسبه توزیع دز اشعه به منظور بهینه‌سازی، حفاظت از ارگان‌های حساس و بهبود دقت در طراحی درمان ایفا می‌کند. در این راستا به کارگیری الگوریتم‌های خودکار بخش‌بندی و بهبود مدل‌های یادگیری عمیق در زمینه تحلیل تصاویر پزشکی دقت و سرعت را بهبود می‌بخشد. هدف این مطالعه ارزیابی دو شبکه عصبی کانولوشن (CNN) و معرفی یک مدل مؤثر و کارآمد برای انجام بخش‌بندی استخوان، ریه و بافت نرم با دقت بالا براساس تصاویر سی تی اسکن است.

روش کار: در این مطالعه، شبکه عصبی عمیق مبتنی بر DeepLabV3+ و معماری‌های از پیش آموزش دیده ResNet-18 و MobileNet-v2 به عنوان مدل‌های پایه برای بخش‌بندی استفاده شدند. به منظور پیش پردازش تصاویر سی تی اسکن و تهیه داده‌های ورودی به الگوریتم شبکه عصبی، از نرم افزار 3d slicer به منظور تولید تصاویر ماسک شامل بافت‌های نرم، استخوان‌ها و ریه‌ها می‌باشد، بهره برداری شده است. فرآیند توسعه و تنظیم پارامترهای آموزش مدل یادگیری عمیق در محیط MATLAB انجام گرفته است و عملکرد الگوریتم‌های تقسیم‌بندی به صورت همزمان برای ارگان‌های ذکر شده با استفاده از دو شبکه عصبی مذکور، براساس پارامترهای دقت و ضریب ژاکارد ارزیابی شده‌اند.

یافته‌ها: نتایج نشان می‌دهد که دقت بخش‌بندی معنایی استخوان برای شبکه‌های عصبی ResNet-18 و MobileNet-v2 به ترتیب ۹۷٪ و ۹۶٪ است. برای تقسیم‌بندی ریه و بافت نرم، دقت شبکه‌های مذکور به ترتیب ۹۶/۹٪، ۹۶/۷٪ (برای ریه) و ۹۹/۲٪، ۹۹٪ (برای بافت نرم) گزارش شده است. همچنین، معیار ارزیابی ضریب ژاکارد برای تقسیم‌بندی معنایی استخوان توسط شبکه‌های ResNet-18 و MobileNet-v2 به ترتیب ۸۵٪ و ۸۴٪ اندازه گیری شده است. برای بخش‌بندی ریه و بافت نرم، این معیار به ترتیب برای شبکه‌های ResNet-18، MobileNet-v2 به ۹۰/۸٪، ۹۱/۲٪ (برای ریه) و ۹۹٪، ۹۹٪ (برای بافت نرم) است.

نتیجه گیری: براساس نتایج به دست آمده، شبکه عصبی MobileNet-v2 عملکرد بهتری نسبت به ResNet-18 در تحلیل تصاویر سی تی اسکن و بخش‌بندی همزمان بافت‌ها از نظر معیارهای مختلف ارزیابی و سرعت عمل نشان می‌دهد. **کلیدواژه‌ها:** بخش‌بندی معنایی تصاویر پزشکی، یادگیری عمیق، تصاویر توموگرافی کامپیوتری، شبکه‌های عصبی کانولوشن (CNN)

مقدمه

توسعه سیستم‌های کامپیوتری هوشمند در حوزه تشخیص بالینی با استفاده از تصاویر توموگرافی کامپیوتری (Computed Tomography) (سی تی اسکن)، سهم مهمی در تشخیص دقیق و درمان ایفا می‌کنند. اهمیت این رویکرد در تشخیص زودهنگام بیماری‌ها برجسته است، چرا که سیستم‌های پیشرفته تشخیصی می‌توانند به پزشکان کمک کنند تا بیماران را پیش از بروز عوارض و آسیب‌های جدی نجات دهند [۱].

بخش‌بندی (segmentation) دقیق ساختارهای بدن از جمله ساختارهای استخوانی، ریوی و بافت نرم بر مبنای تصاویر سی تی اسکن، شامل شناسایی و تعیین مناطق مورد نظر (Region of Interest)، یک وظیفه اساسی در تحلیل تصاویر پزشکی محسوب می‌شود [۱]. تقسیم‌بندی دستی استخوان‌ها، ریه و بافت نرم به شدت زمان‌بر و نیازمند کار و دقت بالا است. از این رو، توسعه یک الگوریتم خودکار برای انجام این بخش‌بندی‌ها ضرورت دارد. کاربرد تکنیک‌های آستانه‌گذاری (Threshold) یکی از متداول‌ترین روش‌های تقسیم‌بندی است [۲، ۳]؛ اما با مشکلات خاصی مواجه است که باید در نظر گرفته شوند [۴]. از جمله مشکلات می‌توان تنوع در شکل و تراکم استخوان‌ها و بافت نرم را نام برد که تعریف یک یا دو آستانه برای مشخص کردن این مناطق را غیرعملی می‌سازد.

شبکه‌های عصبی (Neural Networks) که بخشی از تکنیک‌های یادگیری عمیق هستند، با الهام از ساختار و عملکرد مغز انسان توسعه یافته‌اند و ابزارهای قدرتمندی برای تحلیل داده‌های پیچیده به شمار می‌روند. این فناوری با توانایی یادگیری از داده‌های حجیم و تشخیص الگوهای پیچیده، به‌ویژه در حوزه پردازش تصاویر پزشکی، به عنوان راه‌حلی کارآمد برای رفع مشکلات روش‌های سنتی مطرح شده است. در شرایطی که روش‌های سنتی تحلیل دستی تصاویر ممکن است زمان‌بر، مستعد خطا، و به شدت وابسته به تبحر و تجربه کاربر می‌باشد، شبکه‌های عصبی با ارائه قابلیت‌های خودکار و دقت بالا، سرعت پردازش مناسب و توانایی یادگیری الگوهای پیچیده به‌طور مؤثری چالش‌های موجود در بخش‌بندی و تحلیل تصاویر پزشکی را برطرف می‌کنند [۵].

این شبکه‌ها با رویکرد یادگیری عمیق، قادر به شناسایی ویژگی‌های پیچیده و غیرخطی در تصاویر پزشکی هستند و با کاهش دخالت انسانی و ارائه نتایج خودکار و قابل اعتماد، امکان تحلیل دقیق‌تر بافت‌ها و ارگان‌ها را فراهم کرده و به‌ویژه در کاربردهایی مانند دزیمتری و طراحی درمان در رادیوتراپی شناسایی ساختارهای خاص نظیر استخوان، ریه و بافت نرم را با دقت بیشتری انجام می‌دهند [۶].

تحقیقات اخیر نشان داده‌اند که شبکه‌های عصبی عمیق قادرند بخش‌بندی را بر روی تصاویر سی تی اسکن اسکن پزشکی انجام دهند و دقت عملکرد آن‌ها با دقت متخصصان پزشکی قابل مقایسه است. یکی از کاربردهای رایج این فناوری، تقسیم‌بندی اندام‌های حساس است که به‌طور مؤثر توسط شبکه‌های عصبی عمیق به انجام می‌رسد. بخش‌بندی دقیق ساختارهای استخوانی، ریوی و بافت نرم می‌تواند تشخیص بیماری‌ها و ارزیابی دزیمتری پس از درمان را تسهیل کرده و در برنامه‌ریزی و هدایت روش‌های درمانی نظیر جراحی، رادیولوژی مداخله‌ای و پرتودرمانی نقش کلیدی ایفا کند [۷].

استفاده از شبکه‌های عصبی کانولوشنال (Convolutional Neural Networks) که حساس به مرز هستند، به دلیل دقت بالا، در انجام تقسیم‌بندی بافت نرم بسیار مؤثر واقع شده است [۸]. روش‌های تقسیم‌بندی اعضای بدن با تفکیک مرز بین بافت‌های مختلف می‌تواند به تشخیص دقیق‌تر پزشکان کمک کند. گزارشی از داده‌های بخش‌بندی استخوان‌ها براساس الگوریتم‌های یادگیری عمیق (Deep learning algorithm) نشان از این دارد که استخوان‌های مختلف می‌توانند به ۴۹ مجموعه دسته‌بندی شوند [۹، ۱۰]. علاوه بر این تکنیک‌های تصویربرداری در تشخیص بیماری‌های ریوی بسیار مؤثر واقع می‌شوند و می‌توانند اطلاعات با ارزش و واضحی را از تصاویر سی تی اسکن ارائه دهند [۱۱-۱۳]. شبکه‌های یادگیری عمیق در بسیاری از زمینه‌ها، از جمله تقسیم‌بندی تصویر پزشکی، موفقیت‌های قابل‌توجهی را کسب کرده‌اند [۱۴، ۱۵]. چندین تحقیق به بررسی معماری‌های مبتنی بر شبکه‌های عصبی کانولوشنال برای بخش‌بندی استخوان براساس تصاویر سی تی اسکن پرداخته‌اند [۱۶، ۱۷]. پیشرفت‌های جدید در استفاده از این الگوریتم‌ها، کارایی را در تشخیص بافت‌های آسیب دیده بهبود بخشیده است [۱۸، ۱۹].

هدف این مطالعه، مقایسه دو مدل مبتنی بر شبکه‌های عصبی کانولوشنال برای تقسیم‌بندی استخوان، ریه و بافت نرم بر روی تصاویر سی تی اسکن کل بدن با دوز پایین و ارزیابی دقت و قابلیت تعمیم‌پذیری این مدل‌ها است. این تحقیق می‌تواند به ارائه بینش‌های جدید در زمینه بهبود تشخیص بالینی و درمان بیماری‌ها از طریق کاربردهای پیشرفته یادگیری عمیق کمک کند.

روش کار


مجموعه داده مورد استفاده در این مطالعه شامل ۳۰۰۰ برش از تصاویر توموگرافی کامپیوتری (سی تی اسکن) قسمت‌های مختلف بدن می‌باشد. تصاویر به صورت میدانی از مراکز درمانی جمع‌آوری شده‌اند. تصاویر با استفاده از اسکنر سی تی اسکن برند Siemens Biograph به دست آمده‌اند که ضخامت برش آن‌ها ۳ میلی‌متر و وضوح تصویر درون صفحه محوری آن‌ها بین ۰/۴۱ تا ۰/۶۸ میلی‌متر است.

در مرحله پیش پردازش برای آموزش شبکه در ابتدا بایستی برای ارگان‌های استخوان، ریه و بافت نرم ماسک‌های مربوطه تهیه شود. برچسب‌گذاری داده‌ها با استفاده از نرم‌افزار 3d slicer انجام شده است که نرم‌افزاری برای تجزیه و تحلیل و تجسم تصاویر پزشکی محسوب می‌شود [۲۰، ۲۱]. در مرحله نخست، برچسب‌های پایه با استفاده از ابزارهای تقسیم‌بندی موجود در 3d slicer، نظیر آستانه‌گذاری و روش‌های نیمه اتوماتیک، به منظور شناسایی و درک بهتر نواحی مختلف بافت‌ها ایجاد گردید. سپس، اصلاحات دستی برچسب‌گذاری توسط متخصصان پزشکی با استفاده از ابزار تقسیم‌بندی دستی این نرم‌افزار انجام شد. در نهایت، تمامی برچسب‌ها توسط یک رادیولوژیست با ۲۰ سال تجربه در تصویربرداری تشخیصی تأیید و ویرایش شدند.

تصاویر و ماسک‌های به دست آمده در مرحله بعد با توجه به این‌که تصاویر تک کاناله (gray scale) هستند، همه تصاویر به تصاویر سه کاناله جهت استفاده در شبکه تبدیل شد. مقدار RGB (Red-Green-Blue) تصاویر تقسیم‌بندی شده برای هر سه کلاس مشخص شده بیماران مختلف در تابع طراحی شده باید یکسان در نظر گرفته شود. مناطق اضافه از تصاویر مانند تخت یا فضای اطراف بیمار جهت جلوگیری از انحراف مسیر آموزش حذف شدند. از روش‌های افزایش داده (augmentation) مانند چرخش تصاویر به زوایای مختلف، برعکس کردن تصویر به صورت افقی یا عمودی (Flipping) برای افزایش عمومیت‌پذیری داده‌ها استفاده شده است.

در این مطالعه، از شبکه‌های عصبی برای بخش‌بندی معنایی استفاده شد تا هر پیکسل در تصویر سی تی اسکن به طور دقیق دسته‌بندی شود. به منظور مقایسه مدل تقسیم‌بندی مبتنی بر شبکه‌های عصبی کانولوشنال، داده‌ها به سه مجموعه تقسیم شدند: فرآیند آموزش شبکه‌های عصبی با استفاده از ۸۰ درصد از کل تصاویر موجود صورت گرفته است [۷]. باقی مانده تصاویر به دو گروه با اندازه مساوی تقسیم شده‌اند که به طور تصادفی برای مقاصد اعتبارسنجی (Validation) و آزمایش در نظر گرفته شده‌اند [۸، ۱۴].

در این راستا، اسکن‌های مربوط به یک بیمار به طور تصادفی در هیچ یک از دو مجموعه داده آموزشی و اعتبارسنجی تکرار نشده و از تداخل آن‌ها جلوگیری گردید. نحوه تقسیم‌بندی و برچسب‌گذاری توسط نرم‌افزار 3d slicer در شکل ۱ قابل مشاهده است.



شکل ۱: نمونه‌ای از تصاویر تقسیم شده توسط نرم‌افزار 3d slicer برای الف) استخوان، ب) ریه و ج) بافت نرم در نماهای سه بعدی، محوری (axial) و ساجیتال (sagittal)

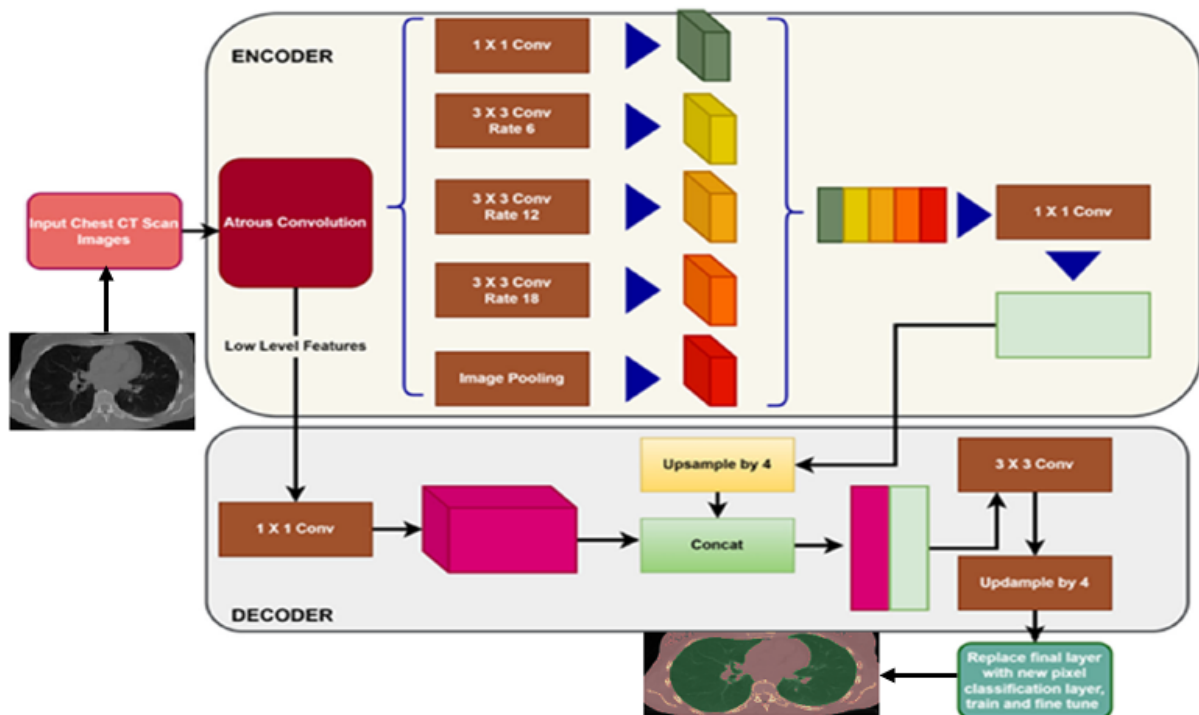
در این مطالعه از معماری DeepLabV3+ استفاده شده است. شبکه‌های ResNet-18 و MobileNet-v2 به عنوان شبکه‌های پایه (backbone) بخش استخراج ویژگی‌های سطح بالا از تصویر عمل می‌کنند و سپس از این ویژگی‌ها برای انجام بخش‌بندی معنایی (Semantic segmentation) استفاده می‌شود.

در این مطالعه معماری شبکه عصبی کانولوشنال [۲۲-۲۴] با استفاده از مدل‌های از پیش آموزش دیده ResNet-18، MobileNet-v2 در محیط MATLAB نسخه ۲۰۲۳ پیاده سازی گردید. تصاویر ورودی به شبکه، به طور دقیق به سه کلاس اصلی (استخوان، ریه و بافت نرم) تقسیم‌بندی می‌شوند و در نهایت، عملکرد شبکه‌ها مورد ارزیابی قرار می‌گیرد.

مدل‌های از پیش آموزش دیده نظیر ResNet-18، MobileNet-v2 نیازمند اندازه تصویر ورودی یکنواخت هستند و برای این منظور، اندازه تصاویر ورودی به ۲۲۴ در ۲۲۴ پیکسل تعیین شده است. به منظور حفظ سازگاری با DeepLabV3+، در شکل ۲ ارائه شده است، یک فرآیند تغییر اندازه در مرحله پیش پردازش بر روی هر تصویر اعمال گردید، به گونه‌ای که اطلاعات بافت مورد نظر تحت تأثیر قرار نگیرد و یکنواختی در ورودی شبکه‌ها حفظ شود.


در ادامه بایستی هم جهت بودن و هماهنگ بودن همه تصاویر با ماسک‌های مربوطه باید مورد ارزیابی قرار بگیرد تا از بر روی هم قرار گرفتن تصاویر و ماسک‌های مربوطه اطمینان حاصل شود.

مجموعه تصاویر تقسیم‌بندی شده با استفاده از نرم‌افزار 3d slicer که از قبل تهیه و پردازش شده‌اند به عنوان ماسک بارگذاری شد. در حالت ایده‌آل همه کلاس‌ها دارای تعداد پیکسل‌های مساوی نیستند. که یک مسئله رایج در مجموعه داده‌های استخوان، ریه و بافت نرم از تصویربرداری پزشکی هستند. این عدم تعادل اگر به درستی مدیریت نشود، می‌تواند برای فرآیند یادگیری مضر باشد، زیرا یادگیری به نفع طبقات غالب انجام می‌شود. در ادامه، از وزن‌دهی معکوس کلاس‌ها برای بر طرف کردن این مشکل استفاده شده است.



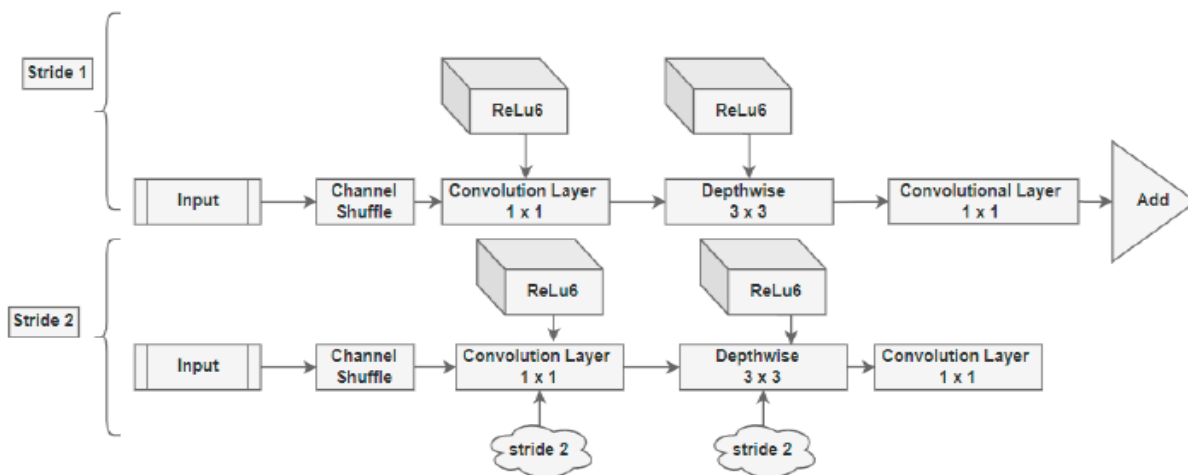
شکل ۲: معماری DeepLabv3+ شبکه عصبی عمیق مورد استفاده برای تقسیم خودکار

ResNet-18 یک شبکه عصبی کانولوشن است که ۱۸ لایه عمیق دارد. یک شبکه ای از پیش آموزش دیده (Transfer learning) است و می‌تواند تصاویر را به ۱۰۰۰ کلاس شی مختلف طبقه‌بندی کند. این شبکه دارای اندازه ورودی تصویر ۲۲۴ در ۲۲۴ است [۲۵]. شکل (۳).



شکل ۳: تصویر شماتیک معماری ResNet-18 مورد استفاده در مطالعه [۲۵]

MobileNet-v2 یک شبکه عصبی کانولوشن است که ۵۳ لایه عمیق دارد. شکل (۴).



شکل ۴: تصویر شماتیک معماری MobileNet-v2 مورد استفاده در مطالعه [۲۶]

به منظور بهینه‌سازی نرخ یادگیری، از یک برنامه زمان بندی برای تنظیم تدریجی آن در طول فرآیند آموزش استفاده شد. به طور خاص، نرخ یادگیری به ازای هر ده دوره معادل با $\frac{0}{3}$ کاهش یافت. این رویکرد به یادگیری سریع تر شبکه کمک می‌کند و امکان استفاده مؤثرتر از نرخ یادگیری اولیه را فراهم می‌آورد. به علاوه، شبکه به طور مداوم در برابر داده‌های اعتبارسنجی در هر دوره آموزشی با تنظیم پارامتر «اعتبارسنجی داده‌ها» آزمایش شد. مقدار پارامتر «تأیید اعتبار داده‌ها» برابر با ۴ تنظیم گردید تا در صورت همگرا شدن دقت اعتبارسنجی، فرآیند آموزش به طور خودکار متوقف شود. این اقدامات به منظور جلوگیری از بروز پدیده (تطابق بیش از حد) (overfitting) شبکه با مجموعه داده‌های آموزشی اتخاذ شده است.

مجموعه داده‌های استفاده شده شامل ۶۰۰۰ برش تصویر سی تی اسکن بدن برای هر دو شبکه مد نظر بود، که به صورت مشخص شامل ۳۰۰۰ برش تصویر برچسب‌گذاری شده (با استفاده از نرم‌افزار 3D slicer) و ۳۰۰۰ برش تصویر خام می‌باشد. تصاویر برچسب‌گذاری شده به سه دسته اصلی تقسیم‌بندی شدند: استخوان، بافت نرم و ریه، که این طبقه‌بندی برای توسعه شبکه‌های عصبی ضروری است [۲۷،۲۸].

برای ارزیابی عملکرد شبکه برای تقسیم‌بندی خودکار ریه، استخوان و بافت نرم، پارامتر وزن داده شده ضریب ژاکارد (Intersection Of Union) مورد استفاده قرار گرفت. معادله ۱ برای محاسبه این پارامتر استفاده می‌شود که میانگین ضریب ژاکارد را برای هر کلاس محاسبه کرده و براساس تعداد پیکسل‌ها در آن کلاس وزن دهی می‌کند [۲۹،۳۰].

معادله (۱)


$$IoU = \frac{TP}{TP + FP + FN}$$

نتایج

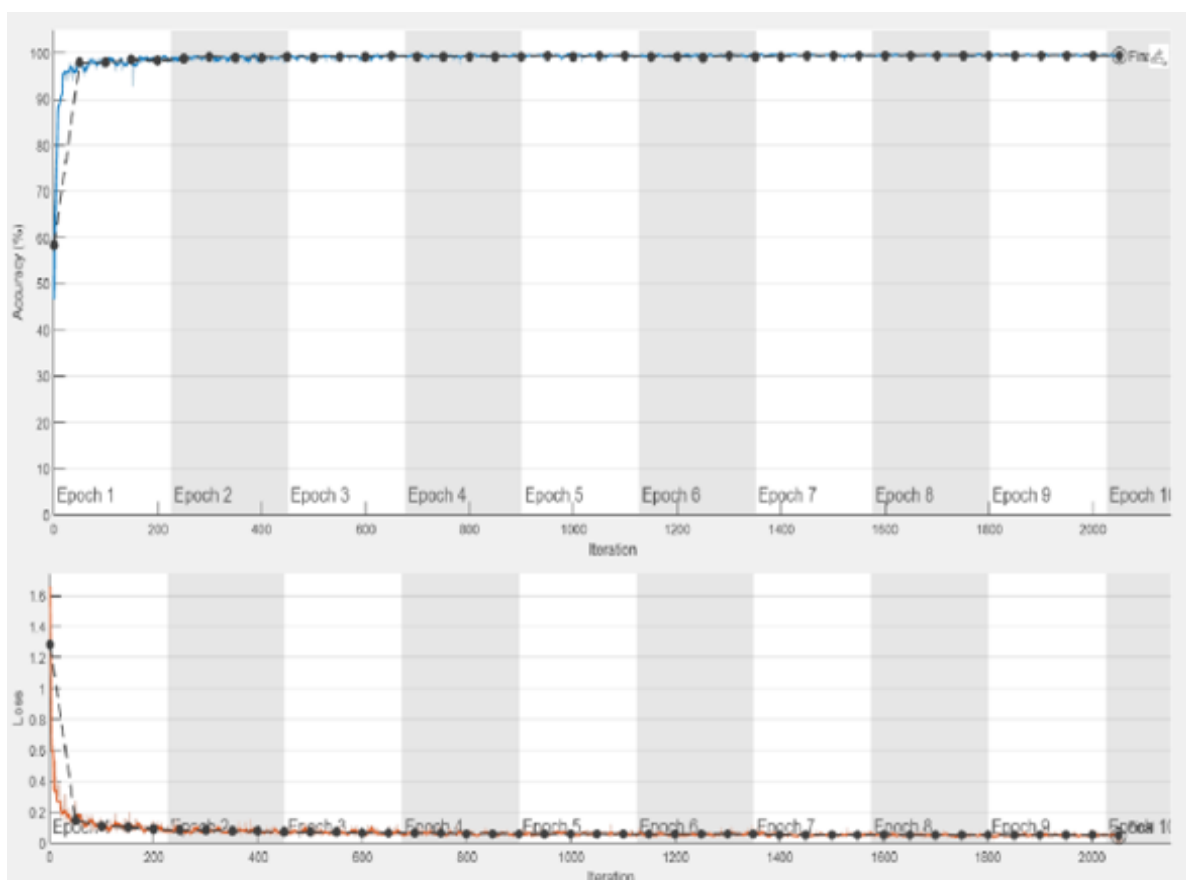
نتایج به دست آمده از اجرای شبکه‌های ResNet-18، MobileNet-v2 در جدول ۱ ارائه شده است. این نتایج شامل ارزیابی عملکرد این دو مدل در زمینه تقسیم بندی داده‌های ورودی می‌باشد. علاوه بر این، فرآیند آموزش این شبکه‌های عصبی به ترتیب در شکل‌های ۵ و ۶ نمایش داده شده است. این نمودارها اطلاعاتی درباره پیشرفت یادگیری، نوسانات نرخ خطا و دقت مدل‌ها در طی دوره‌های آموزشی را ارائه می‌دهند. تحلیل این نمودارها به درک عمیق‌تری از کارایی و رفتار این دو مدل در زمان آموزش کمک می‌کند و می‌تواند به شناسایی نقاط قوت و ضعف هر یک از آن‌ها در راستای بهبودهای آینده منجر شود.

جدول ۱: پارامترهای خروجی شبکه عصبی ResNet-18، MobileNet-v2

| عنوان | تعداد دوره | Iteration | دقت اولیه | اعتبار سنجی دقت | اعتبار سنجی خطا |
|--------------|------------|-----------|-----------|-----------------|-----------------|
| Resnet18 | ۱ | ۱ | ٪۴۶/۶۹ | ٪۵۸/۴۸ | ۱/۲۸۵۳ |
| | ۹ | ۲۰۰۰ | ٪۹۹/۲۲ | ٪۹۹/۳۷ | ۰/۰۵۲۰ |
| MobileNet-v2 | ۱ | ۱ | ٪۱۷/۰۳ | ٪۱۹/۳۰ | ۱/۶۹۱۱ |
| | ۱۰ | ۲۲۰۰ | ٪۹۹/۳۱ | ٪۹۹/۳۸ | ۰/۰۶۷۹ |



شکل ۵: نمودار معیارهای ارزیابی (دقت اعتبارسنجی) با استفاده از شبکه عصبی ResNet-18




شکل ۶: نمودار معیارهای ارزیابی (دقت اعتبارسنجی) با استفاده از شبکه عصبی MobileNet-v2

این بخش بندی به ما امکان می دهد داده های برچسب گذاری شده (labeling) و تصاویر خام را به طور مناسب بین مجموعه های آموزشی، اعتبارسنجی و آزمایشی توزیع شود.


شکل های ۷ و ۸ به مقایسه نتایج پیش بینی شده توسط شبکه های ResNet-18، MobileNet-v2 می پردازند؛ این نتایج در مجموعه داده های آزمایشی ثبت شده اند. مناطق سبز و بنفش برجسته نتایج تقسیم بندی هستند که از لحاظ ارزیابی متفاوت است.

نتایج به دست آمده از هر دو شبکه مورد بررسی نشان می دهد که نواحی مشخص شده با رنگ بنفش به عنوان نواحی دارای خطا شناسایی شده اند. به عبارتی نواحی مشخص شده با رنگ بنفش در مدل ارائه شده در کلاس اشتباهی قرار داده شده اند، در حالی که نواحی رنگ سبز توسط شبکه به درستی تشخیص داده نشده اند و شبکه نتوانسته است برای این مناطق کلاسی در نظر بگیرد. این دقت سنجی به ما کمک می کند تا نقاط قوت و ضعف مدل ها را شناسایی کرده و براساس آن به بهینه سازی عملکرد آن ها پرداخته شود.

علاوه بر این، در این مطالعه اقدام به توسعه یک شبکه عصبی عمیق شد که قادر به انجام تقسیم بندی خودکار ریه، استخوان و بافت نرم با دقت های مختلف می باشد. برای این هدف، پارامترهای مورد استفاده در فرآیند آموزش برای هر کدام از شبکه ها بهینه شده اند تا دقت کارایی فرآیند تقسیم بندی به حداکثر برسد.



شکل ۷: نتایج آزمایش شبکه عصبی ResNet-18



شکل ۸: نتایج آزمایش شبکه عصبی MobileNet-v2

برای ارزیابی عملکرد شبکه‌های عصبی، میزان همپوشانی در هر کلاس با استفاده از شاخص ضریب ژاکارد اندازه‌گیری شد. در هر دوره آموزشی، مدل بر روی داده‌های اعتبارسنجی (Validation data) آزمایش و دقت آن‌ها با استفاده از تصاویر آزمایش (Test data) محاسبه گردید. معمولاً تا زمانی که خطای مدل در داده‌های آموزشی کاهش یابد، خطای مربوط به داده‌های اعتبارسنجی نیز به طور همزمان کاهش می‌یابد.

با این حال، پس از یک نقطه خاص، همان‌طور که مدل به حفظ داده‌های آموزشی ادامه می‌دهد، ممکن است دچار پدیده‌ای به نام بیش انطباق (overfitting) شود. در این حالت، در حالی که خطای مدل نسبت به داده‌های آموزشی همچنان کاهش می‌یابد، خطای مربوط به داده‌های اعتبارسنجی به جای کاهش، افزایش می‌یابد.

در این مطالعه، پارامترهای دقت و ضریب ژاکارد برای نواحی بافت نرم، ریه و استخوان محاسبه و نتایج به دست آمده برای مدل‌های ResNet-18، MobileNet-v2 با یکدیگر مقایسه شده‌اند (جدول ۲). این مقایسه به ما امکان می‌دهد تا عملکرد هر یک از مدل‌ها را در زمینه تقسیم‌بندی دقیق این بافت‌ها ارزیابی کرده و درک بهتری از توانایی‌های آن‌ها به دست آورده شود.



جدول ۲: نتایج پارامترهای دقت برای شبکه‌های عصبی MobileNet-v2, ResNet-18

| عنوان | ResNet-18 | | MobileNet-v2 | |
|----------|-----------|---------|--------------|---------|
| | دقت | IoU | دقت | IoU |
| استخوان | ۰/۹۷۹۵ | ۰/۸۵۳۸۸ | ۰/۹۶۵۶۲ | ۰/۸۴۸۲۸ |
| ریه | ۰/۹۶۹۵۲ | ۰/۹۰۸۰۱ | ۰/۹۶۷۵۶ | ۰/۹۱۲۲۵ |
| بافت نرم | ۰/۹۹۰۳ | ۰/۹۸۸۹۸ | ۰/۹۹۲۷۱ | ۰/۹۹۰۴۳ |

یکی از موارد مهم در انتخاب شبکه مناسب زمان آموزش شبکه است که در این مطالعه، زمان اجرا برنامه برای شبکه MobileNet-v2 طولانی‌تر از ResNet-18 می‌باشد.

بحث و نتیجه‌گیری

برای دهه‌ها، تکنیک‌های متنوعی برای بخش‌بندی استخوان [۲]، ریه [۱۸] و بافت نرم [۳۱] در تصاویر سی تی اسکن به کار رفته‌اند. از بین این روش‌ها، تکنیک آستانه‌گذاری به دلیل قابلیت جدا کردن مؤثر ساختارهای استخوانی با تراکم بالاتر از بافت نرم، به ویژه در تصاویر سی تی اسکن، به طور گسترده‌ای مورد استفاده قرار گرفته است [۳۲، ۳۳]. روش‌های دیگر، مانند تشخیص لبه، معمولاً با تکنیک‌های دیگر ترکیب می‌شوند [۳۴] و به ندرت به طور مستقل به کار گرفته می‌شوند. علاوه بر این، بسیاری از روش‌های مذکور به درجاتی از ورودی دستی نیاز دارند که این موضوع در روش‌های تقسیم بندی خودکار ریه [۳۵] مشهود است. این وابستگی به نظارت دستی می‌تواند فرآیند را زمان بر نماید و به تجربه کاربر در عمل بالینی بستگی داشته باشد.

مطالعات متعددی معماری‌های مبتنی بر شبکه‌های عصبی کانولوشن را برای تقسیم بندی استخوان، ریه و بافت نرم در تصاویر سی تی اسکن کل بدن مورد بررسی قرار داده‌اند. امروزه، روش‌های مبتنی بر شبکه‌های عصبی کانولوشنال به دلیل توان شگرف آن‌ها در استخراج ویژگی‌ها و یادگیری عمیق، به نتایج قوی در زمینه‌های مختلف، از جمله تقسیم بندی تصاویر پزشکی، دست یافته‌اند [۱۲]. این پیشرفت‌ها می‌تواند به بهبود دقت و کارایی در تشخیص‌های بالینی و ارتقاء کیفیت خدمات پزشکی منجر شود [۳۶-۳۸]. تقسیم بندی در این چارچوب می‌تواند به صورت معنایی یا مبتنی بر نمونه انجام شود که در آن، اشیاء مختلف به عنوان کلاس‌های متمایز در نظر گرفته می‌شوند.

در این مطالعه معماری شبکه‌های MobileNet-v2, ResNet-18 نقش اصلی در استخراج ویژگی‌ها از تصویر را ایفا می‌کنند و سپس DeepLabV3+ با استفاده از ویژگی‌های و الگوریتم ASPP (Atrous Spatial Pyramid Pooling) و به کارگیری الگوریتم کانولوشن (Atrous Convolution) Atrous اطلاعات زمینه‌ای بیشتری را از تصویر در مقیاس‌های مختلف استخراج می‌کند. در نهایت، این ویژگی‌ها برای تولید نقشه بخش بندی شده نهایی مورد استفاده قرار می‌گیرند. ترکیب شبکه‌های از پیش آموزش دیده مذکور و DeepLabV3+ موجب می‌شود که شبکه بتواند با دقت بالاتر و قدرت تفکیک بهتر، بخش بندی معنایی را بر روی تصاویر انجام دهد. مدل پیشنهادی در ارزیابی‌های صورت گرفته نتایج قابل قبولی را در تمامی معیارهای ارزیابی محاسبه شده ارائه داد و توانایی آن در تولید تصاویر تقسیم بندی شده با کیفیت بالا در مجموعه داده‌های مختلف نشان‌دهنده کارایی مطلوب آن بود. ارزیابی‌های انجام شده بر روی مدل با استفاده از یک GPU (Graphics Processing Unit) نشان می‌دهد که زمان لازم برای بخش بندی یک سی تی اسکن کل بدن با ۳۲۹ برش تنها ۴۵ ثانیه می‌باشد.

با این که دقت تقسیم بندی با این مدل در مجموعه داده‌های مختلف قابل قبول بود، با این حال، برخی خطاها نیز شناسایی شدند. رایج‌ترین منابع خطا، غضروف دنده‌ای و دیسک‌های بین مهره‌ای هستند. غضروف دنده‌ای به ویژه در بیماران سالخورده مشابه شکل و تراکم دنده‌ها در تصاویر سی تی اسکن نمایان می‌شود، که این امر می‌تواند منجر به اشتباه در برچسب گذاری و شناسایی آن به عنوان استخوان گردد. همچنین در فرآیند بخش بندی ریه و نای، لازم است دقت کافی به کار گرفته شود تا از حذف نواحی مورد نظر جلوگیری شود. این چالش‌ها تأکیدی بر ضرورت پیشرفت‌های بیشتر در تکنیک‌های تقسیم بندی و به کارگیری شبکه‌های عصبی عمیق برای بهبود دقت تشخیص در تصاویر پزشکی دارند.

با توجه به این که شبکه‌های ذکر شده قبلاً بر روی مجموعه تصاویر imageNet آموزش دیده‌اند و وزن‌های اولیه داشته‌اند در اولین epoch شاهد دقت نسبتاً خوب ۹۷ درصد هستیم (این مقدار در ابتدای اولین epoch و در اولین تکرار ۴۶/۹۶ درصد است که در انتهای نهمین epoch و پس از آموزش دقت به حدود ۹۹/۲۲ درصد می‌رسد).

نکته دیگری که حائز اهمیت است استفاده از تصاویر سی تی اسکن برای بخش‌بندی است که از مرزهای نسبتاً خوبی در مقایسه با دیگر تصاویر پزشکی از جمله تصاویر پزشکی هسته‌ای برخوردار هستند و دقت به دست آمده در این حوزه قابل انتظار است. آن چه که در مورد نتایج به دست آمده از این شبکه‌ها اهمیت دارد توانایی شبکه‌ها برای بخش‌بندی استخوان، ریه و بافت نرم به طور همزمان است. در کارهای مشابه تنظیم دقیق (Fine tune) ابر پارامترهای (Hyper parameters) شبکه‌ها برای بخش‌بندی هر کدام از ارگان‌ها به صورت مجزا انجام می‌شود و ممکن است مثلاً شبکه‌ای که تنظیمات لازم برای بخش‌بندی استخوان را داشته باشد نتواند همزمان بخش‌بندی ریه یا بافت نرم را هم با دقت بالایی انجام دهد. از آن جایی که هدف از توسعه این شبکه استفاده از هوش مصنوعی برای مقاصد محاسبات دوزیمتری و طراحی درمان در رادیوتراپی براساس تصاویر سی تی اسکن بوده است بخش‌بندی همزمان و سریع سه ارگان ذکر شده، حائز اهمیت است که این مهم با استفاده از شبکه‌های مذکور امکان‌پذیر می‌باشد. مدل‌های پیشنهادی در ارزیابی‌های صورت گرفته نتایج قابل قبولی را در تمامی معیارهای ارزیابی محاسبه شده ارائه دادند و توانایی آن‌ها در تولید تصاویر تقسیم‌بندی شده با کیفیت بالا در مجموعه داده‌های مختلف نشان‌دهنده کارایی مورد نظر بود. البته لازم به ذکر است، یکی از پارامترهای ارزشمند برای ارزیابی کارایی و عملکرد شبکه‌ها در حوزه بخش‌بندی تصاویر ضریب ژاکارد می‌باشد. این کمیت بیانگر شباهت بین ناحیه پیش‌بینی شده توسط شبکه و حقیقت مرجع (Ground Truth) را به صورت درصدی از همپوشانی ارزیابی می‌کند. این پارامتر ارزیابی، بیشتر برای ارگان‌های بزرگ استفاده می‌شود و همان‌طور که در جدول ۲ مشاهده می‌شود، میزان این کمیت برای بافت نرم بیشینه و برای استخوان کمینه می‌باشد. دلیل این مهم ناشی از وجود ساختارهای ظریف و استخوان‌های کوچک در ساختار اسکلتی بدن انسان است.

از طرف دیگر نتایج ضریب ژاکارد در جدول ۲ نشان می‌دهد شبکه ResNet-18 اندکی بهتر از شبکه MobileNet-v2 عمل می‌کند، چون این شبکه مدلی عمیق‌تر با لایه‌های بیشتر است. با این وجود از آن جایی که MobileNet-V2 برای سرعت و کارایی در دستگاه‌های موبایل بهینه‌سازی شده است و از فشرده‌سازی شبکه بهره می‌برد از پیچیدگی کمتری برخوردار است و سرعت بالاتری دارد. در نتیجه با توجه به اهمیت سرعت برای بخش‌بندی استخوان، ریه و بافت نرم و عدم تفاوت زیاد در دقت و ضریب ژاکارد دو شبکه، در این مطالعه شبکه سریع‌تر و سبک‌تر MobileNet-V2 پیشنهاد می‌شود.

در این مطالعه، دو شبکه کاملاً خودکار برای تقسیم‌بندی ساختارهای آناتومیکی شامل استخوان، ریه و بافت نرم طراحی و مقایسه شد. این شبکه‌ها مبتنی بر معماری‌های پیشرفته شبکه عصبی کانولوشنال و آموزش دیده با استفاده از مجموعه داده‌های تصاویر سی تی اسکن با دز پایین بودند. با بهره‌گیری از مدل DeepLabv3+ و تنظیم پارامترهای آموزش دقت قابل قبولی در شناسایی و بخش‌بندی ساختارهای استخوان، ریه و بافت نرم به صورت همزمان به دست آمده است.

نتایج ارزیابی‌ها نشان داده است که شبکه MobileNet-v2 عملکرد بهتری نسبت به شبکه ResNet-18 در تقسیم‌بندی استخوان، ریه و بافت نرم از نظر سرعت از خود نشان می‌دهد. این یافته‌ها بر پتانسیل MobileNet-v2 در بهبود دقت بخش‌بندی در تصاویر پزشکی تأکید دارد. در ادامه نویسندگان این مطالعه در حال بررسی مدل‌های دیگر و آزمایش معماری‌های متنوع به منظور شناسایی بهترین گزینه با کارایی بالاتر هستند. این تجزیه و تحلیل‌ها می‌توانند به توسعه ابزارها و تکنیک‌های خودکار و مؤثر برای کاربردهای بالینی در زمینه تصویربرداری پزشکی کمک شایانی نمایند.

تعارض منافع

ندارد.

حمایت مالی

ندارد.



کد اخلاق

کد اخلاق این مطالعه با شماره IR.KMU.REC.1404.047 از دانشگاه علوم پزشکی کرمان گرفته شده است.

سهام مشارکت نویسندگان

کلیه نویسندگان در این پژوهش همکاری داشته‌اند.

References

- [1]. Jiang H, Diao Z, Shi T, Zhou Y, Wang F, Hu W, et al. A review of deep learning-based multiple-lesion recognition from medical images: classification, detection and segmentation. *Computers in Biology and Medicine* 2023;157:106726. <https://doi.org/10.1016/j.compbiomed.2023.106726>
- [2]. Abdullah MF, Sulaiman SN, Osman MK, Karim NA, Setumin S, Isa IS. A new procedure for lung region segmentation from computed tomography images. *International Journal of Electrical and Computer Engineering (IJECE)* 2022;12(5):4978-87. doi: 10.11591/ijece.v12i5.pp4978-4987
- [3]. Rich JM, Bhardwaj LN, Shah A, Gangal K, Rapaka MS, Oberai AA, et al. Deep learning image segmentation approaches for malignant bone lesions: a systematic review and meta-analysis. *Frontiers in Radiology* 2023;3:1241651. <https://doi.org/10.3389/fradi.2023.1241651>
- [4]. Didziokas M, Pauws E, Kölby L, Khonsari RH, Moazen M. BounTI (boundary-preserving threshold iteration): A user-friendly tool for automatic hard tissue segmentation. *Journal of Anatomy* 2024;245(6):829-41. <https://doi.org/10.1111/joa.14063>
- [5]. Montesinos López OA, Montesinos López A, Crossa J. Fundamentals of artificial neural networks and deep learning. In *Multivariate statistical machine learning methods for genomic prediction*; 2022 Jan 14; Cham: Springer International Publishing; 2022. p. 379-425.
- [6]. Habib G, Qureshi S. Optimization and acceleration of convolutional neural networks: A survey. *Journal of King Saud University-Computer and Information Sciences* 2022;34(7):4244-68. <https://doi.org/10.1016/j.jksuci.2020.10.004>
- [7]. Ouvrard E, Kaseb A, Poterszman N, Porot C, Somme F, Imperiale A. Nuclear medicine imaging for bone metastases assessment: what else besides bone scintigraphy in the era of personalized medicine?. *Frontiers in Medicine* 2024;10:1320574. <https://doi.org/10.3389/fmed.2023.1320574>
- [8]. Renjun X, Junliang Y, Yi W, Mengcheng S. Fault Detection Method Based on Improved Faster R-CNN: Take ResNet-50 as an Example. *Geofluids* 2022;2022(1):7812410. <https://doi.org/10.1155/2022/7812410>
- [9]. Xu Y, Quan R, Xu W, Huang Y, Chen X, Liu F. Advances in medical image segmentation: a comprehensive review of traditional, deep learning and hybrid approaches. *Bioengineering* 2024;11(10):1034. <https://doi.org/10.3390/bioengineering11101034>
- [10]. Takahashi R, Matsubara T, Uehara K. RICAP: Random Image Cropping and Patching Data Augmentation for Deep CNNs. *Proceedings of The 10th Asian Conference on Machine Learning*; 2018 Nov 4; PMLR; 2018. p. 786-98. <https://doi.org/10.48550/arXiv.1811.09030>
- [11]. Kaulgud RV, Patil A. Analysis based on machine and deep learning techniques for the accurate detection of lung nodules from CT images. *Biomedical Signal Processing and Control* 2023;85:105055. <https://doi.org/10.1016/j.bspc.2023.105055>
- [12]. Prayer F, Röhrich S, Pan J, Hofmanninger J, Langs G, Prosch H. Künstliche Intelligenz in der Bildgebung der Lunge. *Der Radiologe*. 2020;60(1). doi:10.1007/s00117-019-00611-2
- [13]. Benmalek E, Elmhamdi J, Jilbab A. Comparing CT scan and chest X-ray imaging for COVID-19 diagnosis. *Biomed Eng Adv* 2021;1:100003. doi: 10.1016/j.bea.2021.100003
- [14]. Zhang Z, Sejdić E. Radiological images and machine learning: trends, perspectives, and prospects. *Computers in Biology and Medicine* 2019;108:354-70. <https://doi.org/10.1016/j.compbiomed.2019.02.017>
- [15]. Hesamian MH, Jia W, He X, Kennedy P. Deep learning techniques for medical image segmentation: achievements and challenges. *Journal of Digital Imaging* 2019;32:582-96.
- [16]. Lv Y, Ke J, Xu Y, Shen Y, Wang J, Wang J. Automatic segmentation of temporal bone structures from clinical conventional CT using a CNN approach. *The International Journal of Medical Robotics and Computer Assisted Surgery* 2021;17(2):e2229. <https://doi.org/10.1002/rcs.2229>
- [17]. Fontenele RC, Gerhardt MD, Picoli FF, Van Gerven A, Nomidis S, Willems H, et al. Convolutional neural network-based automated maxillary alveolar bone segmentation on cone-beam computed tomography images. *Clinical Oral Implants Research* 2023;34(6):565-74. <https://doi.org/10.1111/clr.14063>
- [18]. Dutta S, Sikder R, Islam MR, Al Mukaddim A, Hider MA, Nasiruddin M. Comparing the Effectiveness of Machine Learning Algorithms in Early Chronic Kidney Disease Detection. *Journal of Computer Science and Technology Studies*. 2024;6(4):77-91. doi: 10.32996/jcsts

- [19]. Shen SC, Fernández MP, Tozzi G, Buehler MJ. Deep learning approach to assess damage mechanics of bone tissue. *Journal of the Mechanical Behavior of Biomedical Materials*. 2021;123:104761. <https://doi.org/10.1016/j.jmbbm.2021.104761>
- [20]. Li R, Chen X. An efficient interactive multi-label segmentation tool for 2D and 3D medical images using fully connected conditional random field. *Computer Methods and Programs in Biomedicine* 2022;213:106534. <https://doi.org/10.1016/j.cmpb.2021.106534>
- [21]. Zhang Y, Feng H, Zhao Y, Zhang S. Exploring the application of the artificial-intelligence-integrated platform 3D slicer in medical imaging education. *Diagnostics* 2024;14(2):146.
- [22]. Malik H, Anees T, Chaudhry MU, Gono R, Jasiński M, Leonowicz Z, et al. A novel fusion model of hand-crafted features with deep convolutional neural networks for classification of several chest diseases using X-ray images. *IEEE Access* 2023;11:39243-68.
- [23]. Arslan M, Haider A, Khurshid M, Bakar SS, Jani R, Masood F, et al. From pixels to pathology: employing computer vision to decode chest diseases in medical images. *Cureus*. 2023 Sep 20;15(9). doi: [10.7759/cureus.45587](https://doi.org/10.7759/cureus.45587)
- [24]. Murugappan M, Bourisly AK, Prakash NB, Sumithra MG, Acharya UR. Automated semantic lung segmentation in chest CT images using deep neural network. *Neural Computing and Applications* 2023;35(21):15343-64.
- [25]. Ou X, Yan P, Zhang Y, Tu B, Zhang G, Wu J, et al. Moving object detection method via ResNet-18 with encoder-decoder structure in complex scenes. *IEEE Access* 2019;7:108152-60. doi: [10.1109/ACCESS.2019.2931922](https://doi.org/10.1109/ACCESS.2019.2931922)
- [26]. Srinivasu PN, SivaSai JG, Ijaz MF, Bhoi AK, Kim W, Kang JJ. Classification of skin disease using deep learning neural networks with MobileNet V2 and LSTM. *Sensors* 2021;21(8):2852. <https://doi.org/10.3390/s21082852>
- [27]. Uzundurukan A, Poncet S, Boffito DC, Micheau P. Computed Tomography-Based Finite Element Model of the Human Thorax for High-Frequency Chest Compression Therapy. In *Proceedings of the 10th International Conference on Biomedical Engineering and Systems (ICBES 2023)*; 2023 Aug 3-5; London, United Kingdom: Brunel University; 2023. doi: [10.11159/icbes23.123](https://doi.org/10.11159/icbes23.123)
- [28]. Wang J, Sourlos N, Zheng S, Van der Velden N, Pelgrim GJ, Vliegenthart R, et al. Preparing CT imaging datasets for deep learning in lung nodule analysis: Insights from four well-known datasets. *Heliyon* 2023;9(6).
- [29]. Cho YJ. Weighted Intersection over Union (wIoU) for evaluating image segmentation. *Pattern Recognition Letters* 2024;185:101-7. <https://doi.org/10.1016/j.patrec.2024.07.011>
- [30]. Wu Z, Yang R, Gao F, Wang W, Fu L, Li R. Segmentation of abnormal leaves of hydroponic lettuce based on DeepLabV3+ for robotic sorting. *Computers and Electronics in Agriculture* 2021;190:106443. <https://doi.org/10.1016/j.compag.2021.106443>
- [31]. Lee YS, Hong N, Witanto JN, Choi YR, Park J, Decazes P, et al. Deep neural network for automatic volumetric segmentation of whole-body CT images for body composition assessment. *Clinical Nutrition* 2021;40(8):5038-46. <https://doi.org/10.1016/j.clnu.2021.06.025>
- [32]. Demehri S, Baffour FI, Klein JG, Ghotbi E, Ibad HA, Moradi K, et al. Musculoskeletal CT imaging: state-of-the-art advancements and future directions. *Radiology* 2023;308(2):e230344. <https://doi.org/10.1148/radiol.230344>
- [33]. Ding AS, Lu A, Li Z, Sahu M, Galaiya D, Siewerdsen JH, et al. A self-configuring deep learning network for segmentation of temporal bone anatomy in cone-beam CT imaging. *Otolaryngology-Head and Neck Surgery*. 2023;169(4):988-98. <https://doi.org/10.1002/ohn.317>
- [34]. Kim CM, Hong EJ, Park RC. Chest X-ray outlier detection model using dimension reduction and edge detection. *IEEE Access* 2021;9:86096-106. doi: [10.1109/ACCESS.2021.3086103](https://doi.org/10.1109/ACCESS.2021.3086103)
- [35]. Carmo D, Ribeiro J, Dertkigil S, Appenzeller S, Lotufo R, Rittner L. A systematic review of automated segmentation methods and public datasets for the lung and its lobes and findings on computed tomography images. *Yearb Med Inform* 2022;31(1):277-95. doi: [10.1055/s-0042-1742517](https://doi.org/10.1055/s-0042-1742517)
- [36]. Vocaturo E, Zumpano E, Caroprese L. Convolutional neural network techniques on X-ray images for COVID-19 classification. In *2021 IEEE International Conference on Bioinformatics and Biomedicine (BIBM)*; 2021 Dec 9; Houston, TX, USA: IEEE; 2021. p. 3113-5. doi: [10.1109/BIBM52615.2021.9669784](https://doi.org/10.1109/BIBM52615.2021.9669784)
- [37]. Prakash NB, Murugappan M, Hemalakshmi GR, Jayalakshmi M, Mahmud M. Deep transfer learning for COVID-19 detection and infection localization with superpixel based segmentation. *Sustainable Cities and Society* 2021;75:103252. <https://doi.org/10.1016/j.scs.2021.103252>
- [38]. Mohammadian M, Khazaei Moghaddam M, Saniei A. Segmentation Automatic lung Based on deep learning with use from image Tomography Computer ct. *2nd International Conference on Artificial Intelligence and Software Engineering* 2024.