

ارائه یک چارچوب هوشمند کامپیوتری جهت تشخیص غدد مشکوک ریوی

رضا مجیدپورخوئی^۱، مهدی علیلو^۲، کامبیز مجیدزاده^۳، امین بابازاده سنگر^۴

تاریخ دریافت ۱۳۹۹/۰۷/۲۵ تاریخ پذیرش ۱۳۹۹/۱۱/۳۰

چکیده

پیش‌زمینه و هدف: یکی از نشانه‌های بروز سرطان ریه، که یکی از مرگبارترین سرطان‌ها محسوب می‌گردد، غده‌های ریوی می‌باشند. به دلیل اینکه آشکارسازی این غده‌های ریز از روی تصاویر سی‌تی‌اسکن ریه با چشم بسیار دشوار می‌باشد بنابراین سیستم‌های هوشمند یا سیستم‌های تشخیص به کمک کامپیوتر (CAD)، می‌توانند به‌عنوان کمک کار متخصص در آشکارسازی، محل یابی و ارزیابی کیفیت غده کمک کنند. مهم‌ترین چالش سیستم‌های هوشمند موجود، ارتقاء متعادل معیارهای دقت، تشخیص، حساسیت و کاهش نرخ خطای مثبت کاذب (FPr) بوده و همچنین پیچیدگی این سیستم‌ها، باعث کاهش کارایی و سرعت اجرا شده است بنابراین هدف از انجام پژوهش حاضر، ارائه یک چارچوب چابک و بهینه سازی چالش مدنظر می‌باشد.

مواد و روش کار: یکی از زیرشاخه‌های نوین هوش مصنوعی، یادگیری عمیق و گرایش شبکه‌های CNN می‌باشند که در سال‌های اخیر، در تحلیل تصاویر پزشکی کاربرد زیادی یافته‌اند. در این پژوهش، یک شبکه ابتکاری مبتنی بر شبکه‌های CNN از نوع LeNet جهت استخراج ویژگی‌های تصویر و همچنین کلاس بندی تصاویر پیشنهاد می‌گردد. دیتاست مورد استفاده، یک زیرمجموعه به تعداد ۷۰۷۲ قطعه تصویر که از مجموعه دیتاست استاندارد LIDC-IDRI حاصل شده است، می‌باشد. غده‌های موجود در این تصاویر که جهت آموزش و اعتبارسنجی شبکه، استفاده می‌شوند دارای اندازه‌های ۱ تا ۴ میلی متر می‌باشند.

یافته‌ها: فرآیندهای آموزش و اعتبارسنجی این شبکه با یک دستگاه رایانه دارای پردازنده Core i5 2.4GHz، حافظه 8GB و کارت گرافیک Intel Graphics 520 در مدت زمان، پنج ساعت و یازده دقیقه اجرا شده و به میزان دقت، حساسیت و تشخیص به ترتیب برابر با ۹۱،۱ درصد، ۸۵،۳ درصد و ۹۲،۸ درصد دست یافته است.

بحث و نتیجه‌گیری: با توجه به مبنای استاندارد مدل ارائه شده و نیز استفاده از تصاویر پایگاه داده معتبر برای سنجش شبکه و مقایسه با کارهای پیشین، نتایج حاصل شده از آن، تعادل خوبی را بین معیارهای ارزیابی برقرار نموده و با اجرای سریع‌تر، قابلیت لازم برای کاربردهای زمان واقعی را کسب می‌نماید.

کلید واژه‌ها: سیستم‌های کمک تشخیص کامپیوتری، پردازش تصویر پزشکی، غدد ریوی، شبکه‌های عصبی مصنوعی، یادگیری عمیق

مجله مطالعات علوم پزشکی، دوره سی و دوم، شماره اول، ص ۸۱-۶۷، فروردین ۱۴۰۰

آدرس مکاتبه: ارومیه، گروه مهندسی کامپیوتر، واحد ارومیه، دانشگاه آزاد اسلامی، تلفن: ۰۹۱۴۲۷۵۷۰۷۲

Email: me.alilou@gmail.com

مقدمه

سرطان ریه دومین سرطان شایع در مردان و زنان است (در مردان، سرطان پروستات و در زنان سرطان سینه رتبه اول را دارد). انجمن بین‌المللی سرطان آمریکا، آمار سرطان ریه این کشور را برای سال ۲۰۲۰ به صورت زیر برآورد کرده است:
✓ حدود ۲۲۸،۸۲۰ مورد جدید سرطان ریه (۱۱۶،۳۰۰ در مردان و ۱۱۲،۵۲۰ در زنان)

غدد ریوی، ضایعات کوچکی داخل ریه‌ها هستند که معمولاً به صورت گرد دیده می‌شوند و در صورت آشکارسازی با تأخیر می‌توانند باعث بروز سرطان ریه شوند. سرطان ریه در مراحل اولیه، به دلیل وجود تباین پایین، اندازه‌ی کوچک و محل قرارگیری غده‌ها، هیچ گونه علائمی در تصاویر سی‌تی‌اسکن نداشته و زمانی علائم آن ظاهر می‌شود که بیماری در مراحل پیشرفته‌تری قرار گرفته باشد.

^۱ دانشجوی دکتری رشته مهندسی کامپیوتر سیستم‌های نرم افزاری، واحد ارومیه، دانشگاه آزاد اسلامی، ارومیه، ایران

^۲ استادیار، گروه مهندسی کامپیوتر، واحد ارومیه، دانشگاه آزاد اسلامی، ارومیه، ایران (نویسنده مسئول)


^۳ استادیار، گروه مهندسی کامپیوتر، واحد ارومیه، دانشگاه آزاد اسلامی، ارومیه، ایران

^۴ استادیار، گروه مهندسی کامپیوتر، واحد ارومیه، دانشگاه آزاد اسلامی، ارومیه، ایران

✓ حدود ۱۳۵،۷۲۰ مرگ ناشی از سرطان ریه (۷۲،۵۰۰ در مردان و ۶۳،۲۲۰ در زنان)

استفاده از جراحی، رادیوتراپی و شیمی درمانی، روش‌های رایج درمان سرطان ریه هستند (۱) و با تشخیص زود هنگام سرطان ریه، نرخ زنده ماندن ۵ ساله افراد را از ۱۶ درصد به ۵۰ درصد افزایش می‌دهند و این مهم، در صورت استفاده از روش‌های استاندارد و روتین تصویربرداری پزشکی میسر می‌گردد. تصاویر سی‌تی‌اسکن همواره به‌عنوان یکی از رایج‌ترین و دقیق‌ترین روش‌های موجود برای تشخیص غدد مشکوک ریوی محسوب می‌گردند. با توجه به زمان کم و تعداد زیاد تصاویر سی‌تی‌اسکن هر بیمار، که به‌صورت برشهایی از بافت می‌باشند، امکان تشخیص دقیق توسط پزشکان به‌طور سنتی میسر نمی‌باشد و همچنین با چالش تفسیر شخصی نیز مواجه است

فلذا با طراحی سیستم‌های تشخیص پزشکی به کمک کامپیوتر^۱ با هدف افزایش سرعت و کیفیت تشخیص، فرایندهای ذهنی^۲ به عینی^۳ تبدیل می‌گردند. چنین سیستم‌هایی به‌عنوان ابزاری هوشمند که نظر دوم را برای متخصص فراهم می‌کنند، بکار برده می‌شوند که غدد مشکوک در تصاویر را به متخصص نشان داده و از این طریق به متخصص در تشخیص هر چه صحیح‌تر بیماری کمک می‌نمایند. در واقع ایده‌ی اساسی این نیست که به‌طور کلی، تشخیص بیماری به یک ماشین محول شود بلکه، هدف اصلی، افزایش دقت و حساسیت تشخیص و کاهش نرخ خطای مثبت کاذب^۴ می‌باشد (۲). فلوجارت کلی روش‌های تشخیص کامپیوتری تصاویر پزشکی در شکل ۱ نشان داده شده است.



شکل (۱): بلوک دیاگرام کلی روش‌های تشخیص کامپیوتری تصاویر پزشکی (CAD) (۳)

این سیستم‌ها معمولاً از مؤلفه‌های: بهبود تصویر، بینایی ماشین و یادگیری ماشین^۱ که از شبکه‌های عصبی مصنوعی^۲ یا ماشین بردار پشتیبان^۳ برای استخراج ویژگی‌های تصویر و کلاس بندی تصاویر در مرحله آموزش مدل استفاده می‌کنند، تشکیل شده‌اند. همچنین از تکنیک‌های قطعه بندی^۴ برای تقسیم تصویر به بخش‌های معنی دار استفاده می‌شود (۴).

روش‌های هوشمند قبلی برای استخراج ویژگی‌های تصاویر از روش‌های دستی^۵ استفاده می‌کردند مثلاً الگوریتم انتخاب ویژگی

شناور متوالی^۶ یا الگوریتم ژنتیک^۷ که می‌توانند به تولید ویژگی‌های بهینه شده کمک کنند (۵)، با این حال در ویژگی‌های با ابعاد بزرگ مانند تصاویر، از اثر کمتری برخوردار بودند (۶). در سال‌های اخیر، سیستم‌های CAD از فناوری یادگیری عمیق که ویژگی‌های تصاویر را به‌صورت خودکار استخراج می‌نماید، استفاده کرده‌اند (۷) و بسیاری از برنامه‌های پردازش تصویر پزشکی به دلیل استفاده از فناوری یادگیری عمیق^۸ موفقیت آمیز بوده‌اند (۸). سیستم‌های تشخیص غدد مشکوک ریوی، از تصاویر سی‌تی‌اسکن نیز اخیراً از

³ SVM : Support Vector Machine

⁴ Segmentation

⁵ Hand-crafted feature extraction

⁶ SFFS : sequential flood feature selection

⁷ GA : Genetic algorithm

⁸ Deep Learning

¹ CAD : Computer Aided Detection

² Subjective

³ Objective

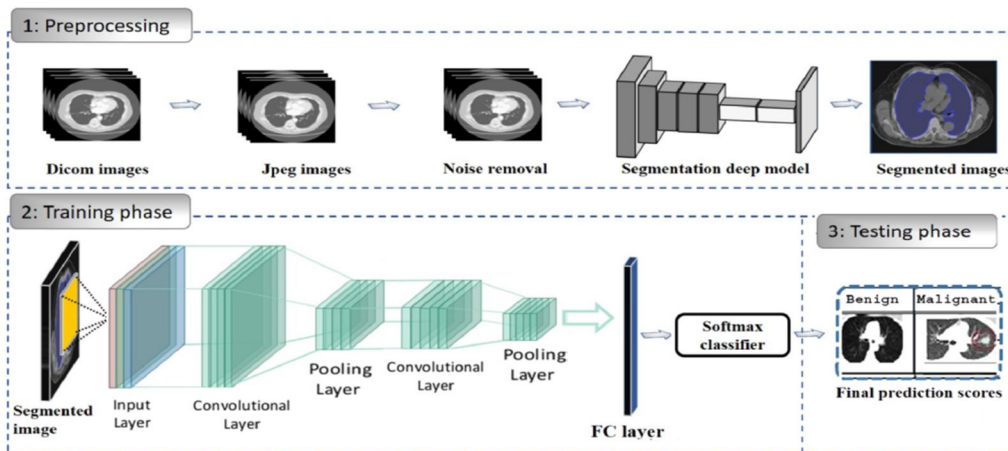
⁴ FPR: False Positive Rate

¹ Machine leaning

² ANN : Artificial Neural Network

سلسله مراتب، فناوری یادگیری عمیق، نوعی از روش‌های یادگیری ماشین بوده که همگی زیرمجموعه شبکه‌های عصبی مصنوعی و الگوریتم‌های ابتکاری^{۱۰} محسوب می‌شوند (۱۱). برای نمونه در شکل ۲ یک چارچوب هوشمند با هدف تشخیص غدد مشکوک ریوی نشان داده شده است.


معماری یادگیری عمیق استفاده کرده‌اند (۹). این سیستم‌ها عملکرد بهتری نسبت به سیستم‌های استخراج ویژگی‌های دستی دارند (۱۰). همچنین، به دلیل انبوه ویژگی‌های داده‌ای ناشی از حجم تصاویر پزشکی، یکی از شاخه‌های یادگیری عمیق به نام شبکه‌های CNN^۹ انتخاب بهتری برای یادگیری این الگوهای پیچیده هستند. از نظر



شکل (۲): یک چارچوب هوشمند کامپیوتری برای تشخیص غدد مشکوک ریوی (۱۲)

عملکرد بهتری نسبت به مدل‌های یادگیری ماشین کلاسیک داشته باشند. برنامه‌های یادگیری عمیق از طبقه‌بندی آسان تصاویر، مانند شناسایی اعداد دست نویس، تا موارد طبقه‌بندی پیچیده‌تر گسترش یافته‌اند (۱۸-۱۴). شبکه‌های عصبی کانولوشن^{۱۱}، مجموعه‌ای از لایه‌های شبکه‌ای هستند که با استخراج خودکار ویژگی‌های داده‌های ورودی، فرایند آموزش را انجام می‌دهند (۱۱). برای نمونه یک شبکه CNN در شکل ۳ نشان داده شده است.

تکنیک‌های یادگیری عمیق مجموعه‌ای از الگوریتم‌هایی می‌باشند که سعی در مدل‌سازی مفاهیم انتزاعی سطح بالا با استفاده از یادگیری در سطوح و لایه‌های مختلف انتزاع از داده‌های موجود را دارند. شبکه‌ای که دارای لایه‌های داخلی بسیاری از جمله پارامترهای شبکه کاهش یافته، ویژگی‌های یادگیری خودکار و توانایی‌های انتزاعی یادگیری می‌باشد (۱۳). مطالعات نشان داده است که الگوریتم‌های یادگیری عمیق در بسیاری از موارد، از جمله پردازش زبان طبیعی، تشخیص گفتار و بینایی رایانه، می‌توانند



شکل (۳): مراحل و گام‌های اساسی یک شبکه CNN (۱۹)

¹⁰ Heuristic Algorithms

⁹ Convolution Neural Network

- ✓ انتخاب یک شبکه سبک و دارای عملکرد مطلوب و حداقل بیش برآزش و کشف بهترین پیکربندی توسط آزمایشاتی که بر روی مجموعه داده^۳ اختصاصی اعمال می‌شود.
- ✓ بهره مندی از روش یادگیری عمیق پایان به پایان^۴، به نظارت^۵ و CNN مبتنی بر بسته^۶ برای طبقه‌بندی تصاویر، که باعث کاهش هزینه‌های محاسباتی و زمان آموزش کل چارچوب می‌شود.
- ✓ نمونه‌های کافی، معتبر و واقع بینانه دیتاست برای آموزش
- ✓ تعداد چرخه مناسب مرحله آموزش به منظور ایجاد چابکی
- ✓ عملکرد مطلوب با تعداد لایه‌های کم CNN
- ✓ بهبود متعادل معیارهای ارزیابی مطرح مانند دقت^۷، حساسیت^۸، نرخ تشخیص^۹ و کاهش نرخ خطای مثبت کاذب^{۱۰}، که چالش اصلی این سری از پژوهش‌ها محسوب می‌گردند.

مواد و روش کار

یادگیری عمیق یک زمینه سریع و تکاملی محسوب می‌شود که کاربردهای زیادی در زمینه تصویربرداری پزشکی دارد. الگوریتم‌های یادگیری عمیق قادر به استخراج و یادگیری ویژگی‌های خام داده‌های تصاویر بوده و محدودیتی در خصوص استخراج ویژگی‌ها ندارند. بنابراین یادگیری عمیق می‌تواند راه حل ایده آلی باشد (۱۱).

چارچوب پیشنهادی:

با توجه به اهداف این پژوهش از جمله، تحلیل سریع، دقت بالا و نرخ خطای مثبت کاذب مطلوب، یک چارچوب سبک که بر روی مجموعه داده، اجرا شده و برای بهبود نتایج، تغییرات ابتکاری در توپولوژی CNN اعمال شده و نتایج چندین بار مشاهده و در نهایت معماری بهینه شده سازگار با مجموعه داده ما و اهداف این

اولین شبکه CNN شبکه LeNet بود که در سال ۱۹۹۸ در مقاله (۲۰) ارائه شد، و اولین شبکه‌ای بود که از فیلترهای کانولوشن استفاده می‌کرد (۲۲-۲۰). در سال‌های بعد، برخی ساختارهای بسیار عمیق CNN پیشنهاد شدند (۲۰) از جمله، AlexNet که توسط Alex Krizhevsky طراحی و شامل ۸ لایه بوده و در مسابقات رقابتی ILSVRC-2012 شرکت کرد و اولین برنامه موفق CNN در حوزه تشخیص بود (۱۸)، شبکه‌های دیگر شامل: VGG-VD دارای ۱۶ و ۱۹ لایه، ساختار GoogleNet دارای ۲۲ لایه و معماری که از بیش برآزش^۱ جلوگیری می‌کند (۲۳)، شبکه ResNet نمونه دیگری از CNN بود که ۲۰ برابر عمیق‌تر از AlexNet و ۸ برابر عمیق‌تر از VGGNet بود (۲۴)، همچنین موارد دیگری مانند SENet و ... نیز ارائه شده‌اند (۲۴-۲۶).

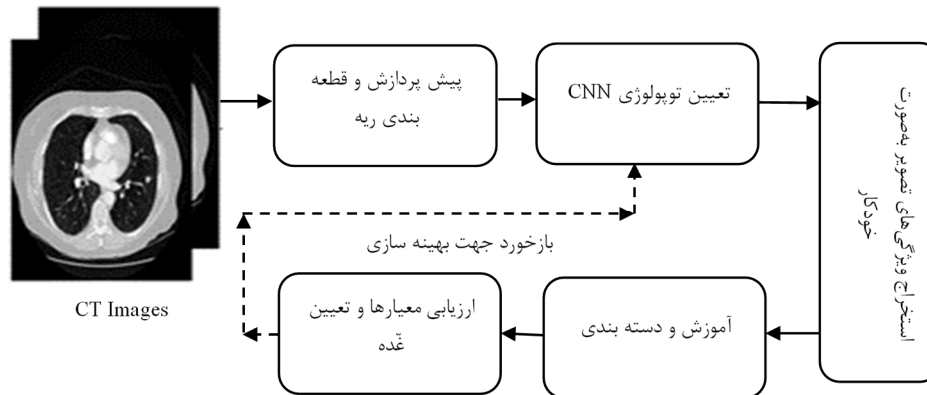
در خصوص مصادیق تشخیص هوشمند غدد مشکوک ریوی، مهدی علیلو و همکاران، یک ساختار شامل ۴ مرحله Segmentation, Identification, Classification و Visualization را پیشنهاد دادند که از SVM جهت Classification استفاده می‌نمود و معیار حساسیت با امتیاز ۸۰ درصد بهینه سازی گردید (۲۷). Qingzang song و همکاران، کارایی انواع شبکه‌های یادگیری عمیق CNN, DNN و SAE در تشخیص غدد مشکوک ریوی را مقایسه کردند که CNN انتخاب گردید (۲۸). Shuo wang و همکاران، یک ساختار کلی CF-CNN دوبعدی و سه‌بعدی با تاکید بر مرکزیت بجای گوشه‌های تصاویر جهت تشخیص غدد مشکوک ریوی با اشکال نامتجانس از نوع juxtopleural را پیشنهاد دادند که با لایه‌های کرنل کوچک، معیارها را تا حد ۸۲،۱۵ درصد بهینه سازی می‌نمود (۲۸). همچنین کارهای مرتبط بیشتری، در جدول شماره ۲ بیان شده‌اند.

اغلب کارهای پیشین، از CNN های پیچیده و عمیق و یا CNN های از قبل آموزش دیده (یادگیری انتقال^۲) استفاده نموده‌اند که نیازمند محاسبات بیشتر و زمان زیادتر جهت نیل به نتیجه نهایی می‌باشند، همچنین چالش بهینه سازی معیارهای ارزیابی، همچنان مطرح می‌باشد. فلذا، نوآوری‌های این پژوهش به شرح زیر می‌باشند:

⁶ Patch based
⁷ Accuracy
⁸ Sensitivity
⁹ Specificity
¹⁰ False Positive

¹ Overfit
² Transfer Learning
³ DataSet
⁴ End to End
⁵ Supervised Learning

پژوهش، به دست آمد. چارچوب پیشنهادی در شکل ۴ نشان داده شده است و مراحل آن در ادامه تبیین می‌شود.




شکل (۴): چارچوب و مدل پیشنهادی

داده کوچکتر که شامل ۲۹۰ سی‌تی‌اسکن بوده از دیتاست مذکور انتخاب و از آن‌ها تعداد ۷۰۷۲ برش^۲ استخراج و بر اساس برچسب، تقسیم بندی گردید (۳۵۳۶ برچسب مثبت و ۳۵۳۶ برچسب منفی). تصاویر دیتاست اصلی در قالب فایل‌های mhd و raw می‌باشند که در این پژوهش از کتابخانه SimpleITK برای خواندن فایل‌های mhd استفاده شده و با توجه به تعداد کافی تصاویر و وجود تعادل و آنتروپی، نیازی به تقویت و افزایش تصاویر نمی‌باشد.

مجموعه داده مورد استفاده:

یکی از چالش‌های اجرای الگوریتم‌های یادگیری عمیق در حوزه تصاویر پزشکی، دسترسی به مجموعه داده‌های مناسب و دارای برچسب می‌باشد. یکی از موارد مطرح در زمینه تصاویر سی‌تی‌اسکن ریه، پایگاه داده LIDC-IDRI^۱ است. یک نمونه از این دیتاست در شکل ۵ نشان داده شده است. با توجه به حجم بودن این دیتاست (حجم ۱۲۴ گیگابایت و تعداد ۲۴۴۶۱۷ تصویر) (۲۹)، یک مجموعه



شکل (۵): یک نمونه تصویر سی‌تی‌اسکن ریه از دیتاست LIDC-IDRI (۳۰)

کاهش میزان پردازش و حافظه لازم، تصاویر بزرگ را به برش‌های کوچکی که شامل ویژگی‌های اصلی هستند، تقسیم می‌کنند (۳۱). مرحله اول در پژوهش حاضر، قطعه بندی تصاویر دیتاست می‌باشد، قطعه بندی به معنای کلاس بندی در سطح پیکسل بوده و در پژوهش ما به معنی استخراج ناحیه‌های اصلی ریه از پس زمینه

مراحل کار و شبکه CNN پیشنهادی:


تصاویر بزرگ به‌عنوان ورودی، منجر به زمان طولانی پردازش می‌شوند همچنین قطعات بزرگ تصاویر معمولاً حاوی مقادیر قابل توجهی از اطلاعات غیرضروری و حاشیه می‌باشند. بنابراین، برای

² Patch

¹ Lung Image Database Consortium image collection and Image Database Resource Initiative

حذف بخش‌های اضافی و بافت‌های همجوار از تصویر می‌باشد. با توجه به اینکه نتایج این مرحله در مراحل بعدی و مدل کانولوشن، استفاده شده و مدل کانولوشن برای اجرا، حافظه زیادی می‌طلبد

فلذا ضرورت فرآیند قطعه بندی مشهود می‌باشد. در شکل ۶ یک نمونه خروجی حاصل از قطعه بندی نشان داده شده است.



شکل (۶): یک نمونه خروجی حاصل از قطعه بندی تصویر سی‌تی‌اسکن ریه دیتاست منتخب

مرحله دوم، تعیین استراتژی آموزش، که شامل چند بخش نمودن^۱ تصاویر و ایجاد برش‌ها و سپس برچسب گذاری نمونه‌های مثبت و منفی می‌باشد، در حقیقت این مرحله منجر به آماده سازی دیتاست می‌گردد. با توجه به اینکه یک نمونه سی‌تی‌اسکن یک بیمار از n مثلاً ۲۰۰ اسلایس^۲ تشکیل شده است. (البته تعدادی از اسلایس‌ها در مرحله اول حذف می‌شوند) و هر اسلایس یک تصویر ۲ بعدی در ابعاد 512×512 میلی‌متر می‌باشد. بنابراین در ابتدا، اطلاعات رقومی تصاویر سی‌تی‌اسکن یک بیمار در یک آرایه سه‌بعدی ذخیره می‌شود (آماده سازی جهت مفهوم سه‌بعدی پروژه). در دیتاست‌های دریافت شده، یک فایل با نام Coordinative به معنی راهنمای مختصات دو بعدی وجود دارد که مختصات حدودی و احتمالی وجود غده را بیان می‌کند. حال عملیات لازم روی آرایه سه‌بعدی فوق‌الذکر شروع می‌شود و اسلایس‌های دو بعدی به بخش‌های کوچک‌تر مثلاً


80×80 میلی‌متر تبدیل می‌شوند و هر کدام از این بخش‌ها به‌عنوان یک Box یا Crop نامگذاری می‌گردد (شکل ۷) و مختصات هر یک از این بخش‌ها با فایل Coordinative قیاس و در صورت مثبت بودن نتیجه با برچسب مثبت، و در غیر این صورت با برچسب منفی جداسازی و ذخیره می‌شوند (شکل ۸). اطلاعات هر یک از این بخش‌ها شامل مختصات اصلی، اطلاعات رقومی و خود تصویر جهت مراحل بعدی می‌باشد. موارد یادشده برای کل بیماران اجرا و نتایج به‌عنوان یک دیتاست برچسب گذاری شده ذخیره می‌شود. ما می‌توانیم به طور بالقوه CNN را در تمام پیکسل‌ها آموزش دهیم، اما این کار هزینه‌های محاسباتی و زمان آموزش را افزایش می‌دهد. بنابراین تصمیم گرفتیم تصاویر را در اطراف مختصات ارائه شده در فایل Coordinate برش دهیم.



شکل (۷): برش یا Crop های یک اسلایس

^۱ Cropping


هر اسلایس یک برش از بافت می‌باشد : Slice^۲



شکل (۸): برجسب گذاری تصاویر دیتاست

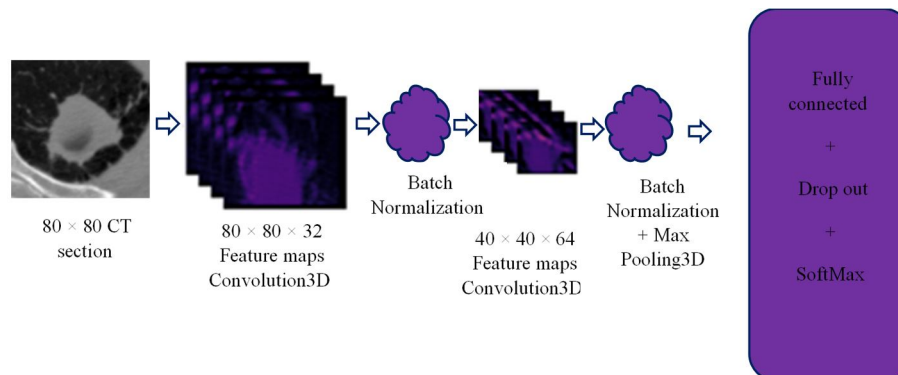
گردیده، نشان داده شده است که موفق ترین مدل، عمیق ترین آن‌ها نبوده بلکه مدلی با لایه‌های نسبتاً کمتر کانولوشن بوده است. عمق شبکه تنها به‌عنوان یک معیار در کنار سایر معیارهای طراحی شبکه مانند: مجموعه داده مورد استفاده، اندازه و شکل اشیاء دسته بندی شده، اندازه هسته نودهای کانولوشن، تعداد دوره‌های آموزشی و جزئیات سخت افزاری اجرا، مطرح می‌باشد و به کل معیارها باید توجه لازم صورت پذیرد.

اخیراً، تعداد لایه‌های CNN بیشتر و بیشتر شده است. افزایش تعداد لایه‌ها در شبکه، مفید است زیرا ویژگی‌ها را می‌توان به راحتی در سطوح مختلف انتزاع فرا گرفت. اما، استفاده از ساختارهای شبکه عمیق نیاز به یادگیری پارامترهای بیشتری دارد که منجر به افزایش پیچیدگی شبکه، زمان آموزش، تعمیم خطا و بیش برآزش بیش از حد می‌شود. در مطالعاتی که بر روی CNN های کم لایه و سبک توسط تاجبخش و همکاران (۳۲) که ساختار مدل آن در شکل ۹ نشان داده شده است و یا El-Regaily و همکاران (۳۳) انجام



شکل (۹): شبکه CNN سبک (Sh-CNN) (۳۲)

مرحله سوم، مرحله اصلی و طراحی شبکه CNN بوده که ما یک مدل چابک با دو لایه کانولوشن مطابق شکل ۱۰ و جدول ۱ بر مبنای مقاله (۳۲) را توسعه دادیم.




شکل (۱۰): شبکه CNN پیشنهادی (test_split=0.2 and patch_size=2 and batch_size=3000)

جدول (۱): شبکه CNN پیشنهادی

Layer (type)	Output Shape	Param #
conv3d_3 (Conv3D)	(None, 39, 39, 3, 8)	80
batch_normalization_3 (Batch)	(None, 39, 39, 3, 8)	32
conv3d_4 (Conv3D)	(None, 19, 19, 3, 8)	584
batch_normalization_4 (Batch)	(None, 19, 19, 3, 8)	32
max_pooling3d_2 (MaxPooling3)	(None, 9, 9, 3, 8)	0

مرحله چهارم، شبیه‌سازی سه‌بعدی و بصری سازی^۱ مدل، می‌باشد. در مرحله تست و یا کاربرد، پس از تشخیص یک Box یا یک Crop به‌عنوان نمونه مثبت، ابتدا محل غده در آن Box از روی مختصات آن، بر روی تصویر کامل سی‌تی‌اسکن اولیه نشان‌گذاری می‌شود. سپس با توجه به اینکه اطلاعات هر یک از این بخش‌ها شامل مختصات اصلی، اطلاعات رقمی و خود تصویر از قبل موجود می‌باشد، در صورتی که Box های مجاور این Box (از روی مختصات آن‌ها قابل شناسایی می‌باشند)، نیز به‌عنوان نمونه مثبت تشخیص داده شده باشند، امکان سه‌بعدی سازی وجود داشته و تصویر سه‌بعدی به‌صورت شبیه‌سازی ارائه می‌شود. (شکل ۱۱).

دیتاست برچسب‌گذاری شده از مرحله قبلی در سه گروه Train، Validation و Test تقسیم می‌شود و سپس دیتاست در مدل طراحی شده، وارد و مراحل آموزش و اعتبارسنجی با ۴۰۰ دور و پس از آن، تست انجام می‌گیرد. بدیهی است مراحل اعم از استخراج ویژگی‌ها و دسته بندی ویژگی‌ها و اصلاح وزن‌ها و تشخیص مختصات غده درون Box به‌طور خودکار توسط شبکه CNN صورت می‌گیرد. سپس معیارهای ارزیابی مدل اعم از ماتریس Confusion و نمودارهای Accuracy, Loss Function, Sensitivity, Specificity, Accuracy, False Positive همچون و معیارهای ارزیابی کیفیت هم‌چون False Positive محاسبه و رصدهای لازم صورت می‌پذیرد.



شکل (۱۱): برآورد لازم جهت شبیه‌سازی سه‌بعدی غده تشخیصی

برای توسعه نرم‌افزاری این پژوهش، از نرم‌افزار Matlab برای پیش پردازش تصاویر و جداسازی ریه از پس زمینه استفاده می‌شود. زبان اصلی برنامه نویسی این پژوهش، پایتون می‌باشد. کتابخانه‌های Anaconda3-64bit, Jupyter Notebook, Tensorflow و Keras برای پیاده‌سازی شبکه CNN استفاده می‌شوند. امکان استفاده از کتابخانه‌های دیگر پایتون از جمله SciPy،

برای توسعه نرم‌افزاری این پژوهش، از نرم‌افزار Matlab برای پیش پردازش تصاویر و جداسازی ریه از پس زمینه استفاده می‌شود. زبان اصلی برنامه نویسی این پژوهش، پایتون می‌باشد. کتابخانه‌های Anaconda3-64bit, Jupyter Notebook, Tensorflow و Keras برای پیاده‌سازی شبکه CNN استفاده می‌شوند. امکان استفاده از کتابخانه‌های دیگر پایتون از جمله SciPy،

^۱ Visualization

یافته‌ها

متغیرها یا معیارهای ارزیابی بهره‌وری مدل ارائه شده در این پژوهش شامل موارد زیر می‌باشند.

Classification Accuracy یا دقت و صحت کلاس بندی، به این معنی که چقدر تشخیص، به واقعیت نزدیکتر هست و به وسیله حاصل تقسیم تعداد نمونه‌هایی که به درستی دسته بندی شده باشند بر تعداد کل نمونه‌ها به دست می‌آید.

True Positive Rate Or recall Or Sensitivity یا حساسیت، داده‌هایی که در کلاس مثبت قرار دارند و به درستی نیز مثبت تشخیص داده شده‌اند.

Precision یا دقت تشخیص، یعنی تشخیص درست، به عبارت دیگر، در ارزیابی‌های متوالی نتایج چقدر به هم نزدیک می‌شوند.

True Negative Rate Or Specificity یا تشخیص، داده‌هایی که در کلاس منفی قرار دارند و به درستی نیز منفی تشخیص داده شده‌اند (۳۴).

حالات تشخیصی به شرح زیر تعریف می‌گردند.

True positive (TP): تعداد غده‌هایی که به صورت خودکار توسط الگوریتم شناسایی شده است.

False negative (FN): تعداد غده‌های شناسایی نشده توسط الگوریتم

True negative (TN): تعداد غیر غده‌هایی که به صورت خودکار شناسایی شده است.

False positive (FP): تعداد غیر غده‌هایی که به اشتباه حذف نشده‌اند (۳۵).

در این پژوهش از روش اعتبارسنجی Cross Validation-کبرای مراحل یادگیری و تست استفاده کرده‌ایم. بنابراین، پس از آموزش شبکه CNN، این مدل را با ۱۴۱۵ برش، تست نموده و ماتریس کانفیوژن به صورت شکل ۱۲ و همچنین معیارهای ارزیابی استخراج می‌گردند.

True Label	No-nodule	1021	79
	Nodule	46	269
		No-nodule	Nodule
		Predicted Label	

شکل (۱۲): ماتریس کانفیوژن

$$\text{Accuracy} = (\text{Tp} + \text{Tn}) / \text{D} = (269 + 1021) / 1415 = 91.1\%$$

$$\text{Precision (PPV)} = \text{Tp} / (\text{Tp} + \text{Fp}) = 269 / (269 + 79) = 77.2\%$$

$$\text{Recall or Sensitivity or TPR} = \text{Tp} / \text{Positive class} = 269 / 315 = 85.3\%$$


$$\text{Specificity} = \text{Tn} / \text{Negative class} = 1 - \text{FPR} = 1021 / 1100 = 92.8\%$$

$$\text{FPR} = \text{Fp} / \text{Negative class} = 1 - \text{specificity} = 79 / 1100 = 0.071 = 7.1\%$$


$$\text{NPV} = \text{Tn} / (\text{Tn} + \text{Fn}) = 1021 / (1021 + 46) = 95.6\%$$

$$\text{FDR} = \text{Fp} / (\text{Fp} + \text{Tp}) = 79 / (79 + 269) = 0.227 = 22.7\%$$

نمودارهای Accuracy و Loss در اشکال ۱۳ و ۱۴ نشان داده شده است.



شکل (۱۳): نمودار Loss



شکل (۱۴): نمودار Accuracy

جدول ۲ مقایسه‌ای بین روش پیشنهادی و سایر روش‌های مشابه قبلی را ارائه می‌دهد. با توجه به این مقایسه ملاحظه می‌شود که معیارهای ارزیابی در حالت متعادل بهبود یافته‌اند، بنابراین روش پیشنهادی عملکرد قابل قبولی را ارائه می‌دهد

جدول (۲): مقایسه روش پیشنهادی با کارهای مشابه

کارهای پیشین با شبکه CNN	مجموعه داده	تعداد سی‌تی‌اسکن استفاده شده	حساسیت %	تشخیص %	دقت %
Kumar et al. (2015) (36)	LIDC-IDRI	888	83.35	NA	75.01
Setio et al. (2016) (37)	LIDC-IDRI	888	85.4%	NA	NA
Shen et al. (2015) (38)	LIDC-IDRI	1010	NA	NA	86.84
Shen et al. (2017) (39)	LIDC-IDRI	888	77	93	87.14
Jiang et al. (2018) (40)	LIDC-IDRI	1010	80.06	NA	NA
Song et al. (2017) (4)	LIDC-IDRI	4581	83.96%	84.32%	84.15%
Gruetzemacher and Gupta (2016) (41)	LIDC-IDRI	1000	78.19	86.13	82.1
Ypsilantis and Montana (2016) (42)	LIDC-IDRI	1018	90.5%	NA	NA
Alakwaa et al. (2017) (43)	LIDC-IDRI(LUNA16)	1397	NA	NA	86.6
Wang et al. (2018) (44)	LIDC-IDRI(LUNA16)	888	95.8%	NA	NA
Xie et al. (2019) (45)	LIDC-IDRI(LUNA16)	1018	86.42%, 73.4% and 74.4%	NA	NA
Silveira et al. (2007) (46)	LIDC-IRDI	800	84.3%	85.9%	84.8%
Hassanpour et al. (2011) (47)	LIDC-IRDI	800	78.8%	81.2%	80.4%
روش پیشنهادی	LIDC-IRDI	290 CTs 7072 patches	85.3%	92.8%	91.1%

بحث و نتیجه‌گیری

امروزه، با توجه به گسترش روزافزون بیماری‌های ریوی در جوامع مختلف خصوصاً جوامع صنعتی، ارائه روش‌های کامپیوتری هوشمند جهت کمک به تشخیص سریع‌تر، صحیح‌تر و به هنگام، جهت اتخاذ روش‌های درمانی مناسب و به‌موقع از چالش‌های اساسی محسوب می‌گردد. البته هدف از توسعه چنین سیستم‌هایی قرار دادن آن‌ها در کنار متخصص به‌عنوان یک پیشنهاددهنده می‌باشد. بدیهی است که خطاهای انسانی در تشخیص، به‌واسطه تعداد زیاد و پیچیدگی تصاویر سی‌تی‌اسکن، امکان‌پذیر می‌باشد. از این‌روی، جهت کاهش خطاهای انسانی، تسریع در امر تشخیص و افزایش صحت و دقت، یک سیستم هوشمند کامپیوتری تشخیص غدد ریوی، جهت کمک به پزشکان در این پژوهش ارائه گردیده است. این سیستم یک معماری هوشمند سبک از نوع شبکه‌های CNN و درعین‌حال کارآمد را پیشنهاد می‌دهد که می‌تواند زمان آموزش را کاهش دهد بدون اینکه دقت طبقه‌بندی را از بین ببرد. در نتیجه باعث کاهش حجم کار متخصصین و اقدامات درمانی مناسب برای بیماران می‌گردد. همچنین این پژوهش، گامی در جهت رفع چالش مطرح در این حوزه که ارتقاء متعادل معیارهای دقت، تشخیص،

حساسیت و کاهش نرخ خطای مثبت کاذب (FPR) می‌باشد، برمی‌دارد.

برای کارهای آینده، می‌توان یک برنامه کاربردی^۱ بر اساس مدل پیشنهادی این پژوهش، خاص تلفن‌های همراه هوشمند را تولید نمود بطوریکه عموم بتوانند با واردکردن فایل تصاویر سی‌تی‌اسکن خود در این برنامه از وجود یا عدم وجود غده در ریه‌ها، آگاه گردند. همچنین، در آینده، می‌توان مدل فعلی را به گونه‌ای توسعه داد که نه تنها قابلیت تشخیص غده را داشته باشد بلکه بتواند نسبت به خوش خیم یا سرطانی بودن غده نیز اظهار نظر کند.

تشکر و قدردانی

این مقاله بدون اخذ مساعدت مالی از هر شخص و سازمانی از رساله دکترای تخصصی مهندسی کامپیوتر دانشگاه آزاد اسلامی واحد ارومیه استخراج شده است و فاقد هرگونه تعارض منافع می‌باشد.

نویسندگان این مقاله از مساعدت‌های تمام کسانی که در اجرای پژوهش یاریگر آن‌ها بودند کمال امتنان و قدردانی را به عمل می‌آورند.

References:

1. American Cancer Society, Key Statistics for Lung Cancer, 2020,
2. Available from <https://www.cancer.org/cancer/lung-cancer/about/key-statistics.html>.
3. A.C. Society, Cancer Facts and Figures, 2017. Available from <http://www.cancer.org/acs/groups/content/@editorial/documents/document/acspc-044552.pdf>.
4. Hussein S, Gillies R, Cao K, Song Q, Bageci U. TumorNet: Lung nodule characterization using multi-view Convolutional Neural Network with Gaussian Process. In 2017 IEEE 14th International Symposium on Biomedical Imaging. 2017. Song Q, Zhao L, Luo X, Dou X. Using Deep Learning for Classification of Lung Nodules on Computed Tomography Images. J Healthc Eng 2017; 2017:1–7. Available from: <http://dx.doi.org/10.1155/2017/8314740>
5. Sun W, Tseng T-LB, Qian W, Zhang J, Saltzstein EC, Zheng B, et al. Using multiscale texture and density features for near-term breast cancer risk analysis. Med Phys 2015;42(6Part1):2853–62. Available from: <http://dx.doi.org/10.1118/1.4919772>
6. Sun W, Huang X, Tseng T-L, Zhang J, Qian W. Computerized lung cancer malignancy level analysis using 3D texture features. Tourassi GD, Armato SG, editors. Medical Imaging 2016: Computer Aided Diagnosis. SPIE; 2016. Available from: <http://dx.doi.org/10.1117/12.2216329>
7. Hossain MS, Muhammad G. Cloud-Based Collaborative Media Service Framework for HealthCare. Int J Distrib Sens Netw 2014;10(3):858712. Available from: <http://dx.doi.org/10.1155/2014/858712>
8. Amin SU, Alsulaiman M, Muhammad G, Mekhtiche MA, Shamim Hossain M. Deep Learning for EEG

¹ Application

- motor imagery classification based on multi-layer CNNs feature fusion. *Future Generat Comput Syst* 2019;101:542–54. Available from: <http://dx.doi.org/10.1016/j.future.2019.06.027>
9. De Carvalho Filho AO, Silva AC, de Paiva AC, Nunes RA, Gattass M. Classification of patterns of benignity and malignancy based on CT using topology-based phylogenetic diversity index and convolutional neural network. *Pattern Recogn* 2018;81:200–12. Available from: <http://dx.doi.org/10.1016/j.patcog.2018.03.032>
 10. Wang Y, Qiu Y, Thai T, Moore K, Liu H, Zheng B. A two-step convolutional neural network based computer-aided detection scheme for automatically segmenting adipose tissue volume depicting on CT images. *Comput Meth Programs Biomed* 2017;144:97–104. Available from: <http://dx.doi.org/10.1016/j.cmpb.2017.03.017>
 11. Monkam P, Qi S, Ma H, Gao W, Yao Y, Qian W. Detection and Classification of Pulmonary Nodules Using Convolutional Neural Networks: A Survey. *IEEE Access* 2019;7:78075–91. Available from: <http://dx.doi.org/10.1109/access.2019.2920980>
 12. Saba T. Recent advancement in cancer detection using machine learning: Systematic survey of decades, comparisons and challenges. *J Infect Public Heal* 2020;13(9):1274–89. Available from: <http://dx.doi.org/10.1016/j.jiph.2020.06.033>
 13. Affonso C, Sassi RJ, Barreiros RM. Biological image classification using rough-fuzzy artificial neural network. *Expert Syst Appl* 2015;42(24):9482–8. Available from: <http://dx.doi.org/10.1016/j.eswa.2015.07.075>
 14. Yu-Jen Chen Y-J, Hua K-L, Hsu C-H, Cheng W-H, Hidayati SC. Computer-aided classification of lung nodules on computed tomography images via deep learning technique. *OncoTargets Ther* 2015; 8:2015-22. Available from: <http://dx.doi.org/10.2147/ott.s80733>
 15. Greenspan H, van Ginneken B, Summers RM. Guest Editorial Deep Learning in Medical Imaging: Overview and Future Promise of an Exciting New Technique. *IEEE Trans Med Imag*; 2016;35(5):1153–9. Available from: <http://dx.doi.org/10.1109/tmi.2016.2553401>
 16. Ongsulee P. Artificial intelligence, machine learning and deep learning. 2017 15th Int Conf ICT Knowl (ICT&KE). IEEE; 2017 Nov; Available from: <http://dx.doi.org/10.1109/ictke.2017.8259629>
 17. Litjens G, Kooi T, Bejnordi BE, Setio AAA, Ciompi F, Ghafoorian M, et al. A survey on deep learning in medical image analysis. *Med Image Anal* 2017;42:60–88. Available from: <http://dx.doi.org/10.1016/j.media.2017.07.005>
 18. Krizhevsky A, Sutskever I, Hinton GE. ImageNet classification with deep convolutional neural networks. *Adv Neural Inf Process Syst* 2017 ;60(6):84–90. Available from: <http://dx.doi.org/10.1145/3065386>
 19. Naik A, Edla DR. Lung Nodule Classification on Computed Tomography Images Using Deep Learning. *Wireless Personal Communications* 2020; 116: 655–90.
 20. Lecun Y, Bottou L, Bengio Y, Haffner P. Gradient-based learning applied to document recognition. *Proceedings of the IEEE*; 1998;86(11):2278–324. Available from: <http://dx.doi.org/10.1109/5.726791>
 21. Coşkun m, yildirim ö, uçar a, demir y, et al. an overview of popular deep learning methods. *Eur J Tech* 2017; 7(2):165–76. Available from: <http://dx.doi.org/10.23884/ejt.2017.7.2.11>
 22. Wang S, Zhou M, Liu Z, Liu Z, Gu D, Zang Y, et al. Central focused convolutional neural networks: Developing a data-driven model for lung nodule segmentation. *Med Image Anal* 2017;40:172–83. Available from: <http://dx.doi.org/10.1016/j.media.2017.06.014>
 23. Szegedy C, Wei Liu, Yangqing Jia, Sermanet P, Reed S, Anguelov D, et al. Going deeper with convolutions. In *Proceedings of the IEEE conference on computer*

- vision and pattern recognition 2015. p. 1-9.; Available from: <http://dx.doi.org/10.1109/cvpr.2015.7298594>
24. 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 2015 p. 1-9. Available from: <http://dx.doi.org/10.1109/cvpr.2016.90>
 25. Hu J, Shen L, Albanie S, Sun G, Wu E. Squeeze-and-Excitation Networks. *IEEE Trans Pattern Anal Mach Intell* 2020 ;42(8):2011–23. Available from: <http://dx.doi.org/10.1109/tpami.2019.2913372>
 26. He K, Zhang X, Ren S, Sun J. Identity Mappings in Deep Residual Networks. *Lect Notes Comput Sci* 2016;630–45. Available from: http://dx.doi.org/10.1007/978-3-319-46493-0_38
 27. Alilou M, Kovalev V, Snezhko E, Taimouri V. a comprehensive framework for automatic detection of pulmonary nodules in lung ct images. *Image Analysis & Stereology* 2014;33(1):13. Available from: <http://dx.doi.org/10.5566/ias.v33.p13-27>
 28. Wang S, Zhou M, Liu Z, Liu Z, Gu D, Zang Y, et al. Central focused convolutional neural networks: Developing a data-driven model for lung nodule segmentation. *Med Image Anal* 2017;40:172–83. Available from: <http://dx.doi.org/10.1016/j.media.2017.06.014>
 29. Lee SLA, Kouzani AZ, Hu EJ. Automated detection of lung nodules in computed tomography images: a review. *Machine vision and applications* 2010 ;23(1):151–63. Available from: <http://dx.doi.org/10.1007/s00138-010-0271-2>
 30. Armato SG, McLennan G, Bidaut L, McNitt-Gray MF, Meyer CR, Reeves AP, et al. The Lung Image Database Consortium (LIDC) and Image Database Resource Initiative (IDRI): A Completed Reference Database of Lung Nodules on CT Scans. *Med Phys* 2011 ;38(2):915–31. Available from: <http://dx.doi.org/10.1118/1.3528204>
 31. Ji S, Zhang C, Xu A, Shi Y, Duan Y. 3D Convolutional Neural Networks for Crop Classification with Multi-Temporal Remote Sensing Images. *Rem Sens* 2018;10(2):75. Available from: <http://dx.doi.org/10.3390/rs10010075>
 32. Tajbakhsh N, Suzuki K. Comparing two classes of end-to-end machine-learning models in lung nodule detection and classification: MTANNs vs. CNNs. *Pattern Recogn* 2017;63:476–86. Available from: <http://dx.doi.org/10.1016/j.patcog.2016.09.029>
 33. El-Regaily SA, Salem MAM, Abdel Aziz MH, Roushdy MI. Multi-view Convolutional Neural Network for lung nodule false positive reduction. *Expert Syst Appl* 2020;162:113017. Available from: <http://dx.doi.org/10.1016/j.eswa.2019.113017>
 34. Bengio Y. Deep learning of representations for unsupervised and transfer learning. In Proceedings of ICML workshop on unsupervised and transfer learning 2012 Jun 27 (pp. 17-36).
 35. Goldberg-Zimring D, Achiron A, Miron S, Faibel M, Azhari H. Automated Detection and Characterization of Multiple Sclerosis Lesions in Brain MR Images. *Magn Reson Imag* 1998;16(3):311–8. Available from: [http://dx.doi.org/10.1016/s0730-725x\(97\)00300-7](http://dx.doi.org/10.1016/s0730-725x(97)00300-7)
 36. Kumar D, Wong A, Clausi DA. Lung Nodule Classification Using Deep Features in CT Images. 2015 12th Conf Comput Robot Vis. IEEE; 2015 Jun; Available from: <http://dx.doi.org/10.1109/crv.2015.25>
 37. Setio AAA, Ciompi F, Litjens G, Gerke P, Jacobs C, van Riel SJ, et al. Pulmonary Nodule Detection in CT Images: False Positive Reduction Using Multi-View Convolutional Networks. *IEEE Trans Med Imag* 2016;35(5):1160–9. Available from: <http://dx.doi.org/10.1109/tmi.2016.2536809>
 38. Shen W, Zhou M, Yang F, Yang C, Tian J. Multi-scale Convolutional Neural Networks for Lung Nodule Classification. *Inform Process Med Imag* 2015;588–99. Available from: http://dx.doi.org/10.1007/978-3-319-19992-4_46
 39. Shen W, Zhou M, Yang F, Yu D, Dong D, Yang C, et al. Multi-crop Convolutional Neural Networks for lung nodule malignancy suspiciousness classification.

- Pattern Recogn 2017;61:663–73. Available from: <http://dx.doi.org/10.1016/j.patcog.2016.05.029>
40. Jiang H, Ma H, Qian W, Gao M, Li Y. An Automatic Detection System of Lung Nodule Based on Multigroup Patch-Based Deep Learning Network. *IEEE J Biomed Health* 2018;22(4):1227–37. Available from: <http://dx.doi.org/10.1109/jbhi.2017.2725903>
 41. Gruetzemacher R, Gupta A. Using deep learning for pulmonary nodule detection & diagnosis. *22 Americas Conf Inform Syst*, 2016; San Diego.
 42. Ypsilantis PP, Montana G. Recurrent convolutional networks for pulmonary nodule detection in CT imaging. *arXiv preprint arXiv:1609.09143* 2016; Sep 28.
 43. Alakwaa W, Nassef M, Badr A. Lung Cancer Detection and Classification with 3D Convolutional Neural Network (3D-CNN). *Lung Cancer* 2017;8(8):409.
 44. Wang B, Qi G, Tang S, Zhang L, Deng L, Zhang Y. Automated Pulmonary Nodule Detection: High Sensitivity with Few Candidates. *Lect Notes Comput Sci*. Springer International Publishing; 2018;759–67. Available from: http://dx.doi.org/10.1007/978-3-030-00934-2_84
 45. Xie H, Yang D, Sun N, Chen Z, Zhang Y. Automated pulmonary nodule detection in CT images using deep convolutional neural networks. *Pattern Recogn* 2019;85:109–19. Available from: <http://dx.doi.org/10.1016/j.patcog.2018.07.031>
 46. Silveira M, Nascimento J, Marques J. Automatic segmentation of the lungs using robust level sets. *29th Annu Int Conf IEEE Eng Med Biol Soc. IEEE*; 2007 Aug; Available from: <http://dx.doi.org/10.1109/iembs.2007.4353317>
 47. Hassanpour H, Yousefian H, Zehtabi A. Pixon-Based Image Segmentation. *Image Segmentation*. InTech; 2011 Apr 19; Available from: <http://dx.doi.org/10.5772/15941>

INTRODUCING AN INTELLIGENT FRAMEWORK FOR DETECTION OF SUSPECTED LUNG NODULES

Reza Majidpourkhoei¹, Mehdi Alilou², Kambiz Majidzadeh³, Amin BabazadehSangar⁴

Received: 16 October 2020; Accepted: 18 February, 2021

Abstract

Background & Aims: One of the symptoms of lung cancer, which is one of the deadliest cancers, is the lung nodules. It is very difficult to detect these tiny nodules on CT scans of the lungs with the naked eye. Therefore, intelligent systems or computer-aided detection (CAD) systems can assist a radiologist in detecting, locating, and evaluating the quality of lung nodules. The most important challenge of existing intelligent systems is the balanced improvement of accuracy, sensitivity, specificity, and reduction of false positive rate (FPr), and also the complexity of these systems has reduced the efficiency and speed of execution. Therefore, the purpose of this study was to provide an agile framework and optimize the challenge.

Materials & Methods: One of the new subfields of artificial intelligence is the deep learning and orientation of CNN networks, which has been widely used in the analysis of medical images in recent years. In this research, an innovative network based on CNN networks of LeNet type is proposed to extract image features as well as image classification. The used dataset is a subset of 7072 image pieces derived from the LIDC-IDRI standard dataset. The size of nodules of these images, which are used to train and validate the network, are 1 to 4 mm.

Results: The training and validation processes of this network were performed with a computer device (configurations 2.4GHz Core i5 processor, 8GB of memory, and Intel Graphics 520) in five hours and eleven minutes and the accuracy, sensitivity, and specificity are 91.1%, 85.3% and 92.8%, respectively.

Conclusion: Based on the standard basis of the proposed model and also the use of valid database images to measure the network and compare with previous works, the results establish a good balance between evaluation criteria, and with faster implementation gain the necessary capability for real time applications.

Keywords: Computer aided detection systems, Medical image processing, Lung nodules, Artificial Neural Networks, Deep learning

Address: Department of Computer Engineering, Urmia Branch, Islamic Azad University, Urmia, Iran

Tel: +989142757072

Email: me.alilou@gmail.com

SOURCE: STUD MED SCI 2021: 32(1): 81 ISSN: 2717-008X

¹ Ph.D. candidate of software systems, Department of Computer engineering, Urmia Branch, Islamic Azad University, Urmia, Iran

² Assistant Professor, Department of Computer engineering, Urmia Branch, Islamic Azad University, Urmia, Iran. (Corresponding Author)

³ Assistant Professor, Department of Computer engineering, Urmia Branch, Islamic Azad University, Urmia, Iran

⁴ Assistant Professor, Department of Computer engineering, Urmia Branch, Islamic Azad University, Urmia, Iran