

تشخیص سرطان ریه از تصاویر رادیوگرافی با شبکه عصبی عمیق با یادگیری با نظارت

زهرة حاجی ولی زاده^(۱) سید محمدحسین معطر*^(۲)

(۱) گروه مهندسی کامپیوتر، واحد مشهد، دانشگاه آزاد اسلامی، مشهد، ایران

(۲) گروه مهندسی کامپیوتر، واحد مشهد، دانشگاه آزاد اسلامی، مشهد، ایران*

چکیده

هدف این مقاله ارائه روشی برای تشخیص ندول سرطانی در عکس‌های رادیوگرافی ریه می‌باشد. تصاویر رادیوگرافی عمدتاً دارای کیفیت پایینی هستند و استخراج ویژگی از تصاویر به سهولت ممکن نیست. برای این منظور در این مقاله، چارچوب پیشنهادی، در ابتدا، تصاویر پالایش‌شده تا کیفیت تصاویر از نظر سطح روشنایی و کنتراست بهبود یابد. سپس عملیات مورفولوژی و آستانه‌گذاری جهت قطعه‌بندی نواحی ریه انجام می‌گردد. در مرحله بعد با قراردادن یک قاب ۶۵ در ۶۵ بر روی نواحی مشکوک، آن‌ها را از تصویر جدا می‌کنیم. در مرحله چهارم که مهمترین نوآوری تحقیق است، از یک شبکه باور عمیق به منظور دسته‌بندی و تصمیم‌گیری استفاده شده است. مزیت این شبکه توانایی استخراج ویژگی‌های جدید و طبقه‌بندی آن‌ها به صورت همزمان است. با توجه به آزمایش‌ها بر روی پایگاه داده JSRT، روش پیشنهادی با بدست‌آوردن نرخ حساسیت ۹۷٫۷۸ درصد و صحت ۹۲ درصد، در مقایسه با روش‌های پیشین موفق عمل کرده است.

واژه‌های کلیدی: تصاویر رادیوگرافی، شناسایی ندول ریوی، قطعه‌بندی، طبقه‌بندی شبکه عصبی عمیق

*عهده دار مکاتبات

نشانی: گروه مهندسی کامپیوتر، واحد مشهد، دانشگاه آزاد اسلامی، مشهد، ایران

تلفن: ۰۹۱۵۵۰۳۰۵۴۰ پست الکترونیکی: moattar@mshdiau.ac.ir

رشد فزاینده بیماری‌های ریوی در جوامع صنعتی امروز، نیاز به روش‌های مدرن در تشخیص صحیح و زودهنگام را دو چندان می‌نماید. در بین بیماری‌های ریوی، سرطان ریه همچنان به عنوان یکی از خطرناک‌ترین سرطان‌ها شناخته می‌شود. یک سوم از مرگ و میرهای ناشی از سرطان‌ها به سرطان ریه اختصاص دارد. در حدود ۸۰ درصد بیماران پس از شناسایی این نوع سرطان در بهترین شرایط پنج سال از عمرشان باقی مانده است. آلودگی هوا از دلایل عمده ابتلا به این بیماری می‌باشد. تشخیص زودهنگام بیماری‌های ریوی تأثیر عمده‌ای در احتمال درمان قطعی بیماری خواهد داشت. روش‌های عمده تشخیصی سرطان ریه شامل روش‌های تصویربرداری، رادیوگرافی و سی‌تی‌اسکن، بیوپسی، برونسکوپي و آزمایش مخاط سینه می‌باشد. ندول ریوی یک توده کوچک، گرد و کدر رنگ است که در داخل بافت ریه ایجاد می‌شود. به بیان دیگر ندول‌ها کدورت‌های رادیو گرافیک کروی با قطر کمتر از سی میلی‌متر هستند [1].

تاکنون پژوهش‌های گوناگونی در راستای شناخت و توصیف بیماری‌های ریوی انجام شده است. به علت حذف و تعداد بالای تصاویر رادیوگرافی ریه و همچنین ساختار پیچیده و غیر یکسان آن تشخیص ندول از رگ، زخم و غیره کاری دشوار برای پزشک متخصص است.

سیستم کمک تشخیص کامپیوتری سیستمی است که به پزشک در امر تشخیص بیماری یاری می‌رساند. در این مقاله یک روش تشخیصی جهت شناسایی ندول‌های ریوی با استفاده از طبقه‌بند شبکه عصبی عمیق پیشنهاد خواهد گردید. کاهش خطای تصمیم‌گیری و خطای مثبت و همچنین افزایش صحت و دقت به عنوان مزیت‌های این روش نسبت به روش‌های موجود مطرح شده است.

در زمینه تشخیص سرطان ریه کارهای زیادی انجام شده است. یودشونی و همکارانش [2] برای تشخیص سرطان ریه از روش شبکه عصبی مصنوعی در تصاویر رادیوگرافی

قفسه سینه استفاده کردند. آن‌ها یک روش منحصر به فرد در تشخیص سرطان ریه از روی تصاویر خام اشعه X در پایگاه داده JSRT ارائه کردند. در مرحله ابتدایی از روش‌های مرسوم فرآوری تصاویر برای حذف نویز و جداسازی ساختار ریه از سایر ساختارهای آناتومیک در تصویر اشعه X قفسه سینه استفاده کرده و مناطقی را که دارای مشخصات ندول ریوی بوده‌اند از تصویر جدا کردند. متعاقباً، دسته اول و دوم از مشخصات آماری بافتها را به‌عنوان ورودی برای تعلیم شبکه عصبی بکار گرفته تا مشخص شود آیا منطقه جدا شده در مرحله اول یک ندول است یا خیر.

بوش و همکارانش [3] به کاوش با استفاده از شبکه عصبی کانولوشنال (CNN) با یادگیری انتقال جهت تشخیص غیر ندول، ندول خوش‌خیم و یا ندول‌های بدخیم و به پیدا کردن محل ندول پرداختند. آزمایشات نشان داده، که این مدل پیشنهادی توانایی کمتری در تمایز بین گره خوش‌خیم و بدخیم دارد و همچنین قادر به تعیین محل دقیق ندول نیست.

چیلهام و همکارانش [4] در سامانه پیشنهادی خود از طبقه‌بند k نزدیک‌ترین همسایه استفاده کرده‌اند. این طبقه‌بندی در واقع با جستجو در فضای ویژگی، k نزدیک‌ترین همسایه در میان همه کاندیداهای ندول را شناسایی می‌کند. در نهایت احتمال تشخیص ندول $\frac{n}{k}$ خواهد بود، که n تعداد ندول‌های واقعی در میان k همسایه مجاور است. آن‌ها در مقاله خود بیان کردند که نتایج طبقه‌بند به میزان زیادی مستقل از تعداد همسایه‌ها می‌باشد.

در مقاله [5]، از ویژگی‌های ترکیبی حاصل از تبدیل موجک و ویژگی‌های مورفولوژیکی به عنوان ورودی شبکه عصبی پرسپترون چندلایه استفاده شده‌اند. تعداد نرون‌ها در لایه نخست به تعداد ویژگی‌های ورودی به شبکه وابسته است و خروجی نرون ندول و یا نرمال بودن ناحیه کاندیدا را مشخص می‌کند. نقطه قوت شبکه عصبی این است که بر اساس یک معیار خطای صریح (میانگین مربع خطا)

آموزش می‌بینند؛ بنابراین کارایی این شبکه‌ها مستقیماً قابل مقایسه نمی‌باشند. از جمله نقاط ضعف شبکه‌های عصبی زمان‌بر بودن فاز آموزشی آن است. همچنین مقدار اولیه‌های وزن‌های شبکه تصادفی انتخاب می‌شوند، که در طول فاز یادگیری اصلاح می‌گردند و سطوح جداساز متفاوتی را تولید کنند. بنابراین همیشه برای پیکربندی نهایی و مناسب نیاز است که چندین بار این شبکه را با وزن‌های اولیه متفاوت اجرا و معیارهای کارایی را محاسبه نماییم.

در مقاله [6] برای تشخیص سرطان ریه از شبکه عصبی مصنوعی و خوشه‌بندی فازی بر روی تصاویر سی‌تی‌اسکن استفاده شده است. این سیستم شامل چهار مرحله است: پیش‌پردازش، ارزیابی منطقه موردنظر، استخراج ویژگی و طبقه‌بندی نهایی با استفاده از شبکه عصبی مصنوعی. مرحله پیش‌پردازش متشکل از تکنیک‌های مختلف بهبود تصویر برای بهبود مشاهدات از تومورها در تصاویر سی‌تی‌اسکن است. سپس ناحیه مورد توجه (ROI) بدست آمده و ویژگی‌های آن به عنوان ورودی به فاز دسته‌بندی استخراج شده است.

هادوی و همکاران [7] روشی جهت تشخیص سرطان ریه با استفاده از تصاویر سی‌تی‌اسکن بر اساس اتوماتای یادگیری سلولی را ارائه دادند. تصاویر شامل برخی داده‌های ناخواسته و برخی از ویژگی‌های است که برای پردازش مهم هستند. در این چارچوب از روش‌های پیش‌پردازش مانند فیلتر گابور برای بهبود تصاویر سی‌تی‌اسکن استفاده شده است. تصاویر به‌دست‌آمده از طریق مراحل قبلی برای آموزش به اتوماتای یادگیری سلولی وارد شده و قوانین اتوماتای استخراج می‌گردد.

در مقاله [8] طبقه‌بندی بافت تومور با شبکه‌های بازگشتی با حافظه کوتاه‌مدت (BLSTMs) ارائه شده است. نمونه‌های آموزشی از طریق توموگرافی از نمونه بافت نرم واقعی به‌دست‌آمده و به‌عنوان ورودی به شبکه داده می‌شوند. آزمایش‌های آنها نشان می‌دهد که این دسته‌بند

انتخاب مناسبی برای طبقه‌بندی است. لی و همکاران [9] از ترکیب روش‌های دوبعدی و سه‌بعدی جهت شناسایی ندول ریوی استفاده کرده‌اند. در اثر این ترکیب خطای مثبت کاذب کاهش یافته است.

طاهر و همکارانش [10] برای تشخیص سرطان ریه از شبکه عصبی مصنوعی و روش خوشه‌بندی فازی استفاده کردند. آن‌ها از دو روش شبکه‌های عصبی هاپفیلد و الگوریتم خوشه‌بندی فازی، برای قطعه‌بندی تصاویر رنگی استفاده کردند. آزمایش‌ها حاکی از عملکرد بهتر شبکه‌های عصبی هاپفیلد جهت طبقه‌بندی نسبت به خوشه‌بندی فازی بوده است.

در مقاله [11] از شبکه عصبی کانولوشنال با چنین برش به منظور شناسایی ندولهای ریوی از تصاویر سی‌تی استفاده شده است. تفاوت این مدل با مدل CNN سنتی در استفاده از یک تابع تجمیع خلاقانه بوده است. در [12] تمرکز اصلی روس استخراج ویژگی از تصاویر سی‌تی سه‌بعدی بوده است و برای این منظور از عملگرهای مورفولوژیکی برای نازک سازی تصاویر استفاده شده است. دسته بند مورد استفاده [12] ماشین بردار پشتیبان بوده است. در [13] نیز به منظور استخراج ویژگی از نگاشت محلی خطی تعبیه شده (LLE) استفاده شده است و از ضرایب همبستگی برای تنظیم معیار فاصله در LLE بهره برده شده است.

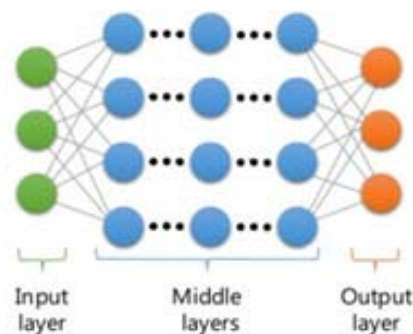
در این مقاله سعی شده است با معرفی یک چارچوب مبتنی بر یادگیری عمیق با ناظر برای اولین بار در این کاربرد، استخراج ویژگی و دسته‌بندی را به صورت همزمان انجام دهیم. البته به منظور بهبود نتایج فازهای پیش‌پردازش نیز در نظر گرفته شده است. ادامه این مقاله به صورت زیر سازماندهی شده است. بخش بعدی به معرفی یادگیری عمیق می‌پردازد. در بخش ۳ چارچوب پیشنهادی معرفی شده است. ارزیابی‌ها و آزمایش‌ها در بخش ۴ مورد بحث قرار گرفته‌اند و در نهایت بخش ۵ به جمع‌بندی و نتیجه‌گیری اختصاص دارد.

۲- یادگیری عمیق

یادگیری عمیق به عنوان یادگیری چند سطحی از بازنمایی مختلف با استفاده از یک ساختار سلسله مراتبی و از روی ویژگی‌های سطح پایین تعریف می‌شود. مهم‌ترین مزیت این شیوه یادگیری، یادگیری بازنمایی به عنوان یک رویکرد استخراج خودکار ویژگی‌ها از ورودی‌های سطح پایین است [14].

۲-۱- شبکه‌های عصبی عمیق

شبکه‌ای که چندین لایه مخفی درونی داشته باشد شبکه عمیق نامیده می‌شود.



شکل ۱- نمایشی از شبکه‌های عصبی عمیق [18]

مدل‌های RBM و Auto-encoder دو مدل معروف به عنوان مدل‌های شبکه عمیق هستند. به مدل‌های شبکه عمیق مبتنی بر RBM شبکه‌های باور عمیق و به مدل‌های مبتنی بر انکدر-دیکدر، مدل کدگذار خودکار پشته‌ای می‌گویند [18].

۲-۲- شبکه‌های باور عمیق

یکی از مدل‌های مولد شبکه باور عمیق است که شامل چندین لایه از متغیرهای پنهان با ماشین‌های بولتزمن محدود شده به عنوان بلوک‌های سازنده می‌باشد. در شبکه باور عمیق در هر لایه یک RBM قرار می‌گیرد که با

یادگیری بدون ناظر آموزش داده می‌شود. پس از یادگیری اولین ماشین، خروجی این لایه (یک توصیف و نمایش جدید از داده‌های خام ورودی) به عنوان ورودی برای لایه دوم (ماشین بولتزمن محدود شده دوم) استفاده می‌شود و این روند ادامه می‌یابد تا تمام لایه‌ها آموزش یابند [14][15]. پس از یادگیری لایه‌ها به صورت بدون ناظر، کل شبکه عصبی با یک الگوریتم با ناظر که معمولاً انتشار روبه عقب است به صورت تفکیک‌پذیر آموزش داده شده و وفق پیدا می‌کند. این مرحله پیش‌پردازش، ناحیه‌ای در فضای وزن‌ها را می‌یابد که اجازه می‌دهد تعمیم توسعه یابد و بیش‌برازش کاهش یابد [16][15][14]. لازم به ذکر است بیش‌برازش زمانی رخ می‌دهد که خطای آموزش کم ولی خطای آزمایش زیاد باشد. از مزایای شبکه باور عمیق در یادگیری ویژگی آن است که می‌تواند ویژگی‌های سطح بالایی از داده‌های آموزشی را استخراج و قدرت تمایز بین دسته‌های مختلف را افزایش دهد [17].

۳- روش پیشنهادی

روش پیشنهادی در این پژوهش دارای چهار مرحله اصلی به صورت زیر است. الف- پیش‌پردازش، ب- قطعه بندی و جدا سازی نواحی ریه، ج- شناسایی نواحی مشکوک، د- استفاده از طبقه‌بند شبکه عصبی عمیق به منظور جداسازی نواحی مشکوک. در ادامه به تفصیل هر یک از قسمت‌ها توضیح داده خواهد شد.

۳-۱- پیش پردازش


پیش‌پردازش تصاویر یکی از مراحل اصلی روش مورد استفاده است. داده‌های خام رادیوگرافی ریه انسان موجود در دیتاست JSRT، عکس‌هایی به اندازه ۲۰۴۸ در ۲۰۴۸ پیکسل هستند، که مقدار هر پیکسل مشخص‌کننده سطح خاکستری در بازه ۰ تا ۴۰۹۵ است. تشخیص ندول از عکس‌های خام حتی برای پزشکان متخصص در این زمینه بسیار دشوار است و نیاز به تجربه و دقت فراوان دارد.

رویه پیش‌پردازش شامل بخش‌های زیر است:

تبدیل داده‌های خام: به دلیل اینکه داده‌ها در فرمت raw است و اطلاعات مخصوصی برای بارگذاری و مشاهده آنها نیاز است، باید توسط برنامه ImageJ خوانده شوند.

تغییر عمق سطح خاکستری و حذف نویز: در ادامه تصاویر با فرمت PNG را در نرم‌افزار Matlab از محدوده ۱۲ بیتی سطح خاکستری به ۸ بیت برای راحتی و استانداردسازی به تصاویر مرسوم ۲۵۶ سطحی تبدیل می‌کنیم و سپس بر روی هر یک فیلتر median را جهت کاهش نویز اعمال می‌کنیم.

بهبود کیفیت تصاویر: به دلیل اینکه تصاویر دارای سطح روشنایی و کنتراست‌های متفاوتی هستند، عمل یکنواخت‌سازی هیستوگرام را بر روی تصاویر انجام می‌دهیم. شکل ۲ فاز پیش‌پردازش را نشان می‌دهد. شکل ۱-۲ تصویر خام با عمق سطح خاکستری ۱۲ بیت، شکل ۲-۲ تصویر تبدیل‌شده به عمق ۸ بیت و پس از اعمال فیلتر median و شکل ۳-۲ تصویر بدست آمده بعد از اعمال یکنواخت‌سازی هیستوگرام را نشان می‌دهد.



شکل ۲- نتیجه پیش‌پردازش بر روی یکی از تصاویر موجود در پایگاه داده

۳-۲- قطعه‌بندی

مرحله دوم روش پیشنهادی، قطعه‌بندی تصاویر برای جداسازی ریه و سپس شناسایی و مشخص کردن نواحی مشکوک در ریه است. برای این کار به ازای هر تصویر یک ماسک به دست می‌آوریم، تا با قرار دادن آن ماسک دو ریه راست و چپ هر داده جدا شوند.

برای تولید ماسک متناظر با هر تصویر ابتدا با استفاده از روش اوتسو، آستانه سطح خاکستری را به دست می‌آوریم.

با استفاده از آستانه به‌دست‌آمده تصویر دودویی متناظر با هر داده را به دست می‌آوریم. لازم به ذکر است که برای دقت بیشتر و به دست آوردن نتیجه بهتر این کارها بر روی آن نواحی از تصاویر که ریه در آنها قرار می‌گیرد اعمال می‌شود. تخمین ناحیه ریه‌ها با میانگین‌گیری تمام تصاویر به‌دست‌آمده است.

بعد از به دست آوردن تصویر دودویی، برای تولید ماسک ریه، بر روی تصویر دودویی مجموعه‌ای از عملگرهای مورفولوژی همچون باز و بسته کردن و همچنین توابع imdilate و imerode برای سیقل دادن و منبسط کردن، اعمال می‌شوند. با اعمال کردن رویه مذکور بر روی تمام داده‌ها، ماسک متناظر با هر تصویر که مشخص‌کننده ناحیه ریه‌ها می‌باشد، به دست می‌آید. بعد از به دست آوردن ماسک در مرحله قبل، به راحتی می‌توان با استفاده از آن ریه‌های موجود در تصویر را از سایر قسمت‌های بدن همچون ستون فقرات، شکم، دست‌ها و سایر موارد نامرتب به مسئله جدا کرد. این کار با ضرب کردن نظیر به نظیر پیکسل‌های هر تصویر در ماسک متناظر آن انجام می‌شود. این حذف کردن نواحی غیر مرتبط با ریه‌ها، سبب ساده‌تر شدن مسئله، کاهش حجم داده‌ها و افزایش کارایی مدل می‌شود.

در شکل ۱-۳ تصویر بهبود یافته در مرحله پیش‌پردازش و در شکل ۲-۳ تصویر دودویی بدست آمده بر اساس آستانه سطح خاکستری بدست آمده از تصویر اول و در شکل ۳-۳ ماسک مشخص‌کننده ریه در تصویر اصلی نشان داده شده است.



شکل ۳- مراحل بدست آوردن ماسک مشخص‌کننده ریه

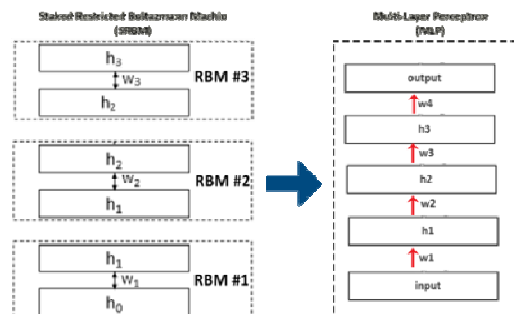
۳-۳- شناسایی نواحی مشکوک

برای استخراج نواحی دارای ندول از تصاویر سرطانی با توجه به اینکه اندازه یک ندول حداکثر ۳۰ میلی‌متر است و مقایسه تصاویر رادیوگرافی نیز مشخص است، می‌توان با قرار دادن یک قاب به اندازه ۶۵ در ۶۵ پیکسل بر روی نواحی مشکوک به ندول آن‌ها را از تصویر جدا کنیم.

برای شناسایی نواحی مشکوک از تصاویر سالم، باید بخش‌هایی از تصویر را مشخص کنیم که بیشترین شباهت ظاهری را به ندول‌های سرطانی دارند. برای این کار از روش‌های پردازش سیگنال استفاده کرده‌ایم تا برای هر یک از ۹۳ تصویر غیر سرطانی ناحیه‌ای را که بیشترین مقدار همبستگی را به ۱۵۴ قطعه ندول مستخرج شده از داده‌های سرطانی دارد، به دست آوریم. پس از آنکه نواحی مشکوک را از تمام تصاویر استخراج کردیم، اندازه آن‌ها را به سبب ۳۳ در ۳۳ تغییر می‌دهیم، تا استفاده کردن از آن‌ها از جهت حافظه و مدت‌زمان موردنیاز برای آموزش مدل، قابل قبول و ممکن باشد.

۳-۴- طبقه بند شبکه عصبی مصنوعی عمیق

در این تحقیق از یک شبکه باور عمیق که یکی از شناخته‌شده‌ترین مدل‌های موجود در یادگیری عمیق است استفاده کرده‌ایم. در بخش دوم گفته شد که این شبکه با قرار دادن تعدادی ماشین بولتزمن محدودشده بر روی هم شکل می‌گیرد.



شکل ۴- شناسایی شبکه‌های باور عمیق پیشنهادی (سمت چپ) و تناظر آن با MLP (سمت راست)

در روش پیشنهادی از سه لایه RBM در ساخت شبکه استفاده شده‌است. تعداد نرون‌های ورودی برای RBM اول باید به اندازه پیکسل‌های هر تصویر باشد. بنابراین RBM اول دارای 1089 نرون (همان اندازه تصویر است 33*33 که به صورت یک بردار یک‌بعدی ذخیره شده‌است) مشاهده‌پذیر است. برای تعداد نرون‌های مخفی RBM اول ۱۲۰۰ نرون در نظر گرفته شده است، که این تعداد متناظر با تعداد نرون‌های مشاهده‌پذیر RBM لایه دوم نیز است. به همین ترتیب برای لایه‌های بعدی از تعداد ۶۰۰ و ۱۰۰ نرون برای ساخت مدل استفاده شده است.

۴- ارزیابی و آزمایش‌ها

در این مقاله، جهت ایجاد قابلیت‌های مقایسه پذیری با دیگر سامانه‌های طراحی‌شده، از پایگاه داده استاندارد موسسه JSRT ژاپن که جهت پردازش تصاویر در موضوعات پزشکی، در اختیار عموم قرار گرفته، استفاده شده است [18]. این پایگاه داده شامل ۲۴۷ عکس رادیوگرافی قفسه سینه است. در این تحقیق تصاویر برای آموزش و آزمون به صورت ۷۰ درصد آموزش و ۳۰ درصد آزمون تقسیم شده‌اند. این درصد از داده برابر است با ۱۷۲ داده برای آموزش و ۷۵ داده برای آزمون روش پیشنهادی می‌باشد.

۴-۱- معیارهای ارزیابی

با توجه به یک ماتریس اغتشاش، برای یک مسئله ۲ حالتی نتایج آزمون را می‌توان در ۴ دسته تقسیم نمود. پیش‌بینی‌شده. مثبت درست (TP) مواردی که ندول سرطانی هستند و به‌عنوان ندول سرطانی طبقه‌بندی می‌شوند را نشان می‌دهد. مثبت نادرست (FP) ناشی از گزارش نادرست موارد غیر ندول به‌عنوان ندول است. منفی درست (TN) مواردی است که ندول غیر سرطانی است و به‌عنوان ندول غیر سرطانی طبقه‌بندی می‌شوند. در نهایت، منفی نادرست (FN) مواردی هستند که واقعاً ندول

هستند، اما به عنوان ندول طبقه‌بندی نمی‌شوند. با استفاده از این مفاهیم طبقه‌بندی‌های درست و نادرست را متمایز می‌کنیم و می‌توانیم مقادیر مختلف برای ارزیابی عملکرد یک طبقه‌بند را تعریف کنیم.

حساسیت نسبت بین نمونه‌های مثبت که درست پیش بینی شده‌اند و تعداد کل از نمونه‌های مثبت است و در ادبیات این مقدار Recall نیز نامیده می‌شود.

(۱)

$$Sensitivity = \frac{TP}{TP + FN}$$

خاصیت بیان نسبت بین نمونه‌های منفی به درستی پیش بینی و تعداد کل نمونه‌های منفی است:

(۲)

$$Specificity = \frac{TN}{TN + FP}$$

با استفاده از نمادهای بالا، صحت به صورت نسبت بین تعدادی از نمونه‌های صحیح طبقه‌بندی شده به تعداد کل نمونه‌ها تعریف می‌شود:

(۳)

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

۴-۲- سناریوی ارزیابی

پارامترهای آماری برای تصاویر بخش‌بندی شده حاوی ۲ ریه محاسبه و به عنوان ورودی به شبکه عصبی داده می‌شود. سپس حساسیت، خاصیت و دقت برای روش پیشنهادی محاسبه می‌شود. یکی از معیارهای ارزیابی هر طبقه‌بند ماتریس اغتشاش است. این ماتریس یک ماتریس مربعی N در N است؛ که N همان تعداد کلاس‌ها در طبقه‌بند است. در این مسئله می‌خواهیم دو کلاس بیمار و غیر بیمار را طبقه‌بندی کنیم. پس N=2 است. در هر کار طبقه‌بندی تعدادی نمونه داریم که قرار است آنها را به طبقه‌بند بدهیم و طبقه‌بند مشخص کند که کدام متعلق به

کلاس بیمار (دارای ندول ریوی) و کدام متعلق به کلاس غیر بیمار (فاقد ندول ریوی) است. تعداد نمونه‌های آزمایشی ۷۵ است؛ که ۴۵ نمونه متعلق به کلاس ندول و ۳۰ نمونه متعلق به کلاس غیر ندول است. ماتریس اغتشاش دسته‌بند به صورت جدول ۱ به دست آمده است.

نتایج به دست آمده نشان می‌دهد که طبقه‌بند شبکه عصبی عمیق قادر به افتراق مؤثر ندول ریه از دیگر سازه‌های ریه می‌باشد. با توجه به ماتریس اغتشاش با حساسیت روش برابر ۹۷٪ و صحت آن ۹۲٪ می‌باشد.

جدول ۱- ماتریس اغتشاش دسته‌بند پیشنهادی (مقادیر به درصد)

	P	N
P	۸۳,۳۳	۱۶,۶۷
N	۲,۲۲	۹۷,۷۸

جدول ۱ نشان می‌دهد که طبقه‌بند ما از ۳۰ نمونه در کلاس NON-Nodule تعداد ۲۵ نمونه را به درستی دسته‌بندی کرده است. همین‌طور از ۴۵ نمونه در کلاس Nodule تعداد ۴۴ نمونه به درستی دسته‌بندی شده‌اند. در نتیجه صحت برابر با ۶۹ نمونه درست تشخیص داده شده از ۷۵ نمونه آزمون است. طبق تعاریف بخش قبل مقدار خطای مثبت و خطای منفی و مثبت درست و منفی درست به صورت جدول ۲ به دست می‌آید.

جدول ۲- معیارهای ارزیابی دسته‌بند پیشنهادی

Non nodule	Nodule	TP	TN	FP	FN	Sen (%)	Spe (%)	Acc (%)
۳۰	۴۵	۴۴	۲۵	۵	۱	۹۷,۷۷	۸۳,۳۳	۹۲

جدول ۲ خلاصه‌ای از نتایج به دست آمده از روش پیشنهادی را نشان می‌دهد. نتایج به دست آمده در طول آزمایش نشان می‌دهد که طبقه‌بند شبکه عصبی عمیق قادر به افتراق مؤثر ندول ریه از دیگر سازه‌های ریه قطع‌بندی شده است. به منظور ایجاد چشم‌اندازی از کیفیت نتایج،

نتایج روش پیشنهادی با روش‌های تشخیص ندول در تصاویر رادیوگرافی دیگر مقایسه شده است. در اینجا مهم این است که یک مقایسه عادلانه از روش‌های ذکر شده، انجام گیرد و همه بر روی پایگاه داده مشترکی انجام شوند. علاوه بر این، برخی از پارامترهای استاندارد، مانند وضوح و بیت در هر پیکسل باید وجود داشته باشد. عامل دیگری که باید مشترک باشد، نسبت آموزش به آزمایش در ارزیابی‌ها است. نتایج گزارش شده در سایر کارهای مشابه مطابق جدول ۳ است.

جدول ۳- مقایسه روش پیشنهادی با کارهای مشابه بر روی

JSRT

دسته بند	Sensitivity (%)	Specificity (%)	Accuracy (%)
Proposed method	97	83	92
Neural Network [5]		86	88 for Feature-based 96 for Pixel-based
convolutional neural network [33]	92		68
FLD [29]			78.1
K نزدیک‌ترین همسایه [12]	91		88

ارزیابی‌ها نشان می‌دهد که حساسیت روش پیشنهادی به خصوص در برخورد با ندول‌های کوچک بسیار مطلوب است. نرخ خطای مثبت برآورد شده برای روش پیشنهادی ۱۶,۶۷٪ است که نسبت به کارهای دیگر کمتر است. در یک مقایسه کیفی، روش پیشنهادی برای تشخیص ندول‌های کوچک که حتی پزشک متخصص هم نمی‌تواند در

عکس‌ها تشخیص دهد، در نظر گرفته شده است. این در حالی است که در کارهای دیگر عمده نگرانی تشخیص ندول‌های بزرگ‌تر است. تشخیص ندول کوچک بسیار پیچیده‌تر از تشخیص‌های بزرگ‌تر است، چرا که آنها سخت‌تر از سازه‌های دیگر ریه جدا می‌شوند. به نظر می‌رسد که این واقعیت دلیل اصلی برتری نتایج در روش پیشنهادی است.

۵- جمع بندی و نتیجه گیری

در این بخش یافته‌ها و نتایج بدست آمده از بخش‌های مختلف سیستم طراحی شده ارائه خواهد شد. در روش پیشنهادی موفق ما شدیم به یک دسترسی سطح بالا از تشخیص ندول به وسیله شبکه عصبی عمیق دست یابیم. برای این منظور از مجموعه‌ای از فرایندهای پردازش تصویر در مرحله ابتدایی برای تشخیص مناطق مشکوک به سرطان ریه از روی مناطق قابل مشاهده در عکس اشعه X استفاده نمودیم. مرحله دوم از شبکه عصبی عمیق برای تشخیص اینکه آیا منطقه مشکوک ندول است یا خیر استفاده شده است. علت استفاده از شبکه عصبی عمیق در مرحله طبقه‌بندی استخراج خودکار ویژگی و طبقه‌بندی به صورت همزمان است.

از پیشنهادهایی که می‌توان به عنوان کارهای آینده نام برد، ارائه یک الگوریتم مؤثر جهت قطعه‌بندی ناحیه ندولار است. چنین الگوریتمی سبب افزایش توانایی سامانه خواهد شد، به طوری که با اعمال آن به نواحی کاندیدا می‌توان شکل فرضی ندول را به دست آورد. هم‌چنین می‌توان مرحله‌ی دیگری به روش پیشنهادی اضافه نمود و آن تشخیص بدخیمی و یا خوش‌خیمی ندول‌ها می‌باشد.

۶- مراجع

- [1] J. Kuruvilla and K. Gunavathi, "Lung cancer classification using neural networks for CT images," *Comput. Methods Programs Biomed.*, vol. 113, no. 1, pp. 202–209, 2014.
- [2] K. G. Udesani, "Statistical Feature-based Neural Network Approach for the Detection of Lung Cancer in Chest X-Ray Images," *Int. J. Image Process.*, vol. 5, no. 4, pp. 425–434, 2011.

- [3] I. Bush, "Lung Nodule Detection and Classification," vol. 20, no. 3, pp. 196–209, 2016.
- [4] A. M. R. Schilham, B. van Ginneken, and M. Loog, "A computer-aided diagnosis system for detection of lung nodules in chest radiographs with an evaluation on a public database.," *Med. Image Anal.*, vol. 10, pp. 247–258, 2006.
- [5] B. Keserci and H. Yoshida, "Computerized detection of pulmonary nodules in chest radiographs based on morphological features and wavelet snake model.," *Med. Image Anal.*, vol. 6, no. 4, pp. 431–47, 2002.
- [6] M. A. Hussain, T. M. Ansari, P. S. Gawas, and N. N. Chowdhury, "Lung Cancer Detection Using Artificial Neural Network & Fuzzy Clustering," *Ijarce*, vol. 4, no. 3, pp. 360–363, 2015.
- [7] N. Hadavi, J. Nordin, and A. Shojaeipour, "Lung Cancer Diagnosis Using CT-Scan Images Based on Cellular Learning Automata," 1960.
- [8] S. Otte, C. Otte, A. Schlaefel, and L. Wittig, "OCT: a scan based lung tumor tissue classification with bidirectional long short term memory networks," Computer Science Department, University of Tuebingen, Germany.
- [9] X. Li and R. Wang, "A new efficient 2D combined with 3D CAD system for solitary pulmonary nodule detection in CT images," *Int. J. Image, Graph. Signal Process.*, vol. 3, no. 4, p. 18, 2011.
- [10] F. Taher and R. Sammouda, "Lung cancer detection by using artificial neural network and fuzzy clustering methods," *GCC Conf. Exhib. (GCC)*, 2011 IEEE, pp. 295–298, 2011.
- [11] W. Shen, et. al. "Multi-crop Convolutional Neural Networks for lung nodule malignancy suspiciousness classification," *Pattern Recognition*, Volume 61, January 2017, pp. 663-673.
- [12] W. Zhang, X. Wang, X. Li and J. Chen, "3D skeletonization feature based computer-aided detection system for pulmonary nodules in CT datasets," *Computers in Biology and Medicine*, Volume 92, 1 January 2018, pp. 64-72.
- [13] P. Wua, K. Xia, H.Yu, "Correlation coefficient based supervised locally linear embedding for pulmonary nodule recognition," *Computer Methods and Programs in Biomedicine*, Volume 136, November 2016, pp. 97-106.
- [14] L. Deng and D. Yu, "Deep Learning: Methods and Applications," *Found. Trends Signal Process.*, vol. 7, no. 3–4, pp. 197–387, 2013.
- [15] B. K. Geoffrey Hinton, Li Deng, Dong Yu, George E. Dahl, Abdel-rahman Mohamed, Navdeep Jaitly, Andrew Senior, Vincent Vanhoucke, Patrick Nguyen, Tara N. Sainath, "Deep neural networks for acoustic modeling in speech recognition: The shared views of four research groups," *Signal Process. Mag.* 29.6, no. November, pp. 114–126, 2012.
- [16] A. R. Mohamed, G. Hinton, and G. Penn, "Understanding how deep belief networks perform acoustic modelling," *ICASSP, IEEE Int. Conf. Acoust. Speech Signal Process. - Proc.*, pp. 4273–4276, 2012.
- [17] N. Jaitly, P. Nguyen, A. Senior, and V. Vanhoucke, "Application of Pretrained Deep Neural Networks to Large Vocabulary Speech Recognition.," *Interspeech*, no. Cd, pp. 2–5, 2012.
- [18] Junji Shiraishi, Kunio Doi, Shigehiko Katsuragawa, Mitate Matsui, Ken'ichi Komatsu, Yoshie Kodera, and Hiroshi Fujita, "Standard Digital Image Database: Chest Lung Nodules and Non-Nodules Created by the Japanese Society of Radiological Technology (JSRT) In cooperation with the Japanese Radiological Society (JRS)," 1997.