

ارائه یک مدل بهبود یافته شبکه عصبی تجمیعی در طبقه‌بندی بیماران سرطان ریه

مرضیه آجرو

گروه مهندسی کامپیوتر، واحد شهرقدس، دانشگاه آزاد اسلامی، تهران، ایران
پست الکترونیکی: marziyeh.ajorloo@gmail.com

راحیل حسینی*

گروه مهندسی کامپیوتر، واحد شهرقدس، دانشگاه آزاد اسلامی، تهران، ایران
پست الکترونیکی: Rahil.hosseini@qodsiau.ac.ir

چکیده

با بهبود ۲/۹٪ نسبت به شبکه عصبی استاندارد و رسیدن به دقت نهایی ۹۴/۳٪ در مقایسه با روش‌های پیشین موفق عمل کرده است.

واژه‌های کلیدی: شبکه عصبی، مدل تجمیعی طبقه بندی، نرخ یادگیری تطبیقی، سرطان ریه

از میان انواع سرطان‌ها، سرطان ریه دارای بالاترین میزان مرگ و میر است. این مشکل ناشی از تشخیص ناحیه گره‌های موجود در بافت نرم ریه در مراحل اولیه می‌باشد. یکی از روش‌های متداول تشخیص ضایعات و گره‌های ریوی استفاده از شبکه عصبی بوده که تا به امروز مورد استفاده محققان زیادی قرار گرفته است. عملکرد شبکه عصبی وابستگی زیادی به معماری شبکه و الگوریتم یادگیری دارد. در این مقاله از یک مدل شبکه عصبی تجمیعی به همراه الگوریتم یادگیری تطبیقی در طبقه‌بندی و تشخیص بیماری سرطان ریه استفاده شده است. هدف اصلی از استفاده از شبکه عصبی تجمیعی، افزایش دقت طبقه‌بندی و بهبود تعمیم‌دهی شبکه عصبی به علت حساسیت در تشخیص بیماری سرطان ریه است. نرخ یادگیری نیز پارامتری مهم در همگرایی شبکه عصبی بوده و بسته به مقدار آن، دقت طبقه‌بندی نیز می‌تواند متفاوت باشد. نتایج این تحقیق نشان می‌دهد که مدل تجمیعی شبکه عصبی با آموزش ۵ شبکه به همراه نرخ یادگیری تطبیقی،

۱- مقدمه

ویژگی اصلی بیماری سرطان ریه از دید بی رویه سلول در بافت‌های ریه می‌باشد. در بیماران مبتلا به سرطان ریه میزان بقا در مقایسه با انواع دیگر سرطان‌ها پایین است، به همین دلیل تشخیص زود هنگام تاثیر عمده‌ای در درمان بیماری خواهد داشت. آلودگی هوا و دخانیات از دلایل عمده ابتلا به این بیماری می‌باشد. روش‌های معمول تشخیص سرطان ریه شامل روش‌های تصویربرداری با تشدید مغناطیسی (MRI)، رادیوگرافی، نمونه‌برداری و اسکن توموگرافی کامپیوتری^۱ می‌باشد. رایج‌ترین روش تصویربرداری توسط رادیولوژیست‌ها

1- Magnetic Resonance Imaging
2-Computed Tomography

سی‌تی‌اسکن می‌باشد که به‌عنوان یکی از بهترین روش‌های تصویربرداری تشخیص داده شده است. در سال‌های اخیر، مرگ و میر ناشی از سرطان ریه با تصاویر سی‌تی‌اسکن حدود ۲۰٪ کاهش یافته است که این آمار توسط موسسه ملی سرطان ایالات متحده گزارش شده است [۲][۱].

فرآیند تشخیص بیماری سرطان ریه، با تصویربرداری سی‌تی‌اسکن به منظور تشخیص رشد غیرطبیعی گره‌ها و ضایعات ریوی آغاز می‌شود. شناسایی گره‌های کوچک (سلول‌های سرطانی) یک فرآیند سخت و پیچیده می‌باشد زیرا ممکن است گره‌ها به عروق یا دیواره‌های قفسه سینه چسبیده باشند. گره‌های ریوی در ریه‌ها رشد نامنظمی دارند که قطر آن تا ۳ میلی‌متر در ناحیه قفسه سینه اندازه‌گیری می‌شود. همچنین، این گره‌ها و سلول‌های سرطانی بر اساس شکل (گرد، شکل نامنظم)، اندازه (کوچک یا بزرگ)، محل (نواحی عروقی یا پلور)، بافت (جامد یا غیر جامد) و طبقه‌بندی می‌شوند.

متخصصان رادیولوژی گره مشکوک را از طریق تصاویر سی‌تی‌اسکن متعدد ارزیابی کرده و تشخیص می‌دهند. بر اساس احتمال بدخیمی که از طریق اطلاعات گره (تراکم، ریخت شناسی^۳، ویژگی‌های بافت) بررسی شده است، تشخیص آن‌ها با یک برنامه درمانی مناسب تأیید می‌شود. کار تشخیص و شناسایی گره‌ها امری نیازمند دقت است. تجربه حرفه‌ای کم، حواس پرتی و خستگی هنگام گرفتن اسکن، ممکن است منجر به سوء تفسیر تصاویر موجود شود. بنابراین، تعدادی از سیستم‌های تشخیص به کمک کامپیوتر (CADx)^۴ برای کمک به رادیولوژیست‌ها در پردازش و تجزیه و تحلیل تصاویر به‌طور خودکار و شناسایی گره‌های ریوی توسعه یافته است. متخصصان رادیولوژی معتقدند که تشخیص گره‌های ریوی در مراحل اولیه از عوامل اصلی میزان بقای بیمار است. برای بهبود کارایی، سیستم‌های CADx باید کم‌هزینه در اجرا و نگهداری باشند و همچنین از امنیت

نرم افزار با سطح بالایی از اتوماسیون برخوردار بوده و باید توانایی تشخیص انواع مختلف گره‌های ریوی را داشته باشند [۳].

به منظور پیاده‌سازی موفق یک سیستم CADx، در نظر داشتن برخی شرایط خاص الزامی است. به‌عنوان مثال پیشگیری از پیشرفت بیماری با تکامل برخی از ریسک فاکتورهای بیماری در ارتباط است. به‌عنوان مثال در برخی بیماری‌های مزمن برخی ریسک فاکتورها شامل ویژگی‌های غیر قابل تغییر مانند سن و جنسیت هستند. در چنین شرایطی سیستم‌های CADx با تمرکز بر ویژگی‌های قابل تغییر فرآیند پیش‌آگاهی را پیچیده و دشوار می‌کنند. هدف اولیه در این سیستم‌ها، تحلیل روابط بین راه‌های پیشگیری یا درمان با وضعیت کنونی بیمار است. امروزه شبکه عصبی در تشخیص انواع بیماری‌ها مورد توجه بسیاری از محققان قرار گرفته است که از میان انواع معماری‌های مختلف آن، پرسپترون چند لایه^۵ (MLP) به‌طور گسترده برای حل مسائل پزشکی مورد استفاده قرار می‌گیرد [۴].

در این تحقیق نیز به دلیل حساسیت مسئله تشخیص بیماری سرطان ریه و نیاز به دقت بالا در طبقه‌بندی داده‌های بیماران، یک روش بهبود یافته مبتنی بر یک سیستم تجمیعی^۶ از شبکه عصبی MLP به همراه الگوریتم یادگیری تطبیقی استفاده شده است. همان‌طور که در بخش‌های بعد نشان داده خواهد شد، استفاده از یک سیستم تجمیعی از چند شبکه عصبی علاوه بر افزایش دقت^۷ طبقه‌بندی نسبت به یک شبکه عصبی سنتی، در تعمیم دهی به داده‌های آزمایشی جدید نیز به خوبی عمل می‌کند. همچنین استفاده از یک نرخ یادگیری تطبیقی علاوه بر افزایش سرعت همگرایی دقت طبقه‌بندی را نیز به مراتب بهبود می‌بخشد. در ادامه جهت ارزیابی مدل پیشنهادی، نتایج حاصل از این سیستم بهبودیافته با تکنیک‌های بیز ساده^۸، ماشین بردار

5- Multilayer Perceptron

6- Ensemble

7-Accuracy

8- Naive Bayes

3-Morphology

4- Computer-Aided Diagnosis

پشتیبان (SVM)^۹، نزدیک‌ترین همسایه (KNN)^{۱۰} و درخت تصمیم^{۱۱} مقایسه شده و نتایج نشان می‌دهد مدل پیشنهادی به مراتب نتایج بهتری در دقت طبقه‌بندی داده‌های بیماران ارائه می‌دهد.

۲- مرور ادبیات

تاکنون پژوهش‌های گوناگونی، در خصوص ارائه روش‌های هوشمند زیادی برای تشخیص و طبقه‌بندی انواع بیماری‌ها و به‌ویژه بیماری سرطان ریه ارائه شده‌اند [۲۴]-[۲۶]. برای مثال، آیوانو و همکاران [۵] در سال ۲۰۰۸، به بررسی امکان استفاده از تحلیل کامپیوتری در تصاویر با تفکیک‌پذیری بالای سی‌تی‌اسکن به منظور طبقه‌بندی شکل گره‌های ریوی پرداختند. آن‌ها از ۱۰۷ تصویر سی‌تی‌اسکن با تفکیک‌پذیری بالا، گره‌های ریوی که از قبل به‌عنوان خوش‌خیم و بدخیم مشخص شده بودند را طبقه‌بندی کردند. آن‌ها با استفاده از تحلیل تفکیک‌کننده برای دو آستانه در ایجاد تمایز بین حالت‌های خوش‌خیم و بدخیم، به حساسیت^{۱۲} ۷۶/۹٪ و تشخیص^{۱۳} ۸۰٪ دست یافتند. Lee و همکاران [۶] در سال ۲۰۱۰، به منظور بهبود روند تشخیص خودکار ضایعات ریوی، یک روش مبتنی بر خوشه‌بندی را پیشنهاد دادند. روش پیشنهادی که ساختاری مبتنی بر خوشه‌بندی جنگل تصادفی هیبرید پیشنهاد می‌دهد، بر روی اسکن‌های ریوی ۳۲ بیمار شامل ۵۷۲۱ تصویری که گره‌های آن‌ها توسط رادیولوژیست مشخص شده بود انجام شده و در نهایت به حساسیت ۹۸٫۳۳٪ و تشخیص ۹۷٫۱۱٪ رسیدند.

در مقاله [۷]، یک روش طبقه‌بندی تصاویر سی‌تی‌اسکن با استفاده از شبکه عصبی پیشنهاد شد. در روش پیشنهادی، گره‌های ریوی با استفاده از عملیات مورفولوژیکی قطعه‌بندی شدند و پارامترهای میانگین و انحراف معیار، به شبکه‌های عصبی رو به جلو و پس‌انتشار خطا وارد شدند.

بهترین نتایج در این تحقیق، شبکه عصبی رو به جلو با الگوریتم پس‌انتشار خطا بود که با این روش به نرخ ۹۳٫۳٪، ۱۰۰٪ و ۹۱٫۴٪ به ترتیب برای دقت، تشخیص و حساسیت رسیدند. در تحقیق دیگری که توسط هولگر و همکاران [۸] انجام شد، سیستم CADx خودکار را برای طبقه‌بندی گره‌های ریوی پیاده‌سازی کردند. این روش در ۳ مجموعه داده مورد ارزیابی قرار گرفت: (۱) گره اسکروتیک از ۵۹ بیمار، (۲) گره لنفاوی از ۱۷۶ بیمار و (۳) گره پولیپ روده بزرگ از ۱۱۸۶ بیمار. همچنین تصاویر جدید ۲ بعدی با استفاده از مقیاس‌بندی و تبدیلات چرخشی مدل‌سازی شدند. شبکه عصبی هم‌آمیختگی^{۱۴} (CNN) با این تصاویر جدید آموزش دیده تا تصاویر را بر اساس احتمال تعلق به هر کدام از کلاس‌های خروجی طبقه‌بندی کنند. در نتیجه این کار برای معیار حساسیت به نرخ ۷۰٪ برای متاستازهای اسکروتیک، ۷۷٪ برای گره‌های لنفاوی و ۷۵٪ برای پولیپ‌های روده بزرگ در هر بیمار رسیدند.

در مقاله حسین و همکاران [۹]، برای تشخیص سرطان ریه از شبکه عصبی مصنوعی و خوشه‌بندی فازی بر روی تصاویر سی‌تی‌اسکن استفاده شده است. سیستم پیشنهادی مبتنی بر چهار مرحله اصلی است: پیش‌پردازش، ارزیابی منطقه مورد نظر (ROI)، استخراج ویژگی و طبقه‌بندی نهایی با استفاده از شبکه عصبی. مرحله پیش‌پردازش متشکل از تکنیک‌های مختلف بهبود تصویر برای بهبود مشاهدات از ضایعات ریوی در تصاویر سی‌تی‌اسکن است. سپس تصویر ROI به‌دست آمده و ویژگی‌های آن به‌عنوان ورودی به مرحله طبقه‌بندی استخراج می‌شوند.

حسین و همکاران [۱۰]، یک سیستم CADx برای تشخیص گره‌های ریوی با استفاده از شبکه عصبی هم‌آمیختگی عمیق بر اساس یادگیری انتقال ایجاد کردند. تصاویر از مجموعه داده‌ای مشتمل بر ۱۴۰۰ نمونه سرطانی و غیرسرطانی تشکیل شده‌اند. تصاویر ورودی در مرحله پیش‌پردازش در قالب مستطیل به ابعاد ۲۲۴×۲۴۴ پیکسلی برش داده شدند. VGG-16 به‌عنوان استخراج‌کننده ویژگی‌ها از تصاویر ROI

9-Support Vector Machine
10-K-nearest neighbor
11- Decision Tree
12- Sensitivity
13- Specificity

14-Convolutional

ورودی استفاده شد و با استفاده از طبقه‌بندی کننده‌های SVM طبقه‌بندی شدند. این سیستم حساسیت ۸۷٫۲٪ را در هر اسکن به نمایش می‌گذارد.

در سال ۲۰۱۸ نیز مقاله‌ای توسط لیندزی و همکاران [۱۱] در مورد یادگیری انتقال نوشته شد. در این مطالعه از تصاویر ۷۹۶ بیمار ریوی مکان‌های گره به صورت دستی از تصاویر سی‌تی‌اسکن با وضوح بالا استخراج شدند. روش کار به این صورت بود که شبکه پیشنهادی با دانش قبلی در مورد آسیب شناسی تایید شده از مقادیر نمونه‌برداری با کمک تصاویر سی‌تی‌اسکن آموزش می‌بیند. استفاده از روش یادگیری انتقال در لایه‌های اولیه شبکه با مجموعه داده‌های ورودی منجر به نرخ AUC ۰/۷ و دقت طبقه‌بندی ۷۱٪ شد.

در مقاله [۱۲] یک روش طبقه‌بندی ضایعات ریوی با استفاده از شبکه عصبی هم‌آمیختی عمیق معرفی شد. این تصاویر از ۶۳۸۹۰ بیمار سرطانی و ۱۷۱۳۴۵ بیمار غیرسرطانی به دست آمده است. اندازه تصاویر مجموعه داده از ۵۱۲×۵۱۲ به ۱۲۰×۱۲۰ پیکسل تغییر اندازه داده شد. لایه هم‌آمیخت اول در این روش از ۵۰ نقشه ویژگی با اندازه فیلتر ۱۱×۱۱ استفاده می‌کند. لایه دوم نیز از ۱۲۰ نقشه ویژگی با اندازه فیلتر ۵×۵ و لایه آخر از ۱۲۰ نقشه ویژگی با اندازه فیلتر ۳×۳ استفاده می‌کند. این روش گره‌های نامزد را به عنوان سرطان و غیرسرطانی طبقه‌بندی می‌کند. در این روش از ۷۵٪ داده‌ها برای آموزش و از ۲۵٪ داده‌ها نیز برای آزمایش شبکه استفاده شده است. به این ترتیب نتایج با دقت ۹۴٫۱٪، حساسیت ۸۷٪ و تشخیص ۹۹٫۱٪ به دست آمد. با کمترین تعداد فیلتر، نقشه ویژگی و مجموعه داده‌های جدید اضافه شده، این روش گره‌های نامزد را به عنوان گره‌های غیرسرطانی، خوش‌خیم و بدخیم بر اساس سطح بدخیمی طبقه‌بندی می‌کند.

تمام روش‌های فوق تا حدودی نتایج امیدوارکننده‌ای را در رابطه با تشخیص بیماری سرطان ریه نشان می‌دهند. به‌طور خلاصه، جدول ۱ تفاوت‌های کلیدی بین روش‌های

تشخیص در مقالات مختلف را نشان می‌دهد. در جدول ۱ تکنیک‌ها و مجموعه داده‌های مورد استفاده برجسته شده و نتایج به دست آمده با سایر آثار مقایسه می‌شود. همان‌طور که پیش‌تر اشاره شد، در تحقیق پیش رو برای بهبود دقت طبقه‌بندی داده‌های بیماران سرطان ریه، یک مدل تجمیعی از شبکه عصبی به همراه نرخ یادگیری تطبیقی ارائه شده است. در ادامه این تحقیق نشان داده خواهد شد که مدل پیشنهادی نتایج بالایی در دقت طبقه‌بندی و تشخیص بیماری سرطان ریه ارائه می‌دهد.

۳- روش تحقیق

اولین گام از طراحی یک سیستم تشخیص پزشکی، به دست آوردن درک درستی از داده‌های ورودی یا همان داده‌های بیماران است. از آنجایی که شرط موفقیت آمیز بودن فرآیند یادگیری، آماده‌سازی داده‌ها پیش از فرآیند مدل‌سازی است [۴]، در ابتدای این بخش به بررسی داده‌ها و آماده‌سازی آن‌ها پرداخته خواهد شد. همان‌طور که در بخش‌های پیشین مطرح شد، مدل پیشنهادی در این تحقیق یک سیستم تجمیعی از چند شبکه عصبی MLP به همراه یک الگوریتم یادگیری تطبیقی است که به‌طور کامل در این بخش شرح داده شده است. همچنین برای سنجش اثربخش بودن این مدل، از تکنیک‌های بیز ساده، ماشین بردار پشتیبان، نزدیک‌ترین همسایه و درخت تصمیم در طبقه‌بندی بیماران سرطان ریه استفاده شده و نتایج استفاده از این روش‌ها با یکدیگر مقایسه شده است.

۳-۱ مجموعه داده

مجموعه داده بیماران سرطان ریه که تحت عنوان LIDC-IDRI [۱۸] در این تحقیق استفاده شده است، با همکاری ۷ مرکز دانشگاهی و ۸ شرکت تصویربرداری پزشکی شامل ۱۰۱۸ نمونه تصویر سی‌تی‌اسکن از ۱۰۱۰ بیمار به دست آمده است. شکل ۱ نمونه‌ای از تصاویر این مجموعه داده را نشان می‌دهد. این تصاویر شامل حاشیه‌نویسی و علامت‌گذاری چهار رادیولوژیست مجرب

بوده که ضایعات و گره‌های ریوی را براساس اندازه آن‌ها در سه دسته «خوش خیم»، «بدخیم» و «غیرسرطانی» برچسب‌گذاری کرده‌اند. این حاشیه‌نویسی شامل تعداد گره‌های هر بیمار به همراه اندازه آن، منشأ اصلی پخش شدن گره و تشخیص نهایی می‌باشد که تمام موارد توسط رادیولوژیست‌ها مشخص شده است.

جدول ۱: مقایسه نتایج به‌دست آمده در طبقه‌بندی و تشخیص سرطان ریه در مقالات مختلف


عنوان مقاله	تعداد نمونه‌ها	روش مورد استفاده	نتایج
طبقه‌بندی تصاویر سی‌تی‌اسکن سرطان ریه با استفاده از شبکه عصبی [۷]	-	بخش بندی تصاویر با استفاده از عملیات مورفولوژی طبقه‌بندی با استفاده از FF-BPNN ¹	دقت ۹۳٫۳٪ حساسیت ۹۱٫۴٪ تشخیص ۱۰۰٪
بهبود تشخیص کامپیوتری با استفاده از شبکه‌های عصبی هم‌آمیختگی و تجمع تصادفی [۸]	۵۹ - ضایعات اسکروتیک ۱۷۶ - غدد لنفاوی ۱۱۸۶ - پولیپ روده بزرگ	تولید تصاویر جدید ۲ بعدی و ۲٫۵ بعدی با استفاده از مقایس بندی و چرخش طبقه‌بندی با استفاده از شبکه عصبی CNN	نرخ حساسیت: ضایعات اسکروتیک ۷۰٪ غدد لنفاوی ۷۷٪ پولیپ روده بزرگ ۷۵٪
شبکه عصبی هم‌آمیختگی چند کاناله برای طبقه‌بندی ضایعات مشکوک به بدخیمی [۱۳]	۲۶۱۸ تصویر	طبقه‌بندی با استفاده از MC-CNN ²	دقت ۸۷٫۱۴٪ حساسیت ۷۷٪ تشخیص ۹۳٪ AUC ۰٫۹۳
تشخیص ضایعات ریوی خوش خیم، سرطان ریه اولیه و سرطان ریه متاستاتیک در اندازه تصاویر مختلف با استفاده از شبکه عصبی هم‌آمیختگی به همراه الگوریتم یادگیری انتقالی [۱۴]	۱۲۳۶ تصویر: ۱۱۱۳ نمونه آموزشی ۱۲۳ نمونه اعتبارسنجی	ارائه یک روش بهینه سازی ابر پارامترها طبقه‌بندی با استفاده از شبکه عصبی VGG16 ³	دقت داده‌های اعتبارسنجی با تعداد نمونه‌های: ۵۶ نمونه: ۶۰٫۷٪ ۱۱۲ نمونه: ۶۴٫۷٪ ۲۲۴ نمونه: ۶۸٪
کاهش نرخ طبقه‌بندی اشتباه در تشخیص ضایعات ریوی در رادیوگرافی قفسه سینه توسط شبکه عصبی هم‌آمیختگی [۱۵]	۹۳ نمونه نرمال ۱۵۴ نمونه مشکوک به سرطان	استفاده از Unsharp mask برای بهبود تصاویر برش تصاویر به قطعات ۲۲۹×۲۲۹ طبقه‌بندی با استفاده از Ensemble CNN با ۵، ۷ و ۹ لایه با داده‌های ورودی متغیر ۱۲×۱۲، ۳۲×۳۲ و ۶۰×۶۰	حساسیت ۹۴٪
تشخیص اتوماتیک ضایعات ریوی در تصاویر سی‌تی‌اسکن با استفاده از شبکه عصبی عمیق هم‌آمیختگی [۱۶]	۱٫۵۰۰٫۷۵۲ گره غیرسرطانی ۳۳۹ گره سرطانی	طبقه‌بندی با استفاده از FR-CNN ⁴	حساسیت ۸۶٫۴۲٪
طبقه‌بندی گره‌های بدخیم ریوی در تصاویر سی‌تی‌اسکن قفسه سینه با استفاده از شبکه عصبی هم‌آمیختگی و یادگیری انتقالی [۱۷]	۷۰۰ گره سرطانی ۷۰۰ گره غیرسرطانی	استفاده از تصاویر قطعه بندی شده ۲۲۴×۲۲۴ استفاده از CNN و الگوریتم یادگیری انتقال استفاده از RestNet جهت استخراج ویژگی طبقه‌بندی با استفاده از SVM	AUC ۰٫۹۳۱
یک روش مبتنی بر شبکه عصبی کانولوشن و یادگیری انتقالی برای کاهش نرخ طبقه‌بندی اشتباه [۱۰]	-	استفاده از عصبی CNN و الگوریتم یادگیری انتقال استخراج ویژگی با استفاده از شبکه عصبی VGG16 طبقه‌بندی با استفاده از SVM	حساسیت ۸۷٫۲٪
روش انتقال یادگیری برای پیش‌بینی ضایعات بدخیم ریوی از داده‌های تصویری: یک مطالعه آزمایشی [۱۱]	۷۹۶ تصویر	استفاده از شبکه عصبی 3D CNN و الگوریتم یادگیری انتقال	دقت ۷۱٪ AUC ۰٫۷۰
یک شبکه عصبی هم‌آمیختگی در تشخیص بیماری سرطان ریه [۱۲]	۱۷۱٫۳۳۵ نمونه غیرسرطانی ۶۳٫۸۹۰ نمونه سرطانی	طبقه‌بندی با استفاده از شبکه عصبی CNN	دقت ۹۴٫۱٪ حساسیت ۸۷٪ تشخیص ۹۹٫۱٪

1- Feed-Forward Back-Propagation Neural Network


2- Multi-Crop Convolutional Neural Network

3- Visual Geometry Group

4- Faster Region Based Convolutional Neural Networks



شکل ۱: نمونه‌هایی از تصاویر مجموعه داده بیماران سرطان ریه [۱۸]




شکل ۲: نمونه‌هایی از گره‌های موجود در تصاویر سی‌تی‌اسکن بیماران؛ گره بدخیم (الف)، گره خوش خیم (ب)، گره غیرسرطانی (ج)

بدخیم، تعداد گره‌های غیرسرطانی، اندازه هر کدام از گره‌ها و مکان هر گره به دست آمد. بر اساس طبقه‌بندی که در جدول ۲ نیز ارائه شده است، گره‌ها با اندازه بزرگ‌تر مساوی ۳ میلی‌متر در دسته گره‌های بدخیم، گره‌های

در مرحله اول، هر رادیولوژیست به‌طور مستقل هر تصویر سی‌تی‌اسکن را بررسی کرده و ضایعات را بر اساس اندازه آن‌ها در سه دسته مذکور طبقه‌بندی کرده است. در شکل ۲ نمونه‌ای از این ضایعات توسط فلش نشان داده شده‌اند. برای مثال تصویر (الف) گرهی را نشان می‌دهد که اندازه آن بزرگ‌تر از ۳ میلی‌متر بوده و توسط هر ۴ رادیولوژیست در دسته گره‌های بدخیم قرار گرفته است. شکل (ب) نیز نمونه‌ای از گره‌های خوش‌خیم را نشان می‌دهد که توسط رادیولوژیست‌ها به دلیل کوچک‌تر بودن از اندازه ۳ میلی‌متر در این دسته قرار گرفته است. در شکل (ج) نیز گره بزرگ‌تر از ۳ میلی‌متر را نشان می‌دهد که به دلیل نداشتن سایر ویژگی‌های بافت‌های سرطانی در دسته گره‌های غیرسرطانی قرار گرفته است. برای تعیین مکان این گره‌ها، رادیولوژیست‌ها از رابط‌های کامپیوتری به منظور ساخت خطوط گره‌ها استفاده کردند. در مرحله بعدی هر رادیولوژیست به منظور رسیدن به یک تصمیم جامع و دقیق، با بررسی علامت‌گذاری‌ها و تشخیص سایر رادیولوژیست‌ها به علامت‌گذاری گره‌ها و حاشیه‌نویسی تصاویر می‌پردازد.

مجموعه تصاویر سی‌تی‌اسکن بیماران با قالب DICOM (تصویربرداری و ارتباطات دیجیتال در پزشکی) که یک استاندارد ذخیره‌سازی و مناسب جهت پردازش تصاویر پزشکی است، در ابعاد 512×512 ذخیره شده‌اند. در ادامه برای هر بیمار، متناسب با حاشیه‌نویسی متخصص رادیولوژی، مکان‌های مورد نظر گره‌ها و ضایعات ریوی در ابعاد 52×52 پیکسل برش داده شدند. بدین ترتیب، ۵۱۸۸ نمونه تصویر ROI از گره‌ها و ضایعات ریوی ۱۰۱۰ بیمار با سطوح بدخیمی ۱ تا ۵ استخراج شدند. گره‌ها در سطوح ۱ و ۲ در دسته خوش‌خیم، گره‌های سطح ۴ و ۵ در دسته گره‌های بدخیم و سایر غیر گره‌های کوچک‌تر از ۳ میلی‌متر نیز در دسته گره‌های غیرسرطانی قرار گرفتند. در نهایت یک مجموعه داده برای ۱۰۱۰ بیمار شامل بردارهای ورودی متشکل از تعداد گره‌های خوش‌خیم، تعداد گره‌های



شکل ۳: نمودار (۱) پراکندگی داده‌ها قبل از نرمال‌سازی و نمودار (۲) پراکندگی داده‌ها بعد از نرمال‌سازی برای هر سه کلاس بدخیم، خوش‌خیم و غیرسرطانی

نرمال‌سازی مقادیر ویژگی‌های موجود در یک مجموعه داده است. با استفاده از نرمال‌سازی که در این تحقیق نیز استفاده شده است، مقادیر ویژگی‌ها با محدوده متفاوت در یک دامنه مشابه به هم قرار می‌گیرد.

در ابتدا، جهت آماده‌سازی داده‌ها باید درک درستی از آن به دست آورد. یکی از روش‌های تحلیل داده‌ها، این است که داده‌ها از لحاظ نرمال بودن مقادیر مورد بررسی قرار گیرند. بدین منظور، پس از تعریف داده‌های ورودی می‌توان با ترسیم نموداری احتمال نرمال بودن توزیع داده‌ها بررسی کرد. همان‌طور که در شکل ۳ نیز نشان داده شده است با دقت در این نمودار و توزیع داده‌ها نسبت به محور صفر می‌توان نتیجه گرفت داده‌های خام در این تحقیق شکل نرمال ندارند. همچنین در شکل ۳ نحوه پراکندگی داده‌ها قبل و بعد از فرآیند نرمال‌سازی داده‌ها نشان داده شده است. برای تبدیل داده‌ها از توزیع نرمال به نرمال استاندارد از نمره استاندارد استفاده می‌شود. تبدیل نمره استاندارد بردار داده‌ها را با میانگین ۰ و انحراف معیار ۱ برمی‌گرداند که نتیجه آن در شکل ۴ نشان داده شده است. فرآیند نرمال‌سازی باعث می‌شود ابعاد مختلف داده توسط الگوریتم بررسی شوند و این روند به یک دقت طبقه‌بندی بهتر نیز کمک می‌کند.


جدول ۲: تشخیص سطح بدخیمی گره بر اساس اندازه آن‌ها

اندازه گره‌ها و ضایعات ریوی	تشخیص
گره‌های کوچک‌تر از ۳ میلی‌متر	گره خوش‌خیم
گره‌های بزرگ‌تر یا مساوی ۳ میلی‌متر	گره بدخیم
غیر گره‌های بزرگ‌تر از ۳ میلی‌متر	گره غیرسرطانی

کوچک‌تر از ۳ میلی‌متر در دسته غده‌های خوش‌خیم و غیر گره‌ها با اندازه بزرگ‌تر از ۳ میلی‌متر و ویژگی‌های ناسازگار با بافت‌های سرطانی، در دسته غیرسرطانی قرار گرفتند. از آنجایی که ضایعات بزرگ‌تر و مساوی با ۳ میلی‌متر احتمال بیشتری از بدخیمی نسبت به ضایعات در دو دسته دیگر را دارند، تمرکز اصلی رادیولوژیست‌ها در طبقه‌بندی بیماران براساس این دسته از غده‌ها بود. در مرحله بعد نیز هر رادیولوژیست نتایج طبقه‌بندی خود را با نتایج سه رادیولوژیست دیگر برای ارائه یک نظر نهایی با اطمینان بالا بررسی کرد.

۳-۲- آماده‌سازی داده‌های ورودی

از آنجایی که الگوریتم‌های یادگیری ماشین توسط داده‌های ورودی آموزش داده می‌شوند، ضروری است با داده‌های مناسب تغذیه شوند. آماده‌سازی هر چه بهتر داده‌های ورودی، نتایج دقیق‌تری را در پی خواهد داشت [۲۲]. یکی از روش‌های آماده‌سازی داده‌های ورودی،



شکل ۴: مقایسه نمودار بررسی نرمال بودن داده‌ها قبل (نمودار ۱) و بعد (نمودار ۲) از نرمال‌سازی داده‌ها

جدول ۳: ضریب همبستگی بین هر جفت متغیر مسئله

ضریب همبستگی		جفت متغیرهای مسئله
۱,۰۰۰۰	۰,۴۹۲۶	۲ و ۱
۰,۴۹۲۶	۱,۰۰۰۰	
۱,۰۰۰۰	۰,۳۲۹۱	۳ و ۱
۰,۳۲۹۱	۱,۰۰۰۰	
۱,۰۰۰۰	۰,۳۸۲۰	۳ و ۲
۰,۳۸۹۲	۱,۰۰۰۰	

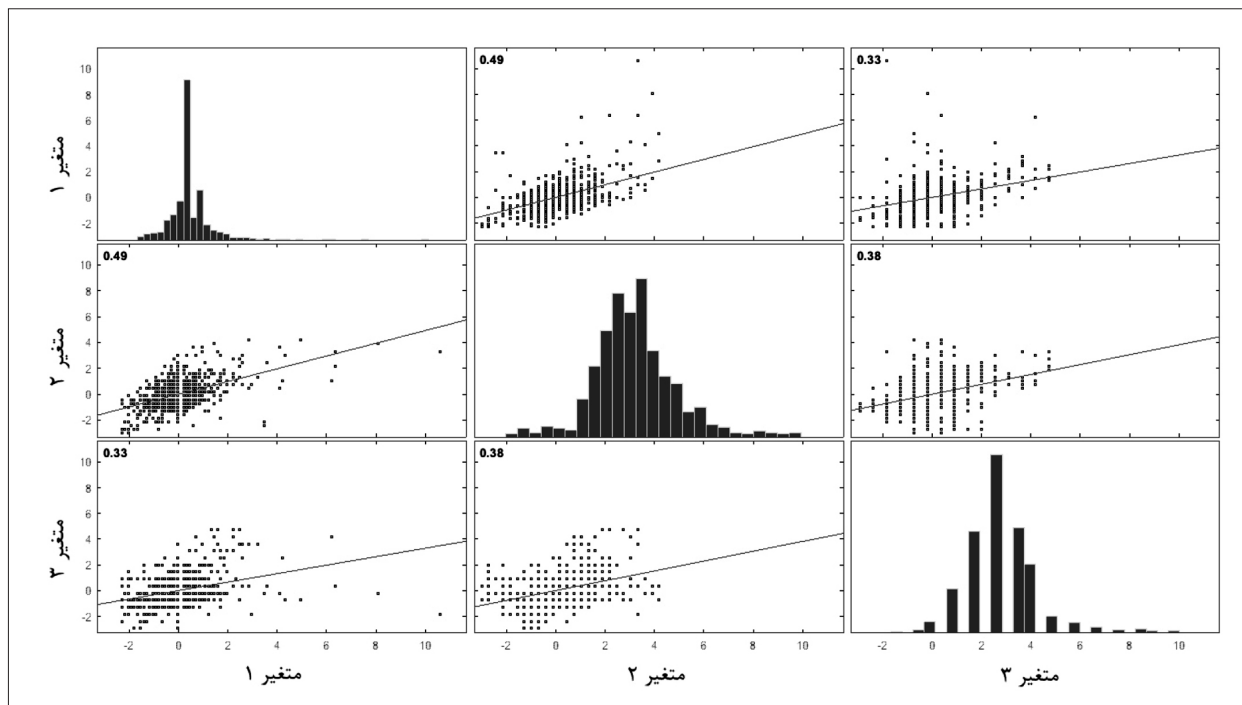
پایه با یکدیگر ترکیب می‌شوند تا یک مدل پیچیده‌تر و قوی‌تر به وجود آید. در این تحقیق یک مدل تجمیعی با استفاده از شبکه عصبی ایجاد شده است. در این روش از مدل‌های پایه یکسان MLP استفاده شده است که به صورت مستقل از یکدیگر آموزش می‌بینند، سپس عملکرد آن‌ها به صورت جداگانه بررسی شده و در نهایت میانگین مجموع عملکرد آن‌ها محاسبه می‌شود. یک نمای ساده از مدل پیشنهادی در شکل ۶ نشان داده شده است. به منظور محاسبه عملکرد شبکه‌های عصبی در این تحقیق، از خطای میانگین مربعات (MSE) به عنوان تابع عملکرد استفاده شده است. تعداد بهینه شبکه‌ها با آزمون و خطا ۵ شبکه تعیین شد. در این شبکه‌ها از ۱۰ نورون در لایه پنهان استفاده شده است. همچنین برای آموزش شبکه از ۸۰٪ داده‌ها و ۲۰٪ باقیمانده جهت آزمایش و ارزیابی شبکه‌ها استفاده شدند.

۳-۳- محاسبه ضریب همبستگی متغیرها

روش‌های مختلفی به منظور اندازه‌گیری ارتباط بین یک جفت متغیر وجود دارد. به عنوان مثال در صورتی که ضریب همبستگی بین دو متغیر مثبت باشد، بدین معنی است که با افزایش یکی آن دیگری نیز افزایش می‌یابد و اگر این ضریب منفی باشد یعنی با کاهش یکی آن دیگری افزایش می‌یابد. بنابراین، هر چه مقدار این دو شاخص بزرگ‌تر باشد، نشان‌دهنده ارتباط بیشتر بین دو متغیر است. یکی از رایج‌ترین شیوه‌های اندازه‌گیری وابستگی بین دو متغیر، ضریب همبستگی پیرسون است [۲۳]. ضریب همبستگی هر جفت ویژگی در جدول ۳ نشان داده شده است. نتیجه استفاده از این ضریب بین ویژگی‌ها نیز در شکل ۵ نشان داده شده است. هیستوگرام متغیرها در امتداد مورب ماتریس ظاهر می‌شوند. با مشاهده این نتایج می‌توان نتیجه گرفت متغیرهای این مجموعه داده به طور متوسط دارای ضریب همبستگی مثبت هستند.

۳-۴- روش پیشنهادی

همان‌طور که در بخش‌های پیشین مطرح شد، مدل پیشنهادی در این تحقیق یک شبکه عصبی تجمیعی متشکل از ۵ شبکه به همراه الگوریتم یادگیری تطبیقی است. در روش یادگیری تجمیعی از ترکیب چندین مدل طبقه‌بندی برای به دست آوردن عملکرد پیش‌بینی بهتر نسبت به تک‌مدل‌ها استفاده می‌شود. در روش‌های یادگیری تجمیعی، چند مدل



شکل ۵: نمودار همبستگی متغیرهای مسئله

ثابت lr_{dec} کاهش می‌یابد. در صورت کوچک‌تر بودن خطا نیز، نرخ یادگیری با ضرب در یک پارامتر ثابت lr_{inc} افزایش می‌یابد.

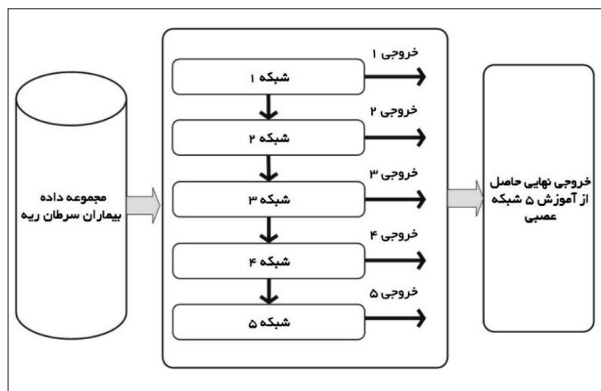
۴- یافته‌ها

همان‌طور که در بخش‌های پیشین مطرح شد، در این تحقیق داده‌های بیماران سرطان ریه با استفاده از یک مدل بهبود یافته از شبکه عصبی تجمیعی طبقه‌بندی شدند. در این بخش اثربخشی این مدل پیشنهادی با استفاده از معیارهای ارزیابی و همچنین در مقایسه با تکنیک‌های طبقه‌بندی بیز ساده، KNN، SVM و درخت تصمیم ارزیابی خواهد شد. شبکه عصبی تجمیعی در این تحقیق به منظور افزایش دقت طبقه‌بندی، بهبود تعمیم دهی شبکه به داده‌های جدید و جلوگیری از بیش‌برازش استفاده شده است. با استفاده از این روش می‌توان شبکه‌ای با نتایج بهینه و مناسب را از میان دیگر شبکه‌ها به دست آورد. در این تحقیق تعداد بهینه شبکه‌ها با آزمون و خطا به ۵ شبکه رسید. در شکل ۷ نمودار افزایش و کاهش دقت طبقه‌بندی

پارامتر نرخ یادگیری نیز در این تحقیق به صورت تطبیقی انتخاب شده است. دلیل استفاده از نرخ یادگیری تطبیقی این است که اگر مقدار آن بزرگ انتخاب شود ممکن است پاسخ بهینه نادیده گرفته شود و شبکه هرگز همگرا نشود، در صورتی هم که مقدار آن کوچک انتخاب شود علاوه بر طولانی شدن زمان همگرایی ممکن است در نقاط مینیمم محلی همگرا شود. در این روش اگر خطای جدید نسبت به خطای قدیمی کمتر شود، مقدار نرخ یادگیری به اندازه پارامتری ثابت افزایش می‌یابد. در مقابل، اگر خطای جدید بیشتر از خطای قبلی باشد، مقدار نرخ یادگیری توسط پارامتری ثابت کاهش می‌یابد [۲۷]، [۸]. این فرآیند به صورت خلاصه در رابطه ۱ نشان داده شده است.

$$a(t+1) = \begin{cases} a(t) \times lr_{dec} & \text{if } e(t) > e(t-1) \\ a(t) \times lr_{inc} & \text{if } e(t) < e(t-1) \end{cases} \quad (1)$$

در ابتدا، خطای اولیه شبکه محاسبه می‌گردد. وزن‌ها در هر گام از شبکه استفاده از نرخ یادگیری فعلی $a(t)$ محاسبه شده و سپس خطاهای جدید محاسبه می‌گردند. در صورتی که خطای جدید $e(t)$ بیشتر از خطای قدیمی $e(t-1)$ باشد، نرخ یادگیری با ضرب در یک پارامتر



شکل ۶: یک طرح ساده از شبکه عصبی تجمیعی پیشنهادی

جدول ۴: نتایج دقت طبقه‌بندی نسبت به تعداد شبکه‌ها

تعداد شبکه‌ها	دقت مجموعه آموزشی	دقت مجموعه آزمایشی	دقت کل
1	%93.9	%93.8	%93.7
2	%94	%91.4	%93.9
3	%94	%93.8	%94
4	%94.3	%93.8	%94.1
5	%95.1	%94.3	%94.2

جدول ۵: نتایج دقت طبقه‌بندی برای دو روش نرخ یادگیری تطبیقی و ثابت

روش مورد نظر	دقت مجموعه آموزشی	دقت مجموعه آزمایشی	دقت کل
شبكة عصبی استاندارد	%92.2	%87.7	%91.3
روش پیشنهادی	%95.1	%94.3	%94.2

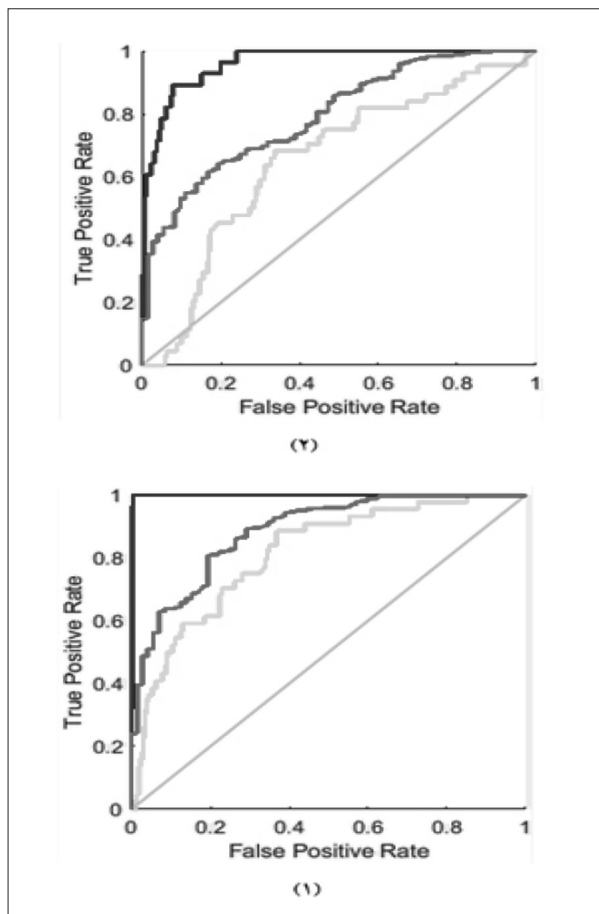
آزمایشی ضعیف عمل کرده اند. همان‌طور که از نتایج این جدول مشخص است، استفاده از سیستم شبکه عصبی تجمیعی و همچنین نرخ یادگیری تطبیقی، با افزایش دقت طبقه‌بندی برای مجموعه آزمایشی نشان می‌دهد که در طبقه‌بندی داده‌های جدید و مشاهده نشده، تا حد زیادی موفق عمل کرده است. همان‌طور که از نتایج مشخص است، مدل بیز ساده بالاترین دقت طبقه‌بندی مجموعه آموزشی را داشته ولی از آنجایی که دقت پایینی با نرخ ۴۹٫۵٪ در طبقه‌بندی مجموعه به دست آورده، مدلی با تعمیم دهی ضعیف در مواجهه با داده‌های جدید است.

در مدل KNN نیز روش‌های مختلف محاسبه فاصله انتخاب شدند و بالاترین دقت طبقه‌بندی مجموعه داده آزمایشی در این مدل استفاده از فاصله اقلیدوسی با

و خطای میانگین مربعات در این مجموعه ۵ عددی نشان داده شده است. از این نمودار قابل مشاهده است که دقت طبقه‌بندی (خط طوسی) از شبکه‌های آغازین تا شبکه‌های انتهایی رو به افزایش و به تبع آن خطای شبکه (خط آبی) رو به کاهش است. با این حال در این روش، دقت طبقه‌بندی پس از تعداد خاصی از شبکه‌ها بهبود پیدا نمی‌کند. جدول ۴ دقت طبقه‌بندی برای مجموعه داده آموزشی و آزمایشی تمام شبکه‌ها را نشان می‌دهد که همان‌طور که از نتایج پیداست بهترین نتایج دقت طبقه‌بندی مربوط به مدل ۵ شبکه‌ای بوده که دقت طبقه‌بندی برای داده‌های آموزشی ۹۵٫۱٪ و برای داده‌های آزمایشی ۹۴٫۳٪ و دقت کلی ۹۴٫۲٪ بوده است.

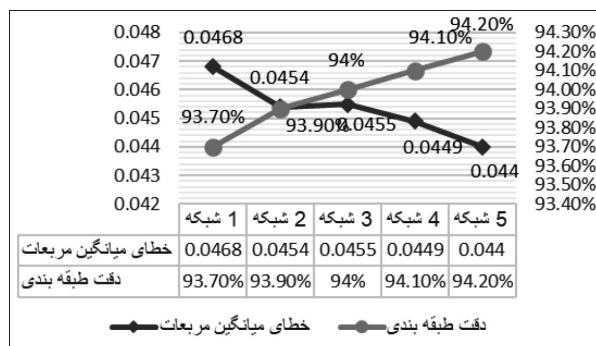
در جدول ۵ نتایج استفاده از مدل بهبود یافته با استفاده از سیستم تجمیعی شبکه عصبی و یک نرخ یادگیری تطبیقی در مقایسه با یک شبکه عصبی به همراه نرخ یادگیری ثابت ارائه شده است. با توجه به جدول ۵ نتایج دقت طبقه‌بندی روش استاندارد برای داده‌های آموزشی، داده‌های آزمایشی و دقت کلی به ترتیب ۹۲٫۲٪، ۸۷٫۷٪ و ۹۱٫۳٪ و با استفاده از روش پیشنهادی به ترتیب ۹۵٫۱٪، ۹۴٫۳٪ و ۹۴٫۲٪ بوده است. به‌طور کلی دقت روش پیشنهادی حدود ۳ درصد بیشتر از شبکه عصبی استاندارد است. ماتریس درهم ریختگی برای این دو روش در شکل ۸ نشان داده شده است. در ادامه منحنی ROC برای هر دو روش تطبیقی و استاندارد در شکل ۹ ارائه شده است. همان‌طور که از این نتایج مشخص است، استفاده از نرخ یادگیری تطبیقی تاثیر بالایی در بهبود عملکرد شبکه عصبی داشته است.

یکی از دلایل استفاده از شبکه عصبی تجمیعی و نرخ یادگیری تطبیقی در این تحقیق، افزایش تعمیم دهی شبکه عصبی در مواجهه با داده‌های جدید است. در جدول ۶، نتایج دقت طبقه‌بندی برای روش‌های بیز ساده SVM، KNN، درخت تصمیم و شبکه عصبی استاندارد ارائه شده است. برخی از این روش‌ها اگر چه دقت بالایی در طبقه‌بندی داده‌های آموزشی داشته، ولی در مواجهه با مجموعه



شکل ۹: مقایسه منحنی ROC برای دو روش پیشنهادی بهبود یافته (۱) و روش استاندارد (۲) (منحنی آبی نمایانگر کلاس خوش خیم، منحنی قرمز نمایانگر کلاس بدخیم و منحنی سبز نمایانگر گره‌های غیرسرطانی است)

همراه الگوریتم یادگیری تطبیقی در طبقه‌بندی و تشخیص بیماری سرطان ریه استفاده شد که هدف اصلی آن، افزایش دقت طبقه‌بندی و بهبود تعمیم‌دهی شبکه عصبی به علت حساسیت در تشخیص بیماری سرطان ریه می‌باشد. همان‌طور که در نتایج این تحقیق نشان داده شد، مدل تجمیعی شبکه عصبی با آموزش ۵ شبکه به همراه نرخ یادگیری تطبیقی، با بهبود ۲/۹٪ نسبت به شبکه عصبی استاندارد و رسیدن به دقت نهایی ۹۴/۳٪ در مقایسه با روش‌های پیشین در تشخیص گره‌ها و ضایعات ریوی موجود در تصاویر سی‌تی‌اسکن مجموعه داده LIDC-IDRI موفق عمل کرده است. به‌عنوان مثال در مقاله ای که در سال ۲۰۱۷ توسط Sun و همکاران [۱۹] ارائه شد، یک معماری انتها-به-انتها برای استخراج خودکار ویژگی‌ها از تصاویر سی‌تی‌اسکن برای تشخیص سرطان ریه طراحی شد. گره‌ها



شکل ۷: نمودار افزایش و کاهش دقت طبقه‌بندی و خطا نسبت به تعداد شبکه‌های انتخابی

28 3.4%	0 0.0%	3 0.4%	90.3% 9.7%
0 0.0%	0 0.0%	0 0.0%	NaN% NaN%
0 0.0%	44 5.4%	739 90.8%	94.4% 5.6%
100% 0.0%	0.0% 100%	99.6% 0.4%	94.2% 5.8%

(۱)

1 0.1%	0 0.0%	0 0.0%	100% 0.0%
0 0.0%	0 0.0%	0 0.0%	NaN% NaN%
27 3.3%	44 5.4%	742 91.2%	91.3% 8.7%
3.6% 96.4%	0.0% 100%	100% 0.0%	91.3% 8.7%


(۲)

شکل ۸: مقایسه ماتریس درهم ریختگی برای دو روش پیشنهادی بهبود یافته (۱) و روش استاندارد (۲)

کسب دقت ۵۰٪ می‌باشد. در مدل SVM با استفاده از کرنل تابع پایه شعاعی نتایج بهتری در طبقه‌بندی مجموعه داده آزمایشی نسبت به روش‌های بیز ساده، KNN و درخت تصمیم به دست آورده است. بهترین نتایج در این تحقیق مربوط به استفاده از روش پیشنهادی بهبودیافته با استفاده از ۵ شبکه عصبی بوده که نتایج دقت طبقه‌بندی مجموعه آموزشی ۹۵٫۱٪ و مجموعه آموزشی ۹۴٫۳٪ به دست آمد. نمودار این نتایج در شکل ۱۰ قابل مشاهده است.

۵- تحلیل و مقایسه نتایج

در این تحقیق از یک مدل شبکه عصبی تجمیعی به



شکل ۱۰: مقایسه دقت طبقه‌بندی مجموعه آزمایشی روش پیشنهادی با سایر روش‌های طبقه‌بندی

پشتیبانی تصمیم‌گیری پزشکی با استفاده از اینترنت اشیا و شبکه‌های حسگر ناحیه بدن یا MBAN^{۱۰} ارائه کردند. مدل پیشنهادی تحت عنوان DFCNET، بر اساس شبکه عصبی عمیق هم‌آمیختگی بوده که برای طبقه‌بندی هر گره ریوی شناسایی شده به چهار مرحله سرطان ریه استفاده شد. نتایج این تحقیق نشان داد که عملکرد مدل پیشنهادی بر روی مجموعه داده LIDC-IDRI از نظر دقت کلی DFCNET به ۸۴/۵۸٪ رسید.

سورش و همکاران [۳] نیز طی تحقیقی در سال ۲۰۲۰ به شناسایی ضایعات ریوی از تصاویر سی‌تی‌اسکن ۱۰۱۰ بیمار سرطان ریه با استفاده از شبکه عصبی هم‌آمیختگی پرداختند. آن‌ها به منظور کاهش حجم پردازش از تصاویر ROI ۲×۲×۵۲ پیکسل از ضایعات ریوی به جای تصاویر اصلی سی‌تی‌اسکن ریه استفاده کردند که در نتیجه این کار ۵۱۸۸ تصویر ROI به دست آمد. آن‌ها همچنین برای رسیدگی به چالش کمبود داده در یادگیری عمیق از شبکه عصبی GAN^{۱۶} برای مدل‌سازی و باز تولید تصاویر سی‌تی‌اسکن استفاده کردند. بدین ترتیب ۵۰۰۰ تصویر ROI جدید برای آموزش شبکه به دست آمد. در نتیجه پیاده‌سازی این مدل آن‌ها به نرخ ۹۳/۹٪، ۹۳٪ و ۹۳/۴٪ به ترتیب برای معیارهای دقت، تشخیص و حساسیت رسیدند.

۶- نتیجه‌گیری

این تحقیق با هدف افزایش دقت طبقه‌بندی داده‌های

15- Medical Body Area Network
16-19 Generative Adversarial Networks

جدول ۶: مقایسه نتایج دقت طبقه‌بندی داده‌های بیماران سرطان ریه با استفاده از روش‌های مختلف طبقه‌بندی

مدل طبقه‌بندی	دقت مجموعه داده آموزشی	دقت مجموعه داده آزمایشی
درخت تصمیم	92%	47.5%
بیز ساده	100%	49.5%
فاصله اقلیدوسی (KNN)	83%	50%
SVM (کرنل خطی)	96.6%	76.6%
SVM (کرنل چند جمله ای)	96.6%	80%
SVM (کرنل تابع پایه شعاعی)	96.6%	86.6%
شبکه عصبی استاندارد	92.2%	87.7%
روش پیشنهادی	95.1%	94.3%

با اعمال چرخش و برش‌هایی که توسط چهار متخصص رادیولوژی انجام شد، تفکیک و مجدداً نمونه‌برداری شدند. در این مقاله، سه الگوریتم یادگیری عمیق مبتنی بر تصاویر ROI چند کاناله طراحی شد: ۱- شبکه عصبی هم‌آمیختگی، ۲- شبکه‌های باور عمیق، ۳- شبکه‌های خود رمزگذار. این روش به دقت ۸۹،۹٪ و برای معیار AUC به نرخ ۰/۸۸۹ برای شبکه عصبی هم‌آمیختگی، ۰/۸۸۴ برای شبکه‌های باور عمیق، ۰/۸۵۲ برای شبکه‌های خود رمزگذار و ۰/۸۴۸ برای CADx سنتی دست یافت.

در مقاله دیگری که در سال ۲۰۱۸ توسط de Carvalho و همکاران [۲۰] نوشته شد، یک رویکرد طبقه‌بندی و استخراج ویژگی با استفاده از شبکه عصبی هم‌آمیختگی جهت تمایز الگوهای نمونه گره‌های خوش‌خیم و بدخیم با استفاده از شاخص تنوع فیلوژنتیک بر روی تصاویر سی‌تی‌اسکن مجموعه داده LIDC-IDRI مطرح کردند. تصاویر ROI استخراج شده شامل ۱۴۰۵ گره (۳۹۴ گره بدخیم و ۱۰۱۱ گره خوش‌خیم) با دقت ۹۲/۶۳٪، تشخیص ۹۳/۴۷٪، حساسیت ۹۰/۷٪ و AUC ۰/۹۳۴ به دست آمد.

در سال ۲۰۱۸ نیز Masood و همکاران [۲۱] یک سیستم

جدول ۷: مقایسه نتایج دقت طبقه‌بندی در مقالات مختلف بر روی مجموعه داده LIDC-IDRI

عنوان مقاله	سال چاپ	مجموعه داده	روش مورد استفاده	نرخ دقت طبقه‌بندی
سیستم پشتیبانی تصمیم‌گیری در تشخیص سرطان ریه با استفاده از طبقه‌بندی تصاویر سی‌تی‌اسکن [۲۱]	۲۰۱۸	LIDC-IDRI	طبقه‌بندی با استفاده از DF-CNN ^۱	٪۸۴/۵۸
یادگیری ویژگی‌های خودکار با استفاده از تصاویر ROI چند کاناله بر اساس الگوریتم‌های ساختاری عمیق برای تشخیص سرطان ریه [۱۹]	۲۰۱۷	LIDC-IDRI	استفاده از تصاویر ROI چند کاناله مبتنی بر یادگیری عمیق طبقه‌بندی با استفاده از CNN, DBN ^۲ , SDAE	٪۸۹/۹
طبقه‌بندی الگوهای خوش‌خیم و بدخیم سرطان ریه بر اساس تصاویر سی‌تی‌اسکن با استفاده از شاخص تنوع فیلوژنتیک مبتنی بر شبکه عصبی هم‌آمیختگی [۲۰]	۲۰۱۸	LIDC-IDRI	یک توپولوژی مبتنی بر بررسی تنوع ژنتیکی و روابط فیلوژنتیکی طبقه‌بندی با استفاده از CNN	٪۹۲/۶۳
یادگیری ویژگی مبتنی بر تصاویر ROI ضایعات ریوی به منظور بهبود نرخ طبقه‌بندی صحیح با استفاده از شبکه عصبی هم‌آمیختگی [۳]	۲۰۲۰	LIDC-IDRI	استخراج ۵۱۸۸ تصویر ROI از ۱۰۱۸ تصویر سی‌تی‌اسکن تولید ۵۰۰۰ تصویر جدید با استفاده از شبکه عصبی GAN استفاده از عصبی CNN و الگوریتم یادگیری انتقال	٪۹۳/۹
روش ارائه شده در مقاله پیش رو		LIDC-IDRI	استفاده از یک مدل تجمیعی شبکه عصبی (یک مدل ۵ شبکه‌ای) به همراه الگوریتم یادگیری تطبیقی	٪۹۴/۳

1- Deep Fully Convolutional Neural Network

2- Deep Belief Network

مراجع

- [۱] مهدی میری، K. تشخیص ندول‌های ریوی با استفاده از تصاویر سی‌تی‌اسکن به کمک شبکه عصبی، p. ۱۵، [Online]، و مین کنفرانس بین‌المللی پژوهش در علوم و تکنولوژی، کازرون، ایران، ۱۳۹۶.
- [۲] از. حاجی‌ولی‌زاده and م. معطر، «تشخیص سرطان ریه از تصاویر رادیوگرافی با شبکه عصبی عمیق با یادگیری بانظارت»، مجله فناوری اطلاعات در طراحی مهندسی، شماره ششم، سال دهم، ۱۳۹۶.
- [3] S. Suresh and S. Mohan, "ROI-based feature learning for efficient true positive prediction using convolutional neural network for lung cancer diagnosis," *Neural Comput. Appl.*, vol. 32, no. 20, pp. 15989–16009, 2020.
- [۴] م. آجرلو and ف. صفارا، «ارائه یک شبکه عصبی بهبود یافته با استفاده از الگوریتم یادگیری تطبیقی در دسته‌بندی بیماران تیروئید»، دانشگاه آزاد اسلامی واحد دماوند، ۱۳۹۶.
- [5] S. Iwano, T. Nakamura, Y. Kamioka, M. Ikeda, and T. Ishigaki, "Computer-aided differentiation of malignant from benign solitary pulmonary nodules imaged by high-resolution CT," *Comput. Med. Imaging Graph.*, vol. 32, no. 5, pp. 416–422, 2008.
- [6] S. L. A. Lee, A. Z. Kouzani, and E. J. Hu, "Random forest based lung nodule classification aided by clustering," *Comput. Med. Imaging Graph.*, vol. 34, no. 7, pp. 535–542, 2010.
- [7] 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, doi: 10.1016/j.cmpb.2013.10.011.
- [8] H. R. Roth et al., "Improving computer-aided detec-

بیماران سرطان ریه از طریق بهبود در عملکرد شبکه عصبی انجام گرفته است. روشی که برای تحقق این هدف در نظر گرفته شد، استفاده از یک سیستم تجمیعی از شبکه عصبی پرسپترون چند لایه به همراه الگوریتم یادگیری تطبیقی بوده است. روش پیشنهادی با بهبود قدرت تعمیم‌دهی شبکه عصبی از طریق افزایش تعداد شبکه‌ها با یک معماری همگون و یکسان، نتایج دقت طبقه‌بندی برای مجموعه داده آزمایشی را در مقایسه با سایر روش‌های طبقه‌بندی که پیش‌تر مطرح شدند، به‌طور قابل ملاحظه‌ای افزایش داده است. همان‌طور که در نتایج نشان داده شد، روش پیشنهادی با استفاده از ۵ شبکه عصبی و نرخ یادگیری تطبیقی که نسبت به سطح خطا واکنش نشان می‌دهد، نتایج دقت طبقه‌بندی را با بهبود ۲/۹٪ نسبت به شبکه عصبی استاندارد به دقت نهایی ۹۴/۳٪ رسانده است.

- [22] S. C. Nayak, B. B. Misra, and H. S. Behera, "Impact of Data Normalization on Stock Index Forecasting," *Int. J. Comput. Inf. Syst. Ind. Manag. Appl.*, vol. 6, no. 2014, pp. 257–269, 2014.
- [۲۳] آ. ریبد، "ضریب همبستگی (Correlation Coefficients) و شیوه محاسبه آن‌ها،" فرادرس، 1398. <https://blog.faradars.org/correlation-coefficients/>.
- [24] Akhoondi, R. and Hosseini, R., 2016. A fuzzy expert system for prognosis of the risk of development of heart disease. *Journal of Advances in Computer Research*, 7(2), pp. 101–114.
- [25] Hosseini, R., Ellis, T., Mazinani, M. and Dehmeshki, J., 2011, September. A genetic fuzzy approach for rule extraction for rule-based classification with application to medical diagnosis. In *European Conference on Machine Learning and Principles and Practice of Knowledge Discovery in Databases (ECML PKDD)* (pp. 05-09).
- [26] Hosseini, R., Dehmeshki, J., Barman, S., Mazinani, M., Jouannic, A.M. and Qanadli, S., 2010, February. A fuzzy logic system for classification of the lung nodule in digital images in computer aided detection. In *IEEE 2010 Fourth International Conference on Digital Society* (pp. 255-259).
- [27] MathWorks, "Gradient Descent with Adaptive Learning Rate Backpropagation," 2015. <https://www.mathworks.com/help/nnet/ref/traingda.html>.
- tion using convolutional neural networks and random view aggregation," *IEEE Trans. Med. Imaging*, vol. 35, no. 5, pp. 1170–1181, 2015.
- [9] M. Hussain, T. Ansari, P. Gawas, and N. Chowdhury, "Lung Cancer Detection Using Artificial Neural Network & Fuzzy Clustering," *IJARCCCE*, vol. 4, pp. 360–363, 2015, doi: 10.17148/IJARCCCE.2015.4386.
- [10] Z. Shi et al., "A deep CNN based transfer learning method for false positive reduction," *Multimed. Tools Appl.*, vol. 78, no. 1, pp. 1017–1033, 2019.
- [11] W. Lindsay, J. Wang, N. Sachs, E. Barbosa, and J. Gee, "Transfer learning approach to predict biopsy-confirmed malignancy of lung nodules from imaging data: A pilot study," in *Image Analysis for Moving Organ, Breast, and Thoracic Images*, Springer, 2018, pp. 295–301.
- [12] M. F. Serj, B. Lavi, G. Hoff, and D. P. Valls, "A deep convolutional neural network for lung cancer diagnostic," *arXiv Prepr. arXiv1804.08170*, 2018.
- [13] W. Shen et al., "Multi-crop convolutional neural networks for lung nodule malignancy suspiciousness classification," *Pattern Recognit.*, vol. 61, pp. 663–673, 2017.
- [14] M. Nishio et al., "Computer-aided diagnosis of lung nodule classification between benign nodule, primary lung cancer, and metastatic lung cancer at different image size using deep convolutional neural network with transfer learning," *PLoS One*, vol. 13, no. 7, p. e0200721, 2018.
- [15] C. Li, G. Zhu, X. Wu, and Y. Wang, "False-positive reduction on lung nodules detection in chest radiographs by ensemble of convolutional neural networks," *IEEE Access*, vol. 6, pp. 16060–16067, 2018.
- [16] H. Xie, D. Yang, N. Sun, Z. Chen, and Y. Zhang, "Automated pulmonary nodule detection in CT images using deep convolutional neural networks," *Pattern Recognit.*, vol. 85, pp. 109–119, 2019.
- [17] R. V. M. da Nobrega, P. P. Rebouças Filho, M. B. Rodrigues, S. P. P. da Silva, C. M. J. M. D. Junior, and V. H. C. de Albuquerque, "Lung nodule malignancy classification in chest computed tomography images using transfer learning and convolutional neural networks," *Neural Comput. Appl.*, pp. 1–18, 2018.
- [18] B. Vendt, "LIDC-IDRI," The Cancer Imaging Archive (TCIA) Public Access, 2021. <https://wiki.cancerimagingarchive.net/display/Public/LIDC-IDRI>.
- [19] W. Sun, B. Zheng, and W. Qian, "Automatic feature learning using multichannel ROI based on deep structured algorithms for computerized lung cancer diagnosis," *Comput. Biol. Med.*, vol. 89, pp. 530–539, 2017.
- [20] A. O. de Carvalho Filho, A. C. Silva, A. C. de Paiva, R. A. Nunes, and M. Gattass, "Classification of patterns of benignity and malignancy based on CT using topology-based phylogenetic diversity index and convolutional neural network," *Pattern Recognit.*, vol. 81, pp. 200–212, 2018.
- [21] A. Masood et al., "Computer-assisted decision support system in pulmonary cancer detection and stage classification on CT images," *J. Biomed. Inform.*, vol. 79, pp. 117–128, 2018.