



## **Lung Cancer Diagnosis from CT Scan Images using Deep Learning and Transfer Learning Methods**

**Rahbar, Kambiz<sup>1\*</sup> / Taheri, Fatemeh<sup>2</sup>**

<sup>1</sup> - Assistant Professor, Department of Computer Engineering, South Tehran Branch, Islamic Azad University, Tehran, Iran

<sup>2</sup> - Ph.D. Candidate, Department of Computer Engineering, South Tehran Branch, Islamic Azad University, Tehran, Iran

### **ARTICLE INFO**

DOI: 10.22041/ijbme.2024.2015895.1870

Received: 16 November 2023

Revised: 2 February 2024

Accepted: 20 February 2024

### **KEYWORDS**

*Lung Cancer*  
*CT Images*  
*Deep Learning*  
*Transfer Learning*

### **ABSTRACT**

Lung cancer is caused by the irregular and uncontrolled growth of cancer cells in the lung tissue. Cancer cells find the ability to divide and increase in an irregular and uncoordinated manner. The result of this proliferation is the formation of a cancerous mass in the lung. Lung cancer can start in different parts of the lung, such as the bronchi (the air tubes that connect to the lungs) or non-bronchial tissues, and quickly spread to other parts of the body. The precise understanding of the mechanism of lung cancer is still a complex issue and many researches are being conducted in this field. However, early diagnosis has an important impact on the disease treatment process. Therefore, in this research, the diagnosis and classification of this disease is discussed with the help of deep learning and transfer learning. In this regard, the pre-trained Alexnet network has been selected. During the process of transfer learning, the network for lung cancer detection is set on IQ-OTH/NCCD data in three categories: normal, benign and malignant. For this purpose, the last all-connection layer of the Alexnet network is removed and replaced by a new all-connection layer corresponding to the number of layers in the dataset. The classification accuracy of the proposed method on the IQ-OTH/NCCD dataset is reported to be 93%.

### **\*Corresponding Author**


**Address:** Department of Computer Engineering, South Tehran Branch, Islamic Azad University, Tehran, Iran

**Postal Code:** 1777613651

**E-Mail:** k\_rahbar@azad.ac.ir

**Tel:** +98-21-33722831





## تشخیص سرطان ریه از روی تصاویر سی تی اسکن با استفاده از روش یادگیری عمیق و یادگیری انتقالی

رهبر، کامبیز<sup>۱\*</sup> / طاهری، فاطمه<sup>۲</sup>

<sup>۱</sup> - استادیار، گروه مهندسی کامپیوتر، دانشکده‌ی فنی و مهندسی، واحد تهران جنوب، دانشگاه آزاد اسلامی، تهران، ایران  
<sup>۲</sup> - دانشجوی دکتری، گروه مهندسی کامپیوتر، دانشکده‌ی فنی و مهندسی، واحد تهران جنوب، دانشگاه آزاد اسلامی، تهران، ایران

### مشخصات مقاله

شناسه‌ی دیجیتال: 10.22041/ijbme.2024.2015895.1870

پذیرش: ۱ اسفند ۱۴۰۲

بازنگری: ۱۳ بهمن ۱۴۰۲

ثبت در سامانه: ۲۵ آبان ۱۴۰۲

### چکیده

### واژه‌های کلیدی

سرطان ریه به دلیل رشد نامنظم و غیرکنترلی سلول‌های سرطانی در بافت ریه ایجاد می‌شود. سلول‌های سرطانی توانایی تقسیم و افزایش خود را به شکل نامنظم و ناهماهنگ پیدا می‌کنند. نتیجه‌ی این تکثیر، تشکیل یک توده‌ی سرطانی در ریه است. سرطان ریه می‌تواند از نقاط مختلف ریه مانند برونش (لوله‌های هوایی متصل به ریه‌ها) یا بافت‌های بدون برونش شروع شده و به سرعت به سایر اعضای بدن منتقل شود. درک دقیق مکانیسم ایجاد سرطان ریه هنوز موضوعی پیچیده بوده و تحقیقات زیادی در این زمینه در حال انجام است. با این حال تشخیص زودهنگام، تاثیر مهمی در فرایند درمان بیماری دارد. از این رو در این پژوهش به تشخیص و طبقه‌بندی این بیماری به کمک یادگیری عمیق و یادگیری انتقالی پرداخته شده است. در این راستا شبکه‌ی از پیش آموزش داده شده‌ی الکسنت انتخاب شده است. طی فرایند یادگیری انتقالی، شبکه جهت تشخیص سرطان ریه روی داده‌ی IQ-OTH/NCCD در سه دسته‌ی نرمال، خوش خیم و بدخیم تنظیم شده است. به این منظور آخرین لایه‌ی تمام اتصال شبکه‌ی الکسنت حذف شده و لایه‌ی تمام اتصال جدید منطبق بر تعداد طبقه‌های مجموعه‌ی داده جایگزین شده است. دقت طبقه‌بندی با روش پیشنهادی روی مجموعه‌ی داده‌ی IQ-OTH/NCCD برابر با ۹۳٪ به دست آمده است.

سرطان ریه  
تصاویر سی تی اسکن  
یادگیری عمیق  
یادگیری انتقالی

### \*نویسنده‌ی مسئول

نشانی: گروه مهندسی کامپیوتر، دانشکده‌ی فنی و مهندسی، واحد تهران جنوب، دانشگاه آزاد اسلامی، تهران، ایران  
کد پستی: ۱۷۷۷۶۱۳۶۵۱  
پست الکترونیک: k\_rahbar@azad.ac.ir  
تلفن: +۹۸-۲۱-۳۳۷۲۲۸۳۱



## ۱- مقدمه

متاستازهای ریه می‌باشند [۸]. کالج آمریکایی داروسازی بالینی<sup>۱۱</sup> (ACCP) احتمال بدخیم بودن ندول با قطر ۳ میلی‌متر و بالاتر را بسیار بیش‌تر از ندول‌های با قطر کم‌تر می‌داند. در صورتی که بافت به صورت لایه‌لایه یا هم‌مرکز باشد و ضایعه در طول یک سال رشد نکند، نشان‌گر خوش‌خیم بودن آن است [۹]. با بررسی این تصاویر پزشک قادر خواهد بود سطح و تغییرات غیرطبیعی، محدوده و اندازه‌ی توده‌ها را تشخیص دهد. ساختار پیچیده و غیریکسان توده‌های سرطان ریه موجب می‌شود که تشخیص ندول‌های مشکوک به سرطان برای پزشکان متخصص نیز یک چالش به شمار آید. بسیاری از سیستم‌های تشخیص به کمک رایانه<sup>۱۱</sup> (CAD) به طور گسترده برای تشخیص و طبقه‌بندی سرطان ریه مورد مطالعه قرار گرفته‌اند [۱۰، ۱۱]. در مقایسه با رادیولوژیست‌های آموزش دیده، سیستم‌های CAD عمل‌کرد بهتری را در تشخیص ندول‌های ریه و سرطان در تصاویر پزشکی ارائه می‌دهند. به طور کلی سیستم تشخیص سرطان ریه مبتنی بر CAD شامل چهار مرحله‌ی پردازش تصویر، استخراج منطقه‌ی مورد نظر<sup>۱۲</sup> (ROI)، انتخاب ویژگی و طبقه‌بندی است. در میان این مراحل، استخراج ویژگی و طبقه‌بندی نقش مهمی را در ثبت ویژگی‌های متمایز کننده و در نتیجه بهبود دقت و حساسیت سیستم تشخیصی ایفا می‌کنند [۱۲]. با وجود تحقیقات گسترده در این زمینه، طبقه‌بندی ندول خوش‌خیم و بدخیم به دلیل شباهت بسیار زیاد آن‌ها یک چالش به حساب می‌آید.

در روش‌های رایج تشخیص به کمک رایانه (CAD) از ویژگی‌های مرتبط از پیش مطالعه شده مانند حجم، شکل و میزان کروی بودن توده‌ها استفاده شده است. در این روش‌ها از ویژگی‌های سطح پایین برای توصیف ویژگی‌های ندول‌های خوش‌خیم یا بدخیم استفاده شده است [۱۳-۱۵]. برای نمونه در مقاله‌ی [۱۵] از الگوهای بافت تصویر شامل ویژگی هارالیک، گابور و الگوهای باینری محلی برای توصیف هر تصویر استفاده شده است. در پژوهش [۱۴] نیز ویژگی‌های آماری بافت مانند میانگین، انحراف معیار و چولگی استخراج شده و از شبکه‌ی عصبی انتشار به جلو<sup>۱۳</sup> و پیش‌خور<sup>۱۴</sup> برای طبقه‌بندی استفاده شده است. در این روش‌ها ویژگی‌های مرتبط با شکل توده‌ها در نظر گرفته نشده است. برای حل این مشکل در مقاله‌ی [۱۶]

سرطان در نتیجه‌ی عوامل مختلفی مانند ژنتیک، عوامل زیست‌محیطی، سن و عادات غذایی ناسالم ممکن است در هر بخشی از بدن رخ دهد [۱]. سرطان ریه به عنوان اولین عامل مرگ و میر ناشی از سرطان‌ها شناخته می‌شود [۲]. این نوع سرطان در نتیجه‌ی ناهنجاری در سلول‌های ریه ایجاد می‌شود. زمانی که روند تقسیم سلول‌ها از حالت نرمال خارج می‌شود، سلول‌ها به طور نامحدود تقسیم شده و یک توده از سلول‌های غیرطبیعی را تشکیل می‌دهند [۳]. این توده‌ی سلولی به تومور معروف است. تومورها می‌توانند بدخیم یا خوش‌خیم باشند. تومورهای بدخیم به سرعت رشد کرده و به بخش‌های دیگری از بدن مهاجرت می‌کنند. در نتیجه توده‌های ثانویه یا پراکنده را تشکیل داده و به عنوان متاستازیس<sup>۱</sup> شناخته می‌شوند [۴]. انواع سرطان ریه در دو دسته‌ی اصلی طبقه‌بندی می‌شوند. عمده‌ترین نوع سرطان ریه، کارسینوم ریه‌ی سلول غیرکوچک<sup>۲</sup> (NSCLC) است. این نوع سرطان ریه به صورت سلول‌های بزرگ و کوچک با شکل غیرعادی تشکیل شده در ریه مشخص می‌شود. نوع دوم، سرطان کارسینوم ریه‌ی سلول کوچک<sup>۳</sup> (SCLC) بوده که به سرعت رشد بالا معروف است [۵]. شناسایی، تشخیص و طبقه‌بندی انواع توده‌های سرطان ریه نقش مهمی در پیش‌گیری و درمان زود هنگام دارد [۶]. روش‌های تشخیصی سرطان ریه شامل تصویربرداری رادیوگرافی و سی‌تی اسکن، بیوپسی<sup>۴</sup> و برونکوسکوپی<sup>۵</sup> است. در این میان روش تصویربرداری سی‌تی اسکن به عنوان یک روش تشخیصی برتر، کاربرد فراوانی دارد [۷]. با روش عکس‌برداری سی‌تی اسکن، تصاویر مقطعی از ساختار داخلی ریه و بافت‌های اطراف آن به دست می‌آید. سی‌تی اسکن می‌تواند به شناسایی خراش‌ها، توده‌ها و تغییرات دیگر در ریه کمک کند. در روش تشخیصی به کمک سی‌تی اسکن، پزشک به بررسی ندول‌های مشکوک در تصاویر ریه می‌پردازد. ندول<sup>۶</sup> ریه یک توده‌ی سلولی کوچک است که درون بافت ریه ایجاد می‌شود. ندول‌های ریه به دو دسته‌ی خوش‌خیم (غیرسرطانی) و بدخیم (سرطانی) تقسیم می‌شوند. علل شایع ایجاد توده‌های خوش‌خیم، گرانولوم<sup>۷</sup> عفونی و هماتوما<sup>۸</sup> است. در حالی که موارد بدخیم ناشی از سرطان اولیه‌ی ریه، تومورهای کارسینوئید<sup>۹</sup> و

<sup>۸</sup> Hematoma<sup>۹</sup> Carcinoid<sup>۱۰</sup> American College of Clinical Pharmacy<sup>۱۱</sup> Computer Aided Diagnosis<sup>۱۲</sup> Region of Interest<sup>۱۳</sup> Feedforward<sup>۱۴</sup> Back Propagation<sup>۱</sup> Metastatic<sup>۲</sup> Non-Small Cell Lung Cancer (NSCLC)<sup>۳</sup> Small Cell Lung Cancer (SCLC)<sup>۴</sup> Biopsy<sup>۵</sup> Bronchoscopy<sup>۶</sup> Nodule<sup>۷</sup> Granulomatous

خوش خیم نیز در این رویکرد به کمک ماشین بردار پشتیبان با کرنل تابع پایه‌ی شعاعی<sup>۴</sup> انجام شده است. در پژوهش [۲۱] ویژگی‌های بافت شامل الگوی باینری محلی<sup>۵</sup> (LBP)، هیستوگرام گرادیان جهت یافته (HOG) و ویژگی‌های مبتنی بر تبدیل موجک با ویژگی‌های شکل از طریق مومنت زرنیک ترکیب شده است. در این روش از الگوریتم بهینه‌سازی ازدحام ذرات فازی (FPSO) برای انتخاب موثرترین ویژگی‌ها استفاده شده است. در مقالات [۲۵] و [۲۶] قطعه‌بندی تصویر به کمک فیلترهای مورفولوژیکی برای جداسازی توده از سایر بخش‌های تصویر مورد توجه قرار گرفته است. سپس ویژگی‌های هارالیک<sup>۶</sup> و گشتاور هو<sup>۷</sup> تنها از بخش توده‌های شناسایی شده استخراج شده است. در پژوهش [۲۷] از پیش‌پردازش تصویر شامل شناسایی و محلی‌سازی نواحی تومور با استفاده از نقاط بذری<sup>۸</sup> توسط پزشک استفاده شده است. پس از آن نواحی اطراف توده به وصله‌های غیرهم‌پوشان تقسیم و ویژگی‌های عمیق استخراج شده است. در روش‌های وابسته به قطعه‌بندی تصویر دقت طبقه‌بندی تا حد زیادی به کیفیت این مرحله وابسته است.

با وجود روش‌های خودکار استخراج ویژگی به کمک رویکردهای مبتنی بر یادگیری عمیق، این سیستم‌ها با چالش تامین تعداد تصاویر مناسب برای مرحله‌ی یادگیری رو به رو هستند [۱۹]. برای حل مشکل تعداد نمونه‌های آموزشی و هزینه‌های آموزش کامل شبکه، استفاده از رویکردهای یادگیری انتقالی مورد توجه قرار گرفته است [۲۸]. این رویکرد اجازه می‌دهد تا از مدل‌های از پیش آموزش دیده روی مجموعه‌ی داده‌های مقیاس بزرگ برای استخراج ویژگی‌های مرتبط استفاده شود و در نتیجه نیاز به داده‌های برچسب‌گذاری شده‌ی گسترده کاهش می‌یابد. برای نمونه در مقاله‌ی [۲۹] یک مدل یادگیری عمیق به روش یادگیری انتقالی معرفی شده است. در این رویکرد دو مرحله‌ای ابتدا قطعه‌بندی توده‌ها به کمک شبکه‌ی DeepLab صورت گرفته و سپس خروجی مرحله‌ی قطعه‌بندی به مرحله‌ی محلی‌سازی و طبقه‌بندی داده شده است.

در این پژوهش با هدف طبقه‌بندی سرطان ریه رویکرد مبتنی بر یادگیری انتقالی به کمک شبکه‌ی عصبی عمیق الکسنت<sup>۹</sup> پیشنهاد شده است. ویژگی‌هایی که به کمک شبکه‌های عصبی استخراج می‌شود به معماری شبکه، تعداد لایه‌های کانولوشن و سائز فیلترها در هر لایه وابسته است [۳۰]. از این رو انتخاب

ویژگی‌های مورفولوژیکی شامل شدت متوسط<sup>۱</sup>، مساحت و محیط توده‌ها برای استخراج ویژگی از تصاویر سی تی اسکن ریه مورد توجه قرار گرفته است. رویکردهای مبتنی بر ویژگی‌های سطح پایین نسبت به تنوع بین تصاویر سی تی اسکن و پارامترهای غربال‌گری مختلف آسیب‌پذیر هستند. از این رو توصیف دقیق ظاهر ندول خوش خیم و بدخیم با هدف طبقه‌بندی با این رویکردها با چالش همراه است.

بسیاری از محققان از تکنیک‌های یادگیری عمیق برای کمک به رادیولوژیست‌ها در تشخیص دقیق تر سرطان ریه استفاده کرده‌اند [۱۷-۱۹]. در این مطالعات نشان داده شده است که سیستم‌های مبتنی بر یادگیری عمیق می‌توانند کارایی و دقت تشخیص پزشکی را به ویژه برای تشخیص سرطان‌های رایج مانند سرطان‌های ریه به طور موثری بهبود بخشند [۲۰]. سیستم‌های مبتنی بر یادگیری عمیق می‌توانند به طور خودکار ویژگی‌های دقیق تری را نسبت به سیستم‌های CAD سنتی از تصاویر استخراج کنند. مزیت استفاده از یادگیری عمیق در این سیستم‌ها یادگیری برجسته‌ترین ویژگی‌ها در طول آموزش و در نتیجه تشخیص قابل تعمیم است زیرا در این رویکردها ویژگی‌های توده‌ها از تصاویر سی تی اسکن مختلف با پارامترهای متفاوت استخراج می‌شود. پس از آموزش شبکه، سیستم می‌تواند یادگیری خود را تعمیم داده و ندول‌های بدخیم را در موارد جدیدی که قبلاً دیده نشده است تشخیص دهد [۲۱].

در حال حاضر از شبکه‌های عصبی کانولوشنی به طور گسترده برای تشخیص و طبقه‌بندی تصاویر پزشکی استفاده می‌شود. برای نمونه در مقاله‌ی [۲۲] از شبکه‌ی عصبی کانولوشنی ResNet50 اصلاح شده برای استخراج ویژگی‌های عمیق استفاده شده است. در مقاله‌ی [۲۳] نیز از ترکیب یک شبکه‌ی باور عمیق<sup>۲</sup> و یک شبکه‌ی عصبی کانولوشن برای طبقه‌بندی توده‌ها در تصاویر توموگرافی کامپیوتری معرفی شده است. آن‌جا که برخی ویژگی‌ها از طریق شبکه‌های عصبی کانولوشن استخراج نمی‌شود رویکردهای ترکیب ویژگی‌های سطح پایین و عمیق در پژوهش [۲۴] مورد توجه قرار گرفته است. در این رویکرد ویژگی‌های عمیق از شبکه‌ی عصبی عمیق Resnet با هیستوگرام ویژگی‌های گرادیان (HOG) ادغام شده است. به منظور کاهش بردار ویژگی نیز از تحلیل مولفه‌های اصلی<sup>۳</sup> استفاده شده است. طبقه‌بندی ندول‌های بدخیم از ندول‌های

<sup>۶</sup> Haralic

<sup>۷</sup> Hu

<sup>۸</sup> Seed Point

<sup>۹</sup> Alexnet

<sup>۱</sup> Average Intensity

<sup>۲</sup> Deep Belief Network

<sup>۳</sup> Principle Component Analysis

<sup>۴</sup> Radial Basis Function

<sup>۵</sup> Local Binary Pattern

سیستم و عدم تعمیم‌پذیری مدل با نمونه‌های دیده نشده شود. در رویکرد پیشنهادی این مقاله روش یادگیری انتقالی به کار گرفته شده که در آن از دانش به دست آمده روی مجموعه‌ی داده‌های مقیاس بزرگ برای حل مسأله‌ی طبقه‌بندی تصاویر سرطان ریه استفاده شده و بدین ترتیب به احتمال پیش‌برازش مدل به دلیل تعداد نمونه‌های آموزشی غلبه شده است.

در رویکرد مقاله‌ی [۳۳] ابتدا داده‌ها با استفاده از تکنیک حذف نویز مبتنی بر فیلتر گبور پیش‌پردازش شده است. علاوه بر این استخراج ویژگی از تصاویر از پیش پردازش شده با کمک مدل NASNetLarge انجام شده است. پیچیدگی محاسباتی مدل NASNetLarge به دلیل تعداد بسیار زیاد پارامترهای این مدل و منابع محاسباتی قابل توجه برای آموزش، امکان استفاده از این مدل در دستگاه‌های دارای محدودیت منابع را با چالش همراه می‌کند. علاوه بر این NASNetLarge به تعداد زیادی نمونه‌ی آموزشی برای دست‌یابی به عمل‌کرد مطلوب نیاز دارد. آموزش شبکه‌های عصبی عمیق مانند NASNetLarge به مجموعه‌ی داده‌های بزرگ و متنوعی نیاز دارد تا طیف وسیعی از تغییرات و الگوها را برای طبقه‌بندی دقیق ثبت کند. در مقابل در رویکرد پیشنهادی این مقاله از یک شبکه‌ی سبک مانند الکسنت با تعداد لایه‌های محدود استفاده شده است. این مدل قابلیت عملیاتی‌سازی روی انواع دستگاه‌ها را خواهد داشت. هم‌چنین چالش تامین نمونه‌های آموزشی در رویکرد یادگیری انتقالی در مدل پیشنهادی مرتفع شده است.

در رویکرد مقاله‌ی [۳۴] از مدل یادگیری چندوظیفه‌ای شامل چندین ماژول یادگیری مبتنی بر توجه استفاده شده است. در این مدل به طور هم‌زمان ۹ ویژگی بصری گره‌های ریه از تصویر سی‌تی اسکن استخراج شده و سپس از یک ماژول توجه برش برای فیلتر کردن برش‌های نامربوط استفاده شده است. یکی از معایب یادگیری چندوظیفه‌ای، احتمال تداخل یا انتقال منفی بین وظایف است. در یادگیری چندوظیفه‌ای، چندین کار مرتبط به طور هم‌زمان با استفاده از یک نمایش مشترک انجام می‌شود. با این حال برای یادگیری یک نمایش کلی با مشکل تداخل رو به رو شده که این تداخل می‌تواند منجر به کاهش عمل‌کرد مدل شود. پیچیدگی و منابع محاسباتی مورد نیاز برای آموزش یک مدل چندوظیفه‌ای در مقایسه با آموزش مدل‌های جداگانه برای هر کار یک نقطه ضعف محسوب می‌شود. در مقابل در رویکرد پیشنهادی پیچیدگی مدل و محدودیت‌های آموزش مدل از طریق یادگیری انتقالی مرتفع شده است.

در رویکرد مقاله‌ی [۳۵] ابتدا شبکه با افزودن ماژول توجه کانال تقویت شده و سپس روی مثال‌های آسان قبل از نمونه‌های

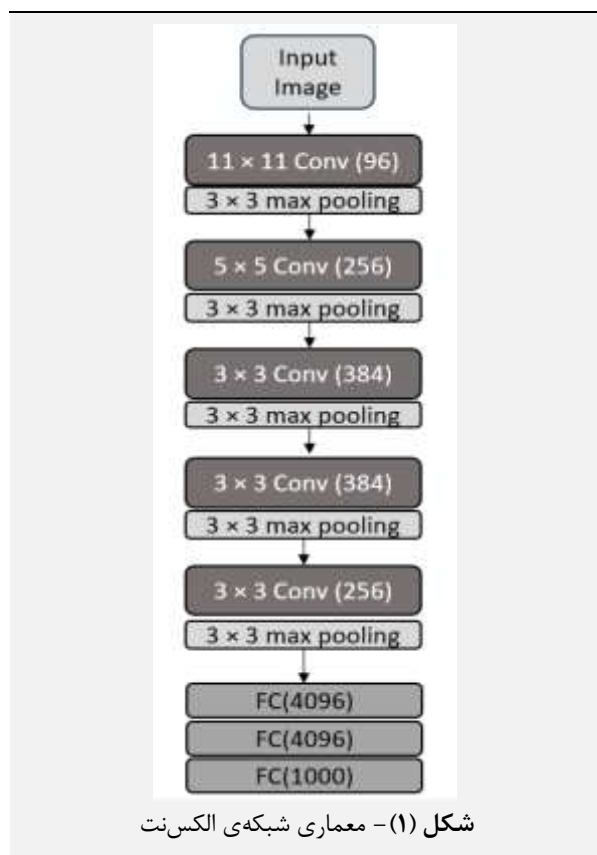
شبکه‌ی از پیش آموزش دیده‌ی مناسب برای وظیفه‌ی استخراج ویژگی از تصاویر سی‌تی اسکن ریه دارای اهمیت است. در این رویکرد از شبکه‌ی الکسنت به دلیل سائز فیلترهای بزرگ در لایه‌های ابتدایی و فیلترهایی با سائز کوچک در لایه‌های انتهایی استفاده شده است. هم‌چنین تعداد لایه‌های محدود این شبکه در افزایش سرعت آموزش موثر است. استفاده از فیلتر بزرگ در لایه‌ی اول شبکه اجازه می‌دهد تا ابتدا ویژگی‌های کلی تصویر استخراج شود. در لایه‌های بعدی با اندازه‌های فیلتر کوچک‌تر، ویژگی‌های ریزدانه و جزئیات بیش‌تری از نقشه‌های ویژگی استخراج می‌شود. این فرایند استخراج ویژگی سلسله‌مراتبی در شبکه‌های عصبی عمیق به یادگیری نمایش‌های پیچیده‌تر از تصاویر سی‌تی اسکن ریه منجر می‌شود. در این رویکرد لایه‌ی انتهایی شبکه‌ی الکسنت حذف شده است. لایه‌ی حذف شده با یک لایه‌ی تمام اتصال با ۳ نورون خروجی برای طبقه‌بندی ندول‌های خوش‌خیم، بدخیم و نرمال جایگزین شده است. به این ترتیب می‌توان بدون نیاز به روش‌های پیش‌پردازش و قطعه‌بندی تصویر، زمان و منابع مورد نیاز سیستم را کاهش داد.

## ۲- مواد و روش‌ها

الگوریتم‌های یادگیری عمیق زیرمجموعه‌ای از الگوریتم‌های یادگیری ماشین بوده که هدف آن‌ها کشف چندین سطح از بازنمایش‌های توزیع شده از داده‌ی ورودی است [۳۱]. معماری یک شبکه‌ی عصبی عمیق کانولوشنی معمولاً شامل مجموعه‌ای از لایه‌های استخراج ویژگی و چند لایه‌ی تصمیم‌گیری است. لایه‌ی ورودی، داده‌ی ورودی مانند تصاویر را دریافت کرده و آن را از طریق لایه‌های مخفی به لایه‌های بعد منتقل می‌کند. هر لایه‌ی مخفی مجموعه‌ای از محاسبات کانولوشنی را انجام می‌دهد. لایه‌ی خروجی پیش‌بینی‌ها یا طبقه‌بندی‌های نهایی را بر اساس نمونه‌های یاد گرفته شده ارائه می‌دهد.

بررسی رویکردهای مختلف طبقه‌بندی تصاویر سرطان ریه مزیت رویکرد یادگیری انتقالی را نسبت به سایر رویکردها نشان می‌دهد. برای نمونه در مقاله‌ی [۳۲] یک چارچوب مبتنی بر یادگیری عمیق با استفاده از مفهوم مورفولوژی تطبیقی همراه با فیلتر گبور برای طبقه‌بندی دقیق ندول‌های ریه معرفی شده است. این چارچوب با دو مسیر قابل آموزش، ویژگی‌های بافتی و مورفولوژیکی ندول‌های ریه را استخراج می‌کند. فرایند یادگیری در رویکردهای مبتنی بر شبکه‌های عصبی عمیق نیازمند تعداد زیادی نمونه‌ی آموزشی بوده و تامین داده‌های آموزشی در تصاویر پزشکی چالش بزرگی است. عدم تامین داده‌ی آموزشی مناسب می‌تواند منجر به برازش بیش از حد

ترکیبی از کانولوشن و لایه‌ی پولینگ و بخش دوم شامل ۳ لایه‌ی کاملاً متصل بوده که برای طبقه‌بندی طراحی شده است. در هر یک از این لایه‌ها به غیر از لایه‌ی خروجی از تابع فعال‌ساز رلو<sup>۱</sup> استفاده شده است. استفاده از تابع رلو به عنوان تابع فعال‌ساز، سرعت فرایند آموزش را افزایش می‌دهد. هم‌چنین در طراحی شبکه از لایه‌های dropout استفاده شده است. این لایه از بیش‌برازش مدل طی فرایند آموزش جلوگیری می‌کند. این مدل روی مجموعه‌ی داده‌ی Imagenet آموزش داده شده که شامل حدود ۱۴ میلیون تصویر در ۱۰۰۰ کلاس است. معماری شبکه‌ی الکسنت در شکل (۱) نشان داده شده است.



در طول فرایند آموزش، شبکه وزن‌ها و بایاس‌های نوروهای خود را بر اساس خطا یا ازدیاد بین جریان خروجی پیش‌بینی شده و خروجی مطلوب تنظیم می‌کند. این فرایند تکراری تا زمانی ادامه می‌یابد که کارایی شبکه قابل قبول باشد. با این حال وجود وزن‌های زیاد، نیاز به داده با حجم بالا را برای این شبکه‌ها اجتناب‌ناپذیر می‌کند. به همین دلیل عموماً فرایند یادگیری در این شبکه‌ها بسیار زمان‌بر و پرهزینه است. شبکه پس از آموزش دارای وجوه مشترکی برای کاربردهای مختلف است. از این رو بحث استفاده‌ی مجدد از شبکه‌ی آموزش داده شده برای کاربردهای دیگر مطرح می‌شود.

سخت آموزش داده شده است. در نهایت با سخت‌تر شدن نمونه‌های آموزشی در طول یادگیری توانایی برای افزایش دقت عمل‌کرد بهبود یافته است. در روش‌های مبتنی بر آموزش مجدد، تامین داده‌های آموزشی متنوع برای جلوگیری از بیش‌برازش مدل اهمیت زیادی دارد. این مدل روی مجموعه‌ی داده‌ی LIDC-IDR با تعداد محدود نمونه آموزش دیده است. اگر چه نتایج گزارش شده عمل‌کرد مدل را تایید کرده اما رتبه‌بندی کردن نمونه‌های مجموعه‌ی داده به نمونه‌های آسان و سخت فرایند پیچیده‌ای است. در مقابل در رویکرد پیشنهادی بدون در نظر گرفتن رتبه‌بندی نمونه‌ها و بیش‌برازش داده‌ها فرایند استخراج ویژگی و طبقه‌بندی نهایی انجام شده است.

در رویکرد پژوهش [۳۶] از تکنیک‌های استخراج ویژگی‌های سطح پایین شامل ماتریس هم‌رخداد سطح خاکستری و فیلتر گبور استفاده شده است. در این روش مکان‌های مرکزی ندول‌های ریوی با ماسک‌های تقسیم‌بندی نواحی تصویر برای یافتن مناطق مورد علاقه مشخص شده است. رویکردهای مبتنی بر ویژگی‌های سطح پایین نسبت به تنوع بین تصاویر سی‌تی اسکن و پارامترهای غربال‌گری مختلف آسیب‌پذیر هستند. از این رو توصیف دقیق ظاهر ندول خوش‌خیم و بدخیم با هدف طبقه‌بندی با این رویکردها با چالش همراه است. به همین دلیل اغلب از روش‌های تکمیلی مانند تقسیم‌بندی تصویر برای محدود کردن و تمرکز بر ناحیه‌ی سرطانی استفاده می‌شود. دقت عمل‌کرد این رویکردها به تکنیک‌های تقسیم‌بندی تصویر نیز وابسته است. در مطالعات متعددی نشان داده شده است که سیستم‌های مبتنی بر یادگیری عمیق می‌توانند کارایی و دقت تشخیص پزشکی را به طور موثری بهبود بخشند. از این رو در رویکرد پیشنهادی از رویکرد یادگیری عمیق استفاده شده است. این رویکرد می‌تواند علاوه بر نتایج موثر، قابلیت تعمیم‌پذیری مناسبی را نیز داشته باشد. هم‌چنین یادگیری انتقالی، منابع محاسباتی مورد نیاز برای آموزش را کاهش می‌دهد زیرا معماری پیچیده‌ی مدل از پیش ایجاد شده است. این موضوع منجر به آموزش سریع‌تر و هم‌چنین کاهش منابع محاسباتی می‌شود.

## ۱-۲- شبکه‌ی از پیش آموزش داده شده‌ی الکسنت

شبکه‌ی الکسنت یکی از مدل‌های پیش آموزش دیده در حوزه‌ی بینایی است. این شبکه توسعه‌ای بر شبکه‌ی Lenet-5 با افزایش تعداد لایه‌ها از ۵ به ۸ لایه است. در شبکه‌ی عصبی عمیق الکسنت ۸ لایه با پارامترهای قابل یادگیری وجود دارد. این ۸ لایه در دو گروه دسته‌بندی می‌شود. بخش اول ۵ لایه

<sup>۱</sup> Relu

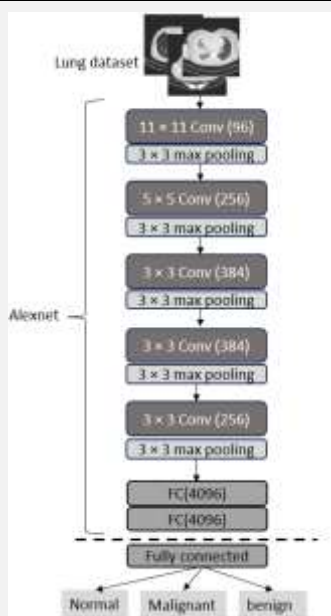
**۲-۲- یادگیری انتقالی**

یادگیری انتقالی یک تکنیک در یادگیری ماشین است که روی استفاده‌ی مجدد از دانش به دست آمده در حین حل یک مشکل و به کارگیری آن برای یک مشکل متفاوت اما مرتبط تمرکز دارد [۳۷]. به عنوان مثال در تشخیص تصویر، دانشی که در تشخیص برخی اشیاء به دست آمده است می‌تواند در تشخیص اشیاء دیگر نیز استفاده شود اگر چه ارتباط عملی بین دو حوزه محدود می‌باشد. استفاده‌ی مجدد/انتقال اطلاعات از وظایف قبلی به وظایف جدید توانایی بهبود یادگیری را به طور قابل توجهی ارتقا می‌دهد [۳۸].

رویکرد پیشنهادی برای بهره‌گیری از شبکه‌ی الکسنت جهت تشخیص سرطان ریه شامل چهار مرحله است. مرحله‌ی اول، آماده‌سازی مجموعه‌ی داده است که در آن باید مجموعه‌ای از تصاویر سرطان ریه جمع‌آوری شده و اطمینان حاصل شود که برچسب‌گذاری مناسب روی داده‌ها انجام شده باشد. به عبارت دیگر لازم است با توجه به نوع سرطان در کلاس‌های مناسب به صورت خوش‌خیم، بدخیم و نرمال برچسب‌گذاری شده باشد. سپس مجموعه‌ی داده باید به سه بخش آموزش، اعتبارسنجی و آزمون تقسیم شود. مرحله‌ی دوم، تغییر لایه‌ی آخر شبکه‌ی الکسنت است. در این مرحله لایه‌ی تمام اتصال شبکه‌ی الکسنت باید با یک لایه‌ی تمام اتصال با وظیفه‌ی طبقه‌بندی جایگزین شود. لایه‌ی جدید باید حاوی تعداد مناسبی نورون خروجی بوده که با کلاس‌های موجود در مجموعه‌ی داده‌ی سرطان ریه مطابقت داشته باشد. مرحله‌ی سوم، قفل کردن لایه‌های شبکه‌ی از پیش آموزش دیده است. در این مرحله لازم است وزن‌های لایه‌های شبکه‌ی از پیش آموزش داده شده‌ی الکسنت منجمد شده تا از به‌روزرسانی آن‌ها در هنگام آموزش با داده‌های جدید جلوگیری شود. این مرحله اطمینان می‌دهد که تنها وزن‌های لایه‌ی جدید اضافه شده توسط ماشین یادگیری برآزش خواهد شد. مرحله‌ی چهارم، آموزش مدل الکسنت اصلاح شده است. شبکه‌ی تغییر یافته لازم است با استفاده از مجموعه‌ی داده‌ی سرطان ریه آموزش داده شود. از مجموعه‌ی آموزش و مجموعه‌ی اعتبارسنجی می‌توان برای بهینه‌سازی هایپرپارامترها از جمله نرخ یادگیری و تعداد تکرارها استفاده کرد. معماری لایه‌ی پیشنهادی برای جایگزینی در لایه‌ی آخر شبکه‌ی الکسنت در شکل (۲) نشان داده شده است. مشاهده می‌شود که یک لایه‌ی تمام اتصال با ورودی به اندازه‌ی ۴۰۹۶ برابر با اندازه‌ی لایه‌ی ماقبل آخر در معماری الکسنت انتخاب شده است. هم‌چنین با توجه به وجود ۳ طبقه در مجموعه‌ی داده، تعداد نورون‌های این لایه ۳ در نظر گرفته شده

است. فرایند ارزیابی برای ۷۰ درصد داده‌ی آموزش، ۱۵ درصد اعتبارسنجی و ۱۵ درصد آزمایشی انجام شده است. پارامترهای آموزش در فرایند انتقال یادگیری در شکل (۳) نشان داده شده است. در این فرایند هم‌گرایی در تکرار ۵۰ حاصل شده است. زمان لازم برای هم‌گرایی روی رایانه‌ی شخصی با ۲۰ گیگابایت حافظه‌ی رم و پردازنده‌ی i5 نسل ۶ به میزبانی اوبونتو ۲۰۲۲ LTS و تحت نرم‌افزار متلب 2023a برابر ۲ ثانیه بوده است. تعداد تکرارهای مجاز ۱۰۰۰ تکرار در نظر گرفته شده است.

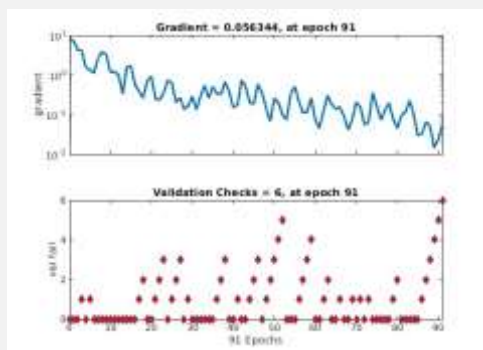
رفتار و بررسی اعتبارسنجی گرادیان طی آموزش در شکل (۴) نشان داده شده است. هم‌چنین گراف تابع بازدهی آموزش در مدل یاد شده در شکل (۵) ترسیم شده است. مشاهده می‌شود که پس از ۹۱ تکرار میزان خطا به کم‌تر از ۰/۰۱ رسیده است.



شکل (۲) - معماری روش پیشنهادی

Unit	Initial Value	Stopped Value	Target Value
Epoch	0	91	1000
Elapsed Time	-	00:00:02	-
Performance	3.58	0.0179	0
Gradient	7.19	0.0563	1e-08
Validation Checks	0	6	6

شکل (۳) - پارامترهای یادگیری



شکل (۴) - رفتار و بررسی اعتبارسنجی گرادیان طی آموزش



### ۲-۳- معیار صحت

صحت یک معیار آماری است که دقت یک مدل طبقه‌بندی را در پیش‌بینی موارد مثبت اندازه‌گیری می‌کند. به عبارت ساده‌تر، صحت نشان می‌دهد که چه تعداد از پیش‌بینی‌های مثبت انجام شده توسط یک مدل واقعا درست است. یک مقدار صحت بالا نشان می‌دهد که عمل کرد مدل در به حداقل رساندن خطاهای مثبت کاذب و ارائه‌ی پیش‌بینی‌های مثبت دقیق خوب است. در مقابل یک مقدار صحت پایین نشان دهنده‌ی بالاتر بودن احتمال پیش‌بینی‌های مثبت کاذب است. نحوه‌ی محاسبه‌ی این معیار در رابطه‌ی (۲) ارائه شده است.

$$Precision = \frac{TP}{TP + FP} \quad (2)$$

### ۳-۳- معیار بازخوانی

این معیار که با عنوان حساسیت نیز شناخته می‌شود یک معیار آماری است که توانایی یک مدل طبقه‌بندی باینری را برای شناسایی صحیح نمونه‌های مثبت اندازه‌گیری می‌کند. به عبارت ساده‌تر، این معیار مشخص می‌کند که چه تعداد از نمونه‌های مثبت واقعی به درستی توسط مدل شناسایی شده است. یک مقدار بازخوانی بالا نشان می‌دهد که مدل در گرفتن بیشتر موارد مثبت موثر است. در حالی که یک مقدار بازخوانی پایین بیان می‌کند که مدل تعداد قابل توجهی از موارد مثبت را از دست می‌دهد. این معیار با رابطه‌ی (۳) قابل محاسبه است.

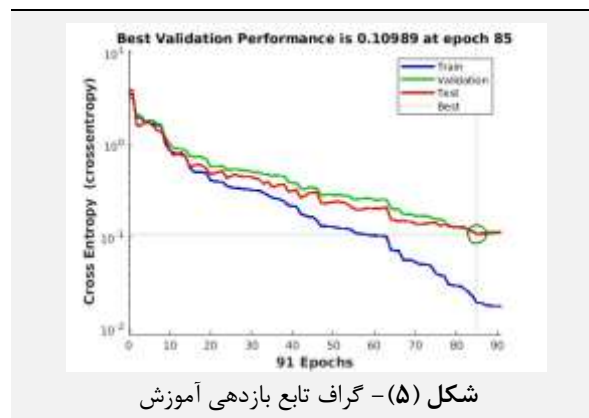
$$Recall = \frac{TP}{P} = \frac{TP}{TP + FN} \quad (3)$$

### ۴-۳- معیار امتیاز F1

امتیاز F1 معیاری است که از آن برای ارزیابی عملکرد یک مدل طبقه‌بندی باینری استفاده می‌شود. این معیار هر دو معیار صحت و بازخوانی را در یک مقدار واحد ترکیب کرده و معیار متعادلی از دقت مدل را ارائه می‌دهد. امتیاز F1 به عنوان میانگین هارمونیک صحت و بازخوانی محاسبه می‌شود. نحوه‌ی محاسبه‌ی این معیار به صورت رابطه‌ی (۴) است.

$$F1 \text{ score} = \frac{2TP}{2TP + FP + FN} \quad (4)$$

نتایج ارزیابی مدل پیشنهادی روی مجموعه‌ی داده‌ی مورد بررسی در جدول (۱) ارائه شده است. در این جدول نتایج معیارهای دقت، صحت، بازخوانی و امتیاز F1 برای داده‌های



شکل (۵) - گراف تابع بازدهی آموزش

### ۳- راست آزمایی روش پیشنهادی

مجموعه‌ی داده‌ی سرطان ریه توسط بیمارستان تخصصی انکولوژی/مرکز ملی بیماری‌های سرطان (IQ-OTH/NCCD) فراهم شده است. برخی از تصاویر مجموعه از سینه‌ی کارمندان وزارتخانه‌های حمل و نقل و نفت عراق به دست آمده است. این مجموعه طی سه ماه در پاییز ۲۰۱۹ جمع‌آوری شده است. این مجموعه شامل سی تی اسکن‌های بیماران مبتلا به سرطان ریه در مراحل مختلف و افراد سالم است. تصاویر مجموعه‌ی داده توسط انکولوژیست‌ها و رادیولوژیست‌ها در این دو مرکز نشانه‌گذاری شده است. این مجموعه‌ی داده شامل ۱۱۹۰ تصویر از برش‌های سی تی اسکن در ۱۱۰ مورد بوده که به سه دسته‌ی طبیعی، خوش‌خیم و بدخیم طبقه‌بندی شده است. نمونه‌ی تصاویر این مجموعه‌ی داده در شکل (۶) نشان داده شده است.



شکل (۶) - نمونه‌ی تصاویر مجموعه‌ی داده

جهت ارزیابی روش پیشنهادی از معیارهای دقت<sup>۱</sup>، صحت<sup>۲</sup>، بازخوانی<sup>۳</sup> و امتیاز F1<sup>۴</sup> استفاده شده است. این معیارها بر اساس شمار مثبت واقعی (TP)، شمار منفی واقعی (FP)، شمار مثبت کاذب (TN) و شمار منفی کاذب (FN) محاسبه می‌شوند.

### ۱-۳- معیار دقت

این معیار نسبت موارد درست تشخیص داده شده به کل داده‌ها را محاسبه کرده که به صورت زیر تعریف می‌شود.

$$Accuracy (ACC) = \frac{TP + TN}{P + N} \quad (1)$$

<sup>۱</sup> Recall

<sup>۲</sup> F1-Score

<sup>۱</sup> Accuracy

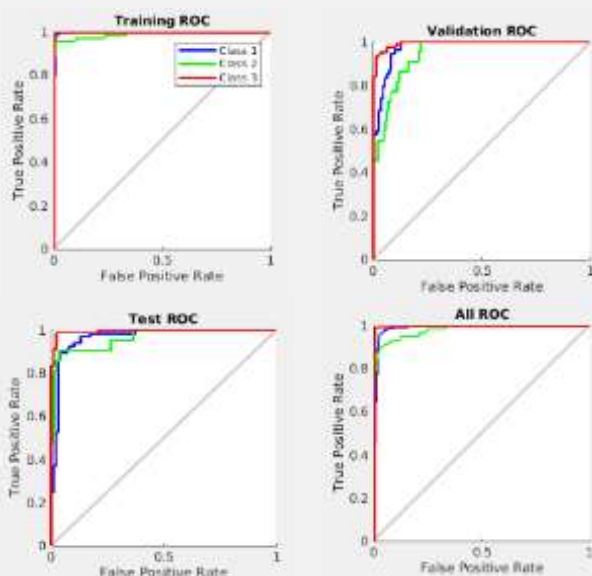
<sup>۲</sup> Precision

طبقه‌ی بدخیم به ترتیب برابر با ۱، ۰/۹۵، ۰/۹۹ و ۰/۹۹ است. مقادیر امتیاز FI روی داده‌های آموزشی، اعتبارسنجی، ارزیابی و کل داده‌ها برای طبقه‌ی طبیعی به ترتیب برابر با ۰/۸۷، ۰/۹۰ و ۰/۹۶ است. مقادیر امتیاز FI روی داده‌های آموزشی، اعتبارسنجی، ارزیابی و کل داده‌ها برای طبقه‌ی بدخیم به ترتیب برابر با ۰/۸۳، ۰/۹۵، ۰/۹۶ و ۰/۸۷ است. مقادیر امتیاز FI روی داده‌های آموزشی، اعتبارسنجی، ارزیابی و کل داده‌ها برای طبقه‌ی بدخیم به ترتیب برابر با ۱، ۰/۹۶، ۰/۹۷ و ۰/۹۹ است. نمودارهای ماتریس درهم‌ریختگی برای داده‌های آموزشی، اعتبارسنجی، تست و کل داده‌ها در شکل (۷) ارائه شده است. مشاهده می‌شود که تشخیص و طبقه‌بندی نمونه‌های بدخیم بهتر از دو طبقه‌ی نرمال و خوش‌خیم انجام شده است. با توجه به حساسیت تشخیص دقیق نمونه‌های بدخیم که در فرایند کنترل و درمان از اهمیت بالاتری برخوردار است بالا بودن نرخ طبقه‌بندی درست اهمیت زیادی دارد. نمودارهای ROC برای داده‌های آموزشی، اعتبارسنجی، تست و کل داده‌ها در شکل (۸) نشان داده شده که در آن هر دو شاخص TP و FT ترکیب شده و به صورت یک منحنی نمایش داده شده است.

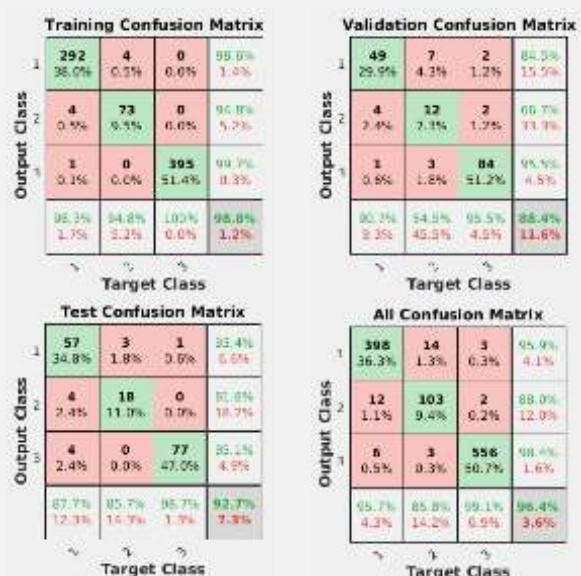
آموزشی، اعتبارسنجی، آزمایشی و هم‌چنین کل داده‌ها نشان داده شده است. مشاهده می‌شود که پس از فرایند آموزش، مقدار دقت روی داده‌های آموزشی، اعتبارسنجی، ارزیابی و کل داده‌ها به ترتیب برابر با ۰/۹۹، ۰/۸۸، ۰/۹۳ و ۰/۹۶ گزارش شده است. مقادیر صحت روی داده‌های آموزشی، اعتبارسنجی، ارزیابی و کل داده‌ها برای طبقه‌ی طبیعی به ترتیب برابر با ۰/۹۹، ۰/۸۳، ۰/۹۳ و ۰/۹۶ گزارش شده است. مقادیر صحت روی داده‌های آموزشی، اعتبارسنجی، ارزیابی و کل داده‌ها برای طبقه‌ی خوش‌خیم به ترتیب برابر با ۰/۸۲، ۰/۶۷، ۰/۹۵ و ۰/۸۸ گزارش شده است. مقادیر صحت روی داده‌های آموزشی، اعتبارسنجی، ارزیابی و کل داده‌ها برای طبقه‌ی بدخیم به ترتیب برابر با ۱، ۰/۹۵، ۰/۹۶ و ۰/۹۹ گزارش شده است. مقادیر بازخوانی روی داده‌های آموزشی، اعتبارسنجی، ارزیابی و کل داده‌ها برای طبقه‌ی طبیعی به ترتیب برابر با ۰/۹۸، ۰/۹۰، ۰/۸۸ و ۰/۹۶ است. مقادیر بازخوانی روی داده‌های آموزشی، اعتبارسنجی، ارزیابی و کل داده‌ها برای طبقه‌ی خوش‌خیم به ترتیب برابر با ۰/۸۶، ۰/۸۶ و ۰/۸۶ است. مقادیر بازخوانی روی داده‌های آموزشی، اعتبارسنجی، ارزیابی و کل داده‌ها برای

جدول (۱) - نتایج معیارهای دقت، صحت، بازخوانی و امتیاز FI برای داده‌های آموزشی، اعتبارسنجی، آزمایشی و کل داده‌ها

امتیاز FI			بازخوانی			صحت			دقت	داده
بدخیم	خوش‌خیم	طبیعی	بدخیم	خوش‌خیم	طبیعی	بدخیم	خوش‌خیم	طبیعی		
۱	۰/۹۵	۰/۹۸	۱	۰/۹۵	۰/۹۸	۱	۰/۹۵	۰/۹۹	۰/۹۹	آموزشی
۰/۹۶	۰/۶	۰/۸۷	۰/۹۵	۰/۵	۰/۹۰	۰/۹۶	۰/۶۷	۰/۸۳	۰/۸۸	اعتبارسنجی
۰/۹۷	۰/۸۳	۰/۹۰	۰/۹۹	۰/۸۶	۰/۸۸	۰/۹۵	۰/۸۲	۰/۹۳	۰/۹۳	آزمایشی
۰/۹۹	۰/۸۷	۰/۹۶	۰/۹۹	۰/۸۶	۰/۹۶	۰/۹۹	۰/۸۸	۰/۹۶	۰/۹۶	کل داده‌ها



شکل (۸) - گراف ROC



شکل (۷) - ماتریس درهم‌ریختگی



#### ۴- یافته‌ها و بحث

نتایج ارزیابی‌های رویکرد پیشنهادی روی مجموعه‌ی داده‌ی IQ-OTH/NCCD نشان می‌دهد که تشخیص و طبقه‌بندی نمونه‌های مجموعه‌ی داده در سه دسته‌ی طبیعی، خوش‌خیم و بدخیم با دقت ۹۶٪ در مجموعه‌ی داده و دقت ۹۳٪ در مجموعه‌ی داده‌های تست انجام شده است. هم‌چنین معیارهای صحت/فراخوان و F1 برای نمونه‌های بدخیم در مجموعه‌ی داده برابر با ۹۹٪ گزارش شده است. این موضوع کارایی رویکرد انتقال یادگیری به روش پیشنهادی را در تشخیص درست نمونه‌های کلاس بدخیم تأیید می‌کند. از آن‌جا که شناسایی درست نمونه‌های بدخیم اهمیت زیادی دارد رویکرد پیشنهادی در طبقه‌بندی و شناسایی این نمونه‌ها بسیار موثر است. با این حال رویکرد پیشنهادی از جنبه‌ی تفکیک نمونه‌های طبیعی و خوش‌خیم نیز با بررسی ویژگی‌های متمایز کننده‌ی این دو طبقه قابل بهبود است. کاهش ابعاد بردار ویژگی و تمرکز بر ویژگی‌های متمایز کننده رویکرد آینده‌ی این پژوهش است. هم‌چنین به منظور مقایسه‌ی رویکرد پیشنهادی با سایر رویکردهای موجود، از مقالات [۳۹-۴۱] به دلیل ارزیابی روی مجموعه‌ی داده‌ی مشابه (IQ-OTH / NCCD) استفاده شده است. در مقاله‌ی [۳۹] یک شبکه‌ی CNN برای استخراج ویژگی از تصاویر سرطان ریه طراحی شده است. در این رویکرد یک شبکه‌ی عصبی با ۵ لایه‌ی کانولوشن با سایز فیلترهای متفاوت طراحی شده است. در این رویکرد دو مرحله‌ی استخراج ویژگی و طبقه‌بندی در یک مدل CNN در نظر گرفته شده است. در مدل ارائه شده به دلیل سادگی مدل امکان استخراج الگوهای ظریف و پیچیده دشوار است. در مقابل در رویکرد

پیشنهادی این مقاله به کمک یادگیری انتقالی و آموزش مدل روی مجموعه‌ی داده‌ی بسیار بزرگ امکان استخراج ویژگی‌های پیچیده میسر شده است. در پژوهش [۴۰] یک الگوریتم فراابتکاری ترکیبی و یک مدل عصبی عمیق برای طبقه‌بندی تصاویر سرطان ریه ارائه شده است. در این رویکرد برای انتخاب بهترین پارامترها و در نتیجه بهترین ترکیب وزن شبکه‌ی عصبی عمیق، الگوریتم جست‌وجوی بهینه‌سازی ابولا (EOA) انتخاب شده است. با توجه به محدود بودن تعداد نمونه‌های آموزشی در این مجموعه‌ی داده ممکن است مدل پیشنهادی با مشکل پیش‌برازش و در نتیجه عدم تعمیم‌پذیری روی نمونه‌های دیده نشده رو به رو شود. در مقاله‌ی [۴۱] به منظور طبقه‌بندی تصاویر مجموعه‌ی داده، سه مرحله شامل بهبود تصویر، تقسیم‌بندی تصویر و تکنیک‌های استخراج ویژگی در نظر گرفته شده است. سپس از ماشین بردار پشتیبان (SVM) در مرحله‌ی نهایی به عنوان طبقه‌بند برای تشخیص کلاس نرمال، خوش‌خیم یا بدخیم استفاده شده است. عمل کرد ماشین بردار پشتیبان به عنوان طبقه‌بندی کننده برای ورودی با ابعاد بالا مانند شبکه‌های عصبی عمیق چالش برانگیز است و اغلب نیاز به روش‌های کاهش ابعاد و مراحل پردازش اضافی دارد. در مقابل، مدل‌های مبتنی بر یادگیری انتقالی با توانایی آن‌ها در مدیریت کارآمد داده‌های با ابعاد بالا شناخته می‌شوند. لایه‌ی تمام اتصال برای شناسایی روابط پیچیده و غیرخطی درون داده‌ها مناسب است و در نتیجه عمل کرد مناسبی برای طبقه‌بندی تصاویر سرطان ریه با ویژگی‌های ریزدانه‌ای<sup>۱</sup> و پیچیده دارد. نتایج مقایسه‌ی رویکرد پیشنهادی این مقاله با سایر رویکردهای موجود در جدول (۲) ارائه شده است.

جدول (۲) - مقایسه‌ی رویکرد پیشنهادی با سایر رویکردها برای طبقه‌بندی تصاویر سرطان ریه روی مجموعه‌ی داده‌ی IQ-OTH/NCCD

روش	تکنیک	مجموعه‌ی داده	دقت (%)
[۳۹]	یادگیری عمیق (شبکه‌ی CNN)	IQ-OTH / NCCD	۸۶/۴۲
[۴۰]	یادگیری عمیق + بهینه‌سازی ابولا	IQ-OTH / NCCD	۸۶/۷۱
[۴۱]	یادگیری عمیق + طبقه‌بندی ماشین بردار پشتیبان	IQ-OTH / NCCD	۸۹/۸۸
روش پیشنهادی	یادگیری عمیق (انتقال یادگیری)	IQ-OTH / NCCD	۹۲/۲۴

زیادی کاهش می‌دهد. با استفاده از این ویژگی‌های تثبیت شده، مدل می‌تواند عمل کرد خود را در مقایسه با شروع از ابتدا یا استفاده از مقداردهی اولیه‌ی تصادفی بهبود بخشد. هم‌چنین لایه‌های تمام اتصال توانایی یادگیری و انطباق با داده‌های جدید در طی فرایند تنظیم دقیق در یادگیری انتقالی را دارند. این سازگاری در سناریوهایی که وظیفه‌ی هدف ممکن است دارای

یادگیری انتقالی از ویژگی‌های آموخته شده‌ی یک مدل از پیش آموزش دیده استفاده کرده که معمولاً از یک مجموعه‌ی داده‌ی بزرگ به دست آمده و این دانش را به مدل طبقه‌بندی سرطان ریه منتقل می‌کند. این رویکرد از انبوهی از اطلاعات ذخیره شده در یک مدل از پیش آموزش دیده استفاده کرده و نیاز به آموزش مجدد در مجموعه‌ی داده‌های محدود سرطان ریه را تا حد

<sup>۱</sup> Fine-Grained

- cancer: Recent advances and therapeutic challenges. *Biomedicine & pharmacotherapy = Biomedecine & pharmacotherapie*, 138. doi:10.1016/J.BIOPHA.2021.111450.
- [5] Erasmus, J. J., Nguyen, Q. N., Stewart, D. J., & Swisher, S. G. (2023). Lung Cancer. *Oncologic Imaging: A Multidisciplinary Approach*, 57–78. doi:10.1016/B978-0-323-69538-1.00007-0.
- [6] Bharati, S., Podder, P., & Mondal, M. R. H. (2020). Hybrid deep learning for detecting lung diseases from X-ray images. *Informatics in Medicine Unlocked*, 20, 100391. doi:10.1016/J.IMU.2020.100391.
- [7] Wang, Q., Shen, F., Shen, L., Huang, J., & Sheng, W. (2019). Lung Nodule Detection in CT Images Using a Raw Patch-Based Convolutional Neural Network. *Journal of Digital Imaging*, 32(6), 971. doi:10.1007/S10278-019-00221-3.
- [8] Ulaner, G. A. (2019). Lung on FDG PET/CT. *Fundamentals of Oncologic PET/CT*, 87–98. doi:10.1016/B978-0-323-56869-2.00008-9.
- [9] Bagheri, R., Haghi, S. Z., Dalouee, M. N., Nasiri, Z., & Rajabnejad, A. (2015). Evaluation of the results of surgery treatment in patients with benign lung tumors. *Lung India: Official Organ of Indian Chest Society*, 32(1), 29. doi:10.4103/0970-2113.148436.
- [10] Porto-Álvarez, J., Barnes, G. T., Villanueva, A., García-Figueiras, R., Baleato-González, S., Huelga Zapico, E., & Souto-Bayarri, M. (2023). Digital Medical X-ray Imaging, CAD in Lung Cancer and Radiomics in Colorectal Cancer: Past, Present and Future. *Applied Sciences* 2023, Vol. 13, Page 2218, 13(4), 2218. doi:10.3390/APP13042218.
- [11] Brown, M. S., Lo, P., Goldin, J. G., Barnoy, E., Kim, G. H. J., McNitt-Gray, M. F., & Aberle, D. R. (2020). Correction to: Toward clinically usable CAD for lung cancer screening with computed tomography. *European radiology*, 30(3), 1822. doi:10.1007/S00330-019-06512-1.
- [12] Gu, Y., Chi, J., Liu, J., Yang, L., Zhang, B., Yu, D., Lu, X. (2021). A survey of computer-aided diagnosis of lung nodules from CT scans using deep learning. *Computers in Biology and Medicine*, 137, 104806. doi:10.1016/J.COMPBIOMED.2021.104806.
- [13] Armato, S. G., Altman, M. B., Wilkie, J., Sone, S., Li, F., Doi, K., & Roy, A. S. (2003). Automated lung nodule classification following automated nodule detection on CT: a serial approach. *Medical physics*, 30(6), 1188–1197. doi:10.1118/1.1573210.
- [14] Kuruvilla, J., & Gunavathi, K. (2014). Lung cancer classification using neural networks for CT images. *Computer Methods and Programs in Biomedicine*, 113(1), 202–209. doi:10.1016/J.CMPB.2013.10.011.
- [15] Han, F., Wang, H., Zhang, G., Han, H., Song, B., Li, L., ... Liang, Z. (2015). Texture Feature Analysis for Computer-Aided Diagnosis on Pulmonary Nodules. *Journal of Digital Imaging*, 28(1), 99. doi:10.1007/S10278-014-9718-8.

ویژگی‌ها یا نمایش ویژگی‌های متفاوتی در مقایسه با کار اصلی مدل از پیش آموزش دیده باشد، اهمیت دارد. با تنظیم دقیق لایه‌ی تمام اتصال، آموزش الگوهای پیچیده منجر به بهبود عمل‌کرد در طبقه‌بندی تصاویر سرطان ریه در کلاس‌های نرمال، خوش‌خیم و بدخیم می‌شود.

## ۵- نتیجه‌گیری

در این پژوهش به موضوع تشخیص و طبقه‌بندی سرطان ریه از روی تصاویر سی‌تی اسکن با استفاده از روش یادگیری عمیق و یادگیری انتقالی پرداخته شده است. به این منظور مساله‌ی سرطان ریه و تشخیص آن به کمک تصویربرداری و علائم و نشانه‌های مشترک سرطان ریه معرفی و بررسی گردیده است. از آن‌جا که استفاده از الگوریتم‌های یادگیری عمیق امکان به کارگیری رویکردهای استانداردتری را در تشخیص سرطان ریه فراهم می‌کند در رویکرد پیشنهادی از شبکه‌ی از پیش آموزش داده شده‌ی الکسنت جهت تشخیص سرطان ریه استفاده شده است. رویکرد مبتنی بر یادگیری انتقالی در این روش موجب شده است که با آموزش شبکه با تعداد محدود نمونه‌های آموزشی، الگوهای موجود استنباط شود و تجزیه و تحلیل یک‌نواخت و بی‌طرفانه‌ای ارائه گردد. با توجه به وجود سه طبقه‌ی طبیعی، خوش‌خیم و بدخیم در مجموعه‌ی داده، لایه‌ی آخر تمام اتصال شبکه‌ی الکسنت حذف شده و به جای آن یک لایه‌ی جدید با سه نورون قرار گرفته است. فرایند یادگیری انتقالی برای مجموعه‌ی داده‌ی یاد شده روی رایانه‌ی شخصی تنها ۲ ثانیه زمان برده است. نتایج آزمایشگاهی دقت ۹۳٪ را روی داده‌های آزمایشی گزارش کرده است.

## ۶- مراجع

- [1] Majérus, M. A. (2022). The cause of cancer: The unifying theory. *Advances in Cancer Biology - Metastasis*, 4, 100034. doi:10.1016/J.ADCANC.2022.100034.
- [2] Thandra, K. C., Barsouk, A., Saginala, K., Aluru, J. S., & Barsouk, A. (2021). Epidemiology of lung cancer. *Contemporary oncology (Poznan, Poland)*, 25(1), 45–52. doi:10.5114/WO.2021.103829.
- [3] Nageswaran, S., Arunkumar, G., Bisht, A. K., Mewada, S., Kumar, J. N. V. R. S., Jawarneh, M., & Asenso, E. (2022). Lung Cancer Classification and Prediction Using Machine Learning and Image Processing. *BioMed Research International*, 2022. doi:10.1155/2022/1755460.
- [4] Xie, S., Wu, Z., Qi, Y., Wu, B., & Zhu, X. (2021). The metastasizing mechanisms of lung

- residual network and morphological descriptor based framework for lung cancer classification and 3D segmentation. *IET Image Processing*, 14(7), 1316–1326. doi:10.1049/IET-IPR.2019.1164/CITE/REFWORKS.
- [27] Chaunzwa, T. L., Hosny, A., Xu, Y., Shafer, A., Diao, N., Lanuti, M., ... Aerts, H. J. W. L. (2021). Deep learning classification of lung cancer histology using CT images. *Scientific Reports* 2021 11:1, 11(1), 1–12. doi:10.1038/s41598-021-84630-x.
- [28] Humayun, M., Sujatha, R., Almuayqil, S. N., & Jhanjhi, N. Z. (2022). A Transfer Learning Approach with a Convolutional Neural Network for the Classification of Lung Carcinoma. *Healthcare*, 10(6). doi:10.3390/HEALTHCARE10061058.
- [29] EL-Bana, S., Al-Kabbany, A., & Sharkas, M. (2020). A Two-Stage Framework for Automated Malignant Pulmonary Nodule Detection in CT Scans. *Diagnostics* 2020, Vol. 10, P. 131, 10(3), 131. doi:10.3390/DIAGNOSTICS10030131.
- [30] Yamashita, R., Nishio, M., Do, R. K. G., & Togashi, K. (2018). Convolutional neural networks: an overview and application in radiology. *Insights into Imaging*, 9(4), 611–629. doi:10.1007/S13244-018-0639-9/FIGURES/15.
- [31] Najafabadi, M. M., Villanustre, F., Khoshgoftaar, T. M., Seliya, N., Wald, R., & Muharemagic, E. (2015). Deep learning applications and challenges in big data analytics. *Journal of Big Data*, 2(1), 1–21. doi:10.1186/S40537-014-0007-7/METRICS.
- [32] Halder, A., Chatterjee, S., & Dey, D. (2022). Adaptive morphology aided 2-pathway convolutional neural network for lung nodule classification. *Biomedical Signal Processing and Control*, 72, 103347. doi:10.1016/J.BSPC.2021.103347.
- [33] Vaiyapuri, T., Liyakathunisa, Alaskar, H., Parvathi, R., Pattabiraman, V., & Hussain, A. (2022). Cat Swarm Optimization-Based Computer-Aided Diagnosis Model for Lung Cancer Classification in Computed Tomography Images. *Applied Sciences* 2022, Vol. 12, Page 5491, 12(11), 5491. doi:10.3390/APP12115491.
- [34] Fu, X., Bi, L., Kumar, A., Fulham, M., & Kim, J. (2022). An attention-enhanced cross-task network to analyse lung nodule attributes in CT images. *Pattern Recognition*, 126, 108576. doi:10.1016/J.PATCOG.2022.108576.
- [35] Al-Shabi, M., Shak, K., & Tan, M. (2022). ProCAN: Progressive growing channel attentive non-local network for lung nodule classification. *Pattern Recognition*, 122, 108309. doi:10.1016/J.PATCOG.2021.108309.
- [36] Gasparri, R., Santonico, M., Valentini, C., -, al, Cardis, E., Richardson, D., ... Shaju Areeckal, A. (2022). Performance analysis of texture characterization techniques for lung nodule classification. *Journal of Physics: Conference Series*, 2161(1), 012045. doi:10.1088/1742-6596/2161/1/012045.
- [16] Chaudhary, A., & Singh, S. S. (2012). Lung cancer detection on CT images by using image processing. *Proceedings: Turing 100 - International Conference on Computing Sciences, ICCS 2012*, 142–146. doi:10.1109/ICCS.2012.43.
- [17] Abdul, L., Rajasekar, S., Lin, D. S. Y., Venkatasubramania Raja, S., Sotra, A., Feng, Y., ... Zhang, B. (2021). Correction: Deep-LUMEN assay - human lung epithelial spheroid classification from brightfield images using deep learning. *Lab on a chip*, 21(2), 447–448. doi:10.1039/D0LC90127J.
- [18] Ali, S., Li, J., Pei, Y., Khurram, R., Rehman, K. U., & Rasool, A. B. (2021). State-of-the-Art Challenges and Perspectives in Multi-Organ Cancer Diagnosis via Deep Learning-Based Methods. *Cancers*, 13(21). doi:10.3390/CANCERS13215546.
- [19] Wang, L. (2022). Deep Learning Techniques to Diagnose Lung Cancer. *Cancers*, 14(22). doi:10.3390/CANCERS14225569.
- [20] Zeiser, F. A., da Costa, C. A., Ramos, G. de O., Bohn, H. C., Santos, I., & Roehe, A. V. (2021). DeepBatch: A hybrid deep learning model for interpretable diagnosis of breast cancer in whole-slide images. *Expert Systems with Applications*, 185, 115586. doi:10.1016/J.ESWA.2021.115586.
- [21] Riquelme, D., & Akhloofi, M. A. (2020). Deep Learning for Lung Cancer Nodules Detection and Classification in CT Scans. *AI 2020, Vol. 1, Pages 28-67*, 1(1), 28–67. doi:10.3390/AI1010003.
- [22] Pandit, B. R., Alsadoon, A., Prasad, P. W. C., Al Aloussi, S., Rashid, T. A., Alsadoon, O. H., & Jerew, O. D. (2023). Deep learning neural network for lung cancer classification: enhanced optimization function. *Multimedia Tools and Applications*, 82(5), 6605–6624. doi:10.1007/S11042-022-13566-9/FIGURES/7.
- [23] Hua, K. L., Hsu, C. H., Hidayati, S. C., Cheng, W. H., & Chen, Y. J. (2015). Computer-aided classification of lung nodules on computed tomography images via deep learning technique. *OncoTargets and therapy*, 8, 2015–2022. doi:10.2147/OTT.S80733.
- [24] Bruntha, P. M., Pandian, S. I. A., Anitha, J., Abraham, S. S., & Kumar, S. N. (2022). A Novel Hybridized Feature Extraction Approach for Lung Nodule Classification Based on Transfer Learning Technique. *Journal of Medical Physics*, 47(1), 1. doi:10.4103/JMP.JMP\_61\_21.
- [25] Bhandary, A., Prabhu, G. A., Rajinikanth, V., Thanaraj, K. P., Satapathy, S. C., Robbins, D. E., ... Raja, N. S. M. (2020). Deep-learning framework to detect lung abnormality – A study with chest X-Ray and lung CT scan images. *Pattern Recognition Letters*, 129, 271–278. doi:10.1016/J.PATREC.2019.11.013.
- [26] Bansal, G., Chamola, V., Narang, P., Kumar, S., & Raman, S. (2020). Deep3DScan: Deep



- using deep learning with CNN. *Medical and Biological Engineering and Computing*, 60(1), 221–228. doi:10.1007/S11517-021-02462-3/TABLES/5.
- [40] Mohamed, T. I. A., Oyelade, O. N., & Ezugwu, A. E. (2023). Automatic detection and classification of lung cancer CT scans based on deep learning and ebola optimization search algorithm. *PloS one*, 18(8), e0285796. doi:10.1371/JOURNAL.PONE.0285796.
- [41] Kareem, H. F., AL-Husieny, M. S., Mohsen, F. Y., Khalil, E. A., & Hassan, Z. S. (2021). Evaluation of SVM performance in the detection of lung cancer in marked CT scan dataset. *Indonesian Journal of Electrical Engineering and Computer Science*, 21(3), 1731–1738. doi:10.11591/IJEECS.V21.I3.PP1731-1738.
- [37] Ren, G., Li, B., Lam, S. K., Xiao, H., Huang, Y. H., Cheung, A. L. yin, ... Cai, J. (2022). A Transfer Learning Framework for Deep Learning-Based CT-to-Perfusion Mapping on Lung Cancer Patients. *Frontiers in Oncology*, 12, 883516. doi:10.3389/FONC.2022.883516/BIBTEX.
- [38] Awais, M., Long, X., Yin, B., Chen, C., Akbarzadeh, S., Abbasi, S. F., ... Chen, W. (2020). Can pre-trained convolutional neural networks be directly used as a feature extractor for video-based neonatal sleep and wake classification? *BMC Research Notes*, 13(1), 1–6. doi:10.1186/S13104-020-05343-4/FIGURES/2.
- [39] Manickavasagam, R., Selvan, S., & Selvan, M. (2022). CAD system for lung nodule detection