

Classification of lung cancer using deep learning and machine learning in order to increase accuracy in early diagnosis

Fattaneh Mohammadi Nezhad ¹, *Ph.D. student*, Mohammad Reza Mollahosseini Ardakani², *Assistant Professor*

¹ Department of Computer Engineering, Technical and Engineering Faculty, Meybod Branch, Islamic Azad University, Meybod, Iran
fatanemohamadi28@gmail.com

² Department of Computer Engineering, Technical and Engineering Faculty, Meybod Branch, Islamic Azad University, Meybod, Iran
mollahoseinimohammadreza5@gmail.com

Received: 11 August 2024

Revised: 22 September 2024

Accepted: 23 October 2024

Abstract:

Given that lung cancer is one of the most fatal and progressive types of cancer, numerous studies focus on using computer-aided systems for its detection. However, there's a need for further development of intelligent systems to achieve high sensitivity, detection, and accuracy in lung segmentation, particularly for identifying various nodule shapes. This challenge highlights the importance of studying the implementation of an AI-based framework for lung cancer detection. In this research, we utilize the LIDC database, which comprises a documented collection of chest CT scans. The proposed system, based on machine learning and deep learning approaches, includes stages of CT scan image reading, image pre-processing, segmentation, feature extraction, and classification. To prevent the loss of critical features, CT scan images are read directly in their raw DICOM file format. Subsequently, image refinement and enhancement techniques are applied using image processing. For image segmentation and the extraction of its performance metrics, Otsu's method, edge detection, and morphological operations are employed. This study proposes a cancer diagnostic model based on an active machine learning approach combined with a deep learning technique. The designed computer-aided diagnostic (CAD) model accurately identifies physiological and pathological changes in the soft tissues of lung cancer lesions, even at early stages of the disease. The results demonstrate that the proposed approach, by combining the advantages of a) the diagnostic accuracy of deep learning methods and b) the simplicity of machine learning classification, can significantly assist radiologists in the early detection of lung cancer and facilitate timely patient management.

Keywords: Feature extraction, lung cancer, support vector machine, deep learning, classification.

Corresponding Author: Dr. Mohammad Reza Mollahoseini Ardakani

Corresponding Author Address: Department of Computer Engineering, Meybod Branch, Islamic Azad University, Meybod, Iran.

طبقه بندی سرطان ریه با استفاده از روش یادگیری عمیق و یادگیری ماشین در راستای افزایش دقت در تشخیص زودهنگام

فتانه محمدی نژاد^۱، دانشجوی دکتری، محمدرضا ملاحسینی اردکانی^۲، استادیار

۱- گروه مهندسی کامپیوتر، دانشکده فنی و مهندسی، واحد میبد، دانشگاه آزاد اسلامی، میبد، ایران
fatanemohamadi28@gmail.com

۲- گروه مهندسی کامپیوتر، دانشکده فنی و مهندسی، واحد میبد، دانشگاه آزاد اسلامی، میبد، ایران
mollahoseinimohammadreza5@gmail.com

تاریخ ارسال مقاله: ۱۴۰۳/۰۵/۲۱ تاریخ بازنگری مقاله: ۱۴۰۳/۰۷/۰۱ تاریخ پذیرش مقاله: ۱۴۰۳/۰۸/۰۲

چکیده: با توجه به اینکه سرطان ریه یکی از انواع سرطان‌های مهلک و رو به پیشرفت است، مطالعات زیادی برای استفاده از سیستم‌های کامپیوتری بمنظور تشخیص سرطان ریه وجود دارد. با این حال، لازم است که بمنظور شناسایی شکل‌های مختلفی از نودل‌ها، بخش بندی ریه برای داشتن میزان بالایی از حساسیت، تشخیص و دقت، سیستم‌های هوشمند بیشتر توسعه پیدا کنند. این چالش، ضرورت مطالعه در پیاده سازی یک طرح بر پایه الگوریتم‌های هوش مصنوعی در راستای تشخیص سرطان ریه را پراهمیت می‌سازد. در این پژوهش، پایگاه داده LIDC که متشکل از یک مجموعه ای از سی تی اسکن‌های مستند مربوط به قفسه سینه است، استفاده می‌گردد. سیستم مبتنی بر روش یادگیری ماشین و روش یادگیری عمیق ارائه شده شامل مراحل خواندن تصویر سی تی اسکن، پیش پردازش تصویر، بخش بندی، استخراج ویژگی و دسته بندی است. بمنظور جلوگیری از دست رفتن ویژگی‌های مهم، تصاویر سی تی اسکن بصورت خام در قالب فایل DICOM خوانده می‌شوند. سپس، روش‌های پالایش‌سازی و بهبود تصویر به کمک پردازش تصویر استفاده می‌شود. برای بخش بندی تصویر و سپس استخراج معیارهای عملکرد آن، روش اتسو، آشکارسازی لبه و عملیات ریخت‌شناسی اعمال می‌گردد. این مطالعه یک مدل تشخیصی سرطان را بر اساس یک روش یادگیری ماشین فعال با تکنیک یادگیری عمیق پیشنهاد می‌کند. مدل طراحی به کمک کامپیوتر پیشنهادی، تغییرات فیزیولوژیکی و پاتولوژیک در بافت‌های نرم ضایعات سرطان ریه را با دقت بالا و در شرایط ابتدای بیماری شناسایی می‌کند. نتایج نشان می‌دهد که رویکرد پیشنهادی می‌تواند با توجه به استفاده از ترکیب دو مزیت (الف) دقت تشخیص در روش یادگیری عمیق و (ب) سادگی طبقه بندی در روش یادگیری ماشین، تا حد زیادی به رادیولوژیست‌ها در تشخیص زودهنگام سرطان ریه و تسهیل مدیریت به موقع بیماران کمک کند.

کلمات کلیدی: استخراج ویژگی، سرطان ریه، ماشین بردار پشتیبان، یادگیری عمیق، طبقه بندی

نام نویسنده‌ی مسئول: دکتر محمد رضا ملا حسینی اردکانی

نشانی نویسنده‌ی مسئول: میبد- دانشگاه آزاد اسلامی واحد میبد- دانشکده مهندسی برق و کامپیوتر

۱- مقدمه

سرطان ریه دومین سرطان متداول و رایج در جهان بوده و با رشد نامنظم و غیرقابل کنترل سلول در بافت ریه ایجاد می شود [۱]. این حالت های غیرطبیعی بافت ریه را معمولاً ندول یا برآمدگی های ریه می نامند. یک ندول ریه، ضایعه ای کوچک داخل ریه است و معمولاً به صورت گرد یا مارپیچی دیده می شود [۲]. تشخیص زود هنگام سرطان ریه اغلب، با روش های تصویر برداری پزشکی امکان پذیر است. سی تی اسکن یکی از رایج ترین و دقیق ترین روش های موجود برای تشخیص سرطان ریه است [۳]. سیستم های تشخیص به کمک کامپیوتر طرح ها و روش های کارآمدی هستند که برای شناسایی و تشخیص ضایعات مختلف در زمینه تشخیص سرطان ریه گسترش و توسعه یافته اند [۴]. هدف اصلی چنین سیستم هایی برای کمک به رادیولوژیست در مراحل مختلف آنالیز است. بنابراین محققان بیشتر بر روی جزئیات سیستم های تشخیص به کمک کامپیوتر خودکار برای تشخیص سرطان ریه متمرکز شده اند [۵]. بسیاری از مقالات در زمینه سیستم های تشخیص خودکار، این نوع سرطان را با استفاده از پردازش تصویر که شامل تکنیک های مختلف برای قطعه بندی، استخراج ویژگی و طبقه بندی است را تحلیل می نمایند [۶]. روش تشخیص به کمک هوش مصنوعی در حال شکل گیری است تا در تشخیص و آشکار سازی انواع زیادی از ناهنجاری های بدست آمده در طول روش های مختلف تصویر برداری، بطور گسترده ای پیاده سازی شود [۷]. مهمترین هدف سیستم های تشخیص به کمک هوش مصنوعی، افزایش دقت و کاهش زمان تشخیص است [۸]، ضمن اینکه نتیجه کلی برای سیستم های مبتنی بر هوش مصنوعی یافتن محل نودل ها و تعیین ویژگی های آنها است [۹]. در مرجع [۱۰]، تکنیک یادگیری عمیق با مقیاس کمی عدم قطعیت ترکیب شده است تا مشخص شود که آیا بیماران سرطان دارند یا نه، و در صورت وجود سرطان، به عنوان خوش خیم یا بدخیم با استفاده از مجموعه داده های توموگرافی ریه طبقه بندی انجام شده است. تکنیک استفاده شده توسعه یک مدل جدید به نام شبکه عصبی کانولوشن ۴ لایه و استفاده از روش های کمی سازی عدم قطعیت است. نتایج عملکرد مدل های شبکه عصبی استفاده شده با در نظر گرفتن عدم قطعیت دارای پیچیدگی بالای در محاسبات می باشد. در [۱۱] یک مدل تشخیصی سرطان را بر اساس ماشین بردار پشتیبان فعال پیشنهاد معرفی نموده است.

مدل طراحی به کمک کامپیوتر پیشنهادی تغییرات فیزیولوژیکی و پاتولوژیک در بافت های نرم مقطع در ضایعات سرطان ریه را شناسایی می کند. این روش نسبت به سایر روش های موجود از جمله شبکه عصبی کانولوشن که بسیار پیچیده است ساده اما نتایج در تشخیص دارای دقت پایین در تصاویر سی تی ریه برای تشخیص ندول را دارد. در یک سیستم تشخیص به کمک کامپیوتر، طبقه بندی تشخیص ندول ریه یک کار چالش برانگیز است. یک رویکرد طبقه بندی برای ندول های ریه بر اساس یادگیری ترکیبی عمیق برای رسیدگی به این چالش ها در مرجع [۱۲] ارائه شده است. در این مرجع عملکرد چندین طرح شبکه عصبی عمیق با حافظه کم برای پردازش تصویر است که در این روش در صورت بالا رفت حجم تصاویر باعث بالا رفتن زمان عملیات و کاهش دقت می باشد. در [۱۳]، از الگوریتم یادگیری عمیق هوشمند در راستای شناسایی سرطان ریه در مراحل اولیه و طبقه بندی آن استفاده از شده است. یکی از دیگر رویکردها در راستای تشخیص سرطان ریه که در [۱۴] معرفی شده تکنیک شبکه عصبی کانولوشنال است که روش مناسبی برای پردازش تصویر پزشکی، شناسایی گره های ریه، استخراج ویژگی و پیش بینی سرطان ریه است. اما هر دو روش یادگیری عمیق و شبکه عصبی کانولوشنال دارای پیچیدگی زیادی در طبقه بندی دارند و نیاز اساسی به یک روش کمکی در این راستا دیده می شود. از آنجا که سرطان ریه یکی از انواع سرطان های مهلک و رو به پیشرفت است، مطالعات زیادی برای استفاده از سیستم های مبتنی بر هوش مصنوعی بمنظور تشخیص سرطان ریه وجود دارد. با این حال، لازم است که بمنظور شناسایی شکل های مختلفی از نودل ها، بخش بندی ریه برای داشتن میزان بالایی از حساسیت، تشخیص و دقت، سیستم های مبتنی بر هوش مصنوعی بیشتر توسعه پیدا کنند. این چالش، انگیزه این مطالعه در پیاده سازی سیستم مبتنی بر هوش مصنوعی برای تشخیص سرطان ریه است. در این مطالعه، پایگاه داده LIDC که متشکل از یک مجموعه ای از سی تی اسکن های مستند مربوط به قفسه سینه است، استفاده می گردد. سیستم مبتنی بر هوش مصنوعی ارائه شده شامل مراحل خواندن تصویر سی تی اسکن، پیش پردازش تصویر، بخش بندی، استخراج ویژگی و دسته بندی است. بمنظور جلوگیری از دست رفتن ویژگی های مهم، تصاویر سی تی اسکن بصورت خام در قالب فایل DICOM خوانده می شوند. سپس، روش های پالایش سازی و بهبود تصویر بصورت پردازش تصویر استفاده می شود.


سرانجام، روش یادگیری ماشین و یادگیری عمیق که بطور وسیعی بعنوان یک طبقه بندی کننده نظارتی استفاده می‌شود، برای مرحله طبقه بندی مورد استفاده قرار می‌گیرد. شبیه سازی جهت تضمین طرح پیشنهادی براساس نرم افزار متلب انجام خواهد شد.

۲- طبقه بندی


اولین گام در تشخیص سرطان ریه، شناسایی علائم آن است. علائم سرطان ریه بطور زیادی نشان دهنده وارد شدن آسیب به ریه‌ها و کارآمدی آنها است. درد قفسه سینه و سرفه رایج ترین علائم سرطان ریه می‌باشند. با گذشت هر روز سرفه بدتر می‌شود و همچنین درد قفسه سینه افزایش پیدا می‌کند [۱۵]. این روزها، یادگیری عمیق به خاطر برتری آن از نظر دقت در هنگامی که به وسیله حجم بسیار زیادی از داده‌ها آموزش داده می‌شود، بسیار مورد توجه قرار گرفته است. هم اکنون الگوریتم‌های یادگیری ماشین با سرعت کمتری حجم عظیمی از داده‌ها را نسبت به آنچه که انتظار می‌رفت مورد کاوش قرار می‌دهند. یادگیری عمیق می‌تواند این مشکل را از طریق معماری لایه‌های پنهان خود حل نماید. الگوریتم‌های یادگیری عمیق کارکرد مغز انسان را شبیه سازی می‌کنند. در معماری‌های سنتی و متعارف یادگیری ماشین، لازم است که ویژگی‌های مهم توسط یک متخصص این حوزه شناسایی شوند تا پیچیدگی داده‌ها کاهش و دقت افزایش یابد. مهم ترین مزیت معماری‌های یادگیری عمیق توانایی و قابلیت آن در یادگیری ویژگی‌های سطح بالا از روی داده‌ها هنگامی‌ست که این ویژگی‌ها در حجم فوق العاده زیادی از داده‌ها نهفته شده باشند و همچنین عدم نیاز به متخصص در این حوزه برای استخراج ویژگی‌های مهم است [۱۶، ۱۷]. شکل‌های ۱ و ۲ به ترتیب فرآیند طبقه بندی توسط معماری‌های یادگیری ماشین و یادگیری عمیق را نشان می‌دهند.

۳- مدل سازی الگوریتم ترکیبی


الگوریتم یادگیری ترکیبی عمیق مزایای تکنیک‌های سنتی یادگیری ماشین و یادگیری عمیق را با هم ادغام می‌نماید. اگرچه مدل‌های یادگیری عمیق معمولاً از لحاظ طبقه بندی سیگنال‌های فونوکاردیوگرام و الکتروکاردیوگرام نسبت به مدل‌های یادگیری ماشین خروجی بهتری بدست می‌دهند، اما اگر این دو معماری برای ایجاد یک مدل طبقه بندی واحد با یکدیگر در آمیخته شوند، می‌توانند طبقه بندی بهینه‌ای را حاصل نمایند. مدل‌های یادگیری ترکیبی عمیق از نظر زمان محاسبه در مقایسه با الگوریتم‌های سنتی یادگیری عمیق برتری دارند [۱۷، ۱۸]. مدل‌های یادگیری ترکیبی عمیق سریع تر هستند و در مقایسه با مدل‌های یادگیری عمیق تنها، نیازی به زمان اضافی برای پردازش ندارند. همچنین، مدل‌های یادگیری ترکیبی عمیق نیازی به تکنیک‌های مهندسی ویژگی که تمامی الگوریتم‌های سنتی یادگیری ماشین به آنها وابسته هستند، ندارند. در مرجع [۱۶]، یک معماری یادگیری ترکیبی عمیق بر روی چهار مجموعه داده مختلف از جمله مجموعه داده کوچکی از فعالیت‌های انسان، مجموعه داده بزرگی از فعالیت‌های انسانی، مجموعه داده‌های کوچکی از احساسات، و مجموعه داده ای برای تحلیل احساسات با استفاده از سیگنال سی تی اسکن ریه، سیگنال‌های فیزیولوژیکی و تصاویر پیاده سازی شده است. شکل ۳، طرح معماری پیشنهادی ترکیبی عمیق را نشان می‌دهد. این معماری دارای چهار لایه کانولوشن یک بعدی به ترتیب با ۲۵۶، ۵۱۲، ۱۰۲۴ و ۲۰۴۸ فیلتر می‌باشد. تمام لایه‌ها دارای هسته یک اندازه به اندازه ۲ هستند. هر لایه کانولوشن از یک تابع فعال سازی ReLU استفاده می‌کند، و هر ماکزیمم لایه ادغام دارای اندازه ۲ است. یک لایه dropout با نرخ dropping ده درصد به هر لایه کانولوشن متصل می‌شود تا مشکل overfitting برطرف شود. بعد از کانولوشن و ماکزیمم لایه ادغام، ویژگی‌های آموزش دیده در داخل یک بردار واحد قرار می‌گیرند و از یک لایه کاملاً متصل با ۵۱۲ فیلتر عبور داده می‌شوند. لایه کاملاً متصل نیز از تابع فعال سازی ReLU با نرخ dropping بیست درصد استفاده می‌کند تا مسئله overfitting برطرف شود. لایه کاملاً متصل به عنوان یک بافر بین ویژگی‌های آموزش دیده و خروجی عمل می‌کند. تابع هزینه به وسیله بهینه ساز adam کمینه می‌گردد. تعداد تکرارهای آموزش، اندازه دسته، و نرخ یادگیری به ترتیب برابر ۱۰۰، ۶۴ و ۰.۰۰۰۱ قرار داده می‌شوند. بعد از بهینه سازی و آموزش یادگیری عمیق، معیارهای کارای آموزش دیده از لایه کاملاً متصل از طبقه بندی کننده یادگیری ماشین عبور داده می‌شوند تا پیش بینی نهایی حاصل شود.



شکل (۱): فرآیند طبقه بندی الگوریتم‌های یادگیری ماشین [۱۶]



شکل (۲): فرآیند طبقه بندی الگوریتم‌های یادگیری عمیق [۱۶]



شکل (۳): معماری مدل یادگیری ترکیبی عمیق برای طبقه بندی سرطان ریه تصویر سی تی اسکن از ریه

۴- ارزیابی معیارهای عملکرد و استخراج ویژگی

در مرحله آزمون از پایگاه داده LIDC استفاده می‌شود. زیرمجموعه ای از پایگاه داده که مجموعاً دارای ۲۷۱ تصویر است، به دو گروه مساوی تقسیم می‌شود. ۱۳۶ تصویر سی تی اسکن ریه که شامل ۲۵ تصویر با نودل و ۱۱۱ تصویر بدون نودل است، برای مرحله آزمون استفاده می‌شود. این سیستم که با ۱۳۵ تصویر سی تی اسکن ریه آموزش دیده شده است، با کل پایگاه داده و همچنین با ۱۳۶ تصویر سی تی اسکن ریه متفاوت از آنها آزمون شده است. عملکرد پیاده سازی و طبقه بندی با اندازه گیری‌های آماری که حساسیت، صحت و دقت می‌باشند، ارزیابی می‌شود. این اندازه گیری‌های آماری بصورت زیر فرمول بندی می‌شوند:

$$Precision = \frac{TP_s}{TP_s + FP_s} \quad (1)$$

$$Specificity = \frac{TN_s}{TP_s + FN_s} \quad (2)$$

$$Accuracy = \frac{TP + TN}{(P + N)} \quad (3)$$

$$P = TP + FN \quad (4)$$

$$P = TP + FN \quad (5)$$

TP یا مثبت درست: در تصویر نودل وجود دارد و بطور صحیحی تشخیص داده شده است که نودل وجود دارد. **FP** یا مثبت نادرست: در تصویر نودل وجود ندارد اما تشخیص داده شده است که نودل وجود دارد. **TN** یا منفی درست: در تصویر نودل وجود ندارد و بطور صحیحی تشخیص داده شده است که نودل وجود ندارد. **FN** یا منفی نادرست: در تصویر نودل وجود دارد ولی تشخیص داده شده است که نودل وجود ندارد. ویژگی‌ها بصورت (سطح، محیط)، (سطح، خروج از مرکز)، (محیط، خروج از مرکز)، (سطح، محیط، خروج از مرکز) گروه بندی می‌شوند و برای اندازه گیری کارایی طبقه بندی با این ویژگی‌های انتخابی در مرحله آزمون مورد استفاده قرار می‌گیرند.

استخراج ویژگی در آشکارسازی و جدا کردن ناحیه مطلوب از تصاویر سی تی اسکن ریه که از تکنیک‌های پردازش تصویر و الگوریتم‌ها استفاده می‌نماید، بسیار مهم است. مرحله استخراج ویژگی، توسط توابع regionprops و graycoprops از توابع مربوط به جعبه ابزار پردازش تصویر در متلب، برای پیش بینی وجود احتمال سرطان ریه انجام می‌شود. سطح، خروج از مرکز، و محیط بعنوان مجموعه ویژگی‌ها انتخاب شده اند. تعاریف این ویژگی‌ها از متلب اقتباس شده است: سطح (Area): یک مقدار اسکالر را بدست می‌دهد که تعداد حقیقی پیکسل‌ها را در ناحیه مورد نظر تعریف می‌کند [۱۲].

تعداد کل پیکسل‌های تصویر = Width × Height = 512 × 512

Pixel1 = 0.264 mm Size of ROI = S = [P × 0.264 mm²]

P = تعداد کل پیکسل‌ها در منطقه مورد نظر


خروج از مرکز (Eccentricity): یک مقدار اسکالر را بدست می‌دهد که خروج از مرکزی بیضی را تعریف می‌کند. ناحیه و خروج از مرکز هر دو دارای ممان‌های دوم یکسان می‌باشند. این نسبت فاصله میان طول قطر اصلی و مرکز بیضی است. محدوده این مقدار اسکالر بین صفر و یک است. می‌توان نتیجه گرفت که اگر این مقدار صفر باشد، دایره است و اگر یک باشد، یک خط است.

محیط (Perimeter): یک مقدار عددی را بدست می‌دهد که می‌تواند بعنوان فاصله دور مرز ناحیه مورد نظر تعریف شود. با فاصله میان هر جفت پیکسل مجاور در اطراف مرز ناحیه مورد نظر، مقدار محیط می‌تواند پیدا شود:

$$P = |S_n S_1| + \sum_{i=1}^{n-1} |S_i S_{i+1}| \quad (6)$$

۵- پیش پردازش

تداخل و پدیده‌های دیگر که توسط نویز و درخشش ضعیف ایجاد می‌شوند، کیفیت و کنتراست تصاویر پزشکی را تحت تاثیر قرار می‌دهند. در این مطالعه، تصاویر سی تی اسکن بصورت فرمت خام DICOM گرفته می‌شوند و تداخل در تصاویر تعیین می‌گردد. بنابراین، بمنظور کاهش نویز salt and pepper و ضمن حفظ لبه‌ها، روش پردازش تصویر فیلتر Median اعمال می‌گردد. همچنین، بر روی تصویر مقیاس خاکستری، تنظیم کنتراست انجام می‌شود. در شکل ۴، تصاویر سی تی اسکن ریه نشان داده شده است. این فرآیند، یکی از مراحل اصلی سیستم مبتنی بر هوش مصنوعی است، زیرا که بهبود کیفیت تصاویر پزشکی، تحلیل بیشتری شامل آنالیز تصویر، تشخیص ویژگی و غیره را در پی خواهد داشت. از دست رفتن اطلاعات مهم راجع به تصویر، موفقیت تحلیل بیشتر تصویر را بطور منفی تحت تاثیر قرار می‌دهد، در نتیجه حفظ ساختار اصلی تصویر بخاطر بهبود تصویر باید در نظر گرفته شود.



ب

الف

شکل (۴): تصویر ریه در مرحله پیش پردازش، الف) تصویر سی تی اسکن ریه بصورت خام، ب) بعد از اعمال فیلتر Median و تنظیم کنتراست


۵-۱ تحلیل داده‌ها

در مرحله یادگیری و آموزش از پایگاه داده LIDC استفاده می‌شود. زیر مجموعه پایگاه داده که بطور تصادفی شکل می‌گیرد، شامل ۲۷۱ تصویر سی تی اسکن از ریه است. تصاویر مقیاس خاکستری در فرمت DICOM که برای تصاویر پزشکی استاندارد است، دارای اندازه ۵۱۲*۵۱۲ پیکسل است. محل‌های نودل‌ها بصورت یک اطلاعات ground truth که توسط رادیولوژیست تشخیص داده شده است، نیز فراهم می‌گردد. کل تعداد نودل‌ها در پایگاه داده برابر ۴۹ عدد می‌باشد. به منظور تضمین یک نتیجه بی غرض، تمام تصاویر بطور تصادفی از پایگاه داده انتخاب می‌شوند. زیر مجموعه پایگاه داده که جمعا دارای ۲۷۱ تصویر است، به دو گروه تقسیم می‌شود. ۵۰٪ از تصاویر سی تی اسکن ریه که دارای نودل می‌باشند و ۵۰٪ که دارای نودل نمی‌باشند، بعنوان مجموعه داده آموزشی استفاده می‌شوند. مرحله آموزش یک فرآیند تکراری در طبقه بندی است اما برای مرحله آموزش ۱۳۵ تصویر سی تی اسکن ریه استفاده می‌شود که شامل ۲۴ تصویر با نودل و ۱۱۱ تصویر بدون نودل است.

۵-۲ تحلیل نتایج

فرآیند تقسیم بندی با هدف دستیابی به بخش بندی کردن تصویر به نواحی مختلف است. استخراج معیارهای عملکرد، نمایش تصویر و اندازه گیری‌های تصویر در تصاویر پزشکی، بطور غالب از عملیات بخش بندی و تقسیم بندی تصویر استفاده می‌کنند.

برای نیازمندی خاصی از این پیاده سازی، فرآیند باینری سازی همراه با فرآیند آستانه گذاری سراسری، تشخیص لبه و عملیات ریخت شناسی که دارای کاربرد اساسی در بهبود و بخش بندی تصویر می‌باشند، بطور رایج بکار گرفته می‌شوند. تصاویر سی تی اسکن ریه مورد مطالعه دارای دو نوع پیکسل با تراکم‌های متفاوت می‌باشند. با استفاده از روش آستانه گذاری سراسری (روش Otsu) که یک ابزار مقاوم برای بخش بندی تصویر است، تصاویر مقیاس خاکستری به باینری تبدیل می‌شوند. تصویر بدست آمده (باینری) در مقایسه با تصویر مقیاس خاکستری دارای مزایایی نظیر داشتن فضای کوچکتر در حافظه و همچنین یک افزایش قابل ملاحظه در سرعت پردازش تصویر است. در نرم افزار متلب، تابع gray thresh از روش آستانه گذاری سراسری Otsu برای تصویر استفاده می‌کند.




ب

الف

شکل (۵): تصویر ریه بعد از روش آستانه گذاری سراسری Otsu، (الف) تصویر ریه بعد از فیلترینگ Median و تنظیم کنتراست، (ب) تصویر ریه بعد از آستانه گذاری Otsu

تراکم وضوح که در سی تی اسکن از مقدار آستانه بزرگتر باشند، مطابق شکل ۵، به سفید و مابقی پیکسل‌ها به سیاه تبدیل می‌شوند. بعد از اعمال روش بخش بندی آستانه گذاری، برای تشخیص مرزهای تصاویر سی تی اسکن ریه، تکنیک آشکارسازی لبه بکار گرفته می‌شود. بعنوان یک اقدام محتاطانه برای جلوگیری از از دست رفتن نودل‌های چسپیده به مرزها، عملگر گرادیان همراه با روش Prewitt برای آشکار سازی، لبه‌های برجسته و مقادیری از تصویر که خارج از مرزها بعنوان نواحی یکنواخت پذیرفته می‌شود، اعمال می‌گردد. با پاک کردن مرزها و پر کردن نواحی آشکار شده شکل ۶ الف، شکل ۶ ب حاصل می‌شود. در نهایت برای تشکیل یک ماسک، تصاویر مقیاس خاکستری ضمن حذف خطوط غیر ضروری پیرامون به باینری تبدیل می‌شوند. با اعمال روش‌های مختلف پردازش تصویر به تصویر سی تی اسکن ریه، یک تصویر باینری همراه با آستانه گذاری سراسری مطابق شکل ۸ الف تولید می‌شود. سپس تصویر باینری در ماسک نشان داده شده در شکل ۷ ب ضرب می‌شود تا تصویر باینری ریه با خطوط پیرامون غیر ضروری حذف شده مطابق شکل ۷ ج تولید شود. این مراحل با عملیات ریخت شناسی نظیر bwmorph، bwareaopen، تا زمان حذف شدن نواحی نامطلوب مانند سیاه رگ‌ها، بافت‌ها نرم و اشیای شبیه نودل‌ها ادامه پیدا می‌کند.




(ج)

(ب)

(الف)

شکل (۶): تشکیل یک ماسک تصویر سی تی اسکن ریه، (الف) آشکار سازی لبه توسط عملگر گرادیان همراه با روش Per-witt، (ب) پاک کردن مرزها و پر کردن تصویر باینری، (ج) ماسک تصویر سی تی اسکن ریه



(ج)

(ب)

(الف)

شکل (۷): مرحله نهایی بخش بندی تصویر سی تی اسکن ریه، (الف) تصویر با خطوط پیرامون حذف شده، (ب) تصویر ریه تقسیم بندی شده، (ج) نودل یا شی شبیه نودل


۳-۵ نتایج حاصل از مرحله انتخاب ویژگی

هدف از این مرحله، انتخاب زیر مجموعه ای از ویژگی‌ها است که طبقه بندی بهتری را بدست دهند. بنابراین، با حذف ویژگی‌های نامربوط، ممکن است که دقت افزایش پیدا کند. همچنین، این به کاهش زمان آموزش، جلوگیری از برازش بیش از اندازه و ایجاد کلیت بهتری کمک می‌کند. ویژگی‌ها بصورت (سطح، محیط)، (سطح، خروج از مرکز)، (محیط، خروج از مرکز)، (سطح، محیط، خروج از مرکز) گروه بندی می‌شوند و برای اندازه گیری کارایی طبقه بندی با معیارهای کارای انتخاب شده در مرحله آموزش استفاده می‌شوند. شکل ۸ مربوط به طبقه بندی ویژگی‌های انتخاب شده، ایجاد می‌شوند.

۴-۵ مقایسه نتایج مرحله آزمون

جدول ۱، ماتریس درهم ریختگی گرفتن را برای روش یادگیری ماشین و روش یادگیری عمیق با استفاده از هسته RBF با کل پایگاه داده نشان می‌دهد. با کل پایگاه داده تصاویر که شامل ۴۹ تصویر با نودل و ۲۲۲ تصویر بدون نودل است، آزمون انجام

شده است. احتمال سیستم در تشخیص مثبت بودن نودل برای زمانی که نودل وجود دارد برابر ۹۵.۹۲٪ است و احتمال سیستم در تشخیص منفی بودن نودل برای زمانی که نودل وجود ندارد برابر ۹۸.۶۵٪ است.



شکل (۸): طبقه بندی ویژگی‌های (محیط، خروج از مرکز) در مرحله آموزش

جدول (۱): روش یادگیری ماشین و روش یادگیری عمیق با استفاده از هسته RBF با کل پایگاه داده

TP	FN	FP	TN	حساسیت	میزان صحت	دقت
a	b	c	d	$a/(a+b)$	$d/(c+d)$	$(a+d)/(P+N)$
47	2	3	219	95.92	98.65	98.15

جدول ۲، ماتریس درهم ریختگی گرفتن را برای روش یادگیری ماشین و روش یادگیری عمیق با استفاده از هسته RBF با بخشی از مجموعه داده آزمون نشان می‌دهد. بعد از فرآیند آموزش تنها با استفاده از مجموعه داده‌های آزمون که شامل ۲۵ تصویر با نودل و ۱۱۱ تصویر بدون نودل است، آزمون انجام شده است. در این حالت، احتمال تشخیص مثبت بودن وجود نودل برای زمانی که نودل وجود دارد برابر ۹۲٪ و احتمال تشخیص منفی بودن وجود نودل برای زمانی که نودل وجود ندارد برابر ۹۷.۳٪ است.


جدول (۲): ماشین برداری پشتیبان و روش یادگیری عمیق با استفاده از هسته RBF با بخشی از پایگاه داده

TP	FN	FP	TN	حساسیت	میزان صحت	دقت
a	b	c	d	$a/(a+b)$	$d/(c+d)$	$(a+d)/(P+N)$
23	2	3	108	92	97.3	97

جدول ۳، ماتریس درهم ریختگی گرفتن را برای روش یادگیری ماشین و روش یادگیری عمیق با استفاده از هسته مربعی یا درجه دوم با بخشی از مجموعه داده آزمون نشان می‌دهد. بعد از فرآیند آموزش تنها با استفاده از مجموعه داده‌های آزمون که شامل ۲۵ تصویر با نودل و ۱۱۱ تصویر بدون نودل است، آزمون انجام شده است. در این حالت، احتمال تشخیص مثبت بودن وجود نودل برای زمانی که نودل وجود دارد برابر ۶۰٪ و احتمال تشخیص منفی بودن وجود نودل برای زمانی که نودل وجود ندارد برابر ۹۳.۶۹٪ است. شکل ۹ طبقه بندی ویژگی‌ها (محیط، خروج از مرکز) مربوط به روش‌های مختلف جهت میزان دقت را نشان می‌دهد.

جدول (۳): روش یادگیری ماشین و روش یادگیری عمیق با استفاده از هسته مربعی با بخشی از پایگاه داده

TP	FN	FP	TN	حساسیت	میزان صحت	دقت
a	b	c	D	$a/(a+b)$	$d/(c+d)$	$(a+d)/(P+N)$
15	10	7	104	60	93.69	87.5



شکل (۹): طبقه بندی ویژگی‌های (محیط، خروج از مرکز) در مرحله آزمون

جدول ۴، ماتریس درهم ریختگی گرفتن را برای روش یادگیری ماشین و روش یادگیری عمیق با استفاده از هسته خطی با بخشی از مجموعه داده آزمون نشان می‌دهد. بعد از فرآیند آموزش تنها با استفاده از مجموعه داده‌های آزمون که شامل ۲۵ تصویر با نودل و ۱۱۱ تصویر بدون نودل است، آزمون انجام شده است.

جدول (۴): روش یادگیری ماشین و روش یادگیری عمیق با استفاده از هسته خطی با بخشی از پایگاه داده

TP	FN	FP	TN	حساسیت	میزان صحت	دقت
a	b	c	D	$a/(a+b)$	$d/(c+d)$	$(a+d)/(P+N)$
18	7	5	106	72	94.59	91

در این حالت، احتمال تشخیص مثبت بودن وجود نودل برای زمانی که نودل وجود دارد برابر ۷۲٪ و احتمال تشخیص منفی بودن وجود نودل برای زمانی که نودل وجود ندارد برابر ۹۴.۵۹٪ است. جدول ۵، اندازه گیری‌های آماری ویژگی‌های انتخاب شده را بر حسب هسته‌های ماشین برداری پشتیبان و روش یادگیری عمیق که در مرحله آزمون پیدا شدند، نشان می‌دهد. آزمایش‌ها نشان دادند که هسته RBF بهترین نتیجه را برای طبقه بندی بدست می‌دهد. تعیین می‌شود که رگ‌های ریه، اقلیت مشخصه مثبت نادرست (FP) را ایجاد می‌کنند در حالی که نودل‌های کوچک، اقلیت مشخصه منفی نادرست را ایجاد می‌نمایند.

جدول (۵): کارایی هسته‌های روش یادگیری ماشین و روش یادگیری عمیق

هسته SVM	حساسیت	میزان صحت	دقت
RBF	92	97.3	97
مربعی	60	93.69	87.5
خطی	72	94.59	91

در مرجع [۱۹]، طبقه‌بندی‌کننده‌های مختلفی بر روی مجموعه داده‌ای که با استفاده از رویکرد پارامتری آماری برای تعیین مراحل سرطان شامل هفت ویژگی اعمال شده است. در مرجع [۱۹]، از چهار طبقه‌بندی‌کننده مختلف استفاده شده است که از میان آنها SVM با دقت ۷۸/۹۵ در رویکرد آماری بهترین عملکرد را در دیگر مراجع داشته است اما استفاده از روش هسته‌های یادگیری ماشین و روش یادگیری عمیق دقتی معادل ۹۷ درصد را داشته که بالاترین عملکرد را دارد. جدول ۶ نتایج به دست آمده از طبقه بندی کننده های مختلف را مورد مقایسه قرار گفته است.

جدول (۶): جدول مقایسه عملکرد

دقت	میزان صحت	طبقه بندی
78.95	0.77	[19]SVM
68.42	0.47	[20]KNN
73.68	0.72	[19]روش گوسی
97	0.973	ماشین برداری پشتیبان و روش یادگیری عمیق

۶- نتیجه گیری

روش ماشین و روش یادگیری عمیق همانطور که چندین مطالعه نشان داده اند، بهترین عملکرد را در مرحله طبقه بندی تصویر بدست می‌دهد. زیر مجموعه ای از پایگاه داده که مجموعاً شامل ۲۷۱ تصویر سی تی اسکن ریه است، به دو گروه تقسیم بندی شد. گروه اول ۵۰٪ از تصاویر سی تی اسکن ریه که شامل نودل می‌باشند و گروه دوم ۵۰٪ از تصاویر سی تی اسکن ریه که فاقد نودل می‌باشند، برای مجموعه داده‌های آموزشی استفاده می‌شوند. به همین ترتیب، ۵۰٪ از تصاویر سی تی اسکن ریه که شامل نودل می‌باشند و ۵۰٪ دیگر که شامل نودل نمی‌باشند، برای مجموعه داده‌های آزمون مورد استفاده قرار می‌گیرند. عملکرد پیاده سازی و طبقه بندی با استفاده از اندازه گیری‌های آماری نظیر حساسیت، دقت و میزان صحت عملکرد مورد آزمون و آزمایش قرار گرفته است. دقت طبقه بندی کننده بر حسب اصول درستی توسط ماتریس درهم ریختگی گرفتن اندازه گیری شده است. این سیستم مبتنی بر هوش مصنوعی دارای میزان دقت ۹۷٪ و حساسیت ۹۲٪ است. مشخص شد که رگ‌های ریه، اقلیت مثبت نادرست را ایجاد می‌کنند و نودل‌های کوچک، اقلیت منفی نادرست را ایجاد می‌کنند. افزایش دقت سیستم پیاده سازی شده با استفاده از پایگاه‌های داده مختلف و بزرگتر برای آموزش ممکن است.

References

مراجع

- [1] M. Islam, R. Rab, "Analysis of CT scan images to predict lung cancer stages using image processing techniques", in *2019 IEEE 10th Annual Information Technology*, 2019, pp. 943-953.
- [2] A. Singareddy, M. E. Flanagan, P. P. Samson, S. N. Waqar, "Trends in stage I lung cancer", *Clinical Lung Cancer*, vol. 31, no. 9, pp. 114-119, 2023.
- [3] M. S. Islam, R. Islam, "A Critical Survey on Developed Reconstruction Algorithms for Computed Tomography Imaging from a Limited Number of Projections", *International Journal of Image and Graphics*, vol. 23, no. 4, pp. 235-243, 2023.
- [4] T. Nakra, A. Mehta, A. Bal, A. Nambirajan, D. Mishra, D. P. Midha, P. Gupta, et al. "Epidermal growth factor receptor mutation status in pulmonary adenocarcinoma: Multi-institutional data discussion at national conference of "Lung Cancer Management in Indian context"', *Current Problems in Cancer*, vol. 44, no. 3, pp. 751-762, Sep. 2020.
- [5] T. Pereira, C. Freitas, J.L. Costa, J. Morgado, F. Silva, E. Negrão, B.F. de Lima et al., "Comprehensive Perspective for Lung Cancer Characterisation Based on AI Solutions Using CT Images", *Journal of Clinical Medicine*, vol. 10, no. 1, pp. 339-346, 2020.
- [6] W. J. Sori, J. Feng, A. W. Godana, S. Liu, "DFD-Net: lung cancer detection from denoised CT scan image using deep learning", *Frontiers of Computer Science*, vol. 15, no. 3, pp. 425-438, 2021.

- [7] F. Bray, J. Ferlay, I. Soerjomataram, R. L. Siegel, L. A. Torre, A. Jemal, "Global cancer statistics 2018", *A Cancer Journal for Clinicians*, vol. 68, no. 6, pp. 394-424, 2018.
- [8] M. Reck, S. Dettmer, H. U. Kauczor, R. Kaaks, "Lung cancer screening with low-dose computed tomography: current status in Germany", *Deutsches Ärzteblatt International*, vol. 120, no. 23, pp. 387-392, 2023.
- [9] L. Guo, Y. Yu, F. Yang, W. Gao, "Accuracy of baseline low-dose computed tomography lung cancer screening: a systematic review and meta-analysis", *Chinese Medical Journal*, vol. 136, no. 9, pp. 1047-1056, 2023.
- [10] S. Üzülmöz, M. A. Çifçi, "Early diagnosis of lung cancer using deep learning and uncertainty measures", *Journal of the Faculty of Engineering and Architecture of Gazi University*, vol. 39, no. 1, pp. 385-400, 2024.
- [11] I. Shafi, S. Din, A. Khan, I. D. L. T. Díez, "An Effective Method for Lung Cancer Diagnosis from CT Scan Using Deep Learning-Based Support Vector Network", *Journal of the Faculty of Engineering, Süleyman Demirel University*, vol. 14, no. 1, pp. 1-18, 2022.
- [12] R. Mothkur, B. N. Veerappa, "Classification of lung cancer using lightweight deep neural networks", *Procedia Computer Science*, vol. 71, no. 1, pp. 1869-1877, 2023.
- [13] N. S. Reddy and V. Khanaa, "Intelligent deep learning algorithm for lung cancer detection and classification", *Bulletin of Electrical Engineering and Informatics*, vol. 35, no. 3, pp. 2089-2096, 2023.
- [14] D. Moitra and R. K. Mandal, "Classification of non-small cell lung cancer using one-dimensional convolutional neural network", *Expert Systems with Applications*, vol. 30, no. 2, pp. 852-863, 2020.
- [15] Z. Yu, P. Ni, H. Yu, T. Zuo, and Y. Liu, "Effectiveness of a single low-dose computed tomography screening for lung cancer: A population-based perspective cohort study in China", *International Journal of Cancer*, vol. 154, no. 4, pp. 659-669, 2024.
- [16] M. T. H. Chowdhury, "Application of Signal Processing and Deep Hybrid Learning in Phonocardiogram and Electrocardiogram Signals to Detect Early Stage Heart Diseases", M.Sc. dissertation, June 2022.
- [17] G. A. H. Alabandi, "Combining Deep Learning with Traditional Machine Learning to Improve Classification Accuracy", M.Sc. dissertation, Department of Computer Science, Texas State University, 2017.
- [18] A. Bhattacharya, "Deep Hybrid Learning — a fusion of conventional ML with state of the art DL", in *GIDS.AI/ML and Data Live*, 2020, pp. 425-437.
- [19] D. Sengupta *et al.*, "A deep hybrid learning pipeline for accurate diagnosis of ovarian cancer based on nuclear morphology", *PLOS ONE*, vol. 17, no. 1, pp. 1-20, Jan. 2022.
- [20] M. Islam, R. Rab, "Analysis of CT scan images to predict lung cancer stages using image processing techniques", in *2019 IEEE 10th Annual Information Technology Conference (ITech)*, 2019, pp. 961-967.