

تشخیص، دسته‌بندی و اندازه‌گیری اتوماتیک ندول‌های ریوی با استفاده از دسته‌بند ترکیبی در تصاویر سی تی اسکن

مرجان نادران طحان^۱، استادیار؛ امیر جمشیدنژاد^۲، استادیار؛ نگار میردريکوند^۳، دانشجوی کارشناسی ارشد هوش مصنوعی

۱- دانشکده مهندسی - دانشگاه شهید چمران اهواز - اهواز - ایران - m.naderan@scu.ac.ir

۲- دانشکده پیراپزشکی - دانشگاه علوم پزشکی جندی شاپور - اهواز - ایران - jamshidnejad-a@ajums.ac.ir

۳- دانشکده مهندسی - دانشگاه شهید چمران اهواز - اهواز - ایران - nmirdrikvand@yahoo.com

چکیده: سرطان ریه یکی از سخت‌ترین و خطرناک‌ترین سرطان‌ها به شمار می‌رود که می‌تواند در مراحل اولیه، به صورت یک جرم کوچک با قطری کمتر از سه سانتی متر، بنام ندول، مشاهده شود. این ندول‌ها به دو دسته‌ی خوش‌خیم و بدخیم یا سرطانی تقسیم‌بندی می‌شوند. در این مقاله، یک سیستم تشخیصی جهت شناسایی و دسته‌بندی ندول‌های ریوی پیشنهاد می‌شود، که در فاز اول ریه‌ها از تصاویر سی‌تی‌اسکن طی عملیات ناحیه‌بندی کانتور فعال جدا می‌شوند. سپس براساس ویژگی‌های سیفت (SIFT)، دسته‌بند بگینگ پیشنهادی تصاویر ریه را به دو دسته سالم و بیمار دسته‌بندی می‌کند. در فاز دوم، براساس یک ناحیه‌بندی گراف کات تمام خودکار، ندول‌ها از تصاویر ریه استخراج شده و قطر آن‌ها اندازه‌گیری می‌شود. در پایان، ندول‌ها براساس اندازه و ویژگی‌های بافتی تصاویر (هارالیک) به دو دسته خوش‌خیم و بدخیم طبقه‌بندی می‌شوند. جهت ارزیابی عملکرد روش پیشنهادی، از تصاویر مجموعه داده LIDC استفاده گردید و کارایی آن در شناسایی ندول‌ها و در مقایسه با روش‌های دیگر با معیار دقت ۹۷٪ و از نظر طبقه‌بندی ندول‌ها به خوش‌خیم و بدخیم با دقت ۹۶٪ قابل رقابت است.

واژه‌های کلیدی: ندول‌های ریوی، تصاویر سی تی اسکن، ناحیه‌بندی گراف کات، ویژگی سیفت، ویژگی‌های هارالیک، دسته‌بند ترکیبی.

Automatic Detection, Classification and Measurement of Lung Nodules using Combined Classifiers in CT Scan Images

Marjan Naderan¹, Assistant Professor; Amir Jamshidnejad², Assistant Professor; Negar Mirdrikvand³, M.Sc. Student of Artificial Intelligence

1- Department of Computer Engineering, Shahid Chamran University of Ahvaz, Ahvaz, Iran, Email: m.naderan@scu.ac.ir

2- Department of Medical Informatics, Ahvaz Jundishapur University of Medical Sciences, Ahvaz, Iran, Email: jamshidnejad-a@ajums.ac.ir

3- Department of Computer Engineering, Shahid Chamran University of Ahvaz, Ahvaz, Iran, Email: nmirdrikvand@yahoo.com

Abstract: Lung cancer is one of the hardest and most dangerous types of known cancer in the world which can be detected in its beginning stages as a small mass of tissue, less than 3 cm in diameter, called a nodule. These nodules are classified to two classes of benign or malignant. In this paper, a detection system for detection and classification of lung nodules is proposed which in the first phase, lungs are separated from the CT scan images according to the active contour segmentation method. Next, based on the SIFT features the proposed Bagging classifier, classifies the lung images into two classes of patient and healthy. In the second phase, according to a fully automatic Graph-Cut segmentation method the nodules are extracted from patient images and their diameters are measured. Finally, nodules are classified to two classes of benign and malignant based on their size and texture Haralick features. To evaluate the proposed method, images of the LIDC database are used and its performance in detection of nodules compared to other methods has an accuracy of 97% and in classification of nodules to benign and malignant an accuracy of 96% is reached.

Keywords: Lung nodules, CT images, Graph-cut segmentation method, SIFT features, Haralick features, Combined classifiers.

تاریخ ارسال مقاله: ۱۳۹۶/۱۱/۰۳

تاریخ اصلاح مقاله: ۱۳۹۷/۰۲/۲۷

تاریخ پذیرش مقاله: ۱۳۹۷/۰۶/۱۳

نام نویسنده مسئول: مرجان نادران طحان

نشانی نویسنده مسئول: دانشکده مهندسی، گروه کامپیوتر، دانشگاه شهید چمران اهواز، اهواز، ایران.

۱- مقدمه

امروزه بیماری سرطان ریه دومین علت مرگ و میر در ایالات متحده و سومین عامل مرگ و میر در کشورهای کم‌تر توسعه یافته از جمله ایران به شمار می‌رود [۱].

بررسی ندول‌های ریوی در شناسایی اولیه سرطان ریه از جایگاه ویژه‌ای برخوردار است، چرا که حدود ۲۰٪ از موارد ندول‌های ریوی نشان دهنده سرطان ریه هستند. ندول ریه توده کوچکی در بافت ریه است که معمولاً در یک رادیوگرافی قفسه سینه و یا توموگرافی کامپیوتری (سی‌تی‌اسکن) به صورت کروی و متراکم با سایه سفید دیده می‌شود. گاهی عروق خونی شبیه لکه‌های دایره‌ای دیده شده که شنا سایی آن‌ها را از ندول‌های ریوی با چشم و تو سط رادیولوژیست دچار مشکل و مستعد خطا می‌کند. اندازه ندول ریه معمولاً حدود ۳ تا ۳۰ میلی‌متر است که هر چه اندازه ندول ریه بزرگتر باشد با احتمال بیشتری می‌توان به سرطانی بودن آن نسبت به ندول کوچک‌تر نظر داد [۲]. بنابراین وجود یک سیستم پردازش تصویر که دارای قدرت استخراج ویژگی‌ها است، می‌تواند در بهبود تشخیص و درمان بسیار مفید واقع شود.

دسته‌بندی ندول‌ها مانند بسیاری از روش‌های یادگیری براساس چند فاز پیش پردازش، استخراج ویژگی و دسته‌بندی است. یکی از تفاوت‌های اولیه در روش‌ها، در مرحله پیش پردازش است، برای مثال پیش پردازش می‌تواند روی تصویر اصلی یا روی تصویر ROI انجام گیرد، یا اصلاً مرحله پیش پردازش نداشته باشد. جدول ۱ تفاوت‌های ساختاری در برخی از کارهای پیشین مرتبط با این حوزه را نشان می‌دهد.

یکی دیگر از تفاوت‌ها، روش‌های ناحیه‌بندی مختلف است. روش‌های ناحیه‌بندی تصاویر پزشکی را می‌توان به سه دسته‌ی روش‌های: مبتنی بر ویژگی‌های آماری [۱۰]، مبتنی بر مدل‌های شکل پذیر [۱۱]، [۱۲]، [۱۳]، مبتنی بر گراف [۱۴] و مبتنی بر برنامه‌نویسی ژنتیک [۱۵] تقسیم بندی کرد.

جدول ۱- مراحل پردازشی در برخی از کارهای پیشین مرتبط

مرجع	مجموعه داده	پیش پردازش	ناحیه‌بندی	شناسایی ندول	کاهش خطای مثبت
[۳]	LIDC	دارد	دارد	دارد	دارد
[۴]	---	ندارد	دارد	دارد	ندارد
[۵]	LIDC	ندارد	دارد	دارد	دارد
[۶]	خصوصی	دارد	دارد	ندارد	ندارد
[۷]	LIDC	ندارد	ندارد	دارد	دارد
[۸]	LIDC	دارد	دارد	دارد	دارد
[۹]	---	دارد	دارد	دارد	دارد

از بین این سه دسته، مشخصات آماری، توزیع روشنایی تصویر را در

نظر می‌گیرند و از آن‌جایی که تصاویر سی‌تی‌اسکن ریه با سطوح خاکستری با مقادیر نزدیک به هم هستند این دسته از روش‌ها کارایی مناسبی در تصاویر سی‌تی ندارند.

مسئله بعدی نوع دسته‌بندی است. در مقالات مربوط به دسته‌بندی و تشخیص ندول‌های ریوی انواع تکنیک‌های دسته‌بندی برای کاهش خطای مثبت مورد استفاده قرار گرفته است، از جمله به شبکه عصبی، بیز ساده و ماشین بردار پشتیبان می‌توان اشاره کرد [۱۶]. به دلیل محدودیت فضا، جدول ۲، مزایا و معایب دسته‌بندی‌های مختلف بکار رفته در برخی از کارهای پیشین مرتبط را نشان می‌دهد.

در این مقاله، چارچوبی پیشنهاد می‌شود که همه‌ی مراحل بخش‌بندی ریه و تشخیص و دسته‌بندی تصاویر موجود را در فاز اول به ندول و غیرندول و در فاز دوم به صورت اتوماتیک به حالت خوش‌خیم و بدخیم انجام می‌دهد.

برای این منظور در ابتدا، یک پیش پردازش سه مرحله‌ای برای حذف نویزها و بهبود کنتراست انجام می‌شود. با استفاده از فیلترهای غیرخطی نویزها حذف شده و از فیلتر انتشار برای همواری تصویر استفاده شود. سپس ناحیه‌بندی در دو بخش مجزا اعمال می‌گردد. ناحیه‌بندی ابتدایی برای حذف ناحیه‌های اضافی و کاهش محاسبات و هزینه‌ها و ناحیه‌بندی دوم به منظور یافتن محل دقیق ندول‌ها انجام می‌گیرد. این مرحله با استفاده از روش گراف-کات تماماً خودکار انجام می‌شود که نیازی به کمک رادیولوژیست ندارد، در حالی‌که در اکثر روش‌های پیشین دخالت انسان لازم است. سپس از دسته‌بندی ترکیبی، به عنوان یک نوآوری جدید، در شناسایی ندول‌ها استفاده می‌شود.

درواقع قصد بر آن است که یک سیستم دو بخشی برای شناسایی و تعیین موقعیت ندول‌ها و سائز آن‌ها، ارائه شود که بتوان دسته بندی افراد را به دو گروه سالم و بیمار در فاز اول و در فاز دوم جداسازی ندول‌ها به گروه‌های خوش‌خیم و بدخیم انجام داد. مراحل این کار عبارتست از:

۱. پیش‌پردازش تصاویر طی سه مرحله جهت بهبود کیفیت تصاویر
۲. استخراج ویژگی‌های سیفت از آنها
۳. دسته‌بندی تصاویر ریه به دو گروه سالم و بیمار با استفاده از دسته‌بند بگینگ پیشنهادی
۴. ناحیه‌بندی تصاویر حاوی ندول با استفاده از روش گراف-کات تماماً خودکار و بدون نیاز به کمک رادیولوژیست برای تعیین بهتر موقعیت ندول‌ها
۵. اندازه‌گیری اندازه‌ی ندول‌ها و استخراج ویژگی‌های هارالیک
۶. دسته بندی الگوهای ندول‌ها به دو گروه بدخیم و خوش‌خیم با استفاده از جنگل تصادفی
۷. ارزیابی سیستم براساس دقت و سطح زیر نمودار راک

جدول ۲- مزایا و معایب دسته‌بندی‌های مختلف به‌کاررفته در برخی از


مرجع	دسته‌بند	مزایا	معایب
[۱۷]	یک روش کلاسترینگ بدون ناظر بنام رگرسیون کرنل محلی	حل مشکل out-of-sample با استفاده از جمله ی رگولاسیون	وابسته بودن به رادیولوژیست که بتواند به صورت دستی ندول را استخراج کند.
[۱۸]	استفاده از ویژگی‌های آماری و هندسی و شبکه یادگیری ژرف برای CNN استخراج ویژگی - دسته‌بند SVM	استفاده از دو دیتاست LIDC و ELCAP، نوآوری اصلی در استخراج ویژگی: ترکیب ویژگی‌های آماری و هندسی همراه با استفاده از CNN	پیچیدگی محاسباتی و زمانی بالا در شبکه‌ی یادگیری عمیق برای استخراج ویژگی‌ها، استفاده از رادیولوژیست برای برچسب گذاری نوع، مکان و اندازه‌ی ندول‌ها
[۱۹]	درخت تصمیم، بیز ساده	پیچیدگی محاسباتی پایین، توانایی ترکیب با دسته‌بندها، سادگی بیز ساده	بالا بودن هزینه هرس درخت، پاسخ نامناسب به داده‌های همپوشانی شده، عدم تضمین جواب بهینه
[۴]، [۲۰]، [۲۱]، [۲۲]	ماشین بردار پشتیبان	تولید جواب بهینه سراسری، پاسخ مناسب به بیشتر مسائل	پیچیدگی بالا، overfitting در اثر آموزش نادرست
[۷]	مبتنی بر قانون (فازی)	سادگی در پیاده سازی، قابلیت ترکیب با شبکه عصبی، knn و درخت تصمیم	نیاز به مقدار آستانه قطع دارد
[۸]	K نزدیک‌ترین همسایه	دادن نتایج مناسب، افزایش سازگاری با افزایش داده‌ها	پیدا کردن K بهینه
[۲۳]، [۲۰]، [۹]	شبکه عصبی صریح برای کاربرد مورد نظر	عملکرد موازی، توانایی یادگیری ارتباط ورودی-خروجی پیچیده، نیاز کم به ویژگی‌های گسترده مساله	مشکل بودن آموزش و تعمیم شبکه، عدم وجود قواعد صریح برای کاربرد موردنظر، عدم وجود روشی عمومی برای تشخیص عملیات داخلی شبکه

ادامه‌ی ساختار این مقاله به شرح زیر است: در بخش ۲، مبانی موردنیاز و روش‌های پیشنهادی شرح داده می‌شود. در بخش ۳ نتایج حاصل از شبیه‌سازی روش‌های پیشنهادی ارائه شده و خروجی‌ها با یکدیگر


مقایسه می‌شوند. در نهایت در بخش ۴، نتیجه‌گیری و جهت‌هایی برای کارهای آتی مطرح شده است.

۲- روش پیشنهادی

معماری کلی روش پیشنهادی در دو شکل ۱ و ۲ نشان داده شده است. در ادامه هر مرحله با جزئیات شرح داده می‌شود. بخشهای ۱-۲ تا ۴-۲ مربوط به فاز اول و بخشهای ۵-۲ الی ۷-۲ مربوط به فاز دوم روش پیشنهادی هستند.



شکل ۱- فاز اول روش پیشنهادی



شکل ۲- فاز دوم روش پیشنهادی

۱-۲- استخراج ROI

برای استخراج ریه‌ها از تصویر با توجه به اینکه شکل ریه‌ها مشابه است و تخمین منحنی اولیه جهت ناحیه‌بندی در این قسمت آسان است از روش کانتور فعال استفاده شد. در این روش منحنی به صورت پارامتریک و طبق (۱) تعریف می‌شود و منحنی در دامنه تصویر حرکت می‌کند تا با حداقل کردن انرژی طبق (۲) تصویر مورد نظر را ناحیه‌بندی کند.

$$X(s) = (x(s), y(s)) \quad 0 \leq s \leq 1 \quad (1)$$

$$E(s) = S(X) + P(X) \quad (2)$$

که در (۱)، $X(s)$ و $Y(s)$ منحنی‌های پارامتریک برحسب s در جهت‌های X و Y هستند. در (۲) جمله اول را تابع انرژی داخلی معادل (۳) و جمله دوم را تابع انرژی خارجی، (۴) می‌گویند:

$$S(X) = \frac{1}{2} \int_0^1 \alpha(s) \left| \frac{\delta X}{\delta s} \right|^2 + \beta(s) \left\| \frac{\delta^2 X}{\delta s^2} \right\| ds \quad (3)$$

$$P(X) = \int_0^1 P(X(s)) ds \quad (4)$$

$$\frac{\partial I}{\partial t} = \text{Div}(g(\|\nabla I\|^2)\nabla I) \quad (9)$$

که در آن، عملگر Div دیورژانس، ∇ عملگر گرادین، I تصویر و g تابعی است که به صورت (۱۰) تعریف می‌شود:

$$g(\|\nabla I\|^2) = \frac{1}{1 + \frac{\|\nabla I\|^2}{K}} \quad K > 0 \quad (10)$$

که در آن، پارامتر K یک ضریب ثابت است که حساسیت به لبه را کنترل می‌کند و معمولاً به صورت تجربی انتخاب می‌شود. پس از مراحل پیش پردازش بر روی ناحیه ROI به مراحل تشخیصی پرداخته می‌شود.

۲-۳- استخراج ویژگی

تبدیل ویژگی مستقل از مقیاس (Scale Invariant Feature Transform) یا سفت یک الگوریتم بینایی ماشین است که برای استخراج ویژگی‌های مشخص از تصاویر جهت شناسایی اجسام به کار می‌رود. یکی از دلایل استفاده از آن در این پژوهش این است که پس از یادگیری سیستم، در مرحله آزمایش، تصاویر غیر ROI را نیز به خوبی شناسایی می‌کند. به طور کلی مراحل استفاده از این توصیف‌گر را می‌توان به سه قسمت اصلی تقسیم نمود:

• یافتن نقاط کلیدی:

در این روش برای یافتن نقاط کلیدی در تصویر، تصویر اصلی به طور پیش‌رونده با فیلترهای گاوسی با سیگما ۱ تا ۲ محو می‌شود تا جایی که تصویر به طور کامل محو شود. یک هرم از تصاویر و کانولوشن تصویر شروع می‌شود. بنابراین فضای مقیاسی به صورت $G(x,y,\sigma)$ در (۱۱) نمایش داده می‌شود:

$$L(x,y,\sigma) = I(x,y) \times G(x,y,\sigma) \quad (11)$$

$$G(x,y,\sigma) = \frac{1}{2\pi\sigma^2} e^{-\frac{(x^2+y^2)}{2\sigma^2}} \quad \text{که}$$

که در آن، "x" نشان دهنده عملگر کانولوشن در x و y است و میزان تاری با پارامتر انحراف استاندارد σ در تابع گاوسین G کنترل می‌شود. فضای مقیاسی DoG با تفریق سطوح مقیاسی مجاور هم مطابق (۱۲) حاصل می‌شود:

$$D(x,y,\sigma) = [G(x,y,k\sigma) - G(x,y,\sigma)] \times I(x,y) \quad (12)$$

با استفاده از (۱۲) خواهیم داشت:

$$D(x,y,\sigma) = L(x,y,k\sigma) - L(x,y,\sigma) \quad (13)$$

هر پیکسل در تصاویر با هشت همسایه‌اش و نه پیکسل (پیکسل متناظر و هشت همسایه‌اش) از هر یک از تصاویر دیگر سری، مقایسه می‌شود و در این مرحله یافتن نقاط ماکسیم یا مینیم انجام می‌شود.

• نمایش توصیف‌گر نقاط کلیدی:

در این مرحله بردار ویژگی اصلی ایجاد خواهد شد. در ابتدا دامنه گرادین و جهت در اطراف نقطه کلیدی نمونه برداری می‌شود. در [۲۷] برای هیستوگرام‌های جهت از آرایه 4×4 با ۸ جهت در هر هیستوگرام استفاده شده است. بنابراین طول بردار ویژگی ۱۲۸ ویژگی خواهد بود.

در (۳)، $\alpha(s)$ سبب می‌شود که منحنی قابلیت انعطاف و کشسانی داشته باشد و $\beta(s)$ باعث صلب بودن منحنی می‌شود. اگر مقدار $\alpha(s)$ و $\beta(s)$ بزرگ باشد، منحنی به نرمی به لبه‌ها میل می‌کند.

در (۴) عبارت $P(X)$ انرژی خارجی است که نیروی خارجی عموماً از ویژگی‌های تصویر استخراج می‌شود. چون در این کار ویژگی‌های لبه، معیار خوبی برای شناسایی شی است و می‌توان از (۵) به منظور محاسبه انرژی خارجی استفاده کرد:

$$P(x,y) = -w\|\nabla I(x,y)\| \quad (5)$$

که در آن w یک ضریب وزنی و I تصویر، ∇ عملگر گرادین است. از آنجایی که هدف حداقل کردن انرژی در (۲) براساس اولر است و یک معادله دیفرانسیل غیرخطی برحسب X است، برای حل آن از روش‌های بهینه‌سازی استفاده می‌شود. در [۲۴] برای حل این مساله از روش کاهش شیب استفاده نمودند که رابطه آن به صورت زیر است:

$$\frac{\partial X}{\partial t} = \frac{\partial}{\partial s} \left(\alpha \frac{\partial x}{\partial s} \right) - \frac{\partial^2}{\partial s^2} \left(\beta \frac{\partial^2}{\partial s^2} \right) - \nabla P(X) \quad (6)$$

با قرار دادن یک منحنی اولیه و اعمال رابطه فوق منحنی به سمت حداقل شدن تابع انرژی حرکت می‌کند. در ادامه با استفاده از روش نیروی جریان برداری گرادین (GVF) در [۲۵]، گرادین مربوط به نقشه لبه استخراج شده از تصویر را به نواحی لبه‌های تصویر منتشر می‌کند. با تعویض $-\nabla P(X)$ با جریان برداری گرادین، نیروی خارجی به صورت (۷) تعریف می‌شود:

$$u_t = \mu \nabla^2 u - (u - \nabla f) |\nabla f|^2 \quad (7)$$

شرط اولیه این معادله به صورت $u(x,y,t=0) = \nabla f$ و در رابطه نقشه لبه است و دارای این ویژگی است که در نقاط لبه دارای مقدار بیشتری است. برای به دست آوردن نقشه لبه می‌توان از $G(x,y) \times I(x,y)$ که $G(x,y)$ تابع گاوسین با انحراف معیار σ و I تصویر مورد نظر است یا هر لبه یاب تصویر استفاده نمود. μ یک ضریب وزنی است.

۲-۲- پیش پردازش

در پیش‌پردازش موردنظر این تحقیق، نویززدایی، افزایش کنتراست و هموارسازی تصویر انجام می‌شود. برای نویززدایی، با استفاده از فیلتر میانه نویزهای تصویر که در اثر تصویربرداری ایجاد شده از بین می‌رود. در مرحله بعد نیز برای افزایش کنتراست تصویر از تبدیل گاما در (۸) استفاده شده است.

$$S = cT^\gamma \quad (8)$$

که در آن، مقدار c ضریب و γ ضریب گاما، T روشنایی تصویر اصلی و S روشنایی تصویر پس از تبدیل است. در مرحله سوم پیش پردازش به هموارسازی تصویر با استفاده از فیلتر انتشار پرداخته شد.

اساس فیلترهای انتشار، هموارسازی تصویر است به گونه‌ای که لبه‌ها در تصویر حفظ شوند. رابطه کلی این فیلتر به صورت (۹) است:

• تطبیق بردارهای ویژگی:

برای به‌کارگیری نقاط کلیدی سift در تطبیق و بازشناسی جسم، از یک الگوریتم نزدیک‌ترین همسایه، به همراه یک تبدیل هاگ استفاده شده است [۲۶]. در این مرحله با مقایسه هر یک از نقاط کلیدی استخراج شده از تصویر آزمایش با مجموعه نقاط کلیدی مربوط به تصویر آموزش انجام می‌گیرد. بهترین نقاط کاندید برای تطبیق، از طریق تشخیص نزدیک‌ترین همسایه در مجموعه نقاط کلیدی تصویر آموزشی یافت می‌شوند.

۲-۴- دسته‌بندی تصاویر به دو دسته‌ی ندول و غیرندول با

استفاده از روش ترکیبی بگینگ و ماشین بردار پشتیبان

روش پیشنهادی در این بخش استفاده از دسته بند بگینگ از نوع ماشین بردار پشتیبان با کرنل گوسین است. دسته‌بند بگینگ یکی از الگوریتم‌های ترکیبی است که واریانس را کاهش داده و باعث اجتناب از آموزش بیش از حد دسته‌بندها می‌شود. در این الگوریتم دسته‌بندها همه یکسان هستند و می‌توان از انواع دسته بندهای منفرد استفاده کرد (که در اینجا از ماشین بردار پشتیبان استفاده می‌شود).

برای نمونه‌های آموزشی دسته‌بندها از نمونه‌گیری همراه با جایگذاری استفاده می‌شود، به طوری که هر دسته‌بند، شامل مجموعه‌ای از داده‌ها است که از مجموع داده‌های اصلی کوچک‌تر است. هر یک از مجموعه داده‌های ساخته شده را به یک دسته‌بند به منظور آموزش داده می‌شود، تصمیم نهایی با توجه به رأی دسته‌بندهای منفرد که روش معمول آن رأی گیری است گرفته می‌شود.

ماشین بردار پشتیبان یکی از تکنیک‌های دسته‌بند تحت نظارت است که برای تفکیک و دسته بندی داده‌هایی که جدایی پذیر خطی و غیرخطی هستند ارائه شد. مزیت این روش این است که می‌تواند جواب کلی مساله را بیابد و برخلاف شبکه عصبی در ماکزیمم محلی قرار نگیرد. فرض کنیم داده‌های آموزشی شامل Π زوج $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$ هستند که $x_i \in R^m$ و $y_i \in (-1, 1)$ موجود باشد. باید ابر صفحه جداکننده‌ای به صورت (۱۴) چنان تعریف شود که بین دو دسته با برچسب‌های ۱ و -۱ بیشترین حاشیه را به وجود آورد، به عبارت دیگر فاصله بین دو ابر صفحه موازی در دو طرف ابر صفحه جداکننده ماکزیمم باشد.

$$\{x: f(x) = x^T w + w_0 = 0\} \|w\| = 1 \quad (14)$$

از این رو

$$(w \cdot x_i) + w_0 \geq +1 + \varepsilon_i \quad \text{اگر} \quad y_i = +1 \quad (15)$$

$$(w \cdot x_i) + w_0 \leq -1 - \varepsilon_i \quad \text{اگر} \quad y_i = -1 \quad (16)$$

$$y_i [(w \cdot x_i) + w_0] \geq 1, i = 1, 2, 3, \dots, n \quad (17)$$

که در آنها، $\varepsilon_i \geq 0$ متغیرهای مازاد محدودیت مساله هستند که خطای مجاز کمی را برای برخی داده‌ها فراهم می‌کنند. اگر تمامی داده‌ها رابطه‌های (۱۵) و (۱۶) را ارضا کنند، متغیر ε مقدار صفر خواهد بود.

ابر صفحه بهینه با کمینه کردن رابطه زیر به دست می‌آید:

$$C \sum_x \varepsilon_i + \frac{1}{2} \|w\|^2 \quad (18)$$

تحت شرط معادله (۱۵) که در آن، پارامتر C پارامتر تنظیم است و توازن بین کارایی دسته بندی و پیچیدگی مساله ایجاد می‌کند. به بیان دیگر، ابر صفحه‌ی جدا کننده ی بهینه، حاشیه‌ی بین دو کلاس را بیشینه می‌کند. با استفاده از هندسه و فاصله نقطه از خط پهنای حاشیه $\frac{2}{\|w\|}$ است پس $\|w\|$ باید مینیمم شود. بنابراین مساله ماکزیمم کردن حاشیه به صورت (۱۹) بیان می‌شود:

$$\varphi(w) = \frac{2}{\|w\|} \quad (19)$$

با استفاده از فرم دوگان مساله با استفاده از ضرایب لاگرانژ غیرمنفی، مساله با رابطه (۲۰) بیان می‌شود:

$$L(w, \alpha) = \frac{1}{2} \|w\|^2 - \sum_{i=1} \alpha_i y_i \alpha_j y_j (x_i, x_j) \quad (20)$$

تحت شرط: $\sum_{i=1} \alpha_i y_i = 0$

براساس ضرایب لاگرانژ α_i از رابطه فوق محاسبه شده و تابع تصمیم‌گیری رابطه (۲۱) ایجاد می‌شود:

$$f(x) = \text{sign}(\sum_{i=1} \alpha_i y_i (x, x_i) + w_0) \quad (21)$$

زمانی که داده‌ها در فضای غیرخطی قرار دارند، فضای غیرخطی ورودی با استفاده از توابع هسته مختلف به فضای ورودی خطی با ابعاد بالاتر تبدیل می‌شود. تابع هسته در ماشین بردار پشتیبان به صورت رابطه (۲۲) تعریف می‌شود:

$$K(x, x') = \varphi(x) \cdot \varphi(x') \quad (22)$$

بر این اساس مساله‌ی بهینه سازی غیرخطی و تابع تصمیم‌گیری به شکل (۲۳) و (۲۴) تبدیل می‌شود:

$$L(w) = \sum_{i=1} \alpha_i - \frac{1}{2} \sum_{i=1, j=1} \alpha_i y_i \alpha_j y_j K(x_i, x_j) \quad (23)$$

$$f(x) = \text{sign}(\sum_{i=1} \alpha_i y_i K(x, x_i) + w_0) \quad (24)$$

تابع کرنل گوسین موردنظر نیز عبارتست از:


$$\text{Exp}(-\frac{\|x - x'\|^2}{\sigma^2})$$

۲-۵- تعیین موقعیت و ساین ندول‌ها

در این بخش ناحیه‌بندی تصویر جهت استخراج ندول‌ها از تصویر برپایه روش جدیدی مبتنی بر الگوریتم‌های ناحیه‌بندی مبتنی بر گراف پیشنهاد می‌شود.

روش گراف-کات یک روش تکرار شونده نیست و تعامل کاربر در حد مشخص کردن چند نقطه از شی موردنظر و چند نقطه از پیش زمینه است. روش کار به این صورت است که پیکسل‌های تصویر به عنوان گره‌های گراف در نظر گرفته شده و گره‌های همسایه به وسیله یال‌های گراف به هم متصل می‌شوند. علاوه بر این گره‌ها، دو گره مخصوص به نام منبع (نماینده شی تحت ناحیه‌بندی) و چاه (نماینده پیش زمینه) به گراف تولید شده اضافه می‌شود. از هر یک از دو گره به هر یک از گره‌های میانی (پیکسل‌های تصویر) یال متصل کننده وجود دارد.

کاهش یابد. از این پس به استخراج ویژگی‌های ندول‌ها برای تکمیل فاز دوم و دسته‌بندی آن‌ها به دو نمونه خوش خیم و بدخیم پرداخته می‌شود.



شکل ۳- یک مثال ناحیه بندی ساده برای یک تصویر 3×3 (الف) دانه‌هایی با O و پس زمینه با B مشخص می‌شود. (ب) تشکیل گراف و دادن هزینه‌ها به آن براساس اصطلاح منطقه رابطه (۲۷) هزینه‌های تی لینک را تعریف می‌کند و اصطلاح مرز رابطه (۲۶) هزینه‌های n-لینک را تعریف می‌کند. (ج) برش گراف کات (د) نتیجه حاصل از برش.

۲-۶- استخراج ویژگی‌های ندول

ویژگی‌های هارالیک جز ویژگی‌های آماری در بررسی بافت تصویر محسوب می‌شوند. به منظور توضیح چگونگی استخراج ویژگی‌های هارالیک، مفهوم ماتریس همجواری بیان می‌شود. ایده کلی ماتریس همجواری که ماتریسی بر مبنای سطح خاکستری پیکسل‌های تصویر است، بیان بافت به صورت یک ماتریس متشکل از رابطه‌ی (۲۹) بین هر دو جفت پیکسل در بافت است. هر عنصر از این ماتریس آماری در رابطه از وقوع نقاطی با مقادیر و ارتباط مکانی مشخص است.

$$G = \begin{bmatrix} p(1,1) & p(1,2) & \dots & p(1,N_g) \\ p(2,1) & p(2,2) & \dots & p(2,N_g) \\ \vdots & \vdots & \ddots & \vdots \\ p(N_g,1) & p(N_g,2) & \dots & p(N_g,N_g) \end{bmatrix} \quad (29)$$

که در آن، N_g تعداد سطوح خاکستری است. اگر درایه‌ی سطر λ ام و ستون μ ام این ماتریس را با $p_{d\theta}(i,j)$ نشان دهیم، آن‌گاه $p_{d\theta}(i,j) = X$ به این معناست که X ، تعداد وقوع پیکسل‌های با فاصله‌ی d و در جهت θ (که می‌تواند ۰، ۴۵، ۹۰، ۱۳۵ باشد) است.

پس از اینکه ماتریس همجواری محاسبه شد، ۱۳ ویژگی هارالیک از ماتریس‌های همجواری استخراج می‌شوند. این ویژگی‌ها عبارتند از: (۱) آنتروپی:

الگوریتم به این صورت عمل می‌کند که ابتدا با توجه به اطلاعات موجود در تصویر (اطلاعات لبه‌ها و ناحیه‌ها) وزن‌هایی به یال‌های گراف نسبت داده و سپس با استفاده از یک الگوریتم بهینه، برش کمینه این گراف را براساس (۲۵) به دست آورده و در نهایت عملیات ناحیه‌بندی را با برجسب زدن گره‌های متصل به گره منبع به شی و گره‌های متصل به گره چاه به پیش زمینه تکمیل می‌کند. ناحیه‌بندی ایجاد یک برش روی گراف و هر ناحیه نشان دهنده یک زیرگراف است. بهترین تقسیم بندی، شباهت هر زیر گراف را حداکثر و شباهت بین زیرگراف‌های تصویر را حداقل می‌کند.

دو نوع یال در گراف تشکیل شده از روی تصویر در این روش وجود دارد: یال‌هایی که گره (پیکسل)های مجاور را به هم وصل می‌کند و یال‌هایی که هر گره میانی را به دو گره منبع و چاه متصل می‌کند. وزن یال‌های نوع اول نمایانگر میزان جریمه بین دو گره مجاور است که اگر آن دو گره، برجسب‌های مختلف (مثلاً برجسب شی و دیگری برجسب پیش‌زمینه) بگیرند. به عبارت دیگر این وزن‌ها نمایانگر انرژی مرزی می‌باشند. متداول‌ترین وزن برای این نوع یال‌ها برای دو گره میانی p و q به صورت (۲۶) است. برای وزن یال دوم از وزن یال‌های وصل کننده گره‌های میانی به دو گره منبع و چاه به ترتیب بیانگر تعلق گره‌های میانی به شی و پیش زمینه است که از طریق انتخاب اولیه‌ای که کاربر انجام می‌دهد، که در (۲۷) مشخص می‌شود.

$$E(A) = \lambda \cdot R(A) + B(A) \quad \text{Where } \lambda \geq 0 \quad (25)$$

$$B(A) = \sum_{\{p,q\} \in N} B\{p,q\} \delta(Ap,Aq) \quad (26)$$

Boundary Term

$$\delta(Ap,Aq) = \begin{cases} 1 & \text{if } Ap = Aq \\ 0 & \text{otherwise} \end{cases}$$

$$B(p,q) = \exp(-(Ip - Iq)^2 / (2\sigma^2)) / \|p - q\|$$

$$R(A) = \sum_{p \in P} Rp(Ap) \quad (27)$$

Regional Term


$$Rp(Ap) = -\ln \Pr(Ip|Ap) \quad (28)$$

در (۲۸) وزن یال وصل کننده گره P به گره منبع و چاه است که از محاسبه احتمال تعلق پیکسل P به شی و به پس زمینه (Ap پس‌زمینه یا شی) با استفاده از نقاط مشخص شده توسط کاربر انجام می‌شود. در روش پیشنهادی در اینجا به جای تعامل با کاربر از آستانه گذاری جهت نقاط اولیه استفاده شد. شکل ۳ یک مثال ساده از گراف کات در یک تصویر 3×3 است که برجسب شی (O) و پس زمینه (B) به هر پیکسل نشان می‌دهد.

پس از ناحیه‌بندی ندول‌ها به اندازه‌گیری سائز ندول‌ها پرداخته می‌شود. ناحیه‌های کمتر از ۳ میلی‌متر از تصویر حذف شدند تا میزان FP

۷-۲- دسته‌بند ترکیبی مبتنی بر جنگل تصادفی

جنگل تصادفی نیز یک دسته‌بندی کننده ترکیبی کاراست. یک جنگل تصمیم‌گیری، گروهی از درخت‌های تصمیم مختلف است که به شکل موازی عمل می‌کنند و هر درخت به طور مستقل دسته بندی را انجام می‌دهد. در این فرآیند درخت‌های تصمیم چندگانه ساخته می‌شوند. هر دسته‌بندی برای طبقه‌بندی یک شیء جدید از برداری ورودی را در انتهای هر یک از درختان جنگل تصادفی قرار می‌دهد. هر درخت به ما یک طبقه‌بندی می‌دهد و می‌گوییم این درخت به آن کلاس "رای" می‌دهد. جنگل طبقه‌بندی‌ای که بیشترین رای را داشته باشد (بین همه درخت‌های جنگل) انتخاب می‌کند. شکل ۴ دسته‌بندی‌های پیشنهادی در این تحقیق را نشان می‌دهد.



شکل ۴- انواع دسته بندی‌های به کار برده شده در فاز اول و دوم پیشنهادی

۳- نتایج شبیه‌سازی و مقایسه‌ها

از میان مجموعه داده‌های مشهور مربوط به ندول‌های ریوی که به صورت عمومی در دسترس وجود دارد می‌توان به مجموعه داده ELCAP در [۲۷] و LIDC در [۲۸] اشاره نمود. مجموعه داده جدیدی به نام LISS در [۲۹] نیز به عنوان مجموعه داده ایجاد شده است. با مقایسه سه مجموعه داده مذکور در جدول ۳ از بزرگ‌ترین مجموعه داده ریه به نام LIDC در این پژوهش استفاده شده است [۳۰]. همچنین تعداد مقالات بیشتری از این مجموعه داده برای پیاده‌سازی کار خود استفاده نموده‌اند، در نتیجه مقایسه نتایج با تعداد بیشتری از کارهای پیشین امکان‌پذیر خواهد بود.

هر تصویر سی‌تی از مجموعه تصاویر (بین ۱۰۰ تا ۳۰۰ برش) با فرمت DICOM ایجاد شده است. در این تحقیق ۷۸ تصویر سی‌تی اسکن شامل ۶۶ تصویر بیمار و ۱۲ تصویر سی‌تی اسکن به کار رفته است. ندول‌های موجود در ۶۶ تصویر بیمار به تعداد ۴۳۳ مورد است که شامل نمونه‌های خوش‌خیم و بدخیم است. ابعاد تصاویر ۵۱۲×۵۱۲ است و در تمامی تصاویر فرض بر آن است که یک ندول وجود دارد. برای پیاده‌سازی، از نرم‌افزار متلب نسخه R2016a و جعبه ابزار پردازش تصویر جهت پیاده‌سازی و ارزیابی تصاویر به کار گرفته شده است.

جدول ۳- مقایسه مجموعه داده‌های مختلف ندول‌های ریوی

ELCAP	LIDC	LISS	مجموعه داده
۳۹۷	۲۶۶۹	۶۷۷	ندول‌ها
۵۰	۱۰۱۰	۲۷۱	بیماران

$$\text{Entropy} = - \sum_i \sum_j p(i,j) \ln p(i,j) \quad (30)$$

(۲) انرژی:

$$\text{Energy} = \sqrt{\sum_i \sum_j p(i,j)^2} \quad (31)$$

(۳) کنتراست:

$$\text{Contrast} = \sum_i \sum_j (i - j)^2 p(i,j) \quad (32)$$

(۴) میانگین مجموع:

$$\text{Sum Average} = 1/2 \sum_i^N \sum_j^N ip(i,j) + jp(i,j) \quad (33)$$

(۵) واریانس:

$$\text{Variance} = \sum_i \sum_j (i - \mu)^2 p(i,j) \quad (34)$$

(۶) همبستگی:

$$\text{Correlation} = \sum_i \sum_j p(i,j)^2 (i - \mu_x)(j - \mu_y) / \sigma_x \sigma_y \quad (35)$$

(۷) احتمال بیشینه:

$$\text{MaxProb} = \max(p(i,j)) \quad (36)$$

(۸) همواری:

$$\text{smoothness} = \frac{1}{2} \sum_i^N \sum_j^N \frac{1}{1 - \|(i - j)\|^2} p(i,j) \quad (37)$$

(۹) میزان خوشه‌واری:

$$\text{cluster Tedenecy} = \sum_i^N \sum_j^N p(i,j) ((i - \mu_x) + (j - \mu_y))^2 \quad (38)$$

(۱۰) واریانس مجموع:

$$\text{SUM Variance} = \sum_{i=2}^{2N} (i - \text{sum Entropy}) p_{x+y}(i) \quad (39)$$

(۱۱) آنترپی مجموع:

$$\text{SUM Entropy} = - \sum_{i=2}^{2N} p_{x+y}(i) \log p_{x+y}(i) \quad (40)$$

(۱۲) تجانس:

$$\text{Homogeneity} = \sum_i \sum_j \frac{1}{1 + (i - j)^2} p(i,j) \quad (41)$$

(۱۳) اختلاف واریانس:

$$\text{Difference Variance} = \sum_{i=0}^{N-1} i^2 p_{x+y}(i) \quad (42)$$


به گونه‌ای که:

$$p_{x+y} = \sum_{i=1}^N \sum_{k=2,3,\dots,2N} \delta_{i+j,k} p(i,j), \quad \delta_{m,n} = \begin{cases} 1 & m = n \\ 0 & m \neq n \end{cases}$$

بیشتر در نظر گرفته می‌شود چرا که باید کل نقاط کلیدی استخراج شود. در این تحقیق تعداد گوسین‌ها ۶ در نظر گرفته شده است. شکل ۸ مرحله اول سیفت را نشان می‌دهد. در مرحله بعد توصیف‌گر سیفت بر حسب جهت و مقیاس ساخته می‌شود. تعداد جهت‌ها را ۸ و پنجره ۴ در نظر گرفته شده است به طوری که ۱۲۸ ویژگی استخراج شده است. در این قسمت این ۱۲۸ ویژگی به مرحله آخر سیفت یعنی تطبیق ویژگی‌ها داده می‌شود تا نزدیک‌ترین تصاویر بازیابی شود. ویژگی‌های سیفت علاوه بر استخراج ویژگی‌های بافت تصویر، می‌تواند تصاویر مشابه را براساس K نزدیک‌ترین همسایه بازیابی کند. در شکل ۹، نزدیک‌ترین تصویر به تصویر مرحله آزمایش نشان داده شده است.


۳-۳- دسته‌بندی تصاویر به ندول و غیرندول

به منظور کاهش خطای مثبت ویژگی‌های مرحله دو سیفت به دسته بند ماشین بردار پشتیبان و دسته بند ترکیبی داده شد که کارایی آن در جدول ۴ نشان داده شده است. در مرحله دسته‌بندی نیز از دسته‌بند ماشین بردار پشتیبان با کرنل گوسین و چند جمله‌ای و دسته بند ترکیبی به نام بگینگ استفاده شد. مقدار سیگما در ماشین بردار پشتیبان ۰/۵ در نظر گرفته شد.



سایزها ندول (mm)	۳-۲۷	۳-۵
برش‌های متعدد از هر گره	بله	خیر
دسته‌بندی پیشنهادی	بله	خیر
اسکن همراه با ماده حاجب	بله	بله
ضخامت برش‌ها (mm)	۱-۱/۲۵	۱/۲۵

علاوه بر نرم افزار مذکور، از بسته نرم افزاری با نام "VLFeat" در فاز استخراج ویژگی کمک گرفته شده است، این بسته نرم افزاری در محیط متلب قابل به کارگیری است و برای به کار بردن دسته‌بندها از بسته نرم افزاری SVMlib در متلب و وکا استفاده شده است. در مرحله اول پیاده‌سازی، تصویر طبق شکل ۵ به سطح خاکستری تبدیل شد و سپس استخراج ریه‌ها جهت پردازش نقاط داخلی آن صورت گرفت.




شکل ۵- تصویر برش ریه- از چپ به راست: تصویر رنگی اسلایس

۲۶- تصویر سطح خاکستری اسلایس ۲۶ ریه

۳-۱- استخراج ریه‌ها به عنوان ناحیه ROI

شکل ۶ تصویر سطح خاکستری دو نمونه دارای ندول جامد و GGO است که مراحل استخراج ریه را روی دو نمونه در ادامه انجام می‌شود. به دلیل وجود دو ریه، پس از محاسبه مرکز ریه‌ها، دو مستطیل را در مرکز ریه‌ها قرار داده و به عنوان منحنی اولیه در دامنه تصویر قرار می‌گیرد. پس از تست‌های مختلف بر روی تصاویر گردایان تصویر برای ایجاد نقشه لبه استفاده شد و پارامتر $G.VF, \mu = 0.25$ برای تصاویر مناسب است. تعداد تکرار در GVF برابر با ۴۰ مرتبه در نظر گرفته شد.



شکل ۶- تصویر دو سی تی شامل ندول -ندول جامد و GGO

تصاویر ۷-الف تا و مراحل GVF، روی دو تصویر مختلف ندول جامد و GGO را نشان می‌دهد و پارامترهای $\alpha = 0.2$ و $\beta = 0.1$ انتخاب نمودیم که میزان انعطاف‌پذیری و صلب بودن منحنی را تنظیم می‌کنند. مقدار α بزرگ‌تر از β در نظر گرفته شد که اهمیت انعطاف‌پذیری در این کار را نشان می‌دهد. با کوچک بودن مقدار β قابلیت تشخیص نقاط تیز نیز داده می‌شود. شکل ۷-د تصویر ریه ناحیه بندی شده با استفاده از منحنی اولیه و شکل ۷-ه تحت کنترل نیروی خارجی GVF و شکل ۷-و تصویر نهایی استخراج ریه‌ها با تعداد تکرار ۸۰۰ مرتبه به طوری که مرز ریه‌ها با دقت بالا و به صورت کامل جدا شود.

۳-۲- استخراج ویژگی

سپس برای استخراج ویژگی، ابتدا فضای DOG برای یافتن نقاط کلیدی در تصویر ساخته شد. هر چه رزولوشن تصویر بالاتر باشد تعداد گوسین‌ها

برای نقاطی و پس زمینه استفاده شد (طبق مثالی که در بخش قبل بیان شد). شکل ۱۰ این مرحله را نشان می‌دهد.



شکل ۱۰- ناحیه‌بندی ندول‌ها با روش گراف-کات، الف) ندول با اندازه‌ی ۲۰ میلی متر، ب) ندول به طول ۸/۱ میلی متر، اندازه‌گیری شد.


سپس روش مومنت جهت اندازه‌گیری سایز ندول‌ها مورد استفاده قرار گرفت. یک مومنت تصویر به طور متوسط وزن شدت پیکسل تصویر و یا یک تابع از چندین مومنت است. مومنت‌های تصویر برای توصیف اشیاء پس از ناحیه‌بندی مفید هستند. خواص ساده از تصویر که از طریق مومنت تصویر شامل طول منطقه (یا شدت کل)، مرکز آن و اطلاعات در مورد جهت‌گیری آن یافت می‌شود، سپس ناحیه‌های کمتر از ۳ میلی‌متر از تصویر حذف شدند تا میزان FP کاهش یابد و به این ترتیب سایز ندول‌ها نیز اندازه‌گیری شد.

در مرحله‌ی بعد، براساس ویژگی‌های هارالیک که از ماتریس همجواری به دست می‌آید، ویژگی‌ها استخراج شدند. فاصله مورد نظر ۲ و جهت صفر برای استخراج ویژگی‌ها در نظر گرفته شده است. سپس ویژگی‌ها به دسته‌بند ترکیبی جنگل تصادفی داده شد تا براساس برچسب‌گذاری به ندول‌های خوش‌خیم و بدخیم دسته‌بندی شود.


۳-۵- ابزارهای ارزیابی

پس از این‌که مدل توسط دسته‌بندها انتخاب شد، سؤال این است که چگونه درصد خطا را تخمین بزنیم. در این مقاله، از اعتبارسنجی متقابل استفاده شد که شامل مراحل زیر است:


- انتخاب زیر نمونه‌ها به صورت تصادفی: تمام داده‌های آموزشی را k بار تکه می‌کنیم. هر تکه داده به صورت تصادفی، تعداد ثابتی نمونه را بدون جایگذاری انتخاب می‌کند. هر تکه داده به $k-1$ به عنوان داده‌های آموزشی به دسته‌بند می‌دهیم و سپس خطای داده‌های آزمایشی را محاسبه می‌کنیم. مقدار خطای صحیح میانگین خطاهاست.
- k بار تازدن: کل داده‌های آموزشی را k بار تا می‌کنیم. $k-1$ را برای آموزش و یکی باقی مانده را برای آزمایش استفاده می‌کنیم. مزیت این روش این است که همه نمونه‌ها بالاخره هم برای آموزش استفاده می‌شوند و هم برای آزمایش. خطا در این روش برابر با میانگین خطاهاست. عیب این روش انتخاب k است. تعداد تاهای



شکل ۷- تصاویر سی‌تی اسکن ریه در مرحله ROI، الف) ساخت نقشه لبه، ب) گرادیان نقشه لبه، ج) GVF، د) منحنی اولیه، ه) ناحیه‌بندی پس از تکرار ۸۰۰، و) تصویر پس از انجام ناحیه‌بندی



شکل ۸- تصویر DOG حاصل از تصویر شکل ۷



شکل ۹- تصاویر بازبازی شده، الف) نزدیک‌ترین تصویر بازبازی شده، ب) تصویر آزمایش


جدول ۴- نتایج حاصل از Kهای متفاوت و انتخاب K بهینه در

دسته‌بندی

Standard deviation	TP Rate	FP Rate	ROC Area	K
±۰/۰۵	۰/۳۳۳	۰/۶۳۷	۰/۲۳۲	۱
±۰/۰۵	۰/۴	۰/۵۹۶	۰/۲۶۸	۵
±۰/۰۵	۰/۶	۰/۴۰۴	۰/۶۰۷	۱۰
±۰/۰۵	۰/۹۹۸	۰	۰/۹	۱۵
±۰/۰۵	۰/۷۳۳	۰/۲۵۱	۰/۷۵	۲۰

۳-۴- نتایج فاز دوم روش پیشنهادی، تعیین موقعیت و سایز ندول‌ها

در روش گراف-کات پیشنهادی براساس اینکه نقاطی از شی دارای شدت مشابه در یک بازه هستند از روش آستانه‌گذاری جهت برچسب اولیه



شکل ۱۱- مقایسه سه نمودار راک، درخت تصادفی، درخت تصمیم و بیزین ساده

۴- نتیجه‌گیری و کارهای آتی

در این مقاله، از روش‌های ناحیه‌بندی تصویر جهت کارایی بالاتر در تشخیص و شناسایی ندول‌های ریوی و برای کاهش خطای مثبت استفاده از دسته‌بندی استفاده شد. در این زمینه، دو دسته‌بندی جدید در زمینه سیستم‌های تشخیص ندول جهت دسته‌بندی به دو نوع ندول و غیرندول و در مرحله بعد دسته‌بندی به نمونه‌های خوش‌خیم از بدخیم استفاده شد.

کارایی روش‌های پیشنهادی در شناسایی ندول‌ها براساس دقت و سطح زیر نمودار راک و میزان خطای مثبت کاذب بررسی شدند. بررسی روی ۷۸ تصویر پایگاه داده LIDC که شامل ۴۳۳ مورد ندول بود نشان داد که روش‌های پیشنهادی کارایی و زمان پاسخ‌گویی قابل مقایسه‌ای با روش‌های دیگر دارند. از ویژگی‌های دیگر این تحقیق می‌توان به موارد زیر اشاره کرد:

- کاهش هزینه‌ها در الگوریتم‌ها با حذف ناحیه‌های غیرمفید و بدون نیاز به کاربر
 - استخراج ندول‌ها بدون دخالت کاربر و به صورت تمام خودکار
 - استفاده از ویژگی سیفت به عنوان ویژگی جدید در شناسایی ندول‌های ریوی
 - دسته‌بندی ندول‌ها با استفاده از دسته‌بندی بگینگ پیشنهادی
 - به کارگیری هر دو دسته‌بندی غیرپارامتریک و پارامتریک در دسته‌بندی ندول‌های ریوی و بررسی آن‌ها
 - کاهش میزان خطای مثبت گراف کات نسبت به روش‌های دیگر
 - اندازه‌گیری سائز ندول‌ها
 - استفاده از دسته‌بندی ترکیبی جهت بهبود داده‌های نامتوازن
 - استفاده از دسته‌بندی جنگل تصادفی جهت دسته‌بندی به خوش‌خیم و بدخیم
- بر پایه روش‌های پیشنهادی می‌توان به موارد زیر به عنوان کارهای آتی برای بهبود روش‌های مطرح شده اشاره نمود:

بالا باعث کاهش بایاس و افزایش محاسبات می‌شود و تعداد تاهای کم بایاس را افزایش می‌دهد.

در دسته‌بندی فاز اول روش پیشنهادی از روش k بار تا زدن استفاده شده است که k برابر با ۷ در نظر گرفته شده است. در دسته‌بندی فاز دوم به علت استفاده از دسته‌بندی ترکیبی بگینگ و جنگل تصادفی و استفاده‌ی این دسته‌بندی از نمونه‌برداری جایگذاری نیازی به استفاده از k بار تا زدن نیست. علاوه بر این، برای نمایش درصد خطا از نموداری به نام نمودار راک و دقت استفاده شده است. شکل ۱۱ نیز مقایسه سه نمودار راک مربوط به درخت تصادفی، درخت تصمیم و بیزین ساده را نشان می‌دهد. در مورد معیار دقت برای تشخیص ندول‌ها از سالم‌ها و ندول‌های خوش‌خیم از بدخیم از معیارهای زیر استفاده می‌شود:

اگر فرد الف به عنوان بیمار سرطان و فرد ب به عنوان فرد سالم در نظر گرفته شود، ارزیابی آزمایش براساس چهار مؤلفه زیر است:

(۱) اگر در حالت تست، فرد الف بیمار در نظر گرفته شود و چون در واقعیت به سرطان دچار است، این فرد به عنوان یک مثبت واقعی (TP) است.

(۲) اگر تست تعیین کند که فرد ب سرطان دارد، این یک مثبت کاذب (FP) و یک خطای نوع اول است.

(۳) اگر تست تعیین کند که الف سرطان ندارد، این به عنوان یک منفی کاذب (FN) و خطای نوع دوم است.

(۴) اگر تست تعیین کند که فرد ب سرطان ندارد، این یک منفی واقعی (TN) است.

با توجه به تعاریف فوق، معیار دقت به صورت رابطه‌ی زیر تعریف می‌شود:

$$(۴۳) \quad \text{دقت} = \frac{TN + TP}{TP + TN + FP + FN}$$

۳-۶- سنجش روش‌های پیشنهادی با روش‌های دیگر

در جداول ۵ و ۶ آمار به دست آمده از روش‌های پیشنهادی از دیدگاه دقت گزارش شده است.

جدول ۵- مقایسه روش‌های پیشنهادی فاز اول با روش‌های دیگر

روش‌ها	دقت	انحراف معیار
[۲۰]	٪۹۳	±۱٪
[۴]	٪۹۰	±۱٪
روش ماشین بردار پشتیبان منفرد با کرنل گوسین پیشنهادی	٪۸۷	±۱٪
روش بگینگ پیشنهادی	٪۹۷	±۱٪

جدول ۶- مقایسه روش‌های پیشنهادی فاز دوم با روش‌های دیگر

روش‌ها	دقت	انحراف معیار
[۹]	٪۴۵	±۱٪
[۳۱]	٪۹۵	±۱٪
روش جنگل تصادفی پیشنهادی	٪۹۶	±۱٪

- [12] R. Bellotti, D. Carlo, G. Gargano, S. Tangaro, D. Cascio, E. Catanzariti, P. Cerello, S. Cheran, P. Delogu, D. Mitri, C. Fulcher, D. Grosso, A. Retico, S. Squarcia, E. Tommasi and G. Bruno, "A CAD system for nodule detection in low-dose lung CTs based on region growing and a new active contour model," *Medical Physics*, vol. 34, 2007.
 - [13] M. Keshani, Z. Azimifar, R. Boostani and A. Shakibafar, "Lung nodule segmentation using active contour modeling," *Machine Vision and Image Processing*, Isfahan, 2010.
 - [14] Y. Y. Boykov and M.-P. Jolly, "Interactive Graph Cuts for Optimal Boundary & Region Segmentation of Objects in N-D Images," *International Conference on Computer Vision*, Vancouver, Canada, 2001.
 - [15] K. Nag and N. R. Pal, "A Multiobjective Genetic Programming-Based Ensemble for Simultaneous Feature Selection and Classification," *IEEE Transactions on Cybernetics*, vol. 46, no. 2, pp. 499-510, 2016.
 - [16] J. Mukherjee, A.K. Choudhury, A. J. Mukherjee, A. Chakrabarti, S. H. Shaikh and M. Kar, "Automatic Detection and Classification of Solitary Pulmonary Nodules from Lung CT Images," *Fourth International Conference of Emerging Applications of Information Technology (EAIT)*, Kolkata, India, 2014.
 - [17] G. Wei, H. Ma, W. Qian, F. Han, H. Jiang, S. Qi, M. Qiu, "Lung nodule classification using local kernel regression models with out-of-sample extension," *Biomedical Signal Processing and Control*, vol. 40, pp. 1-9, 2018.
 - [18] J. Yuan, X. Liu, F. Hou, H. Qin, A. Hao, "Hybrid-feature-guided lung nodule type classification on CT images," *Computers & Graphics*, vol. 70, pp. 288-299, 2018.
 - [19] C. Bhuoaneswari, p. Aruna and D. Hoganathan, "Classification of Lung Diseases by image processing Techniques using computed Tomography Images," *International Journal of Advanced Computer Research*, vol. 4, no. 1, issue 14, pp. 87-93, March 2014.
 - [20] K. Yokota, R. Tachibana, Y. Hirano and S. Kido, "Automatic Detection of GGO Regions on CT Images in LIDC Dataset Based on Statistical Features," *Joint 7th International Conference on Soft Computing and Intelligent Systems (SCIS) and 15th International Symposium on Advanced Intelligent Systems (ISIS)*, Japan, 2014.
 - [21] W. J. Choi and T. S. Choi, "Automated pulmonary nodule detection based on three-dimensional shape-based feature descriptor," *Computer Methods and Programs in Biomedicine*, vol. 113, no. 1, pp. 37-54, 2014.
 - [22] A. M. Santosa, A. O. d. C. Filhoa, A. C. C. d. Paivaa, Nunesb, R. Acatauassu, Gattasc and Marcelo, "Automatic detection of small lung nodules in 3D CT data using Gaussian mixture models, Tsallis entropy and SVM," *Engineering Applications of Artificial Intelligence*, vol. 36, pp. 27-39, 2014.
 - [23] N. Sharma and Sheenam, "Size Estimation of Lung Cancer Using Image Segmentation and Back Propagation," *International Journal for Research in Technological Studies*, vol. 1, no. 9, pp. 14-17, 2014.
 - [24] S. S. Makhanov, "Active contours in medical image processing, Theory and applications," *5th International Conference on Knowledge and Smart Technology (KST)*, Thailand, 2013.
 - [25] C. Xu and J. L. Prince, "Generalized gradient vector flow external forces for active contours," *Signal Processing*, vol. 71, pp. 131-139, 1998.
 - [26] D. Lowe, "Distinctive image features from scale-invariant keypoints," *International Journal of Computer Vision*, vol. 60, pp. 91-110, 2004.
 - [27] ELCAP Public Lung Image Database, 2016. [Online]. Available: <http://www.via.cornell.edu/lungdb.html>.
 - [28] S. G. Armato and et. al, "The Lung Image Database Consortium (LIDC) and Image Database Resource Initiative (IDRI): A completed reference database of lung nodules on CT scans," *Medical Physics*, vol. 38, pp. 915-931, 2011.
 - [29] H. Guanghui, L. Xiabi, H. Feifei, S. N. Tenaya, Z. Yanfeng, Z. Xinming and Z. Chunwu, "The LISS—A Public Database of Common Imaging Signs of Lung Diseases for Computer-Aided Detection and Diagnosis Research and Medical Education," *IEEE Transactions on Biomedical Engineering*, vol. 62, 2015.
 - [30] I. R. S. Rafael, P. C. Cortez, E. C. Neto, J. M. Soares, V. H. C. de Albuquerque and J. M. Tavares, "Automatic 3D pulmonary
- با توجه به ناحیه‌بندی ندول‌ها براساس گراف کات، انتخاب اولیه نقاط براساس روش EM نیز می‌تواند انجام شود.
 - به کارگیری روش‌های بهینه‌سازی تکاملی جهت مرحله برش کات در ناحیه‌بندی تصویر.
 - می‌توان با استفاده از روش‌های تکاملی و کاهش ابعاد ویژگی‌هایی که ندول‌ها را به خوبی تفکیک می‌کند، را انتخاب نمود.
 - بررسی سهم هر کدام از ویژگی‌های سیفت در دقت طبقه‌بندی پیشنهادی

سپاسگزاری

نویسندگان این مقاله از مرکز پردازشهای سریع دانشگاه شهید چمران اهواز به خاطر در اختیار دادن منابع محاسباتی تشکر و قدردانی می‌کنند. همچنین از سرکار خانم دکتر حداد فوق تخصص ریه و جناب آقای دکتر حنفی مسئول بخش سی تی اسکن بیمارستان امام خمینی (ره) اهواز کمال تشکر و سپاسگزاری را دارند.

مراجع

- [1] R. L. Siegel, K. D. Miller and A. Jemal, "Cancer Statistics," *CA Cancer J Clin.*, vol. 65, pp. 5-29, 2015.
- [2] C. N. Carter, *CAD System for Lung Nodule Analysis*, Master's Thesis, University of Louisville, 2012.
- [3] N. M. Noor, J. C. M. Than, O. M. Rijal, R. M. Kassim, A. Yunus, A. A. Zeki, M. Anzidei, L. Saba and J. S. Suri, "Automatic Lung Segmentation Using Control Feedback System," *Journal of Medical Systems*, vol. 39, pp. 22-40, 2015.
- [4] S. Biradar and K. Agalatakatti, "Lung Cancer Identification Using CT Images," *International Journal Of Engineering And Computer Science*, vol. 4, pp. 13022-13025, 2015.
- [5] F. Zhang, Y. Song, W. Cai, M.-Z. Lee, Y. Zhou, H. Huang, S. Shan, M. J. Fulham and D. D. Feng, "Lung Nodule Classification With Multilevel Patch-Based Context Analysis," *IEEE Transactions on Biomedec Engineering*, vol. 61, 2014.
- [6] N. Camarlinghi, "Automatic detection of lung nodules incomputed tomography images: training and validation of algorithms using public research databases," *European Physical Journal Plus*, vol. 128, no. 9, 2013.
- [7] R. Kakinuma, K. Ashizawa, T. Kobayashi, A. Fukushima, H. Hayashi, T. Kondo, M. Machida, M. Matsusako, K. Minami, K. Oikado, M. Okuda, S. Takamatsu, M. Sugawara, S. Gomi, Y. Muramatsu and K. Hanai, "Comparison of sensitivity of lung nodule detection between radiologists and technologists on low-dose CT lung cancer screening images," *British Journal on Radiology*, vol. 85, 2012.
- [8] S. Namin Taghavi, H. Abrishami Moghaddam, R. Jafari, M. Esmaeil-Zadeh and M. Gity, "Automated detection and classification of pulmonary nodules in 3D thoracic CT images," *2010 IEEE International Conference on Systems Man and Cybernetics (SMC)*, Istanbul, Turkey, 2010.
- [9] K. Suzuki, F. Li, S. Sone and K. Doi, "Computer-aided diagnostic scheme for distinction between benign and malignant nodules in thoracic low-dose CT by use of massive training artificial neural network," *IEEE Transactions on Medical Imaging*, vol. 24, 2005.
- [10] J. Kim, J. Fisher, A. Yezzi, M. Cetin and A. Willsky, "A nonparametric statistical method for image segmentation using information theory and curve evolution," *IEEE Transactions on Image Processing*, vol. 14, pp. 1486 - 1502, 2005.
- [11] T. McInerney and D. Terzopoulos, "Deformable Models in Medical Image Analysis: A Survey," *Medical Image Analysis*, vol. 1, pp. 91-108, 1996.

based on the spatial analysis of detected lung nodules,” 9th IEEE International Symposium on Biomedical Imaging (ISBI), Barcelona, Espain, 2012.

nodule detection in CTimages: A survey,” Computer methods and programs in biomedicine, vol. 124, pp. 91-107, 2015.

- [31] A. El-Baz, A. Soliman, P. McClure, G. Gimel'farb, M. Abo El-Ghar and R. Falk, “Early assessment of malignant lung nodules