

تشخیص پنوموتوراکس با استفاده از الگوریتم‌های یادگیری ماشین و رادیومیکس: بررسی امکان جایگزینی رادیوگرافی ساده قفسه سینه به جای سی تی اسکن به منظور کاهش دوز پرتویی

چکیده

دریافت: ۱۴۰۲/۰۳/۲۷ ویرایش: ۱۴۰۲/۰۴/۰۱ پذیرش: ۱۴۰۲/۰۴/۲۵ آنلاین: ۱۴۰۲/۰۵/۰۱

زمینه و هدف: استفاده از الگوریتم‌های هوش مصنوعی برای کمک به تشخیص صحیح در تصاویر پزشکی یکی از مهم‌ترین کاربردهای این فناوری در حوزه تصویربرداری است. در این پژوهش امکان جایگزینی رادیوگرافی ساده قفسه سینه به منظور تشخیص پنوموتوراکس در مواردی که به طور معمول CT درخواست می‌گردد، با هدف کاهش دوز دریافتی بیماران، مورد مطالعه قرار گرفت.

روش بررسی: مطالعه حاضر یک مطالعه تحلیلی بوده و در بازه زمانی آذر ۱۴۰۱ تا خرداد ۱۴۰۲ در دانشگاه علوم پزشکی کرمانشاه انجام شده است. داده‌های مورد استفاده در این تحقیق از پرونده‌های ۳۵۰ فرد مشکوک به پنوموتوراکس استخراج شده است. تصاویر جمع‌آوری شده در نرم‌افزار MATLAB تحت پیش‌پردازش قرار گرفتند. سپس سه الگوریتم یادگیری ماشین، شامل رگرسیون لجستیک شبکه الاستیک (LENR)، رگرسیون لجستیک لاسو (LLR) و بوستینگ تطبیقی (AdaBoost) روی داده‌ها به کار گرفته شد. برای ارزیابی عملکرد این مدل‌ها از معیارهای دقت، صحت، حساسیت، ویژگی، سطح زیر منحنی مشخصه عملکرد سیستم، امتیاز FI و طبقه‌بندی نادرست استفاده شد.

یافته‌ها: در مدل AdaBoost مقدار دقت در تصاویر رادیوگرافی و CT به ترتیب ۹۹/۱۷٪ و ۹۸/۲۷٪ محاسبه شد. مقدار AUC برای همین مدل در تصاویر رادیوگرافی برابر ۱۰۰٪ و در تصاویر سی تی اسکن برابر ۹۶/۹۶٪ به دست آمد. **نتیجه‌گیری:** با توجه به معیارهای مورد ارزیابی در مطالعه، دو مدل LLR و AdaBoost دارای عملکرد مشابهی در تصاویر رادیوگرافی و CT از نظر تشخیص افراد با و بدون پنوموتوراکس هستند، به گونه‌ای که می‌توان این عارضه را با دقت بالایی با استفاده از تکنیک‌های یادگیری ماشین در تصاویر رادیوگرافی نیز تشخیص داد و به این ترتیب از دریافت دوز پرتویی بالا ناشی از انجام CT در بیمار اجتناب نمود.

کلمات کلیدی: هوش مصنوعی، یادگیری ماشین، پنوموتوراکس.

هانیه علی میری ده‌باغی^۱، کریم خوش‌گردا، حمید شریینی^{۲*}، سمیرا جعفری خیرآبادی^۳، فرهاد نعلینی^۴

- ۱- گروه فیزیک پزشکی، دانشکده پزشکی، دانشگاه علوم پزشکی کرمانشاه، کرمانشاه، ایران.
- ۲- گروه مهندسی پزشکی، دانشکده پزشکی، دانشگاه علوم پزشکی کرمانشاه، کرمانشاه، ایران.
- ۳- کمیته تحقیقات دانشجویی، دانشگاه علوم پزشکی کرمانشاه، کرمانشاه، ایران.
- ۴- گروه رادیولوژی، دانشکده پزشکی، دانشگاه علوم پزشکی کرمانشاه، کرمانشاه، ایران.

* نویسنده مسئول: کرمانشاه، خیابان دانشگاه، بلوار شهید شایرودی، دانشگاه علوم پزشکی کرمانشاه، دانشکده پزشکی.

تلفن: ۰۸۳-۳۴۲۷۴۶۱۸

E-mail: hamidsharini@gmail.com

مقدمه

آسیب قفسه سینه تقریباً ۲۵٪ از مرگ‌ومیرهای ناشی از تروما را تشکیل داده که ۵۰٪-۴۰٪ از این بیماران احتمالاً پنوموتوراکس دارند.^۱ پنوموتوراکس غیرتروماتیک یا متعاقب یک بیماری ریوی زمینه‌ای عمدتاً بیماری انسدادی مزمن ریوی (COPD) یا به طور خودکار و بدون یک رویداد محرک شناخته شده روی می‌دهد.^۲ پنوموتوراکس

پنوموتوراکس (Pneumothorax) به معنای تجمع هوا داخل حفره جنب، بین جنب جلداری و جنب احشایی، می‌باشد.^۱ پنوموتوراکس تروماتیک، یکی از عوارض شایع به دنبال ترومای قفسه سینه است.^۲

تصاویر را از نظر وجود پنوموتوراکس بررسی کردند. مدل یادگیری عمیق برای تشخیص پنوموتوراکس، AUC کمتری از دستیارهای رادیولوژی داشت، اما تصاویر را ۱۰۰۰ برابر سریع‌تر شناسایی می‌کرد و همچنین سه پنوموتوراکس اضافی را شناسایی کرد که توسط دستیارها از دست رفته بود.^{۱۱}


هدف پژوهش حاضر، امکان‌سنجی مقایسه رادیوگرافی ساده قفسه سینه و سی‌تی‌اسکن در تشخیص پنوموتوراکس با استفاده از الگوریتم‌های یادگیری ماشین و ویژگی‌های رادیومیکس است. در این پژوهش همچنین به بررسی امکان جایگزینی رادیوگرافی ساده قفسه سینه به منظور تشخیص پنوموتوراکس در مواردی که سی‌تی‌اسکن درخواست می‌گردد، با توجه به استفاده از تکنیک‌های یادگیری ماشین و با هدف کاهش دوز دریافتی بیماران پرداخته شده است.

روش بررسی

داده‌های استفاده‌شده در این پژوهش پس از تایید کمیته اخلاق دانشگاه علوم پزشکی کرمانشاه (IR.KUMS.MED.REC.1401.168) از مراکز آموزشی درمانی شهر کرمانشاه گردآوری شده‌اند. داده‌های جمع‌آوری شده در این پژوهش شامل مشخصات دموگرافیک از قبیل سن، جنسیت، پارامترهای بالینی شامل سابقه بیماری ریوی، وجود تروما، تنگی نفس، درد قفسه سینه و تصاویر رادیوگرافی و سی‌تی‌اسکن بیماران مشکوک به پنوموتوراکس بود که طی سه سال گذشته (از فروردین ۱۳۹۹ تا فروردین ۱۴۰۱) در این مراکز درمانی پذیرش شده‌اند. از بین این افراد، پرونده‌هایی انتخاب شدند که در کمتر از ۲۴ ساعت، بیمار هم تحت رادیوگرافی و هم تحت سی‌تی‌اسکن قرار گرفته بود و در افراد مبتلا، شدت پنوموتوراکس بین دو آزمون تصویربرداری طبق نظر پزشک متخصص تغییر چندانی نکرده بود. تعداد کل افراد انتخاب شده ۳۵۰ نفر بود که از این تعداد ۱۵۰ نفر مبتلا به پنوموتوراکس و ۲۰۰ نفر بدون پنوموتوراکس تشخیص داده شدند. میانگین سنی کل افراد $55/35 \pm 19/44$ سال بود که $116/34$ (۳۴٪) نفر زن و $234/66$ (۶۶٪) نفر مرد بودند. اطلاعات مربوط به مشخصات دموگرافیک، پارامترهای بالینی، پوزیشن بیماران و نوع سیستم رادیوگرافی برای بیماران مبتلا به پنوموتوراکس در جدول ۱ نشان داده شده است.

می‌تواند به تدریج به سمت پنوموتوراکس فشارنده (Tension) پیشرفت کرده و به یک اورژانس تبدیل شود، بنابراین تشخیص به موقع آن امری ضروری می‌باشد.^۳ در پژوهش‌های انجام‌شده بر روی بیماران ICU، در $1/1-3/8$ از بیماران تشخیص پنوموتوراکس پس از مرگ اتفاق افتاده است. پنوموتوراکس توسط ترکیبی از معاینات بالینی شامل سمع ریه و آزمون‌های تصویربرداری تشخیص داده می‌شود.^۶ از آنجایی که پنوموتوراکس عارضه‌ای است که بیشتر در بخش‌های اورژانس با آن مواجه می‌شوند، سمع ریه در شرایط پرسروصدای اورژانس کار دشواری است و ممکن است با خطا همراه باشد.^۲ رادیوگرافی ایستاده قفسه سینه معمولاً اولین و رایج‌ترین مدالیته تشخیصی است که برای تشخیص این عارضه درخواست می‌شود. سی‌تی‌اسکن یک روش با دقت و حساسیت بالا جهت تشخیص پنوموتوراکس‌های پنهان است اما دوز تابشی زیادی نسبت به رادیوگرافی ساده به بیماران تحمیل می‌شود. طبق مطالعات انجام‌شده، دوز موثر بیماران در سی‌تی‌اسکن قفسه سینه، به‌طور متوسط ۵۰ برابر رادیوگرافی است. مطابق با اصول حفاظت در برابر اشعه (به‌خصوص اصل) (As low as reasonably achievable, ALARA) تاجایی‌که امکان دارد، بایستی دوز بیماران را در انجام یک فرآیند تشخیصی کاهش داد. علاوه بر بحث حفاظت در برابر اشعه، در بیماران ناپایدار، سی‌تی‌اسکن همیشه قابل‌انجام نیست چراکه ممکن است در حین اسکن وضعیت بیمار بدتر شود و دسترسی به بیمار برای ادامه احیا وجود ندارد.^{۸-۶} در چند دهه اخیر حیطه تجزیه و تحلیل تصاویر پزشکی پیشرفت چشمگیری داشته است که امکان استخراج ویژگی‌های کمی که با چشم قابل‌مشاهده نیستند، را برای ما فراهم می‌کند. این عمل رادیومیکس (Radiomics) نامیده می‌شود.^{۱۰،۹}

تصویربرداری در بخش اورژانس، با هدف شناسایی سریع بیماران با شرایط اضطراری که نیاز به درمان یا مداخله فوری دارند، یک فرآیند حساس به زمان است.^{۱۱} سیستم‌های هوش مصنوعی می‌توانند با به حداقل رساندن تعداد خطاها در هنگام تفسیر تصویر، عملکرد هر سیستم تشخیص بیماری را بهبود بخشند.^۱ در مطالعه‌ای که توسط Yi و همکاران به صورت گذشته‌نگر انجام شد، یک شبکه عصبی کانولوشنال عمیق (Deep convolutional neural Network) روی ۶۰۲ رادیوگرافی قفسه سینه اجرا شد که این تصاویر از قبل توسط یک رادیولوژیست تفسیر شده بودند. دو دستیار سال اول رادیولوژی نیز



شکل ۱: قطعه‌بندی تصویر رادیوگرافی و سی‌تی‌اسکن بیمار مبتلا به پنوموتوراکس سمت راست

در این مرحله ابتدا روش‌های پیش‌پردازش مختلف شامل متعادل‌سازی هیستوگرام (Histogram equalization)، فیلتر دو لبه (Bilateral filter)، ناواضحی گاوسی (Gaussian blur) و ماسک‌گذاری تطبیقی (Adaptive masking) بر روی تصاویر رادیوگرافی اعمال گردید. در نهایت باتوجه‌به مقالات گذشته و نتایج به‌دست آمده در این پژوهش مشخص شد که بهترین روش پیش‌پردازش مورد استفاده در تجزیه و تحلیل تصاویر رادیوگرافی قفسه سینه اعمال ماسک‌گذاری تطبیقی، متعادل‌سازی هیستوگرام و ناواضحی گاوسی به ترتیب است.^{۱۱} برای تصاویر سی‌تی‌اسکن فقط از متعادل‌سازی هیستوگرام و فیلتر دولبه استفاده شد.

فرایند تقسیم تصویر به قطعات تشکیل‌دهنده به منظور استخراج اشیای مورد نظر، قطعه‌بندی (بخش‌بندی یا ناحیه‌بندی) نام دارد. پس از مرحله پیش‌پردازش، تصاویر رادیوگرافی و سی‌تی‌اسکن در متخصص رادیولوژی قطعه‌بندی شدند. ناحیه مشکوک به پنوموتوراکس قطعه‌بندی شده، بریده و از تصویر خارج گردید.

شکل ۱ نمونه‌ای از قطعه‌بندی پنوموتوراکس در تصویر رادیوگرافی و سی‌تی‌اسکن را نشان می‌دهد. این مرحله به مفهوم رادیومیکس اشاره دارد. هدف رادیومیکس به‌طور کلی استخراج اطلاعات کمی و ایده‌آل قابل تکرار از تصاویر تشخیصی از جمله الگوهای پیچیده‌ای است که تشخیص یا تعیین کمی آن توسط چشم

جدول ۱: مشخصات دموگرافیک، پارامترهای بالینی، پوزیشن بیماران و نوع سیستم رادیوگرافی برای بیماران مبتلا به پنوموتوراکس

ویژگی	میانگین یا درصد فراوانی
سن	۵۰/۴۸±۱۹/۳۸ سال
جنسیت	مرد ۷۲٪ زن ۲۸٪
درد قفسه سینه	۲۶/۶۶٪
تنگی نفس	۷۶٪
وجود بیماری ریوی زمینه‌ای	۷۰٪
تروما	۳۳/۳۳٪
شدت پنوموتوراکس	خفیف ۲۵/۳۳٪ متوسط ۴۲/۶۶٪ شدید ۳۷/۳۳٪
پوزیشن بیمار در رادیوگرافی	خلفی-قدامی ۵۶٪ قدامی-خلفی ۴۴٪
نوع سیستم رادیوگرافی	DR ۶۵/۳۴٪ CR ۳۴/۶۶٪

انحراف معیار=۱۹/۳۸

به‌منظور رعایت ملاحظات اخلاقی، تمام اطلاعات گرفته شده از پرونده بیماران کدگذاری شده و محرمانه بودند. تصاویر رادیوگرافی با استفاده از کیلوولتاژ پیک ۷۰ و اکسپوژر ۱۲ میلی‌آمپر ثانیه (به‌طور متوسط) تهیه شده بودند. دستگاه (Computed Radiography, CR, Shimadzu, Japan) و دستگاه (Digital Radiography, DR, Payamed electronic, Iran) در تصاویر CT، ضخامت برش ۱، ۱/۵، ۲، ۳، ۵ و ۷ میلی‌متر، ولتاژ تیوب ۱۱۰، ۱۲۰ و ۱۳۰ و اکسپوژر (Exposure) نیز از ۲۴ تا ۳۳۲ میلی‌آمپر ثانیه متغیر بود. دستگاه (CT scan, 16 slice, Siemens, Germany) در تصاویر سی‌تی‌اسکن فقط برش‌های آگزیمال مورد استفاده قرار گرفتند و برای هر بیمار، بهترین برش نمایانگر پنوموتوراکس انتخاب و متعاقباً تمام مراحل بر روی همین برش انجام گرفت. همه تصاویر جمع‌آوری شده دارای فرمت دایکام (DICOM) بودند.

مرحله پیش‌پردازش یک بخش مهم در مباحث مربوط به تجزیه و تحلیل تصاویر است. این امر می‌تواند کیفیت تصویر اصلی را بهبود بخشد و نویز یا جزئیات ناخواسته را کاهش دهد.

ویژگی‌های ماتریس طول پیمایش سطح خاکستری (GLRLM) اطلاعاتی را در مورد توزیع فضایی پیمایش پیکسل‌های متوالی با سطح خاکستری یکسان، در یک یا چند جهت، در دو یا سه بعد ارائه می‌دهد.^{۱۰}

ماتریس اندازه ناحیه سطح خاکستری (GLSZM)، براساس یک اصل مشابه با GLRLM است، اما در اینجا، شمارش تعداد گروه‌های (به اصطلاح مناطق) پیکسل‌ها یا وکسل‌های مجاور به هم پیوسته با سطح خاکستری یکسان، اساس ماتریس را تشکیل می‌دهد. یک بافت با همگنی بیشتر باعث ایجاد ماتریس پهن‌تر و مسطح‌تر می‌گردد.^{۱۵،۱۴}

ماتریس تفاوت شدت خاکستری همسایه (NGTDM) مجموع تفاوت‌های بین سطح خاکستری یک پیکسل یا وکسل و میانگین سطح خاکستری پیکسل‌ها یا وکسل‌های مجاور آن در یک فاصله

از پیش تعیین شده را محاسبه می‌کند.^{۱۰}

مدل‌های یادگیری ماشین مورد استفاده در این پژوهش نیازی به انتخاب ویژگی به صورت دستی ندارند و این مدل‌ها با یک کد مشخص در حین اجرا تعدادی از ویژگی‌ها را انتخاب می‌کنند و براساس اهمیتی که آن ویژگی در تصمیم‌گیری توسط مدل دارد یک امتیاز به آن اختصاص داده می‌شود. مهمترین ویژگی‌هایی که در تصاویر رادیوگرافی و سی‌تی‌اسکن در تصمیم‌گیری توسط مدل‌ها دخیل هستند، در جدول ۲ آورده شده‌اند. برای آموزش مدل‌های یادگیری، ابتدا داده‌ها به دو قسمت داده‌های آموزشی و آزمایشی یا تست تقسیم شدند که در این مطالعه ۷۰٪ از داده‌ها برای آموزش و ۳۰٪ داده‌ها نیز برای آزمایش الگوریتم‌ها اختصاص داده شد. داده‌های آموزش به‌طور تصادفی از کل داده‌ها انتخاب شدند.

این‌گونه موضوعات از دسته مسایل یادگیری با نظارت هستند، یعنی به داده‌های برچسب‌گذاری شده نیاز دارند. الگوریتم‌های یادگیری ماشین استفاده شده در این پژوهش، رگرسیون لجستیک شبکه الاستیک (Logistic elastic net regression, LENR)، رگرسیون لجستیک لاسو (Logistic lasso regression, LLR) و بوس‌تینگ تطبیقی (Adaptive boosting, AdaBoost) هستند. این الگوریتم‌ها در محیط برنامه‌نویسی (Python programming environment, Real Python, USA) اجرا شدند. رگرسیون لجستیک یک الگوریتم طبقه‌بندی است که هدف آن پیدا کردن ارتباط بین ویژگی‌ها و احتمال یک خروجی خاص است.^{۱۶}

انسان دشوار است.^{۱۱} این کار در توبلاکس رادیومیکس در 3D Slicer software, version 5.2.2., NIH, USA انجام شد.

ویژگی‌های استخراج شده شامل دو مجموعه ویژگی است، ویژگی‌های آماری مرتبه اول (First order) و ویژگی‌های بافتی (Texture). ۱۸ ویژگی آماری مرتبه اول از نواحی مشکوک به پنوموتوراکس استخراج گردید. مجموعه ویژگی‌های بافتی شامل ۱۴ ویژگی ماتریس وابستگی سطح خاکستری (Gray level dependence matrix)، ۱۶ ویژگی ماتریس طول پیمایش سطح خاکستری (Gray level run length matrix) و ۱۶ ویژگی ماتریس اندازه ناحیه سطح خاکستری (Gray level size zone matrix) و پنج ویژگی ماتریس تفاوت شدت خاکستری همسایه (Neighboring gray tone difference matrix)، مجموعاً ۵۱ ویژگی بود.

بنابراین در مجموع ۶۹ ویژگی از تصاویر استخراج گردیده است و چون این ویژگی‌ها با استفاده از فیلترهای Wavelet با تجزیه‌های مختلف (کلیه ترکیبات ممکن با استفاده از یک فیلتر High pass یا Low pass در هر سه بعد شامل LHH, HLL, HLH, HHL, HHH, LLH, LHL, LLL) به دست آمدند، در مجموع از هر تصویر رادیوگرافی و سی‌تی‌اسکن، ۶۲۱ (۸×۶۹) حالت تجزیه (Wavelet) + یک حالت بدون تجزیه (Wavelet) ویژگی استخراج و تمام این ویژگی‌ها برای تصاویر رادیوگرافی و سی‌تی‌اسکن در فایل‌های اکسل مجزا ذخیره شدند.

تجزیه Wavelet یک تصویر با استفاده از یک جفت فیلتر آینه‌ای مربعی، یک فیلتر بالاگذر و یک فیلتر پایین‌گذر امکان‌پذیر می‌گردد.^{۱۳} فیلتر بالاگذر تغییرات در سطح خاکستری را برجسته کرده و بنابراین بر جزئیات تصویر تاکید می‌کند، در حالی که فیلتر پایین‌گذر تصویر را از نظر سطح خاکستری صاف کرده و جزئیات تصویر را حذف می‌کند.^{۱۰}

ویژگی‌های آماری مرتبه اول، توزیع شدت پیکسل یا وکسل را در ناحیه تصویر تعریف شده توسط ماسک از طریق معیارهای معمول و پایه توصیف می‌کنند.^{۱۴} ویژگی‌های گروه ماتریس وابستگی سطح خاکستری (GLDM)، وابستگی‌های سطح خاکستری در یک تصویر را تعریف می‌کنند. وابستگی سطح خاکستری به‌عنوان تعداد وکسل‌های مرتبط در یک فاصله مشخص که وابسته به وکسل مرکزی هستند، تعریف می‌گردد.^{۱۴}

جدول ۲: مهم‌ترین ویژگی‌های تاثیرگذار در تصمیم‌گیری توسط مدل‌ها. حروف داخل پرانتز نوع فیلتر Wavelet به‌کاررفته را نشان می‌دهد.

سی‌تی‌اسکن	رادیوگرافی	
(LLL, LLH, LHL, LHH, HLL, HLH, HHL, HHH) مجموع انرژی (LLH, HLL, LLL, HLH, LHH) میانگین (LHL, HLL) صدک دهم (HLL, HHL, LHL) کشیدگی (LLL) دامنه بین چارکی (HLL, HLH) ریشه میانگین مربعی (LLL) میانگین انحراف مطلق قوی (HLH, HLL, HHL) میانگین	انرژی مجموع انرژی انرژی (LLL) مجموع انرژی (LLL) کمینه شدت دامنه بین چارکی (HLL) میانگین انحراف مطلق قوی میانگین انحراف مطلق قوی (LHL) میانگین انحراف مطلق قوی (LLL) صدک دهم شدت (HHL)	First order
غیر یکنواختی در سطح خاکستری (LLL, HLL) درصد ناحیه (HLH) واریانس سطح خاکستری (HLH, HLL) تاکید بر نواحی بزرگ با سطوح خاکستری پایین (LHH)	غیر یکنواختی در سطح خاکستری (HHL) غیر یکنواختی در سطح خاکستری (LHL) غیر یکنواختی در سطح خاکستری (HLL) غیر یکنواختی در اندازه نواحی (LLL) غیر یکنواختی در اندازه نواحی (LHL) غیر یکنواختی در اندازه نواحی (HLL) غیر یکنواختی در اندازه نواحی	GLSZM
واریانس سطح خاکستری (HLH) تاکید بر سطوح خاکستری پایین با پیمایش بلند (LLH)	غیر یکنواختی در سطح خاکستری (LLH) غیر یکنواختی در سطح خاکستری غیر یکنواختی در طول پیمایش غیر یکنواختی در طول پیمایش (LLL) واریانس پیمایش (LLH) تاکید بر پیمایش بلند (LHL)	GLRLM
واریانس سطح خاکستری عدم یکنواختی وابستگی (LLH) تاکید بر سطوح خاکستری بالا با وابستگی کوچک قدرت (HLL, LLH) دامنه بین چارکی (HHL) پهچیدگی (LHH)	تاکید بر سطوح خاکستری بالا با وابستگی بزرگ (LLH) شلوغی (LLH)	GLDM NGTDM

ویژگی‌ها را با قوی‌ترین اثرات بر روی تابع هزینه انتخاب می‌کند.^{۱۷} یک رگرسیون لجستیک منظم را می‌توان با اصطلاحات منظم‌سازی مختلف نیز اعمال کرد. رایج‌ترین اصطلاحات منظم‌شده عبارتند از لاسو و شبکه الاستیک.^{۱۹، ۲۰} رگرسیون لجستیک شبکه الاستیک، نوعی روش یادگیری ماشین بوده که انتخاب متغیر و منظم‌سازی را به‌طور

در سال‌های اخیر، روش‌های منظم‌سازی رایج‌تر شده‌اند، که به‌طور کارآمد ویژگی‌ها را انتخاب می‌کنند و همچنین احتمال برازش بیش‌ازحد (Overfitting) را کنترل می‌کنند.^{۱۷، ۱۸} به‌عنوان یک ابزار یادگیری ماشین، رگرسیون لجستیک، یک روش افتراقی قدرتمند در نظر گرفته می‌شود.^{۱۸} رگرسیون لجستیک منظم مجموعه کوچکی از

$\frac{TP}{TP + FN}$	۳- حساسیت
$\frac{TN}{TN + FP}$	۴- اختصاصی بودن (ویژگی)
$\frac{2TP}{2TP + FP + FN}$	۵- امتیاز F1
۱- accuracy	۶- طبقه‌بندی نادرست (Misclassification)

یافته‌ها

نتایج حاصل از عملکرد مدل‌ها در تصاویر رادیوگرافی و سی‌تی‌اسکن در جدول ۳ نشان داده شده است. باتوجه به این جدول، از نظر معیار صحت، مدل AdaBoost با مقدار $98/89\%$ در تصاویر رادیوگرافی و $98/63\%$ در تصاویر سی‌تی‌اسکن، عملکرد بهتری را در تصاویر رادیوگرافی نسبت به سی‌تی‌اسکن از خود نشان داده است. از نظر معیار دقت، همین مدل به ترتیب با مقادیر $99/17\%$ و $98/27\%$ در تصاویر رادیوگرافی و سی‌تی‌اسکن، در مورد تصاویر رادیوگرافی قوی‌تر ظاهر شده است.

در رابطه با معیار اختصاصی بودن، همچنان مدل AdaBoost با مقدار $99/45\%$ در تصاویر رادیوگرافی و $94/67\%$ در تصاویر سی‌تی‌اسکن، عملکرد بهتری در تصاویر رادیوگرافی دارد.

امتیاز F1 که معیاری مناسب برای ارزیابی دقت یک آزمایش محسوب می‌گردد، با استفاده از مدل AdaBoost در تصاویر رادیوگرافی عدد بالاتری (99%) نسبت به سی‌تی‌اسکن ($98/68\%$) به دست آمد که این امر نیز حاکی از عملکرد قوی‌تر مدل در تصاویر رادیوگرافی است.

نتایج حاصل از ارزیابی معیارها نشان می‌دهند که در هر دو مدالیته تصویربرداری مدل‌های LLR و AdaBoost مدل‌های مناسبی بوده و مدل LENR دل ضعیف‌تری است. البته در مدل LENR نیز معیار حساسیت و AUC در دو مدالیته تصویربرداری مشابه یکدیگر هستند. نمودارهای ۱ و ۲ به ترتیب مقایسه عملکرد مدل‌های LLR و AdaBoost را در تصاویر رادیوگرافی با سی‌تی‌اسکن نشان می‌دهند. باتوجه به این نمودارها مشخص است که عملکرد دو مدل LLR و AdaBoost در دو مدالیته تصویربرداری از نظر معیارهای مختلف ارزیابی مشابه یکدیگر است.

هم‌زمان با استفاده از جریمه‌های هر دو تکنیک لاسو و ریدج (Ridge) برای منظم کردن مدل‌های رگرسیون انجام می‌دهد. این روش، منظم‌سازی مدل‌های آماری را با ترکیب هر دو روش لاسو و ریدج بهبود می‌بخشد.^{۲۱}

لاسو یک رویکرد رگرسیون جریمه‌شده است که ضرایب رگرسیون را با به حداکثر رساندن تابع لگاریتم درست‌نمایی (Log-likelihood) با این محدودیت که مجموع مقادیر مطلق ضرایب رگرسیون، کمتر یا مساوی با ثابت مثبت S است، تخمین می‌زند. یکی از ویژگی‌های جالب لاسو این است که تخمین‌های ضرایب رگرسیون پراکنده هستند، به این معنی که بسیاری از مولفه‌ها دقیقاً صفر هستند. یعنی لاسو به‌طور خودکار متغیرهای کمکی غیرضروری را حذف می‌کند.^{۲۲}


بوستینگ تطبیقی یک روش گروهی است که در آن گروهی از طبقه‌بندی‌کننده‌های ضعیف به‌صورت متوالی آموزش داده می‌شود. در بوستینگ تطبیقی به هر نمونه آموزشی یک وزن اختصاص داده می‌شود و برای نمونه آموزشی که توسط طبقه‌بندی‌کننده قبلی آموزش ندیده است، وزن بالاتری تعیین می‌گردد. اگر نمونه به‌طور صحیح توسط طبقه‌بندی ضعیف قبلی آموزش داده شود، وزن نمونه به‌صورت تصاعدی کاهش می‌یابد.

مدل‌های گروهی با ترکیب تعدادی تخمین‌گر پایه به‌دقت بالایی دست می‌یابند و می‌توانند قابلیت اطمینان یادگیری ماشین را در مقایسه با یک تخمین‌گر منفرد افزایش دهند.^{۲۳} در پژوهش‌های مرتبط با تشخیص بیماری با الگوریتم‌های مختلف یادگیری ماشین معمولاً نتایج را با معیارهای مختلفی از جمله صحت، دقت، حساسیت، اختصاصی بودن (ویژگی)، امتیاز F1، طبقه‌بندی نادرست و سطح زیر منحنی مشخصه عملکرد سیستم (AUC) می‌سنجند. روابط ۱ تا ۶ نحوه محاسبه این معیارها را نشان می‌دهند. ((True positive, TP) تعداد موارد مثبت واقعی، (True negative, TN) تعداد موارد منفی واقعی، (False positive, FP) تعداد موارد مثبت کاذب، (False negative, FN) تعداد موارد منفی کاذب).^{۲۱ و ۲۴}


$\frac{TP + TN}{TP + TN + FP + FN}$	۱- صحت
$\frac{TP}{TP + FP}$	۲- دقت

جدول ۳: معیارهای ارزیابی محاسبه‌شده برای هر سه مدل در تصاویر رادیوگرافی و سی‌تی‌اسکن

مدالیت تصویربرداری	نام مدل	صحت	دقت	حساسیت	ویژگی	امتیاز F1	AUC	طبقه‌بندی نادرست
سی‌تی‌اسکن	LENR	٪۷۷/۵۵	٪۷۷/۵۵	٪۹۹/۵۶	-	٪۸۶/۷۵	٪۵۰	٪۲۲/۴۴
	LLR	٪۹۹/۳۱	٪۹۹/۵۶	٪۹۹/۷۶	٪۹۸/۰۷	٪۹۹/۵۶	٪۹۹/۰۲	٪۰/۶۸
	AdaBoost	٪۹۸/۶۳	٪۹۸/۲۷	٪۹۹/۷۸	٪۹۴/۶۷	٪۹۸/۶۸	٪۹۶/۹۶	٪۰/۶۸
رادیوگرافی	LENR	٪۳۴/۵۴	٪۳۳/۶۵	٪۹۹/۷۶	-	٪۵۰/۱۶	٪۵۰	٪۶۵/۴۵
	LLR	٪۹۸/۴۵	٪۹۸/۲۱	٪۹۹/۳۲	٪۹۷/۱۱	٪۹۹/۰۲	٪۹۹/۸۷	٪۱/۵۵
	AdaBoost	٪۹۸/۸۹	٪۹۹/۱۷	٪۹۹/۲۵	٪۹۹/۴۵	٪۹۹	٪۱۰۰	٪۱/۱۱



نمودار ۲: مقایسه عملکرد مدل AdaBoost در تصاویر رادیوگرافی و سی‌تی‌اسکن



نمودار ۱: مقایسه عملکرد مدل LLR در تصاویر رادیوگرافی و سی‌تی‌اسکن

نمود، می‌توان دوز کلی جامعه را کاهش داد و از بروز اثرات تاخیری تشعشع جلوگیری نمود.

علاوه بر ارجحیت رادیوگرافی بر سی‌تی‌اسکن در بحث حفاظت در برابر اشعه، بیمار برای سی‌تی‌اسکن باید به بخش دیگری منتقل شود که درمورد بیماران ناپایدار و با ضایعات نخاعی این امر نگران‌کننده است.^۲ همچنین سی‌تی‌اسکن یک فرایند زمان‌بر نسبت به رادیوگرافی است درحالی‌که تصویربرداری در بخش اورژانس به‌خصوص در بیماران ترومایی بسیار وابسته به زمان است و برخی از ضایعات مانند پنوموتوراکس نیاز به تشخیص سریع و درمان فوری دارند.^{۱۱} زمان طولانی در تصویربرداری سی‌تی‌اسکن می‌تواند باعث ایجاد آرتیفکت حرکتی در تصاویر، تشخیص نادرست و یا تکرار تصویربرداری و دریافت دوز بیش‌ازحد در بدن بیمار شود.^{۲۵}

توسعه الگوریتم‌های هوش مصنوعی از قبیل یادگیری ماشین و یادگیری عمیق در بخش‌های مختلف تصویربرداری به‌خصوص بخش اورژانس منجر به سهولت تشخیص و تسریع درمان در بیماران می‌گردد.^{۱۱} وجود کتابخانه‌های قدرتمند در زبان برنامه‌نویسی پایتون کمک شایانی به عملیاتی‌شدن و استفاده از مباحث یادگیری ماشین

حتی در بعضی از موارد، معیارهای ارزیابی عملکرد بهتری را در تصاویر رادیوگرافی نسبت به سی‌تی‌اسکن نشان می‌دهند. برای مثال در مدل AdaBoost، مقدار AUC در تصاویر رادیوگرافی برابر ۱۰۰٪ و در تصاویر سی‌تی‌اسکن برابر ۹۶/۹۶٪ به‌دست آمد.

بحث

هدف از پژوهش حاضر، مقایسه عملکرد مدل‌های یادگیری ماشین در تشخیص پنوموتوراکس بین دو مدالیت تصویربرداری رادیوگرافی و سی‌تی‌اسکن بود. همچنین به بررسی این موضوع پرداخته شد که آیا می‌توان با به‌کارگیری تکنیک‌های یادگیری ماشین و استخراج ویژگی‌های رادیومیکس در تصاویر رادیوگرافی، این مدالیت تصویربرداری را جایگزین سی‌تی‌اسکن در تشخیص پنوموتوراکس نمود. از آنجایی‌که سی‌تی‌اسکن دوزی چندین برابر رادیوگرافی به بیماران تحمیل می‌کند، اگر بتوان برای تشخیص پنوموتوراکس در مواردی که به‌طور معمول سی‌تی‌اسکن درخواست می‌شود، از کاربرد تکنیک‌های یادگیری ماشین در رادیوگرافی استفاده

واحدهای پردازش گرافیکی (Graphics Processing Units) با کارایی بالا، فضای ذخیره‌سازی بسیار زیاد و ... نیاز است، که از این نظر تکنیک‌های یادگیری ماشین مورد استفاده در پژوهش ما ساده‌تر و کم‌هزینه‌تر هستند. برخلاف روش یادگیری ماشین معمولی، در یادگیری عمیق نمی‌توان الگوریتمی را دنبال کرد تا مشخص شود چرا سیستم تشخیص داده است که یک تصویر خاص متعلق به فرد بیمار است یا سالم، به عبارت دیگر روش‌های DL از مشکل "جعبه سیاه" رنج می‌برند، ورودی به الگوریتم ارایه می‌شود و یک خروجی ظاهر می‌شود، اما دقیقاً مشخص نیست که چه ویژگی‌هایی شناسایی شده‌اند یا چگونه خروجی مدل محاسبه شده است.^{۲۹-۳۱}

در مطالعه دیگری که توسط Röhrich و همکاران با هدف تشخیص پنوموتوراکس در تصاویر سی‌تی‌اسکن با استفاده از یک مدل یادگیری عمیق انجام شد، مقدار AUC برابر ۰/۹۷/۶، حساسیت برابر ۰/۹۱/۶، دقت برابر ۰/۸۸/۶ و اختصاصی بودن برابر ۰/۹۳ به دست آمد که در هر چهار معیار، مدل‌های LLR و AdaBoost مورد استفاده در مطالعه حاضر، عملکرد بهتری داشتند.^{۳۱}

نتایج حاصل از این پژوهش نشان داد که با پیاده‌سازی مدل‌های یادگیری ماشین بر روی تصاویر رادیوگرافی می‌توان به عملکرد تشخیصی معادل با سی‌تی‌اسکن برای تشخیص پنوموتوراکس دست یافت و به این ترتیب دوز دریافتی بیماران و هزینه‌های درمان بسیار کاهش می‌یابد، بنابراین استفاده از سیستم‌های تشخیص خودکار راهکاری سریع و منطقی برای تشخیص پنوموتوراکس محسوب می‌گردد و باتوجه به سهولت به‌کارگیری تکنیک‌های یادگیری ماشین و همچنین مقادیر قابل توجه معیارهای به دست آمده در این پژوهش و سایر مطالعات، توسعه دهندگان حوزه مراقبت‌های بهداشتی را متقاعد می‌سازد تا سیستمی مبتنی بر این تکنیک‌ها برای تشخیص افراد با و بدون پنوموتوراکس در بخش اورژانس ایجاد کنند.

نویسندگان اعلام می‌دارند که هیچ‌گونه تضاد منافی وجود ندارد. **سپاسگزاری:** این مقاله حاصل پایان‌نامه تحت عنوان "امکان‌سنجی مقایسه ارزش تشخیصی سی‌تی‌اسکن و رادیوگرافی ساده قفسه سینه در تشخیص پنوموتوراکس با استفاده از الگوریتم‌های یادگیری ماشین و رادیومیکس" در مقطع کارشناسی ارشد رشته فیزیک پزشکی و طرح تحقیقاتی مصوب دانشگاه علوم پزشکی کرمانشاه به شماره ۴۰۱۰۶۵۴ بوده است.

نموده است.^{۲۶} در پژوهش حاضر برای اولین بار قابلیت تشخیصی دو مدالیته تصویربرداری با کمک تکنیک‌های یادگیری ماشین پیرامون تشخیص پنوموتوراکس مقایسه شده است. نتایج این پژوهش نشان می‌دهد که می‌توان به استفاده از رادیوگرافی به جای سی‌تی‌اسکن برای تشخیص پنوموتوراکس امیدوار بود.

با توجه به این‌که ویژگی‌های رادیومیکس ذکر شده در جدول ۲، اهمیت خود را در تشخیص پنوموتوراکس نشان داده‌اند، می‌توانند کاندیدهای مناسبی برای مارک‌های زیستی در عارضه پنوموتوراکس در نظر گرفته شوند، بنابراین پیشنهاد می‌گردد که در مطالعات آینده همبستگی بین این ویژگی‌ها با پارامترهای بالینی از قبیل افزایش رزونانس، کاهش صداهای ریوی، افزایش تعداد تنفس، سیانوز، آمفییزم زیرجلدی و غیره مورد بررسی قرار گیرد.

در پژوهشی که توسط Ahn و همکاران با هدف بررسی تاثیر هوش مصنوعی بر عملکرد پزشکان در تفسیر تصاویر رادیوگرافی پیرامون تشخیص چهار پاتولوژی ندول، پلورال افیوژن، پنومونی و پنوموتوراکس انجام شد، از یک الگوریتم هوش مصنوعی تجاری در دسترس (Lunit INSIGHT CXR, version 3.1.2.0; Lunit Inc) استفاده گردید.^{۳۷} برای پنوموتوراکس حساسیت برابر ۰/۹۸/۸ به دست آمد که مدل AdaBoost و LLR استفاده شده در پژوهش ما عملکرد بهتری داشتند و معیار اختصاصی بودن برابر ۰/۹۸/۶ به دست آمد که در این مورد نیز مدل AdaBoost مورد استفاده در مطالعه حاضر، موفق‌تر عمل کرده است. معیار AUC پژوهش برابر ۰/۹۹/۹ بود که پایین‌تر از AUC محاسبه شده در مدل AdaBoost پژوهش حاضر (۰/۱۰۰) است.^{۳۷}

در پژوهش دیگری که توسط Thian و همکاران با هدف ارزیابی تعمیم‌پذیری یک مدل یادگیری عمیق (Deep learning) تشخیص پنوموتوراکس بر روی تصاویر رادیوگرافی قفسه سینه که از موسسات مختلف گردآوری شده بودند، انجام شد، بالاترین مقدار برای معیار AUC برابر ۰/۹۸ به دست آمد که پایین‌تر از AUC به دست آمده در پژوهش حاضر است.^{۳۸} بالاترین میزان حساسیت و اختصاصی بودن در این مطالعه برابر ۰/۹۸ و امتیاز FI برابر ۰/۸۸ به دست آمد. که در هر سه معیار مدل AdaBoost در پژوهش حاضر موفق‌تر ظاهر شده است. یادگیری عمیق یک فناوری است که از منابع زیادی استفاده می‌کند. برای آموزش مدل‌ها، به پردازنده‌های گرافیکی قوی‌تر،

References

1. Malhotra P, Gupta S, Koundal D, Zaguia A, Kaur M, Lee H-N. Deep learning-based computer-aided pneumothorax detection using chest X-ray images. *Sensors* 2022;22(6):2278.
2. Tahmasebi M, Salamina S, Abasiyan E. Comparative Accuracy of FAST Sonography and CT Scan for Diagnosis Pneumothorax in Trauma Patients. *Armaghane Danesh* 2020;25(6):792-804.
3. Tran J, Haussner W, Shah K. Traumatic pneumothorax: a review of current diagnostic practices and evolving management. *The Journal of Emergency Medicine* 2021;61(5):517-28.
4. Choi W-I. Pneumothorax. *Tuberculosis and respiratory diseases* 2014;76(3):99-104.
5. Singh SK, Tiwari KK. Analysis of clinical and radiological features of tuberculosis associated pneumothorax. *Indian Journal of Tuberculosis* 2019;66(1):34-8.
6. Karimi DE, Shekarchi DB, Safari DS. Evaluation of the accuracy of portable ultrasound (eFAST) for detection of pneumothorax. *Annals of Military and Health Sciences Research* 2013;11(3):225-30. [Persian]
7. Farsi D, Zohri D, Abbasi S, Hessam R, Navkhasi S, Saifpanahi J. Comparison of the Diagnostic Values of Four-Point and Two-point Ultrasound Versus CT Scan in Determining Pneumothorax. *Pajouhan Scientific Journal* 2019;17(4):9-14. [Persian]
8. Kroft LJM, van der Velden L, Girón IH, Roelofs JJH, de Roos A, Geleijns J. Added Value of Ultra-low-dose Computed Tomography, Dose Equivalent to Chest X-Ray Radiography, for Diagnosing Chest Pathology. *J Thorac Imaging* 2019;34(3):179-86.
9. Gillies RJ, Kinahan PE, Hricak H. Radiomics: images are more than pictures, they are data. *Radiology* 2016;278(2):563-77.
10. Mayerhoefer ME, Materka A, Langs G, Häggström I, Szczypiński P, Gibbs P, et al. Introduction to radiomics. *Journal of Nuclear Medicine* 2020;61(4):488-95.
11. Yi PH, Kim TK, Yu AC, Bennett B, Eng J, Lin CT. Can AI outperform a junior resident? Comparison of deep neural network to first-year radiology residents for identification of pneumothorax. *Emergency Radiology* 2020;27:367-75.
12. Gielczyk A, Marciniak A, Tarczewska M, Lutowski Z. Pre-processing methods in chest X-ray image classification. *Plos one* 2022;17(4):e0265949.
13. Laine A, Fan J. Texture classification by wavelet packet signatures. *IEEE Transactions on pattern analysis and machine intelligence* 1993;15(11):1186-91.
14. Zwanenburg A, Vallières M, Abdalah MA, Aerts HJ, Andrearczyk V, Apte A, et al. The image biomarker standardization initiative: standardized quantitative radiomics for high-throughput image-based phenotyping. *Radiology* 2020;295(2):328-38.
15. Thibault G, Angulo J, Meyer F. Advanced statistical matrices for texture characterization: application to cell classification. *IEEE Transactions on Biomedical Engineering* 2013;61(3):630-7.
16. Choi RY, Coyner AS, Kalpathy-Cramer J, Chiang MF, Campbell JP. Introduction to machine learning, neural networks, and deep learning. *Translational Vision Science & Technology* 2020;9(2):14-.
17. Algamal ZY, Lee MH. Regularized logistic regression with adjusted adaptive elastic net for gene selection in high dimensional cancer classification. *Computers in biology and medicine* 2015;67:136-45.
18. Liang Y, Liu C, Luan X-Z, Leung K-S, Chan T-M, Xu Z-B, et al. Sparse logistic regression with a L1/2 penalty for gene selection in cancer classification. *BMC bioinformatics* 2013;14(1):1-12.
19. Torang A, Gupta P, Klinke DJ. An elastic-net logistic regression approach to generate classifiers and gene signatures for types of immune cells and T helper cell subsets. *BMC Bioinformatics* 2019;20(1):433.
20. Zou H, Hastie T. Regularization and variable selection via the elastic net. *Journal of the royal statistical society: series B (statistical methodology)* 2005;67(2):301-20.
21. Jafari S, Almasi A, Sharini H, Heydari S, Salari N. Diagnosis of borderline personality disorder based on Cyberball social exclusion task and resting-state fMRI: using machine learning approach as an auxiliary tool. *Computer Methods in Biomechanics and Biomedical Engineering: Imaging & Visualization* 2022:1-11. [Persian]
22. Kim SM, Kim Y, Jeong K, Jeong H, Kim J. Logistic LASSO regression for the diagnosis of breast cancer using clinical demographic data and the BI-RADS lexicon for ultrasonography. *Ultrasonography* 2018;37(1):36.
23. Taherkhani A, Cosma G, McGinnity TM. AdaBoost-CNN: An Adaptive Boosting algorithm for Convolutional Neural Networks to classify Multi-Class Imbalanced datasets using Transfer Learning. *Neurocomputing* 2020.
24. Baştanlar Y, Özüysal M. Introduction to machine learning. *miRNomics: MicroRNA biology and computational analysis* 2014:105-28.
25. Nardi C, Taliani GG, Castellani A, De Falco L, Selvi V, Calistri L. Repetition of examination due to motion artifacts in horizontal cone beam CT: comparison among three different kinds of head support. *Journal of International Society of Preventive & Community Dentistry* 2017;7(4):208.
26. Takhti SB, Jahantigh FF. A model for diagnosis of kidney disease using machine learning techniques. *Razi Journal of Medical Sciences* 2019;26(8):14-22. [Persian]
27. Ahn JS, Ebrahimian S, McDermott S, Lee S, Naccarato L, Di Capua JF, et al. Association of Artificial Intelligence–Aided Chest Radiograph Interpretation With Reader Performance and Efficiency. *JAMA Network Open* 2022;5(8):e2229289-e.
28. Thian YL, Ng D, Hallinan JTPD, Jagmohan P, Sia SY, Tan CH, et al. Deep learning systems for pneumothorax detection on chest radiographs: a multicenter external validation study. *Radiology: Artificial Intelligence* 2021;3(4):e200190.
29. Zhou B, Khosla A, Lapedriza A, Oliva A, Torralba A, editors. Learning deep features for discriminative localization. *Proceedings of the IEEE conference on computer vision and pattern recognition* 2016.
30. Zhang Q-s, Zhu S-C. Visual interpretability for deep learning: a survey. *Frontiers of Information Technology & Electronic Engineering* 2018;19(1):27-39.
31. Zeiler MD, Fergus R. Visualizing and understanding convolutional networks. In *Computer Vision—ECCV 2014: 13th European Conference, Zurich, Switzerland, September 6-12, 2014, Proceedings, Part I* 13 2014 (pp. 818-833). *Springer International Publishing*.
32. Röhrich S, Schlegl T, Bardach C, Prosch H, Langs G. Deep learning detection and quantification of pneumothorax in heterogeneous routine chest computed tomography. *European radiology experimental* 2020;4(1):1-11

Diagnosis of pneumothorax using machine learning algorithms and radiomics: Investigating the possibility of replacing simple chest radiography instead of CT scan in order to reduce the radiation dose

Hanieh Alimiri Dehbaghi
M.Sc.¹
Karim Khoshgard Ph.D.¹
Hamid Sharini Ph.D.^{2*}
Samira Jafari Khairabadi Ph.D.³
Farhad Naleini M.D.⁴

1- Department of Medical Physics,
School of Medicine, Kermanshah
University of Medical Sciences,
Kermanshah, Iran.

2- Department of Biomedical
Engineering, School of Medicine,
Kermanshah University of Medical
Sciences, Kermanshah, Iran.

3- Student Research Committee,
Kermanshah University of Medical
Sciences, Kermanshah, Iran.

4- Department of Radiology, School
of Medicine, Kermanshah
University of Medical Sciences,
Kermanshah, Iran.

* Corresponding author: Department of
Biomedical Engineering, School of
Medicine, Kermanshah University of
Medical Sciences, Shahid Shiroudi
Boulevard-St. University, Kermanshah,
Iran.
Tel: +98-83-34274678
E-mail: hamidsharini@gmail.com

Abstract

Received: 17 June, 2023 Revised: 22 June, 2023 Accepted: 16 July, 2023 Available online: 23 July, 2023

Background: The use of artificial intelligence algorithms to help with accurate diagnosis in medical images is one of the most important applications of this technology in the field of medical imaging. In this research, the possibility of replacing simple chest radiography instead of CT scan using machine learning models to detect pneumothorax was investigated in cases where CT is usually requested.

Methods: This study is analytical and was conducted from November 2022 to May 2023 at Kermanshah University of Medical Sciences. The data used in this research was extracted from the files of 350 patients suspected of pneumothorax. The collected images were pre-processed in MATLAB software. Then, three machine learning algorithms, including Logistic elastic net regression (LENR), Logistic lasso regression (LLR) and Adaptive Boosting (AdaBoost) were used. To evaluate the performance of these models, the criteria of precision, accuracy, sensitivity, specificity, area under the receiver operating characteristic curve (AUC), F1 score, and misclassification were used.

Results: In the AdaBoost model, the accuracy value in radiographic and CT images was calculated as 98.89% and 98.63%, respectively, and the precision value was calculated as 99.17% and 98.27%, respectively. In radiographic images, the AUC value for AdaBoost model was calculated as 100% and in CT scan images as 96.96%. The F1 score for the same model in radiographic was 99% and in CT images was 98.68%. The specificity value for the AdaBoost model was calculated as 99.45% in radiographic images and 94.67% in CT scan images. In the LLR model, the AUC value for radiographic and CT scan images was 99.87% and 99.02%, respectively.

Conclusion: According to the criteria evaluated in the present study, two LLR and AdaBoost models have similar performance in radiographic and CT images in terms of pneumothorax detection ability, so that this complication can also be diagnosed with high precision level using machine learning techniques on the radiographic images and thus receiving higher levels of radiation doses due to CT scan can be avoided in these patients.

Keywords: artificial intelligence, machine learning, pneumothorax.

Copyright © 2023 Alimiri Dehbaghi et. al. Published by Tehran University of Medical Sciences.

This work is licensed under a Creative Commons Attribution-Non-Commercial 4.0 International license (<https://creativecommons.org/licenses/by-nc/4.0/>).
Non-commercial uses of the work are permitted, provided the original work is properly cited.