

تشخیص پنوموتوراکس با استفاده از الگوریتم های 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 الگوریتم های هوش مصنوعی برای کمک به تشخیص صحیح در تصاویر پزشکی یکی از مهم ترین 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 در خواست می گردد، با هدف کاهش دوز دریافتی بیماران، مورد مطالعه قرار گرفت.

روش بررسی: مطالعه حاضر یک مطالعه تحلیلی بود و در بازه زمانی آذر ۱۴۰۱ تا خرداد ۱۴۰۲ در دانشگاه علوم پزشکی کرمانشاه انجام شده است. داده های مورداستفاده در این تحقیق از پرونده های ۳۵۰ فرد مشکوک به پنوموتوراکس استخراج شده است. تصاویر جمع آوری شده در نرم افزار MATLAB تحت پیش پردازش قرار گرفتند. سپس سه الگوریتم یادگیری ماشین، شامل رگرسیون لجستیک شبکه الاستیک (LENR)، رگرسیون لجستیک لاسو (LLR) و بوستینگ تطبیقی (AdaBoost) روی داده ها به کار گرفته شد. برای ارزیابی عملکرد این مدل ها از معیارهای دقت، صحت، حساسیت، ویژگی، سطح زیر منحنی مشخصه عملکرد سیستم، امتیاز F1 و طبقه بندی تادرست استفاده شد.

یافته ها: در مدل AdaBoost مقدار دقت در تصاویر رادیوگرافی و CT به ترتیب ۹۹/۹٪ و ۹۸/۲٪ محسوبه شد. مقدار AUC برای همین مدل در تصاویر رادیوگرافی برابر ۱۰۰٪ و در تصاویر سی تی اسکن برابر ۹۶/۹٪ به دست آمد. **نتیجه گیری:** با توجه به معیارهای موردارزیابی 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 گونه ای که می توان این عارضه را با دقت بالایی با استفاده از تکنیک های 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 دهbaghi^۱، کریم

خوش گرد^۱، حمید شرینی^{۲*}، سمیرا

جهفری 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

شیرودی، دانشگاه علوم پزشکی کرمانشاه، دانشکده

پزشکی.

تلفن: ۰۸۳-۳۴۲۷۴۶۱۸

E-mail: hamidsharini@gmail.com

مقدمه

آسیب قفسه سینه تقریباً ۲۵٪ از مرگومیرهای ناشی از ترومما را تشکیل داده که ۴۰-۵۰٪ از این بیماران احتمالاً پنوموتوراکس دارند.^۳ پنوموتوراکس غیرتروماتیک یا متعاقب یک بیماری ریوی زمینه ای عمدتاً بیماری انسدادی مزمن ریوی (COPD) یا به طور خودکار و بدون یک رویداد محرك شناخته شده روی می دهد.^{۴،۵} پنوموتوراکس

پنوموتوراکس (Pneumothorax) به معنای تجمع هوا داخل حفره جنب، بین جداری و جنب احتشایی، می باشد.^۱ پنوموتوراکس تروماتیک، یکی از عوارض شایع به دنبال ترومای قفسه سینه است.^۶

تصاویر را از نظر وجود پنوموتوراکس بررسی کردند. مدل یادگیری عمیق برای تشخیص پنوموتوراکس، AUC کمتری از دستیارهای رادیولوژی داشت، اما تصاویر را 1000×1000 برابر سریع‌تر شناسایی می‌کرد و همچنین سه پنوموتوراکس اضافی را شناسایی کرد که توسط دستیارها از دست رفته بود.¹¹

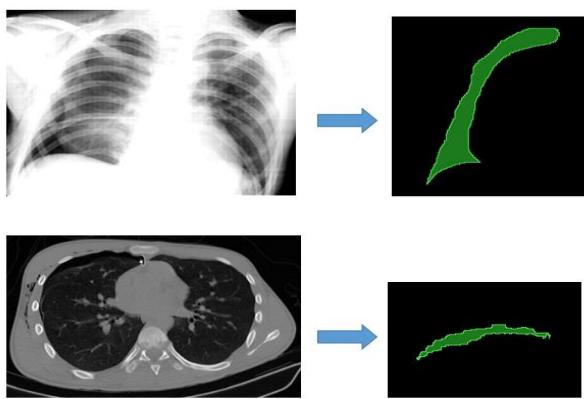
هدف پژوهش حاضر، امکان‌سنجی مقایسه رادیوگرافی ساده قفسه سینه و سی‌تی‌اسکن در تشخیص پنوموتوراکس با استفاده از الگوریتم‌های یادگیری ماشین و ویژگی‌های رادیومیکس است. در این پژوهش همچنین به بررسی امکان جایگزینی رادیوگرافی ساده قفسه سینه به‌منظور تشخیص پنوموتوراکس در مواردی که سی‌تی‌اسکن در خواست می‌گردد،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

روش بررسی

داده‌های استفاده شده در این پژوهش پس از تایید کمیتۀ اخلاق دانشگاه علوم پزشکی کرمانشاه (IR.KUMS.MED.REC.1401.168) از مرکز آموزشی درمانی شهر کرمانشاه گردآوری شده‌اند. داده‌های جمع‌آوری شده در این پژوهش شامل مشخصات دموگرافیک از قبلی سن، جنسیت، پارامترهای بالینی شامل سابقه بیماری ریوی، وجود تروماء، 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 مرکز 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 350 نفر بود که از این تعداد 150 نفر مبتلا به پنوموتوراکس و 200 نفر بدون پنوموتوراکس تشخیص داده شدند. میانگین سنی کل افراد $44/44 \pm 19/35$ سال بود که $(66.6\%)/(.34)$ نفر زن و $(33.4\%)/(.66)$ 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 به‌سمت پنوموتوراکس فشارنده (Tension) پیشرفت کرده و به یک اورژانس تبدیل شود، بنابراین تشخیص بموضع آن امری ضروری می‌باشد.¹² در پژوهش‌های انجام‌شده بر روی بیماران ICU در $11.3\% / 11$ 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.⁶ 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.² رادیوگرافی ایستاده قفسه سینه معمولاً اولین و رایج‌ترین مدل‌الیه 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 50 برابر رادیوگرافی است. مطابق با اصول حفاظت در برابر اشعه (به‌خصوص اصل) (As low as reasonably achievable, ALARA) تاجایی که امکان دارد، بایستی دوز بیماران را در انجام یک فرآیند تشخیصی کاهش داد. علاوه‌بر بحث حفاظت در برابر اشعه، در بیماران ناپایدار، سی‌تی‌اسکن همیشه قابل انجام نیست چراکه ممکن است در حین اسکن وضعیت بیمار بدتر شود و دسترسی به بیمار برای ادامه احیا وجود ندارد.⁶ در چند دهه اخیر حیطه تجزیه و تحلیل تصاویر پزشکی پیشرفت چشمگیری داشته است که امکان استخراج ویژگی‌های کمی که با چشم قابل مشاهده نیستند، را برای ما فراهم می‌کند. این عمل رادیومیکس (Radiomics) نامیده می‌شود.¹³

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.¹⁴ سیستم‌های هوش مصنوعی می‌توانند با به حداقل رساندن تعداد خطاهای در هنگام تفسیر تصویر، عملکرد هر سیستم تشخیص بیماری را بهبود بخشنند.¹ در مطالعه‌ای که توسط Yi و همکاران به صورت گذشته‌نگر انجام شد، یک شبکه عصبی کانولوشنال عمیق (Deep convolutional neural Network) روش 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 سی‌تی اسکن بیمار مبتلا به پنوموتراکس سمت راست

در این مرحله ابتدا روش‌های پیش‌پردازش مختلف شامل معنادل‌سازی هیستوگرام (Histogram equalization)، فیلتر دو لبه (Bilateral filter)، ناواضحی گاوی (Gaussian blur) و ماسک‌گذاری تطبیقی (Adaptive masking) بر روی تصاویر رادیوگرافی اعمال گردید. در نهایت با توجه به مقالات گذشته و نتایج بدست آمده در این پژوهش مشخص شد که بهترین روش پیش‌پردازش مورداستفاده در تجزیه و تحلیل تصاویر رادیوگرافی قفسه سینه اعمال ماسک‌گذاری تطبیقی، معنادل‌سازی هیستوگرام و ناواضحی گاوی به ترتیب است.^{۱۲} برای تصاویر سی‌تی اسکن فقط از معنادل‌سازی هیستوگرام و فیلتر دوبه استفاده شد.

فرایند تقسیم تصویر به قطعات تشکیل دهنده به منظور استخراج
شیای موردنظر، قطعه‌بندی (بخش‌بندی یا ناحیه‌بندی) نام دارد. پس از مرحله پیش‌پردازش، تصاویر رادیوگرافی و سی‌تی اسکن در ساختار خاصی در 3D Slicer software, version 5.2.2., NIH, USA

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

جهود ۱: مشخصات دموگرافیک، پارامترهای بالینی، پوزیشن بیماران و نوع سیستم رادیوگرافی برای بیماران مبتلا به پنوموتوراکس	
متغیر	تعداد
سن	۵۰/۴۸±۱۹/۳۸
جنسیت	مرد٪۷۲
زن	٪۲۸
درد قفسه سینه	٪۲۶/۶۶
تنگی نفس	٪۷۶
وجود بیماری ریوی زمینه‌ای	٪۷۰
تروما	٪۳۳/۳۳
شدت	خفیف٪۲۵/۳۳
پنوموتوراکس	متوسط٪۴۲/۶۶
پوزیشن بیمار در	شدید٪۳۷/۳۳
رادیوگرافی	خلفی-قدامی٪۵۶
نواع سیستم	قدامی-خلفی٪۴۴
رادیوگرافی	DR٪۶۵/۳۴
انحراف معیار	CR٪۳۴/۶۶

به منظور رعایت ملاحظات اخلاقی، تمام اطلاعات گرفته شده از پرونده بیماران کدگذاری شده و محرومانه بودند. تصاویر رادیوگرافی با استفاده از کیلولولتاز پیک ۷۰ و اکسپوزر ۱۲ میلی آمپر ثانیه (به طور متوسط) تهیه شده بودند. دستگاه Computed Radiography، CR، (Digital Radiography، DR، Shimadzu, Japan) و دستگاه Payamed electronic, Iran) بود. در تصاویر CT، ضخامت برش ۱، ۱/۵، ۲، ۳، ۵ و ۷ میلی متر، ولتاژ تیوب ۱۱۰، ۱۲۰ و ۱۳۰ و اکسپوزر (Exposure) نیز از ۲۴ تا ۳۳۲ میلی آمپر ثانیه متغیر بود. دستگاه CT scan، 16 slice، Siemens, Germany) سی تی اسکن فقط برش های آگریال مورداستفاده قرار گرفتند و برای هر بیمار، بهترین برش نمایانگر پنوموتوراکس انتخاب و متعاقباً تمام مراحل بر روی همین برش انجام گفت. همه تصاویر جمع آوری شده دارای فرمت دایکام (DICOM) بودند.

مرحله پیشپردازش يك بخش مهم در مباحث مربوط به تجزيه و تحليل تصاویر است. اين 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 متالی با سطح خاکستری یکسان، در یک یا چند جهت، در دو یا سه بعد ارایه 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 بهم پیوسته با سطح خاکستری یکسان، اساس ماتریس را تشکیل می‌دهد. یک بافتی با همگنی بیشتر باعث ایجاد ماتریس پهن‌تر و مسطح‌تر می‌گردد.^{۱۱} 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.^{۱۲}

مدل‌های یادگیری ماشین مورداستفاده 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 سی‌تی اسکن 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 به طور تصادفی از کل داده‌ها انتخاب شدند.

این گونه موضوعات از دسته مسائل یادگیری با نظرات هستند، یعنی به داده‌های برچسب‌گذاری شده نیاز دارند. الگوریتم‌های یادگیری ماشین استفاده شده در این پژوهش، رگرسیون لجستیک شبکه‌ای استیک (Logistic elastic net regression, LENR)، رگرسیون لجستیک لاسو (Logistic lasso regression, LLR) و بوستینگ تطبیقی (Adaptive boosting, AdaBoost) هستند. این الگوریتم‌ها در محیط Python programming environment, Real Python, برنامه‌نویسی USA اجرا شدند. رگرسیون لجستیک یک الگوریتم طبقه‌بندی است که هدف آن پیدا کردن ارتباط بین ویژگی‌ها و احتمال یک خروجی خاص است.^{۱۳}

انسان دشوار است.^{۱۰} این کار در تولباکس رادیومیکس در 3D Slicer software, version 5.2.2., NIH, USA 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 پنوموتراکس 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)^{۱۶} ویژگی ماتریس اندازه ناحیه سطح خاکستری (Gray level size zone matrix)^{۱۶} و پنج ویژگی ماتریس (Neighboring gray tone difference matrix)^{۵۱} تفاوت شدت خاکستری همسایه 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 HHH، HLL، HHL، HLL و LLL و LHL به دست آمدند، در مجموع از هر تصویر ۸×۶۹ (۶۲۱) حالت تجزیه Wavelet ویژگی استخراج و تمام این ویژگی‌ها برای تصاویر رادیوگرافی و سی‌تی اسکن 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 بر جسته کرده و بنابراین بر جزیات تصویر تأکید می‌کند، در حالی که فیلتر پایین‌گذر تصویر را از نظر سطح خاکستری صاف کرده و جزیات 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 به عنوان 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 به کاررفته را نشان می‌دهد.

سی‌تی‌اسکن	رادیوگرافی	
(LLL, LLH, LHL, LHH, HLL, HLH, Anzai HHL, HHH) مجموع انزای (LLH, HLL, LLL, HLH, LHH, HHL, HHH) میانگین (LHL, HLL) صدک دهم (HLL, HHL, LHL کشیدگی (LLL) دامنه بین چارکی (HLL, HLH) دامنه بین چارکی (LLL) ریشه میانگین مربعی (HLH, HLL, HHL, HHH) میانگین انحراف مطلق قوی (HLH)	انزای مجموع انزای (LLL) مجموع انزای (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) (HLH, HLL) واریانس سطح خاکستری (HLH, Takید 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 (LLL غیر یکنواختی در اندازه نواحی (LHL) غیر یکنواختی در اندازه نواحی (HLL) غیر یکنواختی در اندازه نواحی غیر یکنواختی در سطح خاکستری (LLH غیر یکنواختی در سطح خاکستری غیر یکنواختی در طول پیمایش غیر یکنواختی در طول پیمایش (LLL واریانس پیمایش (LHL تاكید بر پیمایش بلند (LHH)	GLSZM
واریانس سطح خاکستری (HLH تاكید 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 (LLH واریانس پیمایش (LHL تاكید بر پیمایش بلند (LHH)	GLRLM
واریانس سطح خاکستری (LLH عدم یکنواختی وابستگی (HLH تاكید بر سطوح خاکستری بالا با وابستگی بزرگ (HLL, LLH) قدرت (HHL) دامنه بین چارکی (HLL پیشیدگی (LHH)	تاكید بر سطوح خاکستری بالا با وابستگی بزرگ (LLH شلوغی (LLH)	GLDM
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. ^{۱۸} 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 برآش بیش‌ازحد (Overfitting) را کنترل می‌کنند. ^{۱۹} به عنوان یک ابزار یادگیری ماشین، رگرسیون لجستیک، یک روش افتراقی قدرتمند در نظر گرفته می‌شود. ^{۲۰} رگرسیون لجستیک منظم مجموعه کوچکی از	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.^{۱۸} 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 برآش بیش‌ازحد (Overfitting) را کنترل می‌کنند.^{۱۹} به عنوان یک ابزار یادگیری ماشین، رگرسیون لجستیک، یک روش افتراقی قدرتمند در نظر گرفته می‌شود.^{۲۰} 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. با توجه به این جدول، از نظر معیار صحت، مدل AdaBoost با مقدار ۹۸/۸۹٪ در تصاویر رادیوگرافی و ۹۸/۶۳٪ 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 ۹۹/۱۷٪ و ۹۸/۲۷٪ در تصاویر رادیوگرافی و سی‌تی‌اسکن، در مورد تصاویر رادیوگرافی قوی‌تر ظاهر شده است.

در رابطه با معیار اختصاصی بودن، همچنان مدل AdaBoost با مقدار ۹۹/۴۵٪ در تصاویر رادیوگرافی و ۹۴/۶۷٪ 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 (۹۹٪) نسبت به سی‌تی‌اسکن (۹۸/۶۸٪) 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. با توجه 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 جرمیمه‌های هر دو تکنیک لاسو و ریچ (Ridge) برای منظم کردن مدل‌های رگرسیون انجام می‌دهد. این روش منظم‌سازی مدل‌های آماری را با ترکیب هر دو روش لاسو و ریچ بهبود می‌بخشد.^{۲۱}

لاسو یک روش رگرسیون جرمیمه‌شده است که ضرایب رگرسیون را با به حداقل رساندنتابع 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 به طور خودکار متغیرهای کمکی غیرضروری را حذف می‌کند.^{۲۲}

بوستینگ تطبیقی یک روش گروهی است که در آن گروهی از طبقه‌بندی‌کننده‌های ضعیف به صورت 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 به طور صحیح توسط طبقه‌بندی ضعیف قبلی آموزش داده شود، وزن نمونه به صورت تصاعدی کاهش می‌یابد.

مدل‌های گروهی با ترکیب تعدادی تخمین‌گر پایه به دقت 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 (True positive, TP) نحوه محاسبه این معیارها را نشان می‌دهند. ((True negative, TN) تعداد موارد مثبت واقعی، (False negative, FN) تعداد موارد منفی کاذب).^{۲۴} و^{۲۵}

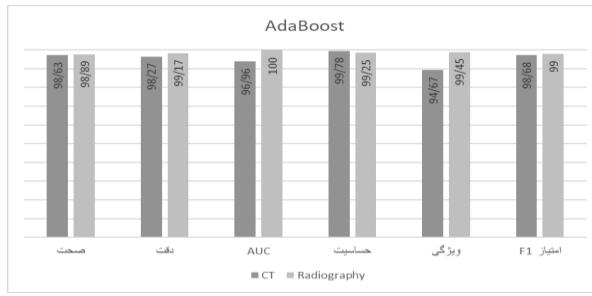
۱- صحت
۲- دقت

$$\frac{TP + TN}{TP + TN + FP + FN}$$

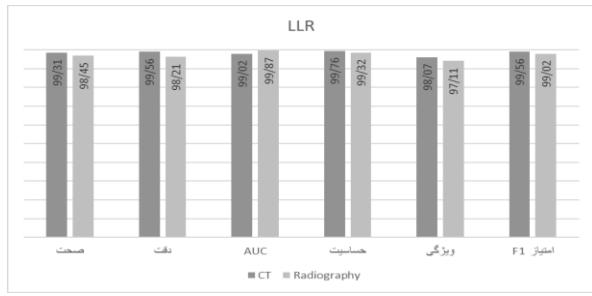
$$\frac{TP}{TP + FP}$$

جدول ۳: معیارهای ارزیابی محاسبه شده برای هر سه مدل در تصاویر رادیوگرافی و سی‌تی اسکن

مدالیته تصویربرداری	نام مدل	صحت	دققت	حساسیت	ویژگی	امتیاز	F1	AUC	طبقه‌بندی نادرست
سی‌تی اسکن	LENR	.۷۷/۰۵۵	.۷۷/۰۵۵	.۹۹/۰۵۶	-	.۸۶/۰۷۵	.۹۹/۰۲	.۹۵۰	.۲۲/۴۴
LLR	LLR	.۹۹/۰۳۱	.۹۹/۰۵۶	.۹۹/۰۷۶	.۹۸/۰۰۷	.۹۹/۰۵۶	.۹۰/۰۶۸	.۹۹/۰۲	.۰/۶۸
AdaBoost	AdaBoost	.۹۸/۰۶۳	.۹۸/۰۲۷	.۹۹/۰۷۸	.۹۴/۰۷	.۹۸/۰۸۸	.۹۶/۰۹۶	.۹۶/۰۹۶	.۰/۶۸
رادیوگرافی	LENR	.۳۴/۰۵۴	.۳۳/۰۶۵	.۹۹/۰۷۶	-	.۵۰/۰۱۶	.۹۹/۰۰۲	.۹۵۰	.۶۵/۰۴۵
LLR	LLR	.۹۸/۰۴۵	.۹۸/۰۲۱	.۹۹/۰۳۲	.۹۷/۰۱۱	.۹۹/۰۰۲	.۹۹/۰۸۷	.۹۹/۰۵۵	.۱/۰۵۵
AdaBoost	AdaBoost	.۹۸/۰۸۹	.۹۹/۰۱۷	.۹۹/۰۲۵	.۹۹/۰۴۵	.۹۹	.۱/۱۱	.۱۰۰	.۱/۱۱



نمودار ۲: مقایسه عملکرد مدل AdaBoost در تصاویر رادیوگرافی و سی‌تی اسکن



نمودار ۱: مقایسه عملکرد مدل LLR در تصاویر رادیوگرافی و سی‌تی اسکن

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

علاوه‌بر ارجحیت رادیوگرافی بر سی‌تی اسکن در بحث حفاظت در برابر اشعه، بیمار برای سی‌تی اسکن باید به بخش دیگری منتقل شود که درمورد بیماران ناپایدار و با ضایعات نخاعی این امر نگران‌کننده است.^۲ همچنین سی‌تی اسکن یک فرایند زمان‌بر نسبت به رادیوگرافی است در حالی‌که تصویربرداری در بخش اورژانس به خصوص 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 سی‌تی اسکن می‌تواند باعث ایجاد آرتیفیکت حرکتی در تصاویر، تشخیص نادرست و یا تکرار تصویربرداری و دریافت دوز بیش از حد در بدن بیمار شود.^{۲۵}

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

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

بحث

هدف از پژوهش حاضر، مقایسه عملکرد مدل‌های یادگیری ماشین در تشخیص پنوموتوراکس بین دو مدلیته تصویربرداری رادیوگرافی و سی‌تی اسکن بود. همچنین به بررسی این موضوع پرداخته شد که آیا می‌توان با به کارگیری تکنیک‌های یادگیری ماشین و استخراج ویژگی‌های رادیومیکس در تصاویر رادیوگرافی، این مدلیته تصویربرداری را جایگزین سی‌تی اسکن در تشخیص پنوموتوراکس نمود. از آنجایی که سی‌تی اسکن دوزی چندین برابر رادیوگرافی به بیماران تحمیل می‌کند، اگر بتوان برای تشخیص پنوموتوراکس در مواردی که به طور معمول سی‌تی اسکن 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 مورداستفاده 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 حاضر، 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 مورداستفاده در مطالعه حاضر، عملکرد بهتری داشتند.^{۳۲}

نتایج حاصل از این پژوهش نشان داد که با پیاده‌سازی مدل‌های یادگیری ماشین بروی تصاویر رادیوگرافی می‌توان به عملکرد تشخیصی معادل با سی‌تی‌اسکن برای تشخیص پنوموتوراکس دست یافت و به‌این 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 با توجه به سهولت به کارگیری تکنیک‌های یادگیری ماشین و همچنین مقادیر قابل توجه معیارهای به دست آمده در این پژوهش و سایر مطالعات، توسعه‌دهندگان حوزه مراقبت‌های بهداشتی را متقاعد می‌سازد تا سیستمی مبتنی بر این تکنیک‌ها برای تشخیص افراد با و بدون پنوموتوراکس در بخش اورژانس ایجاد کنند.

نویسنده‌گان اعلام می‌دارند که هیچ‌گونه تضاد منافعی 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 این که ویژگی‌های رادیومیکس ذکر شده در جدول ۲، اهمیت خود را در تشخیص پنوموتوراکس نشان داده‌اند، می‌توانند کاندیدهای مناسبی برای مارکرهای زیستی در عارضه پنوموتوراکس در نظر گرفته شوند، بنابراین پیشه‌هاد می‌گردد که در مطالعات آینده همبستگی بین این ویژگی‌ها با پارامترهای بالینی از قبیل افزایش رزوئانس، کاهش صدای ریوی، افزایش تعداد تنفس، سیانوز، آمفیزیم 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.^{۳۳} 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.^{۳۴}

در پژوهش دیگری که توسط Thian و همکاران با هدف ارزیابی تعمیم‌پذیری یک مدل یادگیری عمیق (Deep learning) تشخیص پنوموتوراکس بروی 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.^{۳۵} بالاترین میزان حساسیت و اختصاصی بودن در این مطالعه برابر ۰.۹۸٪ و امتیاز F1 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, Salaminia 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, Navkhani 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. Mayerhofer ME, Materka A, Langs G, Häggström I, Szczypinski 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. Gielecik A, Marcinia 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, Andreadczyk 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, Özysal 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.