

Automatic Lung Diseases Identification using Discrete Cosine Transform-based Features in Radiography Images

Shamim Yousefi*, Samad Najjar Ghabel*

*Assistant professor, University of Mohaghegh Ardabili.Ardabil

Abstract

The use of raw radiography results in lung disease identification has not acceptable performance. Machine learning can help identify diseases more accurately. Extensive studies were performed in classical and deep learning-based disease identification, but these methods do not have acceptable accuracy and efficiency or require high learning data. In this paper, a new method is presented for automatic interstitial lung disease identification on radiography images to address these challenges. In the first step, patient information is removed from the images; the remaining pixels are standardized for more precise processing. In the second step, the reliability of the proposed method is improved by Radon transform, extra data is removed using the Top-hat filter, and the detection rate is increased by Discrete Wavelet Transform and Discrete Cosine Transform. Then, the number of final features is reduced with Locality Sensitive Discriminant Analysis. The processed images are divided into learning and test categories in the third step to create different models using learning data. Finally, the best model is selected using test data. Simulation results on the NIH dataset show that the decision tree provides the most accurate model by improving the harmonic mean of sensitivity and accuracy by up to 1.09times compared to similar approaches.

Keywords: Locality Sensitive Discriminant Analysis, Discrete Wavelet Transform, Discrete Cosine Transform, Interstitial lung disease identification, Radiography images, Decision tree

تشخیص خودکار بیماری های ریوی با استفاده از ویژگی های مبتنی بر تبدیل کسینوسی گسسته در تصاویر رادیوگرافی

شمیم یوسفی*، صمد نجار قابل*^x

* استادیار دانشگاه محقق اردبیلی، اردبیل، دانشگاه محقق اردبیلی، دانشکده فنی مهندسی، گروه مهندسی برق و کامپیوتر

تاریخ پذیرش: ۱۴۰۰/۱۲/۰۸

تاریخ دریافت: ۱۴۰۰/۱۱/۰۸

نوع مقاله: پژوهشی

چکیده

استفاده از نتایج خام رادیوگرافی در تشخیص بیماری های ریوی عملکرد قابل قبولی ندارد. یادگیری ماشین می تواند به تشخیص دقیق تر بیماری ها کمک کند. مطالعات گسترده ای در حوزه تشخیص خودکار بیماری ها با کمک یادگیری ماشین کلاسیک و عمیق انجام شده؛ اما این روش ها دقت و کارایی قابل قبولی ندارند یا به داده های یادگیری زیادی نیاز دارند. برای مقابله با این چالش ها، در این مقاله، روش جدیدی برای تشخیص خودکار بیماری های ریوی بینابینی در تصاویر رادیوگرافی ارائه می شود. در گام اول، اطلاعات بیمار از تصاویر حذف شده؛ سپس، پیکسل های باقیمانده، جهت پردازش های دقیق تر، استانداردسازی می شوند. در گام دوم، پایایی روش پیشنهادی با کمک تبدیل رادان بهبود یافته، داده های اضافی با استفاده از فیلتر Top-hat حذف شده و نرخ تشخیص با بهره برداری از تبدیل موجک گسسته و تبدیل کسینوسی گسسته افزایش می یابد. سپس، تعداد ویژگی های نهایی با کمک آنالیز تشخیصی حساس به مکان کاهش می یابد. در گام سوم، تصاویر پردازش شده به دو دسته یادگیری و تست تقسیم می شوند؛ با استفاده از داده های یادگیری، مدل های مختلفی ایجاد شده و با کمک داده های تست، بهترین مدل انتخاب می شود. نتایج شبیه سازی ها بر روی مجموعه داده NIH نشان می دهد که روش پیشنهادی مبتنی بر درخت تصمیم با بهبود میانگین هارمونیک حساسیت و صحت تا ۱/۰۸ برابر، دقیق ترین مدل را ارائه می دهد.

واژگان کلیدی: آنالیز تشخیصی حساس به مکان، تبدیل کسینوسی گسسته، تبدیل موجک گسسته، تشخیص بیماری های ریوی بینابینی، تصاویر رادیوگرافی، درخت تصمیم.

^x نویسنده مسئول: صمد نجار قابل، samad.najjar@gmail.com

۱. مقدمه

امروزه، بیماری های ریوی بینابینی مانند ذات الریه و سل ریوی که بر ساختار ریه تأثیر می گذارند، یکی از دلایل اصلی مرگ و میر در سرتاسر جهان به شمار می روند [۲]، [۱] اگر این بیماری های عفونی به موقع تشخیص داده نشوند، کشنده تر خواهند بود؛ در واقع، رشد سریع ناهنجاری های ریوی می تواند منجر به تشکیل تومور در بدن بیمار شده و احتمال مرگ او را افزایش دهد [۳]. طبق گزارش های سازمان بهداشت جهانی، بیماری های ریوی بینابینی، بعد از ایدز، دومین عامل کشنده در جهان هستند که هر ساله، تقریباً ۱/۶ میلیون قربانی می گیرند [۴].

رادیوگرافی قفسه سینه اولین روش تصویربرداری است که به دنبال بروز علائم بیماری در بدن افراد، برای تشخیص عوارض مختلف ریوی مانند ذات الریه، سل، سرطان ریه و غیره مورد استفاده قرار می گیرد [۶]، [۵]. از آنجایی که نتایج رادیوگرافی، آناتومی قفسه سینه را به طور کامل نشان می دهد، برآمدگی جانبی آن می تواند محل دقیق ناهنجاری های ریه در بدن بیمار را مشخص کند [7]. علاوه بر این، رادیوگرافی قفسه سینه نسبت به سایر روش های تصویربرداری مانند سونوگرافی و سی تی اسکن، ارزان تر است [۸]؛ بنابراین، در جامعه پزشکی امروز، از رادیوگرافی قفسه سینه برای شناسایی بیماری های اندام های داخلی از جمله ریه، به طور گسترده استفاده می شود. با این حال، استفاده از نتایج خام رادیوگرافی قفسه سینه، گاهی اوقات در تشخیص بیماری های ریوی عملکرد قابل قبولی ندارد [۹]. استفاده از رویکردهای آنالیز تصویر مبتنی بر یادگیری ماشین می تواند به شناسایی دقیق تر و سریع تر هر نوع ناهنجاری در ریه های بیمار کمک شایانی کند [۱۰].

بررسی ها نشان می دهند که مطالعات گسترده ای در حوزه تشخیص خودکار بیماری های ریوی بینابینی با بهره برداری از رویکردهای مبتنی بر یادگیری ماشین انجام شده است. گروهی از این رویکردها از الگوریتم های کلاسیک مانند نزدیک ترین همسایه وزن دار مبتنی بر فاصله اقلیدسی، فاصله EarthMovers، ماتریس هم رویداد برای سطوح خاکستری و شبکه عصبی مصنوعی برای تمایز بین ریه های سالم و بیمار در تصاویر رادیوگرافی بهره بردند [۱۲]، [۱۱]. اگرچه این روش ها کارایی قابل قبولی داشتند، اما به دلیل عدم استفاده از مرحله پیش پردازش برای حذف نویز از تصاویر ورودی، حساسیت به چرخش تصویر، مقیاس بندی و شدت، استفاده از طبقه بندی کننده دودویی و عدم توجه به تقسیم داده ای استاندارد، دقت قابل قبولی را برای برنامه های کاربردی پزشکی ارائه

نمی دهند [۱۳]. برای مقابله با این چالش، گروه دیگری از نویسندگان، استفاده از رویکردهای مبتنی بر یادگیری عمیق را پیشنهاد کردند [۱۵]، [۱۴] اگرچه این رویکردها دقت تشخیص بالایی را ارائه می دهند، اما به تعداد داده های یادگیری زیادی نیاز دارند [۱۶].

در اغلب برنامه های کاربردی پزشکی جهت تشخیص بیماری ها، هدف اصلی به حداکثر رساندن دقت تشخیص با استفاده از حداقل تعداد داده های یادگیری است [۱۷]؛ بنابراین، در این مقاله، روش جدیدی برای تشخیص خودکار بیماری های ریوی بینابینی با استفاده از ویژگی های تبدیل کسینوسی گسسته در تصاویر رادیوگرافی ارائه می شود؛ این روش، تشخیص خودکار بیماری های ریوی (ALDI)^۱ نام دارد. در گام اول از روش ALDI، ابتدا اطلاعات بیمار از تصاویر خام رادیوگرافی قفسه سینه حذف می شود. سپس، پیکسل های باقیمانده، جهت دستیابی به وضوح مورد نظر و پردازش های دقیق تر بعدی، استانداردسازی می شوند. در گام دوم، پایایی روش ALDI با استفاده از تبدیل رادان، به نویزهای سفید (صفر) بهبود یافته، داده های اضافی با کمک فیلتر Top-hat حذف شده و نرخ تشخیص با بهره برداری از تبدیل موجک گسسته و استخراج ویژگی های مبتنی بر تبدیل کسینوسی گسسته افزایش می یابد. سپس، ضرایب مستخرج از تبدیل کسینوسی گسسته با استفاده از روش زیگزاگ، از بردار ۲-بعدی به ۱-بعدی تبدیل شده و تعداد ویژگی های نهایی با استفاده از رویکرد آنالیز تشخیصی حساس به مکان کاهش می یابد. در گام سوم، تصاویر پردازش شده در مراحل پیشین، به دو دسته یادگیری و تست تقسیم می شوند تا با استفاده از داده های یادگیری، مدل های مختلفی جهت تشخیص خودکار بیماری های ریوی ساخته شود. در نهایت، با استفاده از داده های تست، مدل های ساخته شده ارزیابی شده و بهترین آن ها، به عنوان مدل نهایی انتخاب می شود.

نتایج حاصل از شبیه سازی روش پیشنهادی بر روی مجموعه داده مرکز بالینی NIH [۱۹]، [۱۸] نشان می دهد که طبقه بندی کننده درخت تصمیم با افزایش مقدار متوسط F-Value نسبت به رویکردهای K-نزدیک ترین همسایه، ماشین بردار پشتیبان و شبکه عصبی مصنوعی، تصاویر رادیوگرافی قفسه سینه را با صحت و حساسیت بیشتری طبقه بندی می کند. همچنین، این رویکرد با به حداقل رساندن خطای اعتبارسنجی متقابل در تشخیص خودکار بیماری های ریوی بینابینی، عملکرد بهتری نسبت به سایر طبقه

^۱ Automatic Lung Diseases Identification

استفاده کردند. سامانه موردنظر با استفاده از ۲۰ تصویر آزمایشی تصادفی دیگر که از همان پایگاه داده استخراج شده بود، مورد ارزیابی قرار گرفت. در این روش، ویژگی‌های پایه‌ای با بهره‌گیری از هشت عامل تبدیل موجک [۲۳] استخراج شدند. سپس، ویژگی‌های تصاویر ریه‌های سالم و ناسالم با کمک روش نزدیک‌ترین همسایه وزن‌دار مبتنی بر فاصله اقلیدسی [۲۴] متمایز شدند. اگرچه استفاده از این رویکردهای مبتنی بر تبدیل موجک توانسته است دقت استخراج ویژگی‌ها از تصاویر رادیوگرافی را بهبود بخشد، اما این روش فاقد مرحله پیش‌پردازش برای حذف نویز از تصاویر ورودی است.

خاتری و همکاران او [۲۵] استفاده از فاصله [۲۶] EarthMovers را برای تشخیص ذات‌الریه در تصاویر رادیوگرافی پیشنهاد کردند. در مرحله پیش‌پردازش، نویسندگان مناطق ریه در تصاویر خام را جهت حذف نویزهای احتمالی برش دادند. سپس، شدت تصاویر استانداردسازی شده و از تفاوت فاصله EarthMovers برای تشخیص نمونه‌های بیمار از سالم استفاده شد. اگرچه استفاده از رویکرد مبتنی بر فاصله EarthMovers، دقت قابل‌قبولی دارد، اما این روش به تغییرات ناشی از چرخش تصویر، مقیاس‌بندی و شدت، حساس است؛ بنابراین، نمی‌تواند حجم بالایی از داده‌ها را مدیریت کند.

وارلا-سانتوس و پاتریشیا [۲۷] یک رویکرد مبتنی بر یادگیری ماشین برای طبقه‌بندی تصاویر رادیوگرافی شامل ریه‌های سالم و مبتلا به بیماری‌های بینابینی معرفی کردند. ابتدا، نویسندگان از روش پیش‌پردازش مبتنی بر یکسان‌سازی هیستوگرام جهت استخراج مناطق ریه از تصاویر ورودی و تغییر اندازه داده‌ها استفاده کردند. برای استخراج ویژگی‌ها و طبقه‌بندی تصاویر نیز، ماتریس هم‌رویداد برای سطوح خاکستری [۲۸] و شبکه عصبی مصنوعی [۲۹] مورد استفاده قرار گرفتند. نتایج تجربی نشان می‌دهد که این روش نه تنها دقت پایینی دارد، بلکه فقط از طبقه‌بندی‌کننده دودویی برای تشخیص ریه‌های بیمار در تصاویر رادیوگرافی استفاده می‌کند.

چیکارا و همکاران او [۳۰] از رویکردهای پیش‌پردازش و شبکه عصبی پیچشی از پیش آموزش‌دیده [۳۱] برای تجزیه و تحلیل تصاویر و تشخیص اشیا، جهت تمایز بین تصاویر رادیوگرافی مبتلا به ذات‌الریه و ریه سالم در کودکان استفاده کردند. در واقع، این روش از فیلتر میانه [۳۲] برای کاهش نویزهای احتمالی موجود در تصاویر ورودی، از تصحیح گاما [۳۳] برای نمایش درست پیکسل‌ها، از همسان‌سازی هیستوگرام تطبیقی [۳۴] برای بهبود کیفیت تصاویر و از رویکرد فشرده‌سازی JPEG [۳۵] برای فشرده‌سازی

بندی‌کننده‌ها دارد. علاوه بر این موارد، روش مبتنی بر درخت تصمیم با بهبود میانگین هارمونیک حساسیت و صحت، دقیق‌ترین مدل را نسبت به رویکردهای اخیر موجود در حوزه تشخیص خودکار بیماری‌های بینابینی ریوی ارائه می‌دهد. بر این اساس، استفاده از رویکرد درخت تصمیم برای طبقه‌بندی تصاویر پردازش‌شده می‌تواند دقیق‌ترین نتایج را در برنامه‌های کاربردی پزشکی مانند تشخیص خودکار بیماری‌های بینابینی ریوی ارائه دهد. به‌طور خلاصه، نوآوری‌های اصلی این مقاله به شرح زیر می‌باشند:

- ارائه روشی نوین جهت تشخیص خودکار بیماری‌های ریوی با حداکثر دقت و با استفاده از حداقل تعداد داده‌های یادگیری.
- بهبود نرخ تشخیص با استفاده از تبدیل موجک گسسته و استخراج ویژگی‌های مبتنی بر تبدیل کسینوسی گسسته.
- کاهش تعداد ویژگی‌های مورد استفاده با استفاده از رویکرد آنالیز تشخیصی حساس به مکان.
- استفاده از رویکردهای مختلف برای استخراج بهترین مدل جهت طبقه‌بندی تصاویر پردازش‌شده به دو گروه ریه‌های سالم و بیمار با حداکثر حساسیت و کم‌ترین میزان خطای اعتبارسنجی متقابل.

ساختار بخش‌های بعدی مقاله، به شرح زیر تنظیم شده است: در بخش دوم، رویکردهای پیشین موجود جهت تشخیص خودکار بیماری‌های ریوی بررسی خواهند شد. بخش سوم، شامل توضیحاتی در مورد گام‌های اصلی روش پیشنهادی مقاله است. در بخش چهارم، به ارزیابی نتایج حاصل از راهکار پیشنهادی و مقایسه آن با آخرین روش‌های موجود پرداخته شده، نشان داده می‌شود که روش ALDI تا چه حد توانسته است به اهداف موردنظر مقاله نزدیک شود. در نهایت، نتیجه‌گیری مقاله در بخش پنجم آورده شده است.

۱- روش‌های پیشین

بررسی‌ها نشان می‌دهند که مطالعات گسترده‌ای در حوزه تشخیص خودکار بیماری‌های ریوی با استفاده از رویکردهای مبتنی بر یادگیری ماشین انجام شده است. در همین راستا، الیوریا و همکاران او [۲۰] شبکه مبتنی بر یادگیری ماشین [۲۲]، [۲۱] را برای تشخیص بیماری‌های ریوی، به‌ویژه ذات‌الریه ارائه کردند. نویسندگان، زیرمجموعه‌ای از ۴۰ تصویر پایگاه داده (۲۰ تصویر از ریه سالم و ۲۰ تصویر از ریه بیمار) را برای آموزش روش پیشنهادی

بهره بردند. همچنین، یک مدل اصلاح شده یادگیری عمیق که از لایه شکاف به جای لایه پهن استفاده می کند، جهت بهبود دقت تشخیص معرفی شد. اگرچه این رویکرد دقت قابل قبولی دارد، اما از تقسیم داده های استاندارد برای ارزیابی روند تشخیص بیماری استفاده نمی کند.

در نهایت، رویکردهای جدیدتر بر تشخیص خودکار بیماری COVID-19 در تصاویر رادیوگرافی قفسه سینه تمرکز کرده اند [۴۶]-[۴۳] اغلب این روش ها، شبکه عصبی عمیق را جهت تجزیه و تحلیل دقیق تر تصاویر داده های استاندارد مورد استفاده قرار داده اند. باین حال، این رویکردها نیز به تعداد داده های یادگیری زیادی نیاز دارند.

بررسی دقیق تر روش های پیشین موجود در حوزه تشخیص خودکار بیماری های ریوی بینابینی نشان می دهد که اغلب این رویکردها به دلیل عدم استفاده از مرحله پیش پردازش برای حذف نویز از تصاویر ورودی، حساسیت به چرخش تصویر، مقیاس بندی و شدت، استفاده از طبقه بندی کننده دودویی و عدم توجه به تقسیم داده ای استاندارد، دقت قابل قبولی را برای برنامه های کاربردی پزشکی ارائه نمی دهند. علاوه بر این، رویکردهای مبتنی بر یادگیری عمیق با دقت تشخیص بالا، به تعداد داده های یادگیری زیادی نیاز دارند. این در حالی است که در اغلب برنامه های کاربردی پزشکی جهت تشخیص بیماری ها، هدف اصلی به حداکثر رساندن دقت تشخیص با استفاده از حداقل تعداد داده های یادگیری است.

۲- روش پیشنهادی

در این بخش، یک روش جدید مبتنی بر هوش مصنوعی برای تشخیص خودکار بیماری های ریوی بینابینی در تصاویر رادیوگرافی قفسه سینه ارائه خواهد شد. روش ارائه شده، تشخیص خودکار بیماری های ریوی (ALDI) نام دارد. همان طور که در شکل ۱ نشان داده شده است، روش ALDI شامل سه گام پیش پردازش، پردازش اصلی و طبقه بندی است. در گام اول، ابتدا اطلاعات بیمار از تصاویر خام رادیوگرافی قفسه سینه حذف می شود. سپس، پیکسل های باقیمانده، جهت دستیابی به وضوح مورد نظر و پردازش های دقیق تر بعدی، استانداردسازی می شوند. در گام دوم، پایایی روش پیشنهادی با استفاده از تبدیل رادان، به نویزهای سفید (صفر) بهبود یافته، داده های اضافی با کمک فیلتر Top-hat حذف شده و نرخ تشخیص با بهره برداری از تبدیل موجک گسسته و استخراج ویژگی های مبتنی بر تبدیل کسینوسی گسسته افزایش می یابد.

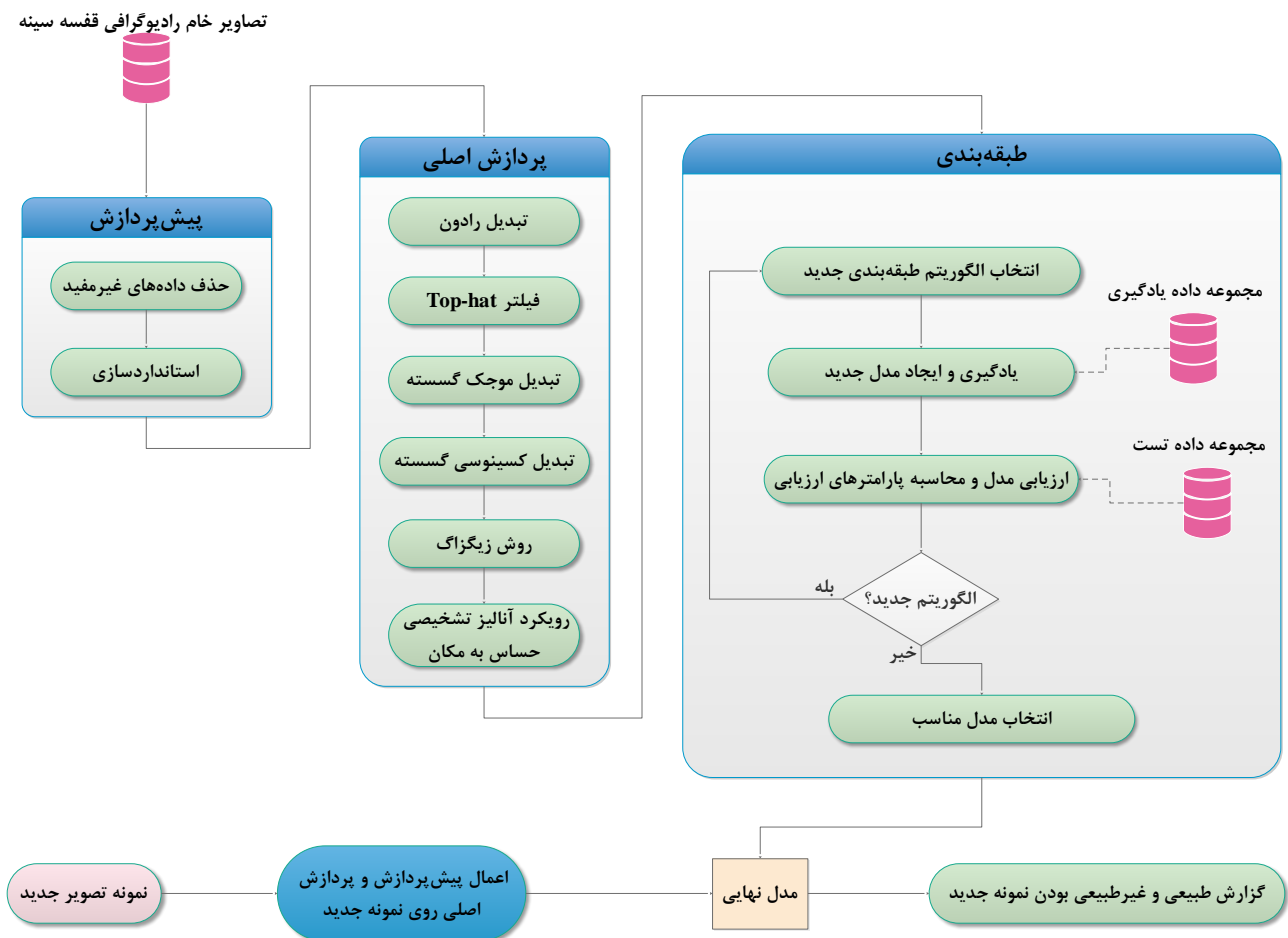
اندازه تصاویر، بدون آسیب رساندن به کیفیت آن ها بهره می برد. نتایج تجربی نشان می دهد که استفاده از شبکه عصبی پیچشی از پیش آموزش دیده می تواند به تشخیص دقیق تر بیماری های ریوی بینابینی در کودکان کمک کند؛ اما به تعداد داده های یادگیری بالایی نیاز دارد.

تاکور و همکاران او [۳۶] نیز از شبکه عصبی عمیق VGG16 از پیش آموزش دیده برای تشخیص بیماری های ریوی بینابینی در تصاویر رادیوگرافی استفاده کردند. در مرحله آموزش، نویسندگان از آموزش انتقال و تنظیم دقیق، جهت بالا بردن دقت تشخیص بهره بردند؛ باین حال، نتایج حاصل از این مدل امیدوارکننده نبود [۱۱]. برای بهبود نتایج حاصل از شبکه های عصبی عمیق، لیانگ و همکاران او [۳۷]، شبکه عصبی پیچشی ۴۹-لایه ای را جهت تشخیص بیماری های ریوی بینابینی مانند ذات الریه بر روی مجموعه داده حاصل از تصاویر رادیوگرافی ریه کودکان ارائه دادند. این رویکرد، مشکل وضوح پایین تصاویر رادیوگرافی و همپوشانی در ناحیه التهابی داده های اولیه را حل کرده، با کمک پارامترهای وزن-دار، روند تشخیص را در مجموعه داده های با مقیاس بزرگ بهبود بخشید. اگرچه این رویکرد نیز مشابه سایر روش های مبتنی بر شبکه های عصبی عمیق، با کاهش تأثیر نویزهای موجود در داده ها، دقت تشخیص را بالا می برد، اما به تعداد داده های یادگیری بالایی نیاز دارد.

وو و همکاران او [۳۸] استفاده ترکیبی از فیلتر میانی تطبیقی، الگوریتم جنگل تصادفی [۳۹] و شبکه عصبی عمیق را برای تشخیص بیماری ذات الریه در تصاویر رادیوگرافی پیشنهاد کردند. در این رویکرد، ابتدا نویزهای موجود در داده های اولیه توسط فیلتر میانی تطبیقی حذف می شود. سپس، ویژگی های مورد نظر توسط شبکه عصبی عمیق استخراج شده، در نهایت، تصاویر با استفاده از الگوریتم جنگل تصادفی طبقه بندی می شوند. هراتی و همکاران او [۱۸] نیز رویکرد ترکیبی مبتنی بر شبکه ترانسفورماتور فضایی، تقویت داده ها و شبکه های عصبی عمیق را جهت تشخیص بیماری های ریوی بینابینی در تصاویر رادیوگرافی با جهت گیری های مختلف ارائه کردند. نتایج بررسی ها نشان می دهد که اگرچه رویکردهای ترکیبی، سریع تر از سایر روش های مشابه به نتیجه می رسند، اما دقت قابل قبولی ندارند. در مقاله دیگری، سرکار و همکاران او [۴۰] روش مبتنی بر پیش پردازش را برای ارائه مدل بهینه یادگیری عمیق جهت تشخیص بیماری های ریوی بینابینی در تصاویر رادیوگرافی پیشنهاد کردند. نویسندگان از فیلتر دوطرفه [۴۱] و الگوریتم CLAHE [۴۲] برای بهبود کیفیت تصاویر ورودی


در مراحل پیشین به دو دسته یادگیری و تست تقسیم شده؛ با استفاده از داده‌های یادگیری، مدل‌های مختلفی ایجاد می‌شود. در نهایت، با کمک داده‌های تست، مدل‌های ساخته شده، ارزیابی شده و بهترین آن‌ها به‌عنوان مدل نهایی انتخاب می‌شود.

سپس، ضرایب مستخرج از تبدیل کسینوسی گسسته با استفاده از روش زیگزاگ، از حالت بردار ۲-بعدی به ۱-بعدی تبدیل شده و تعداد ویژگی‌های نهایی با استفاده از رویکرد آنالیز تشخیصی حساس به مکان کاهش می‌یابد. در گام سوم، تصاویر پردازش شده



شکل ۱: شمای کلی روش پیشنهادی (ALDI)

شوند تا با مقادیر هیستوگرام‌های شدت هر پنجره، سازگار باشند. شکل ۲ تصاویر رادیوگرافی ریه‌های سالم و بیمار را که اندازه آن‌ها تغییر داده شده است، نشان می‌دهد.



(ب)

(الف)

شکل ۲: تصاویر رادیوگرافی قفسه سینه که اندازه آن‌ها تغییر داده شده است؛ (الف) ریه سالم و (ب) ریه بیمار.

۳-۱ گام اول: پیش پردازش

در اولین گام از روش ALDI، اطلاعات بیماران از تصاویر خام رادیوگرافی قفسه سینه حذف می‌شود، به طوری که فقط پیکسل‌های مربوط به اندام‌های قفسه سینه باقی بمانند. سپس، پیکسل‌های باقیمانده، جهت دستیابی به وضوح موردنظر و پردازش‌های دقیق‌تر بعدی، استانداردسازی می‌شوند. علاوه بر این، کنتراست تصاویر رادیوگرافی قفسه سینه با اندازه طبیعی و غیرطبیعی، با استفاده از رویکرد همسان‌سازی هیستوگرام تطبیقی کنتراست محدود [۴۷] بهبود می‌یابد. این رویکرد، تصاویر ورودی را که اندازه آن‌ها تغییر داده شده است، به پنجره‌هایی با اندازه مشخص تقسیم می‌کند تا همسان‌سازی هیستوگرام تطبیقی را روی آن‌ها اجرا کند. در نتیجه، شدت پیکسل‌های پنجره‌ها با مقادیر شدت جدید جایگزین می‌شود.

۲-۲ گام دوم: پردازش اصلی

در این گام، پردازش اصلی روش ALDI بر روی تصاویر رادیوگرافی قفسه سینه که اندازه آن‌ها تغییر داده شده است، اعمال می‌شود. این گام، شامل مراحل تبدیل رادان، فیلتر Top-hat، تبدیل موجک گسسته، تبدیل کسینوسی گسسته، رویکرد زیگزآگ و آنالیز تشخیصی حساس به مکان است. به بیان دقیق‌تر، پایایی روش ALDI با استفاده از تبدیل رادان، به نویزهای سفید (صفر) بهبود یافته، داده‌های اضافی با کمک فیلتر Top-hat حذف شده و نرخ تشخیص با بهره‌برداری از تبدیل موجک گسسته و استخراج ویژگی‌های مبتنی بر تبدیل کسینوسی گسسته افزایش می‌یابد. سپس، ضرایب مستخرج از تبدیل کسینوسی گسسته با استفاده از روش زیگزآگ، از حالت بردار ۲-بعدی به ۱-بعدی تبدیل شده و تعداد ویژگی‌های نهایی با استفاده از رویکرد آنالیز تشخیصی حساس به مکان کاهش می‌یابد. در ادامه، هر یک از این مراحل تشریح خواهند شد.

۱-۲-۳ تبدیل رادان

در برنامه‌های کاربردی پزشکی با هدف تشخیص بیماری‌های خاص، استفاده از تبدیل رادان بر روی تصاویر رادیوگرافی که اندازه آن‌ها تغییر داده شده است، می‌تواند پایایی روش ALDI را به نویزهای سفید (صفر) بهبود دهد [۴۸]. تابع تبدیل رادان دوبعدی به صورت (۱) تعریف می‌شود:

$$Rf(L) = \int_L f(x) |dx| \quad (1)$$


در این معادله، پارامتریزه شدن خط مستقیم L با توجه به طول k به صورت (۲) صورت می‌گیرد:

$$(x(z), y(z)) = ((z \sin \alpha + s \cos \alpha), (-z \cos \alpha + s \sin \alpha)) \quad (2)$$

در این معادله، s فاصله L از مبدأ و زاویه‌ای است که بردار نرمال L با محور x می‌سازد. مقادیر (α, s) به عنوان مختصات مساحت روی خطوط در فضای دوبعدی در نظر گرفته می‌شوند. تبدیل رادان در این مختصات به صورت (۳) تعریف می‌شود:

$$Rf(\alpha, s) = \int_{-\infty}^{\infty} f(x(z), y(z)) dz \quad (3)$$

خروجی حاصل از اعمال تبدیل رادان دوبعدی بر روی تصاویر رادیوگرافی قفسه سینه که اندازه آن‌ها تغییر داده شده، در شکل ۳ نشان داده شده است.



(ب)

(الف)

شکل ۳: نتایج حاصل از اعمال تبدیل رادان بر روی تصاویر رادیوگرافی که اندازه آن‌ها تغییر داده شده است؛ (الف) ریه سالم و (ب) ریه بیمار.

۲-۲-۳ فیلتر Top-hat

خروجی حاصل از اعمال تبدیل رادان، به عنوان ورودی مرحله فیلتر Top-hat استفاده می‌شود؛ یعنی پس از تبدیل رادان، فیلتر Top-hat بر روی تصاویر رادیوگرافی ورودی اعمال می‌شود تا داده‌های اضافی را حذف کند. فرآیند اصلی فیلتر Top-hat شامل دو نوع فیلتر (بر اساس تغییر عملکرد عناصر ساختاری) است [۴۹]:

- فیلتر Top-hat سیاه که ساختارهای تیره را از تصاویر رادیوگرافی قفسه سینه استخراج می‌کند.
- فیلتر Top-hat سفید که ساختارهای روشن را از تصاویر رادیوگرافی قفسه سینه استخراج می‌کند.

اعمال فیلتر Top-hat بر روی تصاویر رادیوگرافی، روند تشخیص بیماری‌های ربوی بینابینی را بهبود می‌بخشد. در واقع، فرآیند فیلتر کردن، شیب بین پیکسل‌های روشن و تیره را در تصاویر ورودی افزایش می‌دهد؛ بنابراین، پیکسل‌های اضافی از تصاویر رادیوگرافی حذف شده، در نتیجه، لبه‌های این پیکسل‌ها مشخص‌تر می‌شوند. نتایج حاصل از فیلتر Top-hat بر روی تصاویر رادیوگرافی قفسه سینه که تبدیل رادان بر روی آن‌ها اعمال شده، در شکل ۴ نشان داده شده است.



(ب)




(الف)

شکل ۵: نتایج حاصل از اعمال تبدیل موجک گسسته؛ (الف) ریه سالم و (ب) ریه بیمار.

۳-۲-۴ تبدیل کسینوسی گسسته

ضرایب تقریبی حاصل از تبدیل موجک گسسته به‌عنوان ورودی به مرحله تبدیل کسینوسی گسسته داده می‌شوند تا ویژگی‌های حوزه فرکانس استخراج گردند، زیرا این ویژگی‌ها در مقایسه با ضرایب حاصل از تبدیل موجک گسسته، توانایی تشخیص بهتری دارند. درواقع، تبدیل کسینوسی گسسته یک روش فشرده‌سازی تصویر است که ماتریس ویژگی‌های حوزه فرکانس را استخراج می‌کند. نتایج حاصل از اعمال تبدیل کسینوسی گسسته بر روی ضرایب تقریبی حاصل از تبدیل موجک گسسته در شکل ۶ نشان داده شده است.



(ب)



(الف)

شکل ۶: نتایج حاصل از اعمال تبدیل کسینوسی گسسته؛ (الف) ریه سالم و (ب) ریه بیمار.

۳-۲-۵ رویکرد زیگزاگ

در این مرحله از تجزیه و تحلیل تصاویر رادیوگرافی قفسه سینه، تعداد محدودی از ضرایب حاصل از تبدیل کسینوسی گسسته، انتخاب می‌شوند؛ سایر ضرایب حذف خواهند شد. لازم به ذکر است



(ب)



(الف)

شکل ۴: نتایج حاصل از اعمال فیلتر Top-hat؛ (الف) ریه سالم و (ب) ریه بیمار.

۳-۲-۳ تبدیل موجک گسسته

برای بهبود نرخ تشخیص در برنامه‌های کاربردی پزشکی مانند تجزیه و تحلیل تصاویر رادیوگرافی، می‌توان بر روی پیکسل‌های حاصل از مرحله فیلتر Top-hat، تبدیل موجک گسسته را اعمال کرد [۵۰]. اعمال تابع تبدیل موجک گسسته هر بر روی تصاویر رادیوگرافی قفسه سینه می‌تواند تغییرات ناگهانی در ضرایب سیگنال را با توجه به شکل آن‌ها، به‌طور مؤثری بازیابی کند. درواقع، نتایج تبدیل موجک گسسته، ضرایب افقی، عمودی و مورب را با فیلترهای بالاگذر و پایین‌گذر جدا می‌کند. نتایج حاصل از اعمال تبدیل موجک گسسته بر روی تصاویر رادیوگرافی قفسه سینه که فیلتر Top-hat بر روی آن‌ها اعمال شده، در شکل ۵ نشان داده شده است.

۳-۳ گام سوم: طبقه بندی

هدف گام آخر از روش ALDI، ایجاد مدل نهایی با کمک تصاویر پردازش شده در مراحل قبلی است. به عبارت دیگر، در این گام مدل های مختلفی با استفاده از داده های یادگیری ایجاد و بر اساس پارامترهای اساسی ارزیابی می شوند تا بهترین مدل به عنوان خروجی گزارش شود.

همان طور که در شکل ۱ نشان داده شده است، دستیابی به هدف گام سوم از روش پیشنهادی، با اعمال چند مرحله ممکن خواهد بود؛ بدین صورت که بعد از اعمال دو گام قبلی روی همه تصاویر رادیوگرافی، داده ها به دو دسته یادگیری و تست تقسیم می شوند.

سپس، الگوریتم های مختلف طبقه بندی، جهت ایجاد مدل های مناسب روی داده های یادگیری اعمال می شوند. در ادامه، با استفاده از داده های تست، مدل های ایجاد شده جهت انتخاب بهترین مدل مورد ارزیابی قرار می گیرند. در نهایت، مدلی که بهترین کارایی را دارد، به عنوان خروجی گام سوم انتخاب می شود. در این نقطه، نمونه های جدیدی از تصاویر را که سالم یا بیمار بودن آنها مشخص نیست، می توان با استفاده از مدل نهایی با دقت بالایی طبقه بندی کرد. در روش ALDI، طبقه بندی کننده درخت تصمیم (DT) [۵۴]، k -نزدیک ترین همسایه (k-NN) [۵۵]، ماشین بردار پشتیبان (SVM) [۵۶] و شبکه عصبی مصنوعی (ANN) [۵۷] برای به دست آوردن مدل نهایی استفاده می شوند. در ادامه، هر یک از این طبقه بندی کننده ها به طور مختصر توضیح داده می شوند:

- درخت تصمیم (DT): یکی از پرکاربردترین الگوریتم های داده کاوی در برنامه های کاربردی پزشکی مانند تشخیص بیماری ها از روی تصاویر رادیوگرافی پردازش شده، الگوریتم درخت تصمیم است. این الگوریتم، به صورت یک مدل پیش بینی کننده تعریف می شود، به طوری که بتواند برای برنامه های کاربردی مبتنی بر طبقه بندی مورد استفاده قرار گیرد. از آنجایی که الگوریتم درخت تصمیم، مجموعه داده های دارای خطا، مقادیر مفقوده و روش های ناپارامتری را مدنظر قرار می دهد، یک رویکرد غنی برای نمایش هرگونه طبقه بندی به شمار می رود [۵۴].

- K -نزدیک ترین همسایه (K-NN): الگوریتم K -نزدیک ترین همسایه، یکی از ساده ترین رویکردهایی است که برای

که انتخاب ضرایب از ماتریس تبدیل کسینوسی گسسته یک مرحله حیاتی در فرآیند استخراج ویژگی ها در برنامه های کاربردی تشخیص بیماری ها است. در روش ALDI مقاله، از رویکرد زیگزاگ برای تبدیل ضرایب حاصل از تبدیل کسینوسی گسسته دوبعدی مستخرج به آرایه یک بعدی استفاده می شود [۵۱]. به بیان دقیق تر، از رویکرد زیگزاگ جهت درهم آمیزی ضرایب حاصل از تبدیل کسینوسی گسسته استفاده می شود تا عناصر موجود در ماتریس دوبعدی ضرایب، اسکن شده؛ سپس از گوشه سمت چپ بالایی، به صورت یک ماتریس یک بعدی مرتب شوند.

۳-۲-۶ آنالیز تشخیصی حساس به مکان

در مرحله آخر از پردازش اصلی، آرایه ضرایب یک بعدی حاصل از تبدیل کسینوسی گسسته جهت کاهش ابعاد ویژگی ها، به عنوان ورودی الگوریتم آنالیز تشخیصی حساس به مکان مورد استفاده قرار می گیرند. الگوریتم آنالیز تشخیصی حساس به مکان کلاس ها و همبستگی داده ها را مشخص می کند [۵۲]. فرض بر این است که n داده $X_1, X_2, \dots, X_n \in \mathbb{R}^M$ نمونه های دلخواهی از M نوع مختلف هستند. فشردگی بین کلاس ها (C_c) و تفکیک پذیری بین آنها (C_s) در این الگوریتم جهت کاهش بعد داده ها، به ترتیب، طبق (۴) و (۵) محاسبه می شوند:

$$C_c = \min \sum_{lm} (k_1 - k_m)^2 W_{c,lm} \quad (4)$$

$$C_s = \min \sum_{lm} (k_1 - k_m)^2 W_{s,lm} \quad (5)$$

در این معادله ها، $k_m = \alpha^T X_m$ و $k_1 = \alpha^T X_1$ به ترتیب نگاشت های یک بعدی X_m و X_1 را نشان می دهند. همچنین، X_m و X_1 به ترتیب به ماتریس های وزن فشردگی بین کلاس ها و تفکیک پذیری بین آنها اشاره دارند. α نیز جهت داده های پیش بینی شده را نمایش می دهد.

در نهایت، تجزیه و تحلیل واریانس برای انتخاب ویژگی ها استفاده می شود [۵۳]. این روش، میانگین جمعیت بیش از دو کلاس را مقایسه می کند؛ اگر این اختلاف بیشتر از یک آستانه از پیش تعیین شده باشد، ویژگی به عنوان یک ویژگی معنی دار در نظر گرفته می شود و بالعکس. رتبه بندی ویژگی ها با استفاده از رویکرد تجزیه و تحلیل واریانس محاسبه می شود؛ ویژگی با بالاترین F -value، رتبه اول را به دست می آورد و بالعکس.

^۱ Decision Tree

^۲ K-Nearest Neighbors

^۳ Support Vector Machine

^۵ Artificial Neural Network

قرار می گیرند.

در گام پیش پردازش، پس از حذف اطلاعات بیماران از تصاویر خام، اندازه بخش های باقیمانده به حالت استاندارد 480×480 پیکسل تبدیل می شود تا مراحل پردازش اصلی با تأثیر یکسان روی همه داده ها اعمال شود. همچنین، از رویکرد اعتبارسنجی متقابل K لایه ای^۶ با $K=10$ در تحلیل آماری مجموعه داده ها استفاده می شود تا بررسی گردد که مدل پیشنهادی تا چه اندازه قابل تعمیم بوده و مستقل از داده های یادگیری عمل می کند [۵۸]. به بیان دقیق تر، استفاده از رویکرد اعتبارسنجی متقابل ۱۰ لایه ای مشخص می کند که مدل پیشنهادی مقاله تا چه اندازه در برنامه های کاربردی واقعی مفید خواهد بود. این رویکرد، داده ها را به ۱۰ زیرمجموعه افراز می کند تا هر بار یکی از زیرمجموعه ها برای اعتبارسنجی و ۹ زیرمجموعه دیگر برای یادگیری مورد استفاده قرار گیرند. این روند ۱۰ بار تکرار می شود تا همه داده ها فقط یکبار برای یادگیری و یکبار برای اعتبارسنجی استفاده شوند. در نهایت، میانگین نتیجه ۱۰ بار اعتبارسنجی به عنوان تخمین نهایی گزارش می شود.

در نهایت، به منظور تجزیه و تحلیل عملکرد روش ALDI، همه شبیه سازی ها در نرم افزار MATLAB R2018a و در کامپیوتری با سیستم عامل Windows 10 با ویژگی های Intel (R) Core i7 (TM) 8 GB @ 2.90 GHz CPU و 3520M RAM انجام شده است.

۴-۱ مقایسه روش های طبقه بندی مورد استفاده

در این بخش، به بررسی عملکرد طبقه بندی کننده های مورد استفاده در روش تشخیص خودکار بیماری های ریوی بینابینی (DT, K-NN, SVM و ANN)، با مقایسه شاخص های خطای اعتبارسنجی متقابل، مثبت درست، منفی درست، مثبت کاذب، منفی کاذب، دقت، حساسیت، صحت و F-Value پرداخته می شود.

خطای اعتبارسنجی متقابل، خطای حاصل از مدل رگرسیون اعتبارسنجی متقابل (خطای میانگین مربعات) را نشان می دهد [۵۸]. به بیان دقیق تر، خطای هر لایه غیر یادگیری از مدل اعتبارسنجی متقابل K لایه ای، با استفاده از مشاهدات مدل لایه یادگیری محاسبه می شود. همان طور که در ستون دوم از جدول ۱ نشان داده شده است، خطای اعتبارسنجی متقابل برای طبقه بندی-

حل مسائل طبقه بندی مورد استفاده قرار می گیرد. با وجود سادگی، نتایج این الگوریتم قابل رقابت با الگوریتم های مشابه است. سهولت در تفسیر نتایج خروجی، قدرت پیش بینی بالا و زمان محاسبه قابل قبول باعث شده است که از این الگوریتم به طور گسترده ای در برنامه های کاربردی پزشکی مانند تشخیص بیماری ها از روی تصاویر رادیوگرافی پردازش شده استفاده شود [۵۵].

- ماشین بردار پشتیبانی (SVM): ماشین بردار پشتیبانی یک الگوریتم طبقه بندی بسیار قدرتمند است. زمانی که این رویکرد همراه با الگوریتم ها و ابزارهای یادگیری ماشین دیگر استفاده شود، می تواند مدل غنی تری برای طبقه بندی داده های حساس مانند تصاویر پزشکی ارائه دهد. همچنین، الگوریتم ماشین بردار پشتیبانی در برنامه های کاربردی که قدرت پیش بینی بالایی مورد نیاز است، یک گزینه عالی به شمار می رود. با این حال، تصویرسازی این الگوریتم دشوار است، زیرا فرمول بندی پیچیده ای دارد. علاوه بر این، هنگامی که مجموعه داده ورودی، نویز زیادی داشته باشد، الگوریتم ماشین بردار پشتیبانی عملکرد قابل قبولی ندارد، زیرا کلاس های هدف دچار همپوشانی می شوند [۵۶].

- شبکه عصبی مصنوعی (ANN): شبکه عصبی مصنوعی یکی از رویکردهای محاسباتی نوین در حوزه یادگیری ماشین، نمایش دانش و پیش بینی نتایج خروجی از سامانه های پیچیده است. ایده اصلی این الگوریتم از روند کارکرد سیستم عصبی-زیستی مغز انسان برای پردازش داده ها جهت یادگیری الهام گرفته است. الگوریتم شبکه عصبی مصنوعی برای تخمین و تقریب، کارایی بسیار خوبی از خود نشان می دهد. بر این اساس، گستره کاربرد این مدل ریاضی، بسیار وسیع می باشد که به عنوان نمونه می توان به طبقه بندی تصاویر رادیوگرافی پردازش شده جهت تشخیص بیماری ها اشاره کرد [۵۷].

۳- ارزیابی روش پیشنهادی

در این بخش، به ارزیابی روش ALDI و مقایسه آن با رویکردهای اخیر موجود جهت تشخیص خودکار بیماری های ریوی در تصاویر رادیوگرافی پرداخته می شود. برای این منظور، در مطالعه موردی مقاله، از مجموعه داده تصاویر رادیوگرافی قفسه سینه مرکز بالینی NIH استفاده می شود [۱۹]، [۱۸]. از این مجموعه داده، ۶۷۰ تصویر رادیوگرافی قفسه سینه با وضوح 1024×1024 پیکسل به عنوان نمونه استخراج شده است که ۴۶۹ مورد (۷۰٪)، به عنوان داده یادگیری و ۲۰۱ مورد (۳۰٪)، به عنوان داده تست مورد استفاده

^۶ K-fold Cross-validation

بیماری های ریوی، طبقه بندی کننده های DT، ANN، K-NN و SVM به ترتیب، دقیق ترین عملکردها را ارائه می دهند. این نتایج نیز، برتری رویکرد DT نسبت به سایر طبقه بندی کننده ها را نشان می دهد.

حساسیت معیاری است که میزان بودن رویکردهای طبقه بندی کننده مورد استفاده برای تشخیص بیماری های ریوی بینابینی را نشان می دهد. به عبارت دیگر، این شاخص بیان می کند که چند درصد از نمونه های مثبت (تصاویر ریه های مبتلا به بیماری) به صورت درستی برچسب گذاری شده اند [۶۰]. حساسیت (Sensitivity) بر اساس (۷) محاسبه می شود:

$$Sensitivity = \frac{TP}{P} \quad (7)$$

در این معادله نیز TP و P به ترتیب، به نتایج مثبت درست و تعداد تصاویر رادیوگرافی مبتلا به بیماری های ریوی بینابینی اشاره دارند. همان طور که در ستون هشتم از جدول ۱ نشان داده شده است، بر اساس شاخص حساسیت، طبقه بندی کننده های DT و K-NN (با حساسیت کامل) عملکرد بهتری نسبت به سایر رویکردها ارائه می دهند. همچنین، این نتایج نشان می دهد که رویکرد ANN نسبت به طبقه بندی کننده SVM حساسیت بالاتری در تشخیص نمونه های مثبت درست دارد؛ بنابراین، می توان استدلال کرد که در تشخیص خودکار بیماری های ریوی، طبقه بندی کننده های DT و K-NN با حساسیت کامل، نسبت به رویکردهای مشابه، در تشخیص نمونه های مثبت درست عملکرد بهتری ارائه می دهند.

شاخص صحت نیز یکی از معیارهای پرکاربرد برای مقایسه روش های طبقه بندی جهت تشخیص انواع بیماری ها در تصاویر رادیوگرافی است. صحت را می توان به عنوان معیاری برای ارزیابی میزان دقت رویکردهای طبقه بندی در نظر گرفت. این شاخص بیان می کند که چند درصد از نمونه هایی (تصاویر رادیوگرافی قفسه سینه) که با عنوان مثبت برچسب گذاری شده اند، واقعاً مبتلا به بیماری هستند [۶۱]. صحت (Precision) بر اساس (۸) محاسبه می شود:

$$Precision = \frac{TP}{TP + FP} \quad (8)$$

در این معادله، TP و FP به ترتیب، نشان گر نتایج مثبت درست و مثبت کاذب هستند. همان طور که در ستون نهم از جدول ۱ نشان داده شده است، بر اساس شاخص صحت، طبقه بندی کننده ANN (با صحت کامل) عملکرد بهتری نسبت به سایر رویکردها ارائه می دهد. همچنین، این نتایج نشان می دهد که رویکردهای K-

کند DT، صفر است. همچنین، مقدار این خطا در صورت استفاده از رویکردهای K-NN و ANN، کم تر از SVM است.

مثبت درست، تعداد نتایجی را نشان می دهد که در آن ها، مدل پیشنهادی مقاله، به درستی کلاس مثبت (ریه های مبتلا به بیماری) را برای داده های تست پیش بینی کرده است. به طور مشابه، منفی درست، به تعداد نتایجی اشاره دارد که در آن ها، مدل پیشنهادی مقاله، به درستی کلاس منفی (ریه های سالم) را پیش بینی کرده است. همچنین، مثبت کاذب، تعداد نتایجی را نشان می دهد که در آن ها، مدل پیشنهادی مقاله، کلاس مثبت (ریه های مبتلا به بیماری) را به درستی پیش بینی نکرده است. به طور مشابه، منفی کاذب، به تعداد نتایجی اشاره دارد که در آن ها، مدل پیشنهادی مقاله، کلاس منفی (ریه های سالم) را به درستی پیش بینی نکرده است [۵۹]. همان طور که در ستون های سوم تا ششم از جدول ۱ مشاهده می شود، طبقه بندی کننده DT با بیشترین مجموع مثبت درست و منفی درست، عملکرد بهتری نسبت به سایر رویکردها دارد. همچنین، نتایج حاصل از این جدول نشان می دهد که رویکرد ANN در تشخیص نمونه های مثبت/منفی بهتر از K-NN عمل می کند. در این میان، طبقه بندی کننده SVM ضعیف ترین عملکرد را در تشخیص درست نمونه های مثبت/منفی ارائه می دهد. این نتایج، برتری طبقه بندی کننده DT در تشخیص خودکار بیماری های ریوی را نشان می دهد، زیرا سایر شاخص های مورد استفاده برای تجزیه و تحلیل روش های خودکار تشخیص بیماری ها بر اساس مقادیر مثبت/منفی درست یا کاذب محاسبه می شوند.

دقت یا نرخ تشخیص، یکی از شاخص های اساسی برای بررسی عملکرد روش های خودکار تشخیص بیماری ها است. این شاخص، نسبت کل پیش بینی های درست به کل داده ها را نشان می دهد [۵۹]. دقت (Accuracy) بر اساس (۶) محاسبه می شود:


$$Accuracy = \frac{TP + TN}{P + N} \quad (6)$$

در این معادله، TP و TN به ترتیب، به نتایج مثبت درست و منفی درست اشاره دارند. همچنین، P و N به ترتیب، نشان گر تعداد تصاویر رادیوگرافی مبتلا به بیماری های ریوی بینابینی و سالم هستند. همان طور که در ستون هفتم از جدول ۱ نشان داده شده است، بر اساس شاخص دقت نیز طبقه بندی کننده DT عملکرد بهتری نسبت به سایر رویکردها ارائه داده است. همچنین، این نتایج نشان می دهد که رویکردهای ANN و K-NN تقریباً دارای دقت یکسانی هستند. این در حالی است که طبقه بندی کننده SVM با پایین ترین دقت به طبقه بندی تصاویر رادیوگرافی قفسه سینه می پردازد؛ بنابراین، می توان ادعا کرد که در تشخیص خودکار

جدول ۱ مقایسه طبقه‌بندی‌کننده‌های مورد استفاده

F-Value	صحت	حساسیت	دقت	منفی کاذب	مثبت کاذب	منفی درست	مثبت درست	خطای اعتبارسنجی متقابل	طبقه‌بندی‌کننده
۰/۹۹۴	۰/۹۸۹	۱	۰/۹۹۵	۰	۱	۱۰۴	۹۶	۰	DT
۰/۹۸	۰/۹۶	۱	۰/۹۸۵۱	۰	۳	۱۰۲	۹۶	۰/۰۵۹۷	K-NN
۰/۹۸۴	۱	۰/۹۶۸۷	۰/۹۸۵۱	۳	۰	۱۰۵	۹۳	۰/۰۵۸۴	ANN
۰/۷۷	۰/۶۵۲۱	۰/۹۳۷۵	۰/۷۳۱۳	۶	۴۸	۵۷	۹۰	۰/۲۳۸۸	SVM

صورت افزایش تعداد داده‌های یادگیری، مقدار F-Value برای طبقه‌بندی‌کننده DT به ۱۰۰٪ میل می‌کند. این نتایج بیان می‌کند که رویکرد DT نسبت به طبقه‌بندی‌کننده‌های مشابه با میانگین هارمونیک حساسیت و صحت بالاتر، بهترین رویکرد برای برنامه‌های کاربردی پزشکی مانند تشخیص خودکار بیماری‌های ریوی با استفاده از تصاویر رادیوگرافی می‌باشد.



شکل ۷: مقدار متوسط F-Value با افزایش تعداد داده‌های یادگیری.

۴-۳ مقدار متوسط خطای اعتبارسنجی متقابل

با افزایش تعداد داده‌های یادگیری

همان‌طور که در بخش ۴-۱ اشاره شد، خطای اعتبارسنجی متقابل، خطای میانگین مربعات هر لایه غیر یادگیری از مدل اعتبارسنجی متقابل K-لايه‌ای را با استفاده از مشاهدات مدل لایه یادگیری نشان می‌دهد. در این بخش، به مقایسه میانگین تغییرات این شاخص در صورت استفاده از رویکردهای طبقه‌بندی مختلف، بر اساس افزایش تعداد داده‌های یادگیری پرداخته می‌شود. همان‌طور که در شکل ۸ نشان داده شده است، با افزایش تعداد داده‌های یادگیری به بیش از ۵۰٪ کل داده‌ها، خطای اعتبارسنجی متقابل طبقه‌بندی‌کننده DT، صفر می‌شود، درحالی‌که این خطا برای روش‌های K-NN، SVM و ANN، حتی در صورت استفاده از ۱۰۰٪ از داده‌ها به‌عنوان داده‌های یادگیری، به صفر نمی‌رسد. همچنین، این نمودار نشان می‌دهد که متوسط خطای اعتبارسنجی

NN و SVM نسبت به طبقه‌بندی‌کننده DT صحت پایین‌تری دارند؛ بنابراین، می‌توان استدلال کرد که در تشخیص خودکار بیماری‌های ریوی، طبقه‌بندی‌کننده‌های ANN و DT (با صحت بالا)، به ترتیب، نسبت به رویکردهای مشابه، نمونه‌های مثبت را با دقت بالاتری برچسب‌گذاری می‌کنند.

در نهایت، معیار کلی برای ارزیابی رویکردهای مورد استفاده جهت طبقه‌بندی تصاویر رادیوگرافی قفسه سینه، استفاده ترکیبی از معیارهای حساسیت و صحت است. این شاخص با عنوان F-Value یا میانگین هارمونیک حساسیت و صحت شناخته شده و به صورت (۹) محاسبه می‌شود [۶۲]:

$$F - Value = \frac{2 \times Precision \times Sensitivity}{Precision + Sensitivity} \quad (9)$$

همان‌طور که در ستون دهم از جدول ۱ نشان داده شده است، بر اساس شاخص F-Value نیز طبقه‌بندی‌کننده DT عملکرد بهتری نسبت به سایر رویکردها ارائه داده است. همچنین، این نتایج نشان می‌دهد که طبقه‌بندی‌کننده SVM با پایین‌ترین مقدار F-Value، به طبقه‌بندی تصاویر رادیوگرافی قفسه سینه می‌پردازد؛ بنابراین، می‌توان ادعا کرد که در تشخیص خودکار بیماری‌های ریوی، طبقه‌بندی‌کننده DT نسبت به سایر طبقه‌بندی‌کننده‌ها عملکرد بهتری دارد.

۴-۲ مقدار متوسط F-Value با افزایش تعداد

داده‌های یادگیری

همان‌طور که در بخش ۴-۱ تعریف شد، F-Value با استفاده ترکیبی از میانگین هارمونیک شاخص‌های حساسیت و صحت، به ارزیابی کلی رویکردهای مورد استفاده جهت طبقه‌بندی تصاویر رادیوگرافی قفسه سینه می‌پردازد. مقدار متوسط F-Value با افزایش تعداد داده‌های یادگیری برای طبقه‌بندی‌کننده‌های DT، K-NN، SVM و ANN در شکل ۷ نشان داده شده است. بر اساس این شکل، متوسط F-Value در صورت استفاده از رویکرد DT برای تشخیص خودکار بیماری‌های ریوی بینابینی، نسبت به روش‌های K-NN، SVM و ANN، به ترتیب، ۱/۷۳، ۱/۰۷ و ۱/۷ برابر بیشتر است. همچنین، این نمودار نشان می‌دهد که در

می کند که روش پیشنهادی مقاله، با استفاده از حداقل تعداد داده-های یادگیری، دقت تشخیص را به حداکثر می رساند.

ستون سوم از جدول ۲ نشان می دهد که روش پیشنهادی مقاله با حساسیت کامل به تشخیص بیماری های ریوی در تصاویر رادیوگرافی قفسه سینه می پردازد. به بیان دقیق تر، حساسیت روش ALDI نسبت به رویکردهای A, B, C, D و E، به ترتیب، ۱/۵۷، ۱/۰۴، ۱/۰۷، ۱/۰۲ و ۱/۰۱ برابر بالاتر است. بنابراین، می توان استدلال کرد که در تشخیص خودکار بیماری های ریوی، روش پیشنهادی مقاله با حساسیت کامل، نسبت به رویکردهای مشابه، در تشخیص نمونه های مثبت درست عملکرد بهتری ارائه می دهد.

ستون های چهارم و پنجم از جدول ۲ نشان می دهند اگرچه روش پیشنهادی مقاله نسبت به رویکردهای C و E صحت پایین تری دارد، اما در مجموع، با مقدار F-Value بالاتر نسبت به رویکردهای مورد مقایسه، تصاویر رادیوگرافی قفسه سینه را با میانگین هارمونیک حساسیت و صحت بالاتری طبقه بندی می کند. این نتایج بیان می کند که ALDI میانگین حساسیت و صحت را نسبت به رویکردهای A, B, C, D و E، به ترتیب، ۱/۵۴، ۱/۰۳، ۱/۰۲، ۱/۰۱ و ۱/۰۱ برابر افزایش می دهد. بنابراین، می توان ادعا کرد که در تشخیص خودکار بیماری های ریوی، روش پیشنهادی مقاله نسبت به سایر رویکردها عملکرد بهتری دارد.

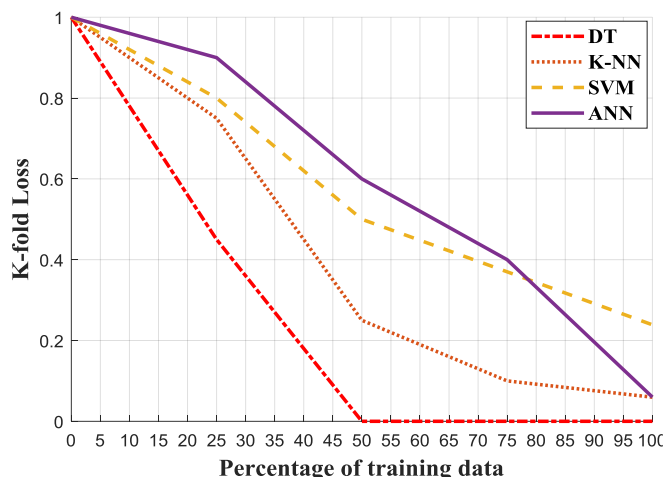
جدول ۲ مقایسه راهکار پیشنهادی با سایر رویکردها

رویکردها	دقت	حساسیت	صحت	F-Value
A [۱۸]	۰/۷۱۹	۰/۶۳۵	۰/۶۶۵	۰/۶۴۴
B [۴۴]	۰/۹۵۸	۰/۹۶	۰/۹۵۶	۰/۹۵۸
C [۴۶]	۰/۹۹۴	۰/۹۹۳	۰/۹۹۲	۰/۹۹۲
D [۴۳]	۰/۹۸	۰/۹۸۱	۰/۹۷۹	۰/۹۸
E [۴۵]	۰/۹۹۳	۰/۹۸۷	۱	۰/۹۹۳
ALDI	۰/۹۹۵	۱	۰/۹۸۹	۰/۹۹۴

۴- نتیجه گیری

در این مقاله، روش جدیدی برای تشخیص خودکار بیماری های ریوی بینابینی با بهره گیری از روش های مبتنی بر یادگیری ماشین ارائه شده است. در گام اول از روش پیشنهادی، ابتدا اطلاعات بیمار از تصاویر خام رادیوگرافی قفسه سینه حذف شده؛ سپس، پیکسل های باقیمانده، جهت دستیابی به وضوح مورد نظر و پردازش های دقیق تر بعدی، استانداردسازی شدند. در گام بعدی، پایایی روش پیشنهادی با استفاده از تبدیل رادان، به نوبه های سفید بهبود یافته، داده های اضافی با کمک فیلتر Top-hat حذف شده و نرخ

متقابل در صورت استفاده از رویکرد DT برای تشخیص خودکار بیماری های ریوی بینابینی، نسبت به روش های SVM, K-NN و ANN، به ترتیب، ۳۲/۸۷٪، ۵۰/۰۸٪ و ۵۱/۰۱٪ کاهش می یابد. این نتایج اثبات می کند که طبقه بندی کننده DT با به حداقل رساندن مقدار خطای اعتبارسنجی متقابل، رویکرد مناسبی برای طبقه بندی تصاویر رادیوگرافی قفسه سینه جهت تشخیص بیماری های ریوی بینابینی به شمار می رود.



شکل ۸: مقدار متوسط خطای اعتبارسنجی متقابل با افزایش تعداد داده های یادگیری.

۴-۴ مقایسه روش پیشنهادی با سایر رویکردها

در این بخش، به مقایسه نتایج حاصل از روش پیشنهادی با آخرین رویکردهای موجود در حوزه تشخیص خودکار بیماری های ریوی بینابینی پرداخته می شود. لازم به ذکر است که در این مقایسه، مدل مبتنی بر درخت تصمیم (DT) با نتایج بهتر نسبت به سایر طبقه بندی کننده ها، به عنوان مدل نهایی مقاله در نظر گرفته شده است. همچنین، رویکردهای مورد مقایسه با حروف A, B, C, D و E نام گذاری شده اند. برای دستیابی به نتایج دقیق تر، این رویکردها نیز بر روی مجموعه داده تصاویر رادیوگرافی قفسه سینه مرکز بالینی NIH (با جزئیات مورد استفاده در پیاده سازی روش پیشنهادی) شبیه سازی می شوند [۱۹]، [۱۸]. نتایج این مقایسه ها در جدول ۲ نشان داده شده است.

همان طور که در ستون دوم از جدول ۲ نشان داده شده است، روش پیشنهادی مقاله نسبت به سایر رویکردها، دقت بالاتری دارد. به بیان عددی، دقت تشخیص بیماری ها در صورت استفاده از روش ALDI نسبت به رویکردهای A, B, C, D و E، به ترتیب، ۱/۳۸، ۱/۰۳، ۱/۰۱، ۱/۰۱ و ۱/۰۲ برابر بهبود می یابد. این نتایج بیان

- diseases,” *Eur. Respir. J.*, vol. 55, no. 6, p. 2000085, Jun. 2020.
- [5] F. Liu *et al.*, “The application of artificial intelligence to chest medical image analysis,” *Intell. Med.*, Jul. 2021.
- [6] A. A. Peters *et al.*, “Performance of an AI based CAD system in solid lung nodule detection on chest phantom radiographs compared to radiology residents and fellow radiologists,” *J. Thorac. Dis.*, vol. 13, no. 5, pp. 2728–2737, May 2021.
- [7] E. Matsuyama, “A Novel Method for Automated Lung Region Segmentation in Chest X-Ray Images,” *J. Biomed. Sci. Eng.*, vol. 14, no. 06, pp. 288–299, 2021.
- [8] J. Rasheed, A. A. Hameed, C. Djeddi, A. Jamil, and F. Al-Turjman, “A machine learning-based framework for diagnosis of COVID-19 from chest X-ray images,” *Interdiscip. Sci. Comput. Life Sci.*, vol. 13, no. 1, pp. 103–117, Mar. 2021.
- [9] R. Zhang *et al.*, “Diagnosis of Coronavirus Disease 2019 Pneumonia by Using Chest Radiography: Value of Artificial Intelligence,” *Radiology*, vol. 298, no. 2, pp. E88–E97, Feb. 2021.
- [10] T. Kwon *et al.*, “Diagnostic performance of artificial intelligence model for pneumonia from chest radiography,” *PLoS One*, vol. 16, no. 4, p. e0249399, Apr. 2021.
- [11] W. Khan, N. Zaki, and L. Ali, “Intelligent Pneumonia Identification From Chest X-Rays: A Systematic Literature Review,” *IEEE Access*, vol. 9, pp. 51747–51771, 2021.
- [12] A. Olson *et al.*, “Estimation of the Prevalence of Progressive Fibrosing Interstitial Lung Diseases: Systematic Literature Review and Data from a Physician Survey,” *Adv. Ther.*, vol. 38, no. 2, pp. 854–867, Feb. 2021.
- [13] S. T. H. Kieu, A. Bade, M. H. A. Hijazi, and H. Kolivand, “A Survey of Deep Learning for Lung Disease Detection on Medical Images: State-of-the-Art, Taxonomy, Issues and Future Directions,” *J. Imaging*, vol. 6, no. 12, p. 131, Dec. 2020.
- [14] D. R. Sarvamangala and R. V. Kulkarni, “Convolutional neural networks in medical image understanding: a survey,” *Evol. Intell.*, Jan. 2021.
- تشخیص با بهره‌گیری از تبدیل موجک گسسته و استخراج ویژگی - های مبتنی بر تبدیل کسینوسی گسسته افزایش یافت. سپس، ضرایب مستخرج از تبدیل کسینوسی گسسته با استفاده از روش زیگزگ، از حالت بردار ۲-بعدی به ۱-بعدی تبدیل شده و تعداد ویژگی‌های نهایی با استفاده از رویکرد آنالیز تشخیصی حساس به مکان بهینه شدند. در گام نهایی، تصاویر پردازش‌شده، به دو دسته یادگیری و تست تقسیم شدند تا با استفاده از داده‌های یادگیری، مدل‌های مختلفی جهت تشخیص خودکار بیماری‌ها ساخته شود. در نهایت، با استفاده از داده‌های تست، بهترین مدل انتخاب شد. نتایج حاصل از شبیه‌سازی روش پیشنهادی بر روی مجموعه داده NIH نشان می‌دهد که رویکرد DT با افزایش مقدار متوسط F-Value نسبت به رویکردهای مشابه، می‌تواند تصاویر رادیوگرافی قفسه سینه را با میانگین صحت و حساسیت بیشتری طبقه‌بندی کند. همچنین، این رویکرد با به حداقل رساندن خطای اعتبارسنجی متقابل در تشخیص خودکار بیماری‌های ریوی، عملکرد بهتری نسبت به طبقه‌بندی‌کننده‌های SVM، K-NN و ANN دارد. علاوه بر این موارد، روش مبتنی بر درخت تصمیم با بهبود میانگین هارمونیک حساسیت و صحت، دقیق‌ترین مدل را نسبت به رویکردهای اخیر موجود در حوزه تشخیص خودکار بیماری‌های بینابینی ریوی ارائه می‌دهد؛ بنابراین، می‌توان ادعا کرد که رویکرد مبتنی بر DT دقیق‌ترین مدل (در میان رویکردهای مشابه) برای برنامه‌های کاربردی پزشکی مانند تشخیص خودکار بیماری‌های ریوی بینابینی به شمار می‌رود.

مراجع

- [1] A. L. Olson, P. Patnaik, N. Hartmann, R. L. Bohn, E. M. Garry, and L. Wallace, “Prevalence and Incidence of Chronic Fibrosing Interstitial Lung Diseases with a Progressive Phenotype in the United States Estimated in a Large Claims Database Analysis,” *Adv. Ther.*, vol. 38, no. 7, pp. 4100–4114, Jul. 2021.
- [2] L. Sesé *et al.*, “Adult interstitial lung diseases and their epidemiology,” *Presse Med.*, vol. 49, no. 2, p. 104023, Jun. 2020.
- [3] J. Salonen, M. Purokivi, R. Bloigu, and R. Kaarteenaho, “Prognosis and causes of death of patients with acute exacerbation of fibrosing interstitial lung diseases,” *BMJ Open Respir. Res.*, vol. 7, no. 1, p. e000563, Apr. 2020.
- [4] K. K. Brown *et al.*, “The natural history of progressive fibrosing interstitial lung

- P. Ranjan, and R. Janardhanan, "Pneumonia Identification in Chest X-Ray Images Using EMD," 2020, pp. 87–98.
- [26] R. V. Adiraju, K. K. Masanipalli, T. D. Reddy, R. Pedapalli, S. Chundru, and A. K. Panigrahy, "An extensive survey on finger and palm vein recognition system," *Mater. Today Proc.*, vol. 45, pp. 1804–1808, 2021.
- [27] S. Varela-Santos and P. Melin, "Classification of X-Ray Images for Pneumonia Detection Using Texture Features and Neural Networks," 2020, pp. 237–253.
- [28] S. Aouat, I. Ait-hammi, and I. Hamouchene, "A new approach for texture segmentation based on the Gray Level Co-occurrence Matrix," *Multimed. Tools Appl.*, vol. 80, no. 16, pp. 24027–24052, Jul. 2021.
- [29] M. Kubat, "Artificial Neural Networks," in *An Introduction to Machine Learning*, Cham: Springer International Publishing, 2021, pp. 117–143.
- [30] P. Chhikara, P. Singh, P. Gupta, and T. Bhatia, "Deep Convolutional Neural Network with Transfer Learning for Detecting Pneumonia on Chest X-Rays," 2020, pp. 155–168.
- [31] H. Song, xiu-ying Han, C. E. Montenegro-Marin, and S. Krishnamoorthy, "Secure prediction and assessment of sports injuries using deep learning based convolutional neural network," *J. Ambient Intell. Humaniz. Comput.*, vol. 12, no. 3, pp. 3399–3410, Mar. 2021.
- [32] M. Yildirim, "Analog circuit implementation based on median filter for salt and pepper noise reduction in image," *Analog Integr. Circuits Signal Process.*, vol. 107, no. 1, pp. 195–202, Apr. 2021.
- [33] A. Kumar, R. K. Jha, and N. K. Nishchal, "An improved Gamma correction model for image dehazing in a multi-exposure fusion framework," *J. Vis. Commun. Image Represent.*, vol. 78, p. 103122, Jul. 2021.
- [34] G. Ulutas and B. Ustubioglu, "Underwater image enhancement using contrast limited adaptive histogram equalization and layered difference representation," *Multimed. Tools Appl.*, vol. 80, no. 10, pp. 103122–103132, Jul. 2021.
- [15] J. Ma, Y. Song, X. Tian, Y. Hua, R. Zhang, and J. Wu, "Survey on deep learning for pulmonary medical imaging," *Front. Med.*, vol. 14, no. 4, pp. 450–469, Aug. 2020.
- [16] S. Chen and S. Wu, "Identifying Lung Cancer Risk Factors in the Elderly Using Deep Neural Networks: Quantitative Analysis of Web-Based Survey Data," *J. Med. Internet Res.*, vol. 22, no. 3, p. e17695, Mar. 2020.
- [17] U. R. Acharya *et al.*, "Automated diabetic macular edema (DME) grading system using DWT, DCT Features and maculopathy index," *Comput. Biol. Med.*, vol. 84, pp. 59–68, May 2017.
- [18] S. Bharati, P. Podder, and M. R. H. Mondal, "Hybrid deep learning for detecting lung diseases from X-ray images," *Informatics Med. Unlocked*, vol. 20, p. 100391, 2020.
- [19] "NIH sample Chest X-rays dataset," 2022. .
- [20] L. L. G. Oliveira, S. A. e Silva, L. H. V. Ribeiro, R. M. de Oliveira, C. J. Coelho, and A. L. S. S. Andrade, "Computer-aided diagnosis in chest radiography for detection of childhood pneumonia," *Int. J. Med. Inform.*, vol. 77, no. 8, pp. 555–564, Aug. 2008.
- [21] J. G. Greener, S. M. Kandathil, L. Moffat, and D. T. Jones, "A guide to machine learning for biologists," *Nat. Rev. Mol. Cell Biol.*, Sep. 2021.
- [22] S. Yousefi, F. Derakhshan, and H. Karimipour, "Applications of Big Data Analytics and Machine Learning in the Internet of Things," in *Handbook of Big Data Privacy*, Cham: Springer International Publishing, 2020, pp. 77–108.
- [23] E. Yahaghi, M. Mirzapour, and A. Movafeghi, "Comparison of traditional and adaptive multi-scale products thresholding for enhancing the radiographs of welded object," *Eur. Phys. J. Plus*, vol. 136, no. 7, p. 744, Jul. 2021.
- [24] Y. Dong, X. Ma, and T. Fu, "Electrical load forecasting: A deep learning approach based on K-nearest neighbors," *Appl. Soft Comput.*, vol. 99, p. 106900, Feb. 2021.
- [25] A. Khatri, R. Jain, H. Vashista, N. Mittal,

- network,” *Big Data Min. Anal.*, vol. 4, no. 2, pp. 84–93, Jun. 2021.
- [45] S. Kalaivani and K. Seetharaman, “A three-stade ensemble boosted convolutional neural network for classification and analysis of covid-19 chest x-ray images,” *Int. J. Cogn. Comput. Eng.*, Jan. 2022.
- [46] M. Z. Islam, M. M. Islam, and A. Asraf, “A combined deep CNN-LSTM network for the detection of novel coronavirus (COVID-19) using X-ray images,” *Informatics Med. Unlocked*, vol. 20, p. 100412, 2020.
- [47] W.-N. Mohd-Isa, J. Joseph, N. Hashim, and N. Salih, “Enhancement of digitized X-ray films using Contrast-Limited Adaptive Histogram Equalization (CLAHE),” *F1000Research*, vol. 10, p. 1051, Oct. 2021.
- [48] D. Ziou, N. Nacereddine, and A. B. Goumeidane, “Scale space Radon transform,” *IET Image Process.*, vol. 15, no. 9, pp. 2097–2111, Jul. 2021.
- [49] O. Ramos-Soto *et al.*, “An efficient retinal blood vessel segmentation in eye fundus images by using optimized top-hat and homomorphic filtering,” *Comput. Methods Programs Biomed.*, vol. 201, p. 105949, Apr. 2021.
- [50] M. Shajahan, S. A. M. Aris, S. Usman, and N. M. Noor, “IRPMID: Medical XRAY Image Impulse Noise Removal using Partition Aided Median, Interpolation and DWT,” in *2021 IEEE International Conference on Signal and Image Processing Applications (ICSIPA)*, 2021, pp. 105–110.
- [51] X. Wang and X. Chen, “An image encryption algorithm based on dynamic row scrambling and Zigzag transformation,” *Chaos, Solitons & Fractals*, vol. 147, p. 110962, Jun. 2021.
- [52] H. Yao, Y. Zhang, Y. Wei, and Y. Tian, “Broad Learning System with Locality Sensitive Discriminant Analysis for Hyperspectral Image Classification,” *Math. Probl. Eng.*, vol. 2020, pp. 1–16, Dec. 2020.
- [53] S. B. Scott *et al.*, “A Coordinated Analysis of Variance in Affect in Daily Life,” *Assessment*, vol. 27, no. 8, pp. 1683–1698, Dec. 2020.
- 15067–15091, Apr. 2021.
- [35] M. S. El_Tokhy, “Development of optimum watermarking algorithm for radiography images,” *Comput. Electr. Eng.*, vol. 89, p. 106932, Jan. 2021.
- [36] S. Thakur, Y. Goplani, S. Arora, R. Upadhyay, and G. Sharma, “Chest X-Ray Images Based Automated Detection of Pneumonia Using Transfer Learning and CNN,” 2021, pp. 329–335.
- [37] G. Liang and L. Zheng, “A transfer learning method with deep residual network for pediatric pneumonia diagnosis,” *Comput. Methods Programs Biomed.*, vol. 187, p. 104964, Apr. 2020.
- [38] H. Wu, P. Xie, H. Zhang, D. Li, and M. Cheng, “Predict pneumonia with chest X-ray images based on convolutional deep neural learning networks,” *J. Intell. Fuzzy Syst.*, vol. 39, no. 3, pp. 2893–2907, Oct. 2020.
- [39] S. Wepler *et al.*, “Determining Clinical Patient Selection Guidelines for Head and Neck Adaptive Radiation Therapy Using Random Forest Modelling and a Novel Simplification Heuristic,” *Front. Oncol.*, vol. 11, Jun. 2021.
- [40] R. Sarkar, A. Hazra, K. Sadhu, and P. Ghosh, “A Novel Method for Pneumonia Diagnosis from Chest X-Ray Images Using Deep Residual Learning with Separable Convolutional Networks,” 2020, pp. 1–12.
- [41] E. Yahaghi, M. Mirzapour, A. Movafeghi, and B. Rokrok, “Interlaced bilateral filtering and wavelet thresholding for flaw detection in the radiography of weldments,” *Eur. Phys. J. Plus*, vol. 135, no. 1, p. 42, Jan. 2020.
- [42] A. Vidyarthi and A. Malik, “A hybridized modified densenet deep architecture with CLAHE algorithm for humpback whale identification and recognition,” *Multimed. Tools Appl.*, Jul. 2021.
- [43] Y.-D. Zhang, Z. Zhang, X. Zhang, and S.-H. Wang, “MIDCAN: A multiple input deep convolutional attention network for Covid-19 diagnosis based on chest CT and chest X-ray,” *Pattern Recognit. Lett.*, vol. 150, pp. 8–16, Oct. 2021.
- [44] K. K. Singh and A. Singh, “Diagnosis of COVID-19 from chest X-ray images using wavelets-based depthwise convolution

- [54] H. Lu and X. Ma, "Hybrid decision tree-based machine learning models for short-term water quality prediction," *Chemosphere*, vol. 249, p. 126169, Jun. 2020.
- [55] H. Saadatfar, S. Khosravi, J. H. Joloudari, A. Mosavi, and S. Shamshirband, "A New K-Nearest Neighbors Classifier for Big Data Based on Efficient Data Pruning," *Mathematics*, vol. 8, no. 2, p. 286, Feb. 2020.
- [56] D. A. Pisner and D. M. Schnyer, "Support vector machine," in *Machine Learning*, Elsevier, 2020, pp. 101–121.
- [57] X. Yang *et al.*, "Research and applications of artificial neural network in pavement engineering: A state-of-the-art review," *J. Traffic Transp. Eng. (English Ed.)*, Oct. 2021.
- [58] A. M. Alqudah, S. Qazan, and I. S. Masad, "Artificial Intelligence Framework for Efficient Detection and Classification of Pneumonia Using Chest Radiography Images," *J. Med. Biol. Eng.*, Jun. 2021.
- [59] I. MEJÀRE, H.-G. GRÖNDAHL, K. CARLSTEDT, A.-C. GREVER, and E. OTTOSSON, "Accuracy at radiography and probing for the diagnosis of proximal caries," *Eur. J. Oral Sci.*, vol. 93, no. 2, pp. 178–184, Apr. 1985.
- [60] J. T. Braggio, E. S. Hall, S. A. Weber, and A. K. Huff, "Contribution of AOD-PM2.5 surfaces to respiratory-cardiovascular hospital events in urban and rural areas in Baltimore, Maryland, USA: New analytical method correctly identified true positive cases and true negative controls," *Atmos. Environ.*, vol. 262, p. 118629, Oct. 2021.
- [61] S. Sahoo, A. Subudhi, M. Dash, and S. Sabut, "Automatic Classification of Cardiac Arrhythmias Based on Hybrid Features and Decision Tree Algorithm," *Int. J. Autom. Comput.*, vol. 17, no. 4, pp. 551–561, Aug. 2020.
- [62] X. XU, W. CHEN, and Y. SUN, "Over-sampling algorithm for imbalanced data classification," *JSEE*, vol. 30, no. 6, pp. 1182–1191, 2019.