

## کلاسه‌بندی تصاویر رادیولوژی قفسه سینه به منظور شناسایی بیماران مبتلا به کووید ۱۹ با بهره‌گیری از تکنیک‌های یادگیری ژرف

مرسا غلامزاده<sup>۱</sup>، سید محمد ایوب زاده<sup>۲</sup>، هدا زاهدی<sup>۳</sup>، شراره رستم نیاکان کلهری<sup>۴\*</sup>

### چکیده

**زمینه و هدف:** با توجه به اهمیت بالای تصاویر رادیولوژی برای شناسایی بیماران کووید ۱۹، ایجاد مدلی مبتنی بر یادگیری عمیق از اهداف اصلی این پژوهش است.

**روش بررسی:** از ۱۵۱۵۳ تصویر موجود از تصاویر قفسه سینه مربوط به افراد سالم، مبتلا به کووید ۱۹ و مبتلا به پنومونی در مخزن داده‌های سایت Kaggle به عنوان داده‌های این پژوهش استفاده شد. پیش پردازش داده‌ها شامل نرمال‌سازی تصاویر و تجمعیه برچسب تصاویر و دسته‌بندی آنها به سه دسته‌ی آموزش، اعتبارسنجی و تست می‌شد. سپس با استفاده از زبان پایتون در کتابخانه fastAI مبتنی بر تکنیک کانولوشن (CNN) و براساس چهار معماری (ResNet, VGG MobileNet, AlexNet)، مدل از طریق روش یادگیری انقلالی برای تشخیص افراد سالم از افراد بیمار، آموزش داده شد. در نهایت، میزان عملکرد این مدل‌ها با شاخص‌های چون صحت، حساسیت و ویژگی، و F-Measure ارزیابی شد.

**یافته‌ها:** از بین ۹ مدل ایجاد شده، مدل ResNet101 دارای بیشترین توان تشخیص موارد مبتلا به کرونا از سایر موارد با شاخص حساسیت ۰/۹۵۲۹ بود. دیگر مدل‌های به کار گرفته شده، صحتی بیش از ۰/۹۶٪ در تشخیص درست موارد مختلف تصاویر تست از خود نشان دادند. مدل ResNet101 توانست صحتی معادل ۰/۹۸۷۴ در تشخیص بین موارد سالم و مبتلا از خود نشان دهد.

**نتیجه گیری:** میزان صحت به دست آمده، نشان‌دهنده‌ی عملکرد دقیق مدل پیش‌بینی در تشخیص کووید ۱۹ می‌باشد. بنابراین با پیاده‌سازی یک برنامه کاربردی براساس مدل توسعه‌یافته می‌توان به پزشکان در تشخیص دقیق و زودهنگام موارد مبتلا یاری رساند.

**واژه‌های کلیدی:** شبکه عصبی کانولوشن، کرونا ویروس، کووید ۱۹، یادگیری ماشین، یادگیری ژرف، یادگیری انقلالی

دریافت مقاله: شهریور ۱۳۹۹  
پذیرش مقاله: خرداد ۱۴۰۰

\* نویسنده مسئول:  
شاره رستم نیاکان کلهری؛  
دانشکده پرآپزشکی دانشگاه علوم پزشکی تهران

Email :  
Sh-miakank@sina.tums.ac.ir

۱ دانشجوی دکتری انفورماتیک پزشکی، دانشکده پرآپزشکی، دانشگاه علوم پزشکی تهران، تهران، ایران

۲ دکتری انفورماتیک پزشکی، دانشکده پرآپزشکی، دانشگاه علوم پزشکی تهران، تهران، ایران

۳ دانشجوی کارشناسی ارشد انفورماتیک پزشکی، دانشکده مدیریت و اطلاع‌رسانی پزشکی، دانشگاه علوم پزشکی ایران، تهران، ایران

۴ دانشیار گروه مدیریت اطلاعات سلامت، دانشکده پرآپزشکی، دانشگاه علوم پزشکی تهران، تهران، ایران؛ پژوهشگر موسسه تحقیقات انفورماتیک پزشکی PLRI.

دانشگاه پزشکی هانوفر و دانشگاه فنی برانشوایگ، برانشوایگ، آلمان

## مقدمه

### RT-PCR توصیه کردند(۱).

در چند دهه‌ی گذشته تصویربرداری پزشکی تحت تاثیر ظهور ابزارهای هوشمند تشخیصی غیرتهاجمی همراه با صحت و سرعت بالا قرار گرفته است؛ بنابراین مکانیسم‌های پردازش تصویر قادرند به طور وسیعی در بسیاری از حوزه‌های پزشکی به منظور بهبود تشخیص، شناسایی و درمان بیماری در مراحل اولیه، با افزایش کیفیت و تسهیل تفسیر تصاویر آن هم بدون نیاز به اقدام تهاجمی مورد استفاده قرار گیرند(۲). تحلیل تصاویر پزشکی یکی از ابزارهای نوین به منظور جمع‌آوری، ذخیره و بازیابی، دسته‌بندی و تجزیه و تحلیل اطلاعات پزشکی از تصاویر است. در این ابزارها مراحل مختلفی از جمله پیش‌پردازش، قطعه‌بندی، استخراج ویژگی و شناسایی روی تصویر ورودی انجام می‌شود. به کارگیری تکنیک‌های هوش مصنوعی کارایی این ابزارها را افزایش می‌دهد(۳). یکی از متداول‌ترین روش‌های هوش مصنوعی برای پردازش تصاویر پزشکی، روش‌های مبتنی بر یادگیری عمیق است. یادگیری ماشین الگوریتم‌هایی را ایجاد می‌کند که می‌توانند یاد بگیرند و پیش‌بینی کنند. برخلاف الگوریتم‌های مبتنی بر قوانین، یادگیری ماشین از افزایش مواجهه با مجموعه داده‌های بزرگ و جدید بهره می‌برد و توانایی بهبود و یادگیری با تجربه را دارد(۴ و ۵). به عبارت دیگر، الگوریتم‌های یادگیری عمیق مبتنی بر مجموعه‌ای از الگوریتم‌ها هستند که سعی در مدل‌سازی انتزاعات سطح بالا در داده‌ها دارند(۶).

اثرات مثبت تحلیل تصاویر و میزان کارایی روش‌های یادگیری عمیق برای تشخیص مشکلات ریوی در تصاویر رادیوگرافی در تشخیص زودهنگام مشکلات و ضایعات ریوی در سال‌های اخیر مورد توجه محققان قرار گرفته است(۷-۱۵). در اکتبر سال ۲۰۱۹، محققان یک مرکز تحقیقاتی در سویس الگوریتمی را برای تشخیص میزان فیبرоз ریوی با استفاده از روش‌های یادگیری عمیق طراحی کردند که صحت این الگوریتم برابر با صحت تشخیص تصاویر توسط انسان تعیین شد(۱۶). در رابطه با تشخیص پنومونی یا ذات‌الریه، به دلیل اینکه نمای پنومونی در تصاویر اشعه ایکس غالباً مشخص نیست و می‌تواند با بیماری‌های دیگر اشتباه گرفته شود، محققان در سال‌های اخیر از راهکارهای مبتنی بر یادگیری عمیق در قالب طراحی سیستم‌های پشتیبان کامپیوتری برای کمک به رادیولوژیست‌ها بهره بردنده که توانایی شرح دلایل احتمالی ذات‌الریه را نیز داشت(۱۷). در راستای

در اوخر دسامبر سال ۲۰۱۹، کروناویروس جدیدی، بنام کروناویروس نوین ۲۰۱۹ یا (SARS-CoV-2) باعث آغاز شیوع پنومونی از ووهان به سراسر کشور چین شد که در حال حاضر خطر بزرگی را برای سلامتی عمومی جهان ایجاد کرده است. در ۳۰ ژانویه، WHO همه‌گیری کروناویروس نوین را به عنوان فوریت بهداشت عمومی با نگرانی بین المللی اعلام کرد. تا امروز بیماری همه‌گیر کووید ۱۹ ناشی از کروناویروس نوین-۱۹ در سراسر جهان، در حال گسترش است و با وجود اعمال محدودیت‌ها و تلاش برای قرنطینه بیماران، شیوع بیماری همچنان را به افزایش است(۱). این بیماری قدرت انتقال بالایی همراه با دوره نهفتگی طولانی دارد که می‌تواند بعد از ورود به بدن یافت ریه را مورد حمله قرار دهد(۲).

مهم‌ترین عارضه کووید ۱۹ به عنوان ویروسی که سیستم تنفسی را درگیر می‌نماید، پنومونی شدید به همراه شیوع ضایعات است. عوارض این بیماری در حالت وخیم شامل علایم نارسایی حاد تنفسی، نیاز به تهییه مکانیکی یا تنفس مصنوعی، شوک سپتیک و نارسایی ارگانی خارج ریوی است(۳). با توجه به شیوع نسبتاً بالای بیماری، تشخیص دقیق و زودهنگام آن بسیار حائز اهمیت است. اصلی‌ترین روش تشخیص، از طریق تست‌های آزمایشگاهی PCR است که انجام آن علاوه بر اینکه در شرایط اورژانسی ممکن است در دسترس نباشد، زمانی نیز هست. از آنچاکه شناسایی بیماران مبتلا به COVID-19 در مراحل اولیه آن، به منظور جداسازی بیماران از جمعیت سالم، ضروری است، سیتی‌اسکن و انجام رادیوگرافی ریه با حساسیت بالای ۹۷ درصد از جمله روش‌های تشخیصی ارزشمند برای تشخیص زودهنگام کووید ۱۹ در مقایسه با تست‌های RT-PCR در زمان اپیدمی محسوب می‌شود(۴ و ۵). در واقع محققان معتقدند که تغییراتی که به صورت اختصاصی در ریه بیماران دیده می‌شود، حتی چهار روز قبل از شروع علایم بالینی در بیمار نیز می‌تواند مثبت‌بودن بیماری را اعلام کند. Fang و همکاران در مطالعه‌ای، بر روی پنجاه و یک بیمار، حساسیت تصاویر رادیولوژی را در تشخیص عفونت ناشی از کووید ۱۹، ۹۸٪ و حساسیت روشن تشخیصی RT-PCR، را ۷۱٪ گزارش کردند. با توجه به نتایج این مطالعه، محققان این پژوهش، استفاده از تصاویر رادیولوژی را برای شناسایی بیماران مشکوک به ابتلا به کووید ۱۹ به ویژه در هنگام منفی شدن آزمایش



## روش بررسی

این پژوهش از حیث هدف، کاربردی و از حیث اجرا، توصیفی-توسعه‌ای است. روش به کار گرفته شده در این مطالعه از روش‌های مبتنی بر یادگیری عمیق به عنوان یکی از پر طرفدارترین روش‌های یادگیری ماشین و زیر مجموعه‌ای از الگوریتم‌های شبکه عصبی مصنوعی یا تکنیک کانولوشن یا (CNN) که شامل بیش از یک لایه پنهان است، استفاده شد(۲۴). علت علاقه به استفاده از روش‌های یادگیری عمیق در رادیولوژی وجود موقتیت‌های اخیر و دستیابی به نتایج امیدوارکننده در تشخیص پلورال افیوزن، کاردیومگالی(۲۵)، و نودل‌های ریه در سیتی اسکن(۲۶) است. هر چند استفاده از یادگیری عمیق به دلیل نیاز به حجم عظیمی از داده‌ها برای تشخیص مشکلات پزشکی روندی بسیار گران و زمان‌بر است، اما خوب‌بختانه راه حل‌هایی برای غلبه بر این مسئله وجود دارد. یکی از این روش‌ها تقویت داده‌ها (Data augmentation) است که از پوشش بیش از حد جلوگیری کرده و دقت مدل را بهبود می‌بخشد(۲۷). یکی از این روش‌های تقویت عملکرد که در تفسیر تصاویر رادیولوژی کاربرد دارد به عنوان یادگیری انتقالی (Transfer learning) (۲۸) شناخته می‌شود که دانش آموخته شده از کار قبلی را به یک کار متفاوت اما مرتبط با آن اعمال می‌کند و بدین ترتیب امکان استفاده از داده‌های دارای برچسب موجود برای یک کار جدید اما مرتبط را فراهم می‌کند(۲۹). تکنیک‌های یادگیری عمیق به کار رفته در این پژوهش بیشتر متمرکر بر تشخیص صحیح عفونت و ساخت یک classifier برای دسته‌بندی تصاویر CXR استخراج شده با استفاده از تکنیک یادگیری انتقالی و کلاسه‌بندی نمونه‌ها به سه گروه افراد سالم، افراد مبتلا به کرونا و افرادی با بیماری دیگر با استفاده از مدل پیش‌بینی می‌باشد. در روند طراحی و ساخت classifier از معروف‌ترین و پر کاربردترین مدل‌های پیش‌بینی و استخراج ویژگی‌ها در رابطه با شبکه‌های CNN چون VGG (۳۰)، ResNet (۳۱)، MobileNet (۳۲) و AlexaNet (۳۳) استفاده شد. این مدل‌ها از معروف‌ترین معماری‌های استفاده شده در شبکه‌های عصبی پیچشی هستند که در مطالعات مختلف در مقایسه با مدل‌های همتای خود عملکرد بهتری دارند. در واقع با استفاده از معماری شبکه کانولوشن، تصاویر گروه‌بندی شد و در نهایت مدل‌هایی ایجاد شده با استفاده از تکنیک‌های یادگیری عمیق توسعه یافت. هریک از مدل‌های به دست آمده با شاخص‌های

تشخیص عفونت‌های پنومونی ویروسی و باکتریایی نیز مطالعاتی مبتنی بر یادگیری عمیق برای تجزیه و تحلیل میزان ماده سفید رنگ منتشر شده در دو بخش تصویر اشعه ایکس قفسه‌سینه و کمک به پزشک معالج برای تشخیص آسان مشکل پنومونی به انجام رسیده است(۱۸).

با توجه به نتایج مثبت این مطالعات، از زمان آغاز پاندمی کرونا مطالعاتی به منظور ارزیابی شدت درگیری ریه‌ها در ذات‌الریه ایجاد شده از بیماری کووید ۱۹ و تشخیص زودهنگام آن با هدف جلوگیری از گسترش بیشتر بیماری از روی تصاویر رادیولوژیک بر مبنای روش‌های یادگیری عمیق در حال انجام است. هر چند به دلیل شروع این بیماری از ووهان چین، بیشتر این مطالعات با استفاده از بررسی تصاویر رادیولوژی قفسه‌سینه در کشور چین به انجام رسیده است(۲۰). Wang و همکاران با استفاده از تصاویر سیتی اسکن ۶۱۸ بیمار مبتلا به کووید ۱۹ و استفاده از تکنیک یادگیری عمیق اقدام به ایجاد مدلی برای غربالگری اولیه عفونت ناشی از کرونا ویروس با دقت تشخیصی ۰/۸۶/۷ کردن(۱۹). در مطالعه‌ی مشابه دیگری نیز محققان از ترکیب مدل‌های ReNet50V2 و Xception برای بهبود تشخیص پنومونی و علایم اولیه کووید ۱۹ در حوزه‌ی یادگیری عمیق با صحت نهایی ۰/۹۱ در تشخیص تصاویر در کلاس‌های مختلف به انجام رساندند(۲۱). Hammoudi و همکاران نیز در دوره پاندمیک کرونا ویروس، سیستم هوشمندی را با استفاده از روش‌های یادگیری عمیق برای تشخیص پنومونی و غربالگری کووید ۱۹ با هدف حمایت از رادیولوژیست‌ها و پزشکان ارایه دادند(۲۲). پژوهشگران کشور چین با استفاده از اطلاعات سه مطالعه کوهرت مجزا از طریق تحلیل تصاویر HRCT با کیفیت بالا و استفاده از شبکه DenseNet مدلی را با صحت ۹۸ درصد در تشخیص کووید ۱۹ ارایه دادند(۲۳).

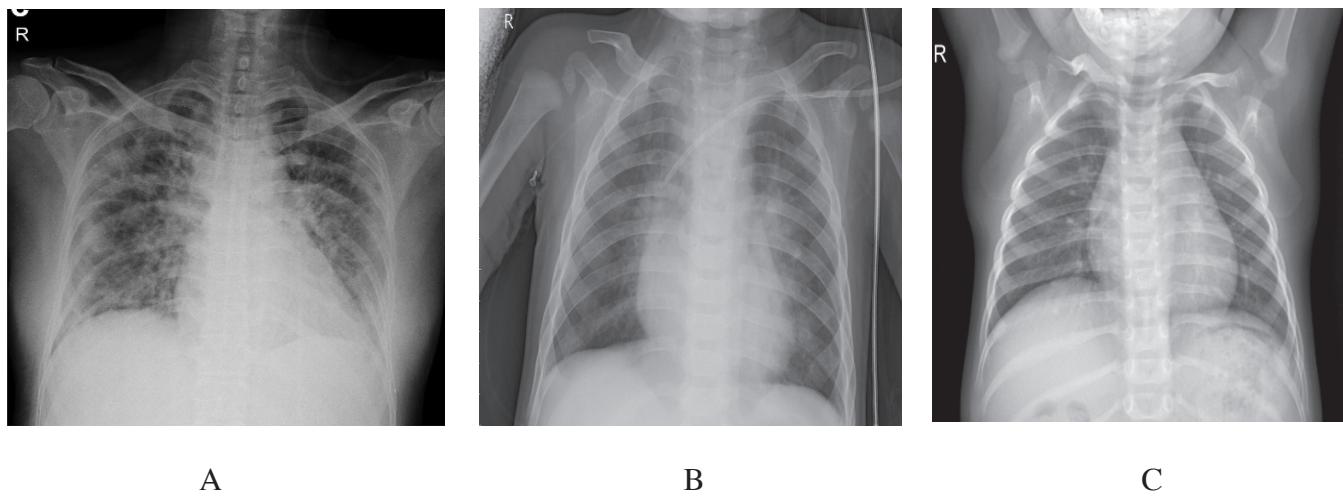
با توجه به حساسیت تشخیص COVID-19، صحت تشخیص یکی از اصلی‌ترین چالش‌ها در تحقیقات است. از طرف دیگر، توجه بر افزایش راندمان تشخیص و ایجاد مدلی برای تشخیص افتراقی این بیماری از سایر عفونت‌های مشابه مانند پنومونی یکی از دغدغه‌های متخصصان بالینی در این حوزه است. در نتیجه هدف از انجام این مطالعه، ایجاد مدلی مبتنی بر یادگیری عمیق و ترکیب آن با روش یادگیری انتقال با هدف بهبود صحت تشخیص COVID-19 می‌باشد.



داده شامل ۳۶۱۶ تصویر CXR با تشخیص مثبت COVID-19، ۱۳۴۵ تصویر X-ray بیماران با تشخیص پنومونی ویروسی، ۶۱۰۲ کدورت در عکس قفسه‌سینه و ۱۰۱۹۲ تصویر اشعه‌ایکس قفسه‌سینه نرمال می‌باشد. نمونه تصویر هر کلاس از مجموعه داده‌های به کار گرفته شده، در شکل ۱ نشان داده شده است. سپس مجموعه داده‌های بازیابی شده به ترتیب به داده‌های آموزشی، داده‌های تست، و داده‌های validation با نسبت‌های ۷/۰، ۰/۰ و ۰/۱ تقسیم شدند.

صحت، حساسیت، و ویژگی مورد ارزیابی قرار گرفتند.

در روش یادگیری عمیق استاندارد موردن توافقی برای اندازه گیری حجم نمونه موجود نیست ولی با توجه به مطالعات پیشین تعداد حداقل ۴۰۰ نمونه برای دستیابی به یک مدل با صحت بالا نیاز است. برای تسريع در روند مدل‌سازی در این پژوهش، از مجموعه داده‌های عمومی موجود در مخزن (<https://www.kaggle.com/tawsifurrahman/covid19-radiography-database>) Kaggle استفاده شد. این داده‌ها در فروردین ماه سال ۱۴۰۰ بازیابی شد. این مجموعه



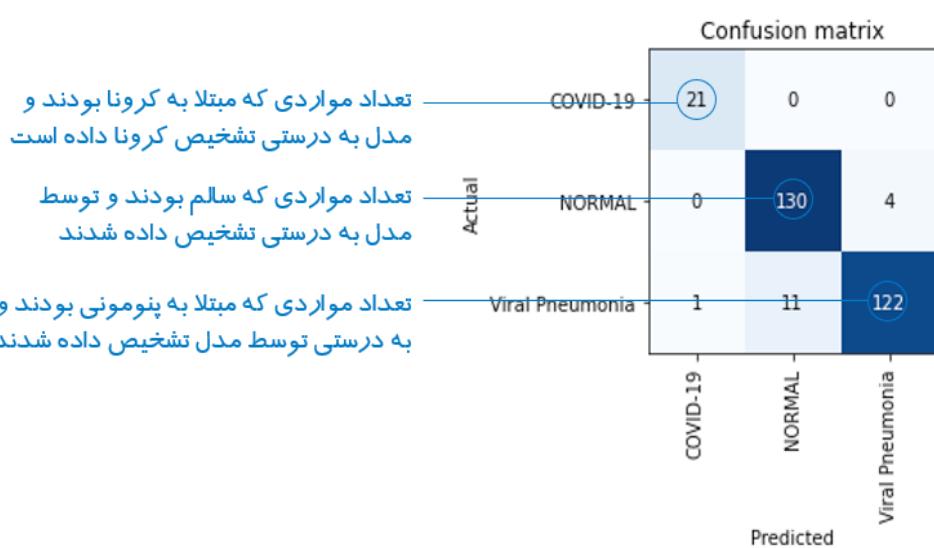
شکل ۱: نمونه ۵۰۰ داده مجموعه دیتاست‌های استفاده شده، (A) تصویر عکس قفسه‌سینه مبتلا به COVID-19، (B) تصویر عکس قفسه‌سینه شفاف مبتلا به پنومونی ویروسی، (C) تصویر عکس نرمال قفسه‌سینه

به کارگیری زبان برنامه‌نویسی پایتون بر روی بستر Google Colab اجرا شدند. زمان اجرای آموزش، نمره خطای یادگیری بر روی مجموعه داده‌های train و validation محاسبه شد. ارزیابی هر مدل بر روی داده‌های validation انجام شد و کارایی مدل‌ها بر روی مجموعه داده‌ی test بررسی گردید.

ماتریس درهم‌ریختگی عملکرد هر مدل براساس داده‌های تست نیز در طی این پژوهش بررسی گردید تا بهترین مدل برای تفسیر تصاویر Chest X-ray و تشخیص افتراقی کووید ۱۹ از پنومونی با بهترین عملکرد انتخاب گردد. زمان آموزش، نمره خطای یادگیری بر روی مجموعه داده‌های آموزش و اعتبارسنجی و صحت هر مدل بر روی داده‌های اعتبارسنجی ارزیابی شد. نمونه‌ای از ماتریس درهم‌ریختگی در شکل ۲ آورده شده است.

به منظور آموزش مدل‌ها توسط تکنیک یادگیری انتقالی، فقط وزن آخرین لایه آموزش داده شد و سایر وزن‌ها توسط مدل‌های پیش‌آموزش دیده شده بر روی دیتاست ImageNet ثابت نگهداشته شد. پس از آن مدل Fastai با بهترین دقت برای تنظیم دقیق عملکرد انتخاب شد. از کتابخانه [Fastai](https://www.fast.ai) در زبان برنامه‌نویسی پایتون در این پژوهش برای ساخت مدل‌ها استفاده شد. در نهایت، صحت مدل استخراج شده ارزیابی گردید. مجموعه‌های training، validation و test با نسبت‌های ۷/۰، ۰/۰ و ۰/۱ ایجاد شد. قبل از مرحله آموزش، تمام تصاویر پیش‌پردازش شدند که شامل تغییر اندازه آنها به ابعاد ۲۲۴ در ۲۲۴ پیکسل در ۳ کanal رنگی (به دلیل شکل ورودی مدل‌های از پیش‌آموزش داده شده) و نرمال کردن مقادیر عددی هر پیکسل به اعداد ۰ تا ۱ بود.

در نهایت شبکه‌های پیشنهادی با استفاده از چارچوب Fastai و



شکل ۱۰: نمونه ماتریس درهم‌ریختگی برای تفسیر نتایج

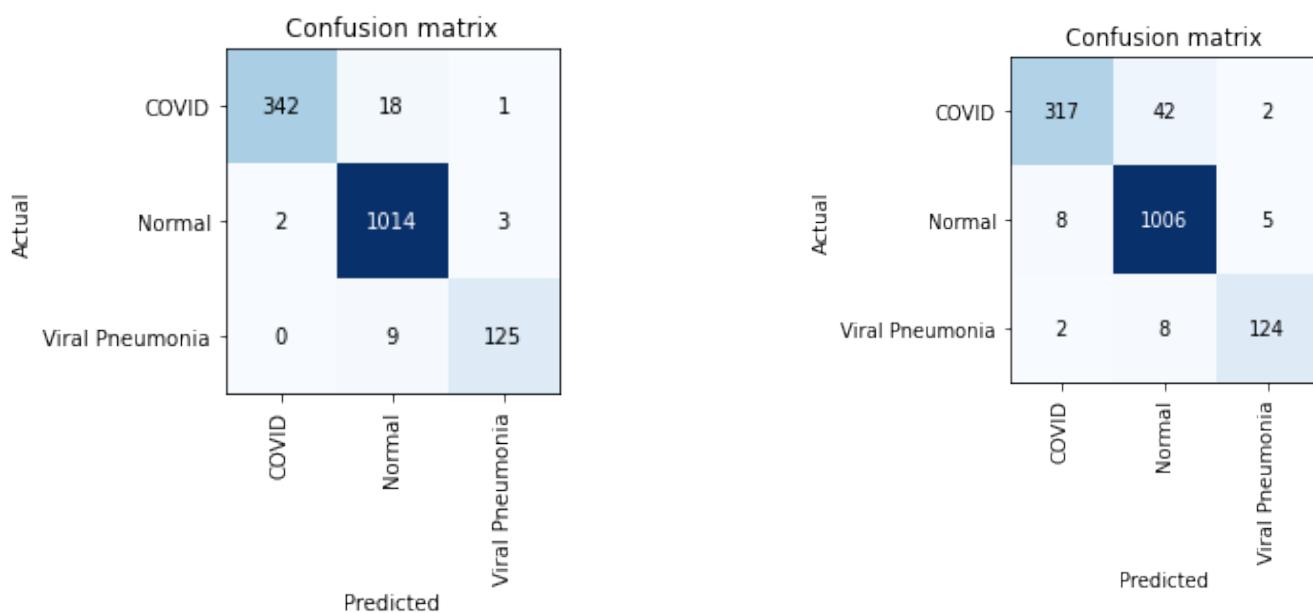
یادگیری بر روی تصاویر افراد سالم، افراد مبتلا به پنومونی، و افراد مبتلا به COVID-19، براساس روش توضیح داده از بخش قبل بدست آمد. با استفاده از ماتریس‌های بهم ریختگی عملکرد بهترین شبکه بر روی مجموعه داده‌های در نظر گرفته شده، در ادامه به تفکیک، عملکرد هر مدل در قالب ماتریس درهم‌ریختگی در شکل ۱۳ آورده شده است.

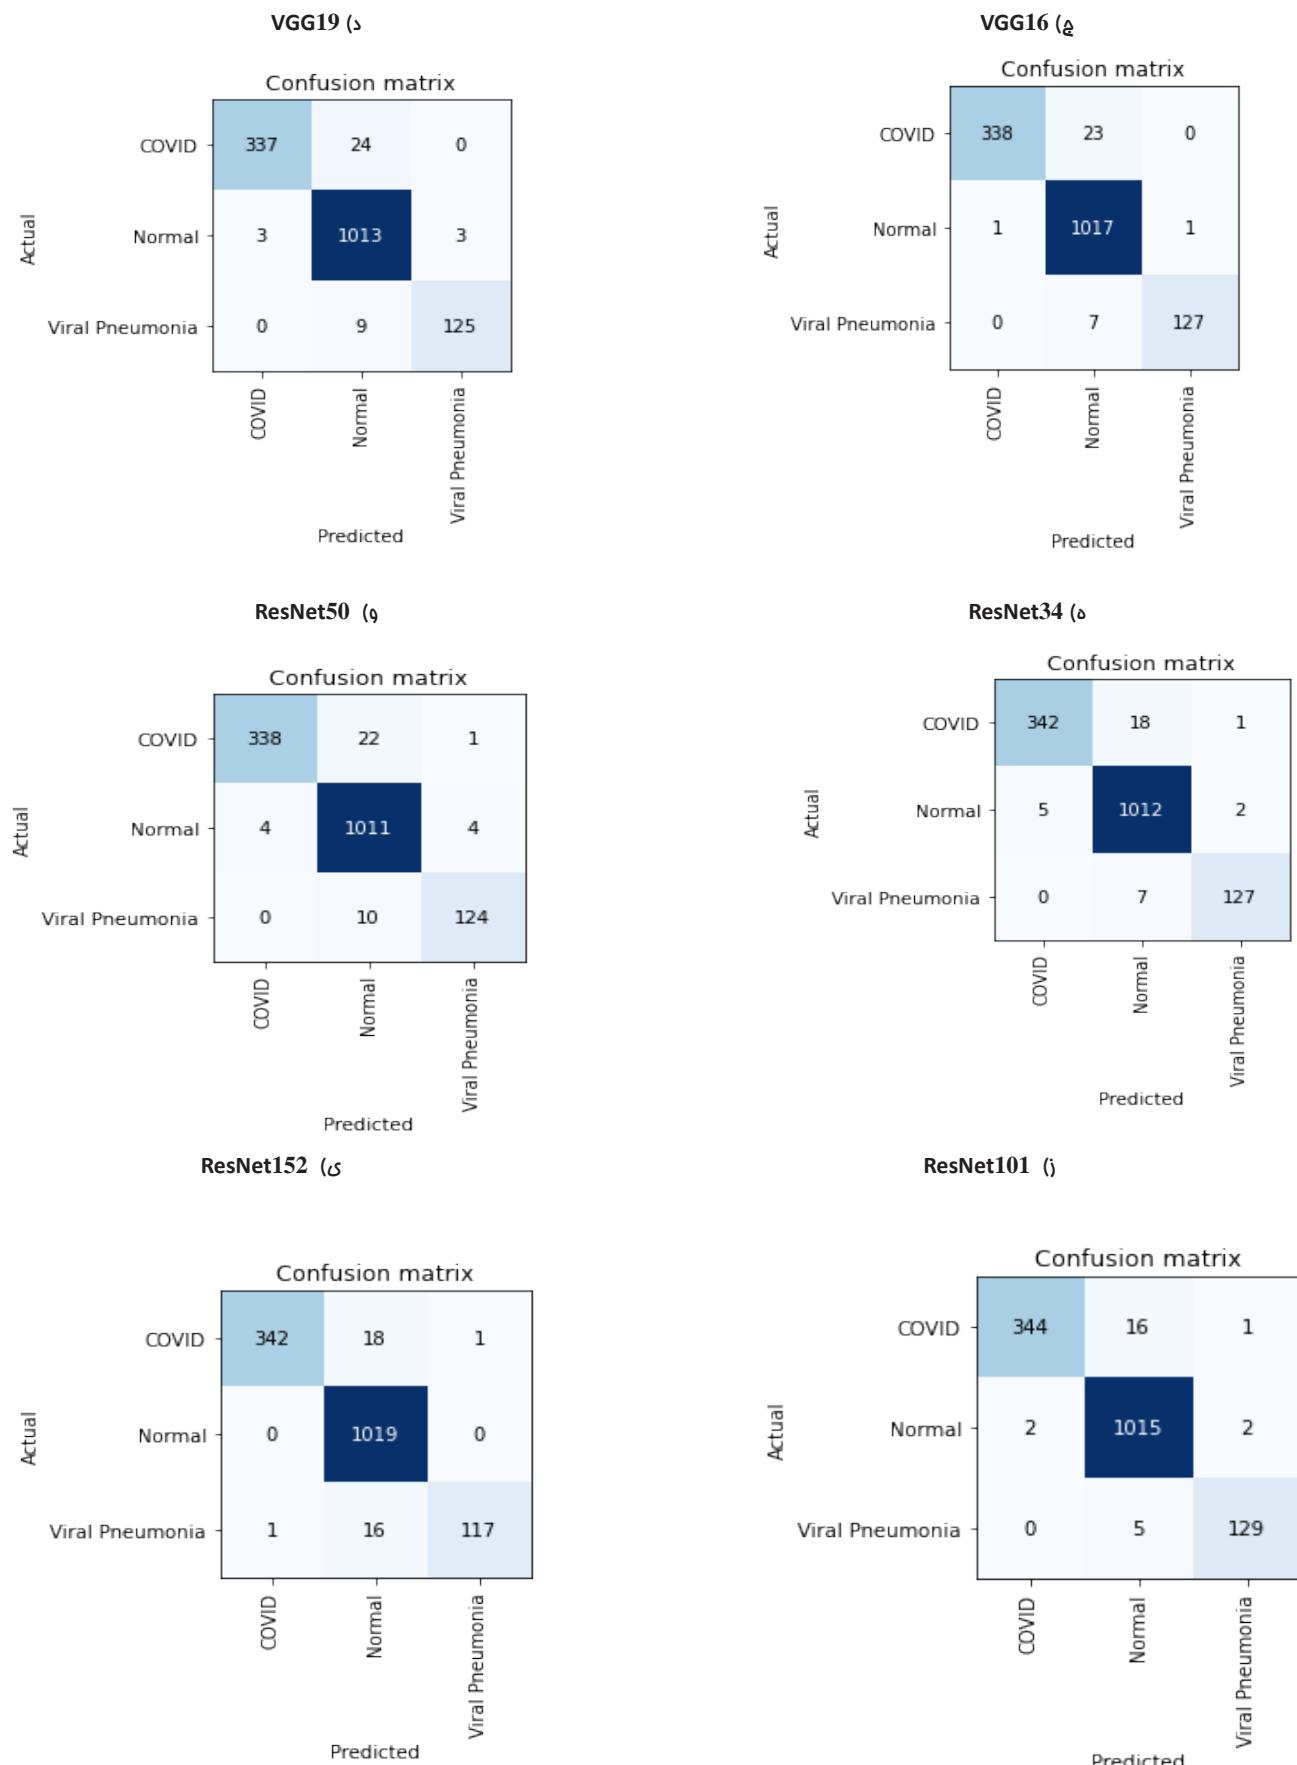
## یافته‌ها

در حقیقت هدف از این مطالعه این است که مدل توسعه یافته بتواند به درستی نتایج مثبت کووید ۱۹ را از سایر ناهنجاری‌ها تشخیص دهد. شبکه‌های ایجاد شده براساس چهار معماری به کار گرفته شده (Alexnet, MobileNet, ResNet VGG) از طریق روش انتقال (Alexnet, MobileNet, ResNet VGG)

MobileNetV2 (ب)

AlexNet (الف)





شکل ۳: تفسیر نتایج به دست آمده از مدل های مختلف به کار گرفته شده در قالب ماتریس درجه ریفتگی

است در حالی که FN (False Negative) تعداد تصاویر یک کلاس است، که به اشتباه بعنوان یک کلاس دیگر تشخیص داده شده‌اند و TN (منفی واقعی) تعدادی از تصاویر است که تعداد موارد منفی متعلق به آن کلاس را به درستی

$$\text{Accuracy} = \frac{\text{Tp} + \text{TN}}{\text{TP} + \text{FP} + \text{TN} + \text{FN}}$$

$$\text{Sensitivity} = \frac{\text{Tp}}{\text{TP} + \text{FN}}$$

$$\text{Specificity} = \frac{\text{TN}}{\text{TN} + \text{FP}}$$

$$\text{F-measure} = \frac{2\text{TP}}{2\text{TP} + \text{FP} + \text{FN}}$$

مدل‌های توسعه‌یافته در نهایت براساس حساسیت ( مقایسه دسته‌ی کرونا و دیگر دسته‌ها )، ویژگی ( مقایسه دسته‌ی کرونا و دیگر دسته‌ها ) و میزان صحت مورد ارزیابی قرار گرفتند. نتایج نهایی حاصل از مقایسه این مدل‌ها در جدول ۱ آورده شده است.

همان‌طور که از ماتریس‌های درهم‌ریختگی مدل‌های مختلف می‌توان استنباط کرد، مدل ResNet 101 در میان مدل‌های به کار گرفته‌شده دارای بیشترین توان تشخیص موارد مبتلا به کرونا از سایر موارد با شاخص حساسیت  $97/78$  می‌باشد، به این معنی که مدل توسعه‌یافته قادر است ۹۸ درصد موارد مربوط به اعتبارسنجی را به درستی تشخیص دهد. دیگر مدل‌های به کار گرفته‌شده، شامل مدل‌های VGG، MobileNet و ResNet صحتی بیش از  $90/90$  در تشخیص درست موارد مختلف تست از خود نشان دادند.

عملکرد classifier‌های به دست آمده با استفاده از شاخص‌های حساسیت، ویژگی و صحت در این مطالعه بررسی شده است. فرمول هر کدام از این شاخص‌ها در ادامه آمده است. در این معادلات، TP (True Positive) تعداد تصاویر طبقه‌بندی شده صحیح است که به درستی به آن کلاس تعلق دارند، FP (False Positive) نیز تعداد تصاویر اشتباه طبقه‌بندی شده یک کلاس

جدول ۱: نتایج ارزیابی مدل‌های توسعه‌یافته

| مدل                   | صحت   | کووید (موارد کووید در مقابل سایر) | کووید در مقابل سایر (موارد کووید در مقابل سایر) | حساسیت نسبت به موارد              | ویژگی نسبت به موارد | F-Measure (موارد کووید در مقابل سایر) |
|-----------------------|-------|-----------------------------------|---|-----------------------------------|---------------------|---------------------------------------|
| AlexNet               | ۹۶/۴  | ۸۷/۸۱                             | کووید در مقابل سایر                             | کووید (موارد کووید در مقابل سایر) | حساست               | ۹۲/۱۵                                 |
| MobileNetV2           | ۹۸/۶  | ۹۴/۷۴                             | کووید در مقابل سایر                             | کووید در مقابل سایر               | حساسیت              | ۹۷/۰۲                                 |
| MobileNetV2 Optimized | ۹۸/۴۱ | ۹۳/۶۳                             | کووید در مقابل سایر                             | کووید در مقابل سایر               | ویژگی               | ۹۶/۵۷                                 |
| VGG16                 | ۹۸/۲  | ۹۳/۳۵                             | کووید در مقابل سایر                             | کووید در مقابل سایر               | صحت                 | ۹۶/۱۵                                 |
| VGG19                 | ۹۸/۴۱ | ۹۴/۷۴                             | کووید در مقابل سایر                             | کووید در مقابل سایر               | حساسیت              | ۹۶/۶۱                                 |
| ResNet34              | ۹۸/۲  | ۹۳/۶۳                             | کووید در مقابل سایر                             | کووید در مقابل سایر               | ویژگی               | ۹۶/۱۶                                 |
| ResNet50              | ۹۸/۷۴ | ۹۵/۲۹                             | کووید در مقابل سایر                             | کووید در مقابل سایر               | صحت                 | ۹۷/۳۱                                 |
| ResNet101             | ۹۸/۶  | ۹۵/۸۴                             | کووید در مقابل سایر                             | کووید در مقابل سایر               | حساسیت              | ۹۷/۰۵                                 |
| ResNet152             | ۹۸/۶۶ | ۹۴/۷۴                             | کووید در مقابل سایر                             | کووید در مقابل سایر               | ویژگی               | ۹۷/۱۶                                 |

بر اساس تبدیل دسته‌ها به دو گروه کووید و غیر کووید (سالم و پنومونی) محاسبه شده است.

در جدول ۱، صحت تشخیص بر اساس سه گروه مبتلا به کووید، مبتلا به پنومونی و موارد سالم محاسبه شده است. دو شاخص حساسیت و ویژگی

## بحث

به کارگیری تکنیک‌های یادگیری عمیق به انجام رسیده است و مورد توجه قرار گرفته است، می‌توان از مطالعه‌ی Asif و Wenhui که ماه می ۲۰۲۰ به انجام رسیده است، نام برد. آنها در مطالعه‌ی خود به ارایه مدلی با صحت ۹۶ درصدی دست یافته‌اند (۳۸). هرچند در این مطالعه در مورد روش توسعه مدل به کار گرفته شده اطلاعاتی ذکر نشده است. مطالعات مشابه دیگری نیز توسط دیگر محققان در این حوزه به انجام رسیده که از نظر نوع مدل‌ها و شبکه‌های به کار گرفته شده با مطالعه‌ی حاضر متفاوت می‌باشند. هرچند از نظر صحت و ویژگی به مقادیر مشابهی دست یافته‌اند (۴۱-۳۸). اما نتایج ارزیابی حاصل از پژوهش پیش‌رو در مقایسه با دیگر مطالعات مشابه نشان داد که مدل توسعه‌یافته در نتیجه این پژوهش با نام Mobile Optimized NetV2 قادر است بر اساس تصویر Chest X-Ray از بیمار مراجعه‌کننده مشکوک به کرونا، ابتلا و یا عدم ابتلای وی به بیماری کرونا را با صحت ۹۵ درصد در تشخیص افتراقی مبتلایان به کووید ۱۹ به پزشکان یاری رساند. به عبارت دیگر این مدل قدرت تشخیص ۱۰۰ درصدی موارد نرمال و درصدی موارد مبتلا به پنومونی ویروسی را دارد. به طور کلی، این مطالعات نشان می‌دهد که هوش مصنوعی پتانسیل کمک به کادر درمان را در تشخیص عفونت COVID-19 و ایزووله‌سازی زودهنگام مبتلایان بر اساس CXR را با صحت بالایی دارد.

هرچند ذکر این نکته ضروری است که در اکثر مبتلایان به کووید ۱۹ که ریه آنها درگیر شده است، در مقایسه با افراد سالم و یا فرد مبتلا به یک پنومونی ساده، ناهنجاری‌ها به شکل واضحی ریه را درگیر می‌کند. بنابراین مدل‌های توسعه‌یافته در این حوزه از آنچاکه با هدف تشخیص ناهنجاری در افراد مبتلا به کووید توسعه می‌یابند، قادرند با دقت بالایی ابتلا را تشخیص دهند. Desai و همکاران نیز معتقد‌ند که دلیل اصلی حساسیت و صحت بالا در مدل‌های توسعه‌یافته نیز همین مطلب است (۴۲).

یکی از مشکلات مطالعات انجام شده برای توسعه‌ی مدل‌های تشخیصی مبتنی بر پردازش تصاویر، کمبود تعداد تصاویر و محدودیت دسترسی به تصاویر دارای برچسب‌های مطمئن است. بنابراین استفاده از روش یادگیری انتقالی به عنوان راه حلی برای تقویت عملکرد مدل‌های توسعه داده شده برای تفسیر تصاویر رادیولوژی و تقویت داده‌ها در این مطالعه برای غلبه بر محدودیت‌های قابل توجه توسعه مدل‌های یادگیری ماشین در نظر گرفته شد.

براساس شواهد علمی، یکی از پرکاربردترین روش‌های عکس‌برداری‌های تشخیصی در تشخیص نهایی ابتلا به کووید ۱۹ و شرایط همه‌گیری مشابه، استفاده از عکس‌برداری قفسه‌سینه یا همان CXR به دلیل در دسترس بودن، کم خطر بودن، و هزینه‌ی کمتر در مقایسه با دیگر روش‌های تشخیصی مانند سیتی اسکن یا MRI است. به همین دلیل در این مطالعه، برای طبقه‌بندی X Ray بیماران استفاده شد که در حال حاضر به عنوان بهترین روش برای غربالگری سریع در شرایط اپیدمی توسط متخصصان بالینی شناخته می‌شود (۳۵-۳۴). ارایه تشخیص اتوماتیک مبتنی بر تصاویر قفسه‌سینه برای تشخیص دقیق ناهنجاری‌های حاصل از کووید ۱۹، از زمان آغاز پاندمی کرونا ویروس به یکی از موضوعات مورد علاقه محققان در علوم پزشکی تبدیل شده است. مدل‌های ارایه‌شده مبتنی بر تکنیک‌های یادگیری عمیق نقش موثری در درک بهتر از ویژگی‌های رادیولوژیکی که در تصاویر قفسه‌سینه قابل مشاهده است، در اختیار متخصصان قرار داده است. دقت و ارایه اطلاعات کافی در زمان موردنظر توسط مدل‌های توسعه‌یافته به پزشکان کمک می‌کند تا در مراحل مختلف با دقت بالاتری بین شرایط ناهنجار و تغییرات طبیعی، تمایز قابل شوند (۱۲). در نتیجه در این مطالعه، با به کارگیری نه مدل مختلف مبتنی بر شبکه‌های کانولشن و روش انتقال یادگیری برای تشخیص افتراقی بین سه حالت پنومونی باکتریال، کووید ۱۹ و فرد سالم آموزش داده شده و در نهایت ارزیابی و مقایسه گردید.

با هدف مشابه، Barandiaran و Saiz نیز در مطالعه خود با استفاده از تصاویر رادیولوژیک قفسه‌سینه (CXR) و توسعه‌ی مدلی مبتنی بر شبکه‌های کانولشن، یک مدل با استفاده از معماری SSD (Single Shot Multibox Detector) ارایه دادند. مدل ارایه‌شده در این مطالعه با حساسیت ۹۲/۰ و ویژگی ۹۴/۰ توانایی تشخیص ناهنجاری حاصل از کووید ۱۹ را برای تمایز از افراد سالم داشت. هر چند مدل ارایه‌شده در مطالعه‌ی حاضر با هدف توانایی تشخیص در بین سه کلاس افراد سالم، مبتلا به پنومونی، و کووید ۱۹ ارایه شده است (۳۶)، در حالی که مدل ارایه‌شده توسط Sekeroglu و Ozsahin یک مدل دو کلاسه برای تشخیص بین افراد سالم و افراد مبتلا به کووید ۱۹ بود (۳۷). به عنوان یکی از مطالعات مشابه که در زمینه بهبود تشخیص بیماری با استفاده از تصاویر رادیولوژی و

در نهایت در مطالعات بعدی مورد ارزیابی قرار گیرد، باشد که در آینده، با استفاده از مجموعه داده‌های بیماران COVID-19 جمع‌آوری شده در سطح کشور و استفاده از آنها، صحت شبکه پیشنهادی ارایه شده در نتیجه‌ی این مطالعه افزایش یابد.

## نتیجه‌گیری

مدل پیشنهادی بر اساس پایگاه داده استخراج شده برای دسته‌بندی بین افراد سالم، افراد مبتلا به پنومونی و افراد مبتلا به کووید ۱۹ با استفاده از مدل‌های مبتنی بر شبکه عصبی و یادگیری عمیق ارایه شده است. با توجه به حساسیت تشخیص زودهنگام بیماری، همه‌گیری بالا، و عوارض جبران‌ناپذیر بیماری کووید ۱۹، مدل ارایه شده می‌تواند سرعت تشخیص و غربالگری بیماران را با کمک به تصمیم‌گیری در فرایند تفسیر تصاویر پزشکی بالا برده و در کنترل هرچه بهتر بیماری موثر باشد. هرچند در عمل برای استفاده از مدل پیشنهادی، نیاز به پیاده‌سازی در قالب یک سامانه کاربردی است تا پزشکان با سامانه طراحی شده بر اساس مدل ارایه شده، به تشخیص تصاویر گردآوری شده پردازنند. در نتیجه طراحی یک سامانه تحت وب براساس مدل ارایه شده برای تشخیص هوشمند تصاویر رادیولوژی می‌تواند موضوعی برای مطالعات بعدی باشد.

## تشکر و قدردانی

این مقاله حاصل طرح پژوهشی ثبت شده در دانشگاه علوم پزشکی تهران با کد اخلاق (IR.TUMS.VCR.REC.1399.150) می‌باشد.

## References

1. Sohrabi C, Alsafi Z, O'Neill N, Khan M, Kerwan A, Al Jabir A, et al. World health organization declares global emergency: A review of the 2019 novel coronavirus (COVID-19). International Journal of Surgery 2020; 76(1): 71-6.
2. Shereen MA, Khan S, Kazmi A, Bashir N & Siddique R. COVID-19 infection: Origin, transmission, and characteristics of human coronaviruses. Journal of Advanced Research 2020; 24(1): 91-8.
3. Zhai P, Ding Y, Wu X, Long J, Zhong Y & Li Y. The epidemiology, diagnosis and treatment of COVID-19. International Journal of Antimicrobial Agents 2020; 55(5): 105955.
4. Hani C, Trieu NH, Saab I, Dangeard S, Bennani S, Chassagnon G, et al. COVID-19 pneumonia: A review of typical CT findings and differential diagnosis. Diagnostic and Interventional Imaging 2020; 101(5): 263-8.
5. Asefi H & Safaei A. The role of chest CT scan in diagnosis of COVID-19. Frontiers in Emergency Medicine (Quarterly) 2020; 4(2 S): 64.

Niz در مطالعه‌ی خود با استفاده از همین روشن، موفق شدند مدلی مبتنی بر شبکه‌های عصبی با صحت ۰/۹۶/۷۸ و حساسیت ۰/۹۸/۶۶ برای تشخیص افتراقی کووید ۱۹ بر مبنای یک دیتابست با حجم پایین ارایه دهند (۴۳). مطالعه‌ی این محققان نیز نشان داد که مدل Mobile NetV2 در مقایسه با دیگر مدل‌های طبقه‌بندی، عملکرد بهتری در تشخیص افتراقی بیماران دارد. این مدل در مطالعه‌ی پیشرو نیز عملکرد بهتری در مقایسه با دیگر مدل‌های ارایه شده نشان داد.

هرچند روش‌های تشخیصی دیگری مانند PCR نیز تاکنون به عنوان یکی از بالهیت‌ترین ابزارهای تشخیصی در این بیماری محسوب می‌شود، اما مجهزبودن به روش تشخیصی سریع، مطمئن و دقیق با گذشت بیش از یک سال از همه‌گیری کووید ۱۹ پکی از دغدغه‌های اصلی کادر درمان به شمار می‌رود. طبقه‌بندی خودکار نتایج تصویربرداری می‌تواند به بهینه‌سازی استفاده از منابع انسانی آموزش دیده کمک شایانی کند. بنابراین، این مدل می‌تواند تحت یک برنامه‌ی کامپیوتری یا در قالب یک اپلیکیشن مبتنی بر تلفن همراه برای پشتیبانی از تصمیم‌بازی در تشخیص کووید ۱۹ در روند ارایه مراقبت توسط پزشکان، پیاده‌سازی شود تا با کمک به تشخیص به موقع این بیماری از عوارض جبران‌ناپذیر آن بر بافت ریه بیماران و مرگ‌ومیر بیشتر جلوگیری کند.

از آن‌جاکه یکی از محدودیت‌های این مطالعه استفاده از داده‌های رایگان و غیر محلی است که در دسترس همگان قراردارد، عملکرد واقعی این مدل در تشخیص‌های افتراقی پنومونی و کووید ۱۹ می‌تواند با استفاده از مجموعه داده‌های تصاویر ریوی واقعی و با تعداد بالاتر ارزیابی شود و



6. Fang Y, Zhang H, Xie J, Lin M, Ying L, Pang P, et al. Sensitivity of chest CT for COVID-19: Comparison to RT-PCR. *Radiology* 2020; 296(2): 115-7.
7. Pesapane F, Codari M & Sardanelli F. Artificial intelligence in medical imaging: Threat or opportunity? Radiologists again at the forefront of innovation in medicine. *European Radiology Experimental* 2018; 2(1): 35.
8. Lee LIT, Kanthasamy S, Ayyalaraju RS & Ganatra R. The current state of artificial intelligence in medical imaging and nuclear medicine. *BJR Open* 2019; 1(1): 20190037.
9. Huang HK. Biomedical image processing. *Critical Reviews in Bioengineering* 1981; 5(3): 185-271.
10. Kohli M, Prevedello LM, Filice RW & Geis JR. Implementing machine learning in radiology practice and research. *American Journal of Roentgenology* 2017; 208(4): 754-60.
11. Choy G, Khalilzadeh O, Michalski M, Do S, Samir AE, Pianykh OS, et al. Current applications and future impact of machine learning in radiology. *Radiology* 2018; 288(2): 318-28.
12. Le Cun Y, Bengio Y & Hinton G. Deep learning. *Nature* 2015; 521(7553): 436-44.
13. Abiyev RH & Ma'aitah MKS. Deep convolutional neural networks for chest diseases detection. *Journal of Healthcare Engineering* 2018; 2018(1): 4168538.
14. Ma J, Song Y, Tian X, Hua Y, Zhang R & Wu J. Survey on deep learning for pulmonary medical imaging. *Frontiers of Medicine* 2019; 14(1): 450-69.
15. Bhandary A, Prabhu GA, Rajinikanth V, Thanaraj KP, Satapathy SC, Robbins DE, et al. Deep-learning framework to detect lung abnormality – A study with chest X-Ray and lung CT scan images. *Pattern Recognition Letters* 2020; 129(1): 271-8.
16. Christe A, Peters AA, Drakopoulos D, Heverhagen JT, Geiser T, Stathopoulou T, et al. Computer-aided diagnosis of pulmonary fibrosis using deep learning and CT images. *Investigative Radiology* 2019; 54(10): 627-32.
17. Jaiswal AK, Tiwari P, Kumar S, Gupta D, Khanna A & Rodrigues JJPC. Identifying pneumonia in chest X-rays: A deep learning approach. *Measurement* 2019; 145(1): 511-8.
18. Acharya AK & Satapathy R. A deep learning based approach towards the automatic diagnosis of pneumonia from chest radio-graphs. *Biomedical and Pharmacology Journal* 2020; 13(1): 449-55.
19. Wang S, Kang B, Ma J, Zeng X, Xiao M, Guo J, et al. A deep learning algorithm using CT images to screen for Corona virus disease (COVID-19). *European Radiology* 2021; 31(1): 6096–104.
20. Xu X, Jiang X, Ma C, Du P, Li X, Lv Sh, et al. A deep learning system to screen Novel Coronavirus Disease 2019 Pneumonia. *Engineering* 2020; 6(10): 1122-9.
21. Rahimzadeh M & Attar A. A modified deep convolutional neural network for detecting COVID-19 and pneumonia from chest X-ray images based on the concatenation of Xception and ResNet50V2. *Informatics in Medicine Unlocked* 2020; 19(1): 100360.
22. Hammoudi K, Benhabiles H, Melkemi M, Dornaika F, Arganda Carreras I, Collard D, et al. Deep learning on chest x-ray images to detect and evaluate pneumonia cases at the era of COVID-19. Available at: <https://arxiv.org/pdf/2004.03399.pdf>. 2020.
23. Yang S, Jiang L, Cao Z, Wang L, Cao J, Feng R, et al. Deep learning for detecting corona virus disease 2019 (COVID-19) on high-resolution computed tomography: A pilot study. *Annals of Translational Medicine* 2020; 8(7): 450.
24. Shen D, Wu G & Suk HI. Deep learning in medical image analysis. *Annual Review of Biomedical Engineering* 2017; 19(1): 221-48.



25. Bar Y, Diamant I, Wolf L & Greenspan H. Deep learning with non-medical training used for chest pathology identification. Available at.. <https://www.cs.tau.ac.il/~wolf/papers/SPIE15chest.pdf>. . 2015.
26. Hua KL, Hsu CH, Hidayati SC, Cheng WH & Chen YJ. Computer-aided classification of lung nodules on computed tomography images via deep learning technique. *Onco Targets and Therapy* 2015; 8(1): 2015-22.
27. Ayan E & Unver HM. Data augmentation importance for classification of skin lesions via deep learning, Istanbul, Turkey: Conference: 2018 Electric Electronics, Computer Science, Biomedical Engineerings' Meeting (EBBT), 2018.
28. Weiss K, Khoshgoftaar TM & Wang D. A survey of transfer learning. *Journal of Big data* 2016; 3(1): 9.
29. Paul R, Hawkins SH, Balagurunathan Y, Schabath MB, Gillies RJ, Hall LO, et al. Deep feature transfer learning in combination with traditional features predicts survival among patients with lung adenocarcinoma. *Tomography* 2016; 2(4): 388-95.
30. Simonyan K & Zisserman A. Very deep convolutional networks for large-scale image recognition. Available at: <https://arxiv.org/pdf/1409.1556.pdf>. 2015.
31. Habibzadeh M, Jannesari M, Rezaei Z, Baharvand H & Totonchi M. Automatic white blood cell classification using pre-trained deep learning models: Resnet and inception, Austria: Tenth International Conference on Machine Vision, 2018..
32. Chen HY & Su CY. An enhanced hybrid mobilenet. Fukuoka, Japan: 9th International Conference on Awareness Science and Technology (iCAST), 2018.
33. Alom MZ, Taha TM, Yakopcic C, Westberg S, Sidiike P, Nasrin MS, et al. The history began from alexnet: A comprehensive survey on deep learning approaches. Available at: <https://arxiv.org/ftp/arxiv/papers/1803/1803.01164.pdf>. 2018.
34. Wielputz MO, Heußel CP, Herth FJF & Kauczor HU. Radiological diagnosis in lung disease: Factoring treatment options into the choice of diagnostic modality. *Deutsches Arzteblatt International* 2014; 111(11): 181-7.
35. Yasin R & Gouda W. Chest X-ray findings monitoring COVID-19 disease course and severity. *Egyptian Journal of Radiology and Nuclear Medicine* 2020; 51(1): 193.
36. Saiz FA & Barandiaran I. COVID-19 detection in chest x-ray images using a deep learning approach. *International Journal of Interactive Multimedia and Artificial Intelligence* 2020; 6(2): 11-6.
37. Sekeroglu B & Ozsahin I. Detection of COVID-19 from Chest X-Ray images using convolutional neural networks. *SLAS Technology* 2020; 25(6): 553-65.
38. Asif S & Wenhui Y. Automatic detection of COVID-19 using x-ray images with deep convolutional neural networks and machine learning. Available at: <https://www.medrxiv.org/content/10.1101/2020.05.01.20088211v1.full.pdf>. 2020.
39. Jain R, Gupta M, Taneja S & Hemanth DJ. Deep learning based detection and analysis of COVID-19 on chest X-ray images. *Applied Intelligence* 2021; 51(1): 1690-700.
40. Hussain L, Nguyen T, Li H, Abbasi AA, Lone KJ, Zhao Z, et al. Machine-learning classification of texture features of portable chest X-ray accurately classifies COVID-19 lung infection. *Bio Medical Engineering On Line* 2020; 19(1): 88.
41. Wang L, Lin ZQ & Wong A. COVID-Net: A tailored deep convolutional neural network design for detection of COVID-19 cases from chest X-ray images. *Scientific Reports* 2020; 10(1): 19549.
42. Desai SB, Pareek A & Lungren MP. Deep learning and its role in COVID-19 medical imaging. *Intelligence-Based Medicine* 2020; 3-4(1): 100013.
43. Apostolopoulos ID & Mpesiana TA. Covid-19: Automatic detection from X-ray images utilizing transfer learning with convolutional neural networks. *Physical and Engineering Sciences in Medicine* 2020; 43(2): 635-40.



# Classification of Chest Radiology Images in Order to Identify Patients with COVID-19 Using Deep Learning Techniques

Marsa Gholamzadeh<sup>1</sup> (M.S.), Seyed Mohammad Ayyoubzadeh<sup>2</sup> (Ph.D.), Hoda Zahedi<sup>3</sup> (M.S.),  
Sharareh Rostam Niakan Kalhori<sup>4\*</sup> (Ph.D.)

1 Ph.D. Candidate in Medical Informatics, School of Allied Medical Sciences, Tehran University of Medical Sciences, Tehran, Iran

2 Ph.D. in Medical Informatics, School of Allied Medical Sciences, Tehran University of Medical Sciences, Tehran, Iran

3 Master of Sciences Student in Medical Informatics, School of Health Management and Information Sciences, Iran University of Medical Sciences, Tehran, Iran

4 Associate Professor, Department of Health Information Management, School of Allied Medical Sciences, Tehran University of Medical Sciences, Tehran, Iran; Research Fellow at Peter L. Reichertz Institute for Medical Informatics, University of Braunschweig–Institute of Technology and Hannover Medical School, Braunschweig, Germany

## Abstract

Received: Aug 2020

Accepted: May 2021

**Background and Aim:** Due to the important role of radiological images for identifying patients with COVID-19, creating a model based on deep learning methods was the main objective of this study.

**Materials and Methods:** 15,153 available chest images of normal, COVID-19, and pneumonia individuals which were in the Kaggle data repository was used as dataset of this research. Data preprocessing including normalizing images, integrating images and labeling into three categories, train, test and validation was performed. By Python language in the fastAI library based on convolution technique (CNN) and four architectures (ResNet, VGG MobileNet, AlexNet), nine models through transitional learning method were trained to recognize patients from healthy persons. Finally, the performance of these models was evaluated with indicators such as accuracy, sensitivity and specificity, and F-Measure.

**Results:** Of the nine generated models, the ResNet101 model has the highest ability to distinguish COVID-19 cases from other cases with 95.29% sensitivity. Other applied models showed more than 96% accuracy in correctly diagnosis of various cases in test phase. Finally, the ResNet101 model was able to demonstrate 98.4% accuracy in distinguishing between healthy and infected cases.

**Conclusion:** The obtained accuracy showed the accurate performance of developed model in detecting COVID-19 cases. Therefore, by implementing an application based on the developed model, physicians can be helped in accurate and early diagnosis of cases. an application based on the developed model, physicians can be helped in accurate and early diagnosis of infected cases.

**Keywords:** Convolutional Neural Network, Coronavirus, COVID-19, Machine Learning, Deep Learning, Transfer Learning

\* Corresponding Author:  
Rostam Niakan Kalhori Sh  
Email:  
Sh-rniakan@sina.tums.ac.ir