

## استفاده از تکنیک‌های یادگیری عمیق برای تشخیص موارد کووید-۱۹ با استفاده از تصاویر اشعه ایکس قفسه سینه

محمود زارع\*

دانشکده فنی و مهندسی - دانشگاه پیام نور - تهران واحد ری - ری - ایران  
پست الکترونیکی: tellbagh1365@gmail.com

### چکیده

می‌کنیم. همچنین، تجزیه و تحلیل‌های مقایسه‌ای بین این مدل‌ها با در نظر گرفتن چندین عامل مهم مثل اندازه دسته، نرخ یادگیری، تعداد دوره‌ها و نوع بهینه‌سازها با هدف یافتن بهترین مدل مناسب انجام شده‌است. مدل‌ها بر روی تصاویر اشعه ایکس قفسه سینه در دسترس عموم تأیید شده و بهترین عملکرد توسط ResNet-34 با دقت ۹۸,۳۳٪ به‌دست آمده است. این مطالعه برای پژوهشگران مفید خواهد بود تا با طراحی مدل‌های موثرتر از شبکه CNN برای تشخیص زودهنگام کووید-۱۹ تحقیق کنند.

واژه‌های کلیدی: کووید-۱۹، SARS-CoV-2، الگوریتم‌های بهینه‌سازی، شبکه‌های عصبی هم‌آمیخت، اشعه ایکس قفسه سینه.

### ۱- مقدمه

شیوع بیماری کرونا ویروس ۲۰۱۹ (کووید-۱۹) کره زمین را از اوایل دسامبر ۲۰۱۹ تحت فشار فوق‌العاده‌ای قرار داده است. تا به امروز، میلیون‌ها نفر در سراسر جهان به این ویروس آلوده شده‌اند و تقریباً دو میلیون و ششصد هزار مورد مرگ تأیید شده توسط سازمان بهداشت جهانی (WHO) وجود دارد [۱]. این بیماری به دلیل سندرم تنفسی حاد کرونا ویروس 2 (SARS-CoV-2) ایجاد می‌شود و علائم رایج کووید-۱۹ شامل تب، درد عضله، سرفه خشک،

ظهور بیماری کرونا ویروس ۲۰۱۹ (کووید-۱۹) در اوایل دسامبر ۲۰۱۹ آسیب زیادی به سلامتی و رفاه جهانی وارد کرده است. در حال حاضر، میلیون‌ها نفر به این ویروس مبتلا شده‌اند و این ویروس جدید به سرعت در سراسر جهان در حال گسترش است. بسیاری از بیمارستان‌ها در سرتاسر جهان هنوز به مقدار کافی به کیت آزمایش مجهز نشده‌اند و آزمایش واکنش زنجیره‌ای پلیمر از رونویسی معکوس (RT-PCR) زمانبر و دردسرساز است. از این رو طراحی یک سیستم تشخیص خودکار و زودهنگام که بتواند تصمیم‌گیری سریع ارائه دهد و خطای تشخیص را تا حد زیادی کاهش دهد بسیار مهم است. تصاویر اشعه ایکس قفسه سینه همراه با روش‌های نوظهور هوش مصنوعی (AI)، به ویژه الگوریتم‌های یادگیری عمیق (DL) اخیراً به گزینه مناسبی برای غربالگری اولیه کووید-۱۹ تبدیل شده‌اند. در این مقاله یک روش خودکار با کمک DL با استفاده از تصاویر اشعه X برای تشخیص زودهنگام عفونت کووید-۱۹ پیشنهاد شده است. ما اثربخشی هشت مدل شبکه عصبی متحرک (CNN) از پیش آموزش دیده مانند AlexNet، VGG-16، GoogleNet، MobileNet-V2، Inception-V3 و ResNet-50، ResNet-34، SqueezeNet را برای طبقه‌بندی کووید-۱۹ از موارد عادی ارزیابی

\* نویسنده مسئول

سردرد، گلودرد و درد قفسه سینه [۲،۳] و بنابراین، به عنوان یک بیماری تنفسی در نظر گرفته می شود. علائم کامل در فرد آلوده ممکن است حدود ۱۴ روز طول بکشد. در حال حاضر، هیچ درمان یا داروی مشخصی برای بهبود این بیماری در دسترس نیست. با این حال، بهترین روش رایج که در تشخیص کووید-۱۹ استفاده می شود، واکنش زنجیره ای پلیمر از رونویسی معکوس<sup>۱</sup> (RT-PCR) نامیده می شود [۴،۵]. اخیراً مشخص شده است که تکنیک های تصویربرداری پزشکی مانند اشعه ایکس<sup>۲</sup> و توموگرافی کامپیوتری<sup>۳</sup> (CT) نقش مهمی در آزمایش موارد کووید-۱۹ دارند [۶،۷-۸]. از آنجا که ویروس به طور کلی باعث عفونت در ریه ها می شود، تصاویر رادیوگرافی قفسه سینه (تصاویر اشعه ایکس قفسه سینه یا CT) به طور گسترده ای مورد توجه قرار گرفته است [۹] و تفسیر این تصاویر به طور دستی توسط رادیولوژیست ها برای یافتن برخی از شاخص های بصری برای عفونت کووید-۱۹ انجام می شود. این شاخص های بصری می تواند به عنوان یک روش جایگزین برای غربالگری سریع بیماران آلوده باشد.

روند تشخیص متعارف نسبتاً سریع تر شده است اما هنوز هم خطر بالایی برای کادر پزشکی ایجاد می کند. علاوه بر این، هزینه بر است و تعداد محدودی از بسته های تست تشخیصی وجود دارد. از طرف دیگر، روش های تصویربرداری پزشکی (به عنوان مثال، اشعه ایکس و CT) مبتنی بر غربالگری نسبتاً ایمن، سریع تر و به راحتی قابل دسترسی هستند. در مقایسه با تصویربرداری CT، از تصویربرداری اشعه ایکس برای غربالگری کووید-۱۹ بسیار استفاده شده است زیرا به زمان تصویربرداری و هزینه کمتری نیاز دارد، اسکنرهای اشعه ایکس به طور گسترده ای حتی در مناطق روستایی نیز در دسترس هستند [۷،۱۰]. با این حال، بازرسی بصری تصاویر اشعه ایکس توسط رادیولوژیست ها در مقیاس بزرگ تر، زمانبر، دست و پاگیر است و به دلیل عدم دانش قبلی در مورد

مناطق آلوده به ویروس، ممکن است منجر به تشخیص نادرست شود. بنابراین، برای دستیابی به تشخیص سریع تر و دقیق کووید-۱۹، نیاز شدیدی به طراحی روش های خودکار وجود دارد. روش های خودکار اخیر از فناوری های معاصر هوش مصنوعی<sup>۴</sup> (AI) (بیشتر الگوریتم های یادگیری عمیق<sup>۵</sup> (DL)) برای افزایش قدرت تصویربرداری با اشعه ایکس استفاده می کردند و هدف آن کاهش حجم کار رادیولوژیست ها بود [۴]. مدل های DL، به ویژه شبکه های عصبی هم آمیخت<sup>۶</sup> (CNN) نشان داده اند که روش های سنتی AI به طور گسترده ای برای تجزیه و تحلیل تصاویر مختلف پزشکی استفاده شده اند [۱۱-۱۵]. اخیراً، CNN برای شناسایی ذات الریه در تصاویر اشعه ایکس قفسه سینه با موفقیت استفاده شده است [۱۶-۱۹]. اخیراً، مطالعات با استفاده از مدل های DL مربوط به تشخیص کووید-۱۹ از طریق تصاویر اشعه ایکس انجام شده است. به عنوان مثال، اوزترکت و همکاران [۲۰] یک شبکه DL ایجاد کردند که اصطلاحاً DarkCovidNet نام دارد و بر اساس تصاویر اشعه X برای تشخیص خودکار کووید-۱۹ ساخته شده است. این مدل برای موارد چند رده ای (کووید-۱۹، طبیعی و ذات الریه) و دو رده ای (کووید-۱۹ و طبیعی) با دقت بالاتری ۸۷،۰۲٪ و ۹۸،۰۸٪ رسیده است. همدان و همکاران [۲۱] با توجه به تصاویر اشعه ایکس مدل COVIDX-Net را توسعه دادند. از هفت مدل مختلف CNN برای آموزش مدل COVIDX-Net استفاده شده است و مدل در ۵۰ تصویر اشعه ایکس (۲۵ مورد طبیعی و ۲۵ مورد کووید-۱۹) تأیید می شود. وانگ و وونگ [۲۲] یک مدل عمیق CNN طراحی کردند که به عنوان COVID-Net برای تشخیص کووید-۱۹ شناخته می شود که دارای دقت آزمایش ۹۲،۶٪ است. اپوستولوفس و همکاران [۲۳] مجموعه ای از مدل های موجود CNN را برای طبقه بندی موارد کووید-۱۹ ارزیابی کردند و بالاترین دقت آزمایش را ۹۳،۴۸٪ و ۹۸،۷۵٪ برای

4- Artificial Intelligence  
5- Deep Learning  
6- Convolutional Neural Networks


1- Reverse Transcription-Polymerase Chain Reaction  
2- X-ray  
3- Computed Tomography

سه رده دوگانه به دست آورده اند. نارین و همکاران [۲۴] با استفاده از مدل ResNet50، دقت تست ۹۸٪ روی مجموعه داده‌ای از ۱۰۰ تصویر (۵۰ مورد طبیعی و ۵۰ مورد کووید-۱۹) را به دست آوردند. ستی و بهرا [۲۵] با استفاده از عکسبرداری اشعه ایکس قفسه سینه، ویژگی‌های مختلفی را از معماری CNN از قبل آموزش دیده به دست آوردند. ResNet50 همراه با طبقه‌بندی ماشین بردار پشتیبانی (SVM) با استفاده از ۵۰ نمونه (۲۵ مورد طبیعی و ۲۵ مورد کووید-۱۹) بالاترین دقت ۹۵٫۳۸٪ را به دست آورد. توگاکار و همکاران [۲۷] یک روش خودکار برای طبقه‌بندی موارد کووید-۱۹ از موارد طبیعی و ذات‌الریه با استفاده از دو مدل DL (SqueezeNet و MobileNetV2) و طبقه‌بندی SVM طراحی کردند. در ضمن مطالعه، مجموعه داده اصلی با استفاده از تکنیک‌های پشته‌سازی رنگ فازی<sup>۷</sup> قبل از استفاده از مدل‌های DL بازسازی شد. ویژگی‌های به دست آمده توسط مدل‌های DL با استفاده از الگوریتم (SMO)<sup>۸</sup> برای به دست آوردن ویژگی‌های کارآمد پردازش شدند و در نهایت SVM بر روی مجموعه ویژگی‌های ترکیبی اعمال شد. به تازگی، فاروقند حافظ [۲۸] مدل ResNet baed CNN را به نام COVIDResNet برای طبقه‌بندی کووید-۱۹ و سه مورد دیگر (ذات‌الریه طبیعی، باکتریایی و ذات‌الریه ویروسی) ساخته است. آن‌ها دقت ۹۶٫۲۳٪ را نسبت به یک مجموعه داده در دسترس عموم (به عنوان مثال، COVIDx) به دست آوردند. با این حال، فقط ۶۸ نمونه کووید-۱۹ در این مطالعه در نظر گرفته شد. مهم‌ترین چالش در استفاده از مدل‌های DL جمع‌آوری تعداد کافی از نمونه‌ها با حاشیه‌نویسی مناسب برای یادگیری موثر است. مطالعات انجام شده نشان می‌دهد که مدل‌های قبلی با استفاده از تعداد کمی از نمونه‌ها اعتبارسنجی می‌شوند و داده‌ها در بیشتر موارد تعادل ندارند. مدل‌های پیش آموزش دیده‌ای که برای طبقه‌بندی موارد کووید-۱۹ تصویب شده‌اند به‌طور کامل از نظر تجربی بررسی نشده‌اند. علاوه بر این، یک مطالعه جامع مقایسه‌ای در بین مدل‌های CNN از پیش

آموزش دیده هنوز گزارش نشده است. از این‌رو، حوزه‌ای برای انجام یک مطالعه تجربی از مدل‌های مختلف CNN از قبل آموزش دیده وجود دارد که می‌تواند برای دستیابی به بهترین مدل عملکردی که می‌تواند به‌عنوان ابزاری جایگزین برای تشخیص سریع کووید-۱۹ استفاده شود. در این مقاله، یک روش غربالگری خودکار کووید-۱۹ با استفاده از تصاویر اشعه ایکس قفسه سینه را ارائه می‌دهیم. هشت مدل‌های آموزش دیده موفق CNN یعنی VGG-16، AlexNet، GoogleNet، MobileNet-V2، Inception-V3 و SqueezeNet، ResNet-34، ResNet-50 بر اساس مفهوم یادگیری انتقال (TL) مورد توجه قرار گرفته‌اند. با مقایسه چندین عامل از جمله اندازه دسته، میزان یادگیری، تعداد دوره‌ها، طبقه‌بندی نادرست و نوع تکنیک‌های بهینه‌سازی، یک تحلیل تطبیقی در بین همه این مدل‌ها انجام شده است و در نهایت، بهترین مدل عملکرد به دست آمده و با روش‌های پیشرفته مقایسه شده است. با استفاده از تعداد بیشتری عکس اشعه ایکس قفسه سینه که از مجموعه داده‌های covidchestxray [۲۹] و ChestX-ray8 [۳۰] جمع‌آوری شده است، اعتبارسنجی شده است. برای کاهش مشکل کمبود داده و عدم تعادل داده‌ها، یک تکنیک تکثیر برون‌خط در چند مقیاس و متعادل‌سازی داده‌ها و نرمال‌سازی آن به تصویب رسیده است. مقایسه مدل پیشنهادی با سایر روش‌های پیشرفته در زمینه حساسیت زیاد به رده کووید-۱۹ انجام شده است. مدل پیشنهادی برای تشخیص کووید-۱۹ به راحتی قابل اجرا است، معماری پایان کار را بدون نیاز به مهندسی ویژگی دستی دنبال می‌کند و می‌تواند به رادیولوژیست‌ها برای تشخیص دقیق و پایدار عفونت کووید-۱۹ کمک کند. سهم عمده این تحقیق پیشنهادی را می‌توان به شرح زیر تشریح کرد:

اثر بخشی هشت مدل کارآمد و مؤثر CNN عمیق، یعنی VGG-16، Inception-V3، ResNet-34، MobileNet-V2، AlexNet، GoogleNet، ResNet-50 و SqueezeNet به‌طور جامع مقایسه شده است. تأثیر بیش از حد پارامترهای مختلف مانند میزان یادگیری، اندازه دسته، تعداد دوره‌ها

7- Fuzzy Color and Stacking  
8- SocialMimic Optimization



شکل ۱: نمونه‌هایی از تصاویر اشعه ایکس قفسه سینه با نمای جلو از مجموعه داده: (الف) مورد کووید-۱۹ و (ب) حالت عادی.

طبیعی و کووید-۱۹ در شکل ۱ نشان داده شده است. از آنجا که اطلاعات مربوط به تقسیم داده واقعی در مجموعه داده‌ها ارائه نشده است، ۷۰٪ از داده‌ها برای آموزش و ۳۰٪ باقیمانده برای آزمایش استفاده شد که منجر به ۲۸۶ تصویر (۱۴۳ کووید-۱۹ و ۱۴۳ مورد عادی) در مجموعه آموزش و ۱۲۰ تصویر (۶۰ کووید-۱۹ و ۶۰ مورد طبیعی) در مجموعه آزمون شد.

## ۲-۲- روش پیشنهادی

مدل پیشنهادی برای تشخیص خودکار موارد کووید-۱۹ در شکل ۲ نشان داده شده است. هدف این مدل طبقه‌بندی یک تصویر Xray سینه مشخص به دسته عادی یا کووید-۱۹ است که شامل دو مرحله حیاتی است: پیش پردازش (عادی‌سازی و افزایش) و طبقه‌بندی با استفاده از معماری‌های CNN از قبل آموزش دیده. شرح هر مرحله در بخش‌های بعدی به تفصیل آورده شده است.

### ۲-۲-۱ پیش پردازش

این بخش شرح مفصلی از روش‌های استفاده شده در مرحله پیش پردازش را بیان می‌کند.

نرمال‌سازی: نرمال‌سازی داده‌ها یک مرحله اساسی است و به‌طور کلی برای حفظ ثبات عددی در معماری CNN استفاده می‌شود. با نرمال‌سازی، یک مدل CNN سریع‌تر یاد می‌گیرد و شیب نزولی احتمالاً پایدار خواهد بود [۳۱]. بنابراین، در این مطالعه، مقادیر پیکسل تصاویر ورودی در محدوده ۰-۱ نرمال شده است. تصاویر مورد استفاده در مجموعه داده‌های در نظر گرفته شده، تصاویر در مقیاس خاکستری هستند و با ضرب ۲۵۵/۱ با مقادیر


و تکنیک‌های بهینه‌سازی مورد مطالعه قرار گرفته است. سرانجام، بهترین مدل استخراج می‌شود که برای محققان مفید خواهد بود تا یک راه حل کارآمدتر مبتنی بر CNN برای تشخیص زود هنگام عفونت کووید-۱۹ طراحی کنند. داده‌ها در مجموعه داده‌های موجود در دسترس، محدود و نامتعادل هستند. برای غلبه بر این، در حالی که نمونه‌ها را برای هر دو رده کووید-۱۹ و عادی متعادل می‌کنیم، عمل تقسیم داده چند منظوره را انجام دادیم. ساختار باقیمانده مقاله به شرح زیر است. بخش ۲ توصیف نمونه‌های مورد استفاده برای اعتبارسنجی مدل‌های مختلف CNN و توصیف مدل خودکار پیشنهادی برای شناسایی کووید-۱۹ است. نتایج و مقایسه‌ها در بخش ۳ ارائه شده است.

## ۲- مواد و روش

در این بخش، شرح مفصلی از روش پیشنهادی طراحی شده برای تشخیص کووید-۱۹ و داده‌های استفاده شده برای اعتبارسنجی مدل پیشنهادی را ارائه می‌دهیم.

### ۲-۱ مجموعه داده

برای تأیید روش پیشنهادی، تصاویر اشعه ایکس قفسه سینه از دو منبع مختلف جمع‌آوری شده است. مجموعه داده (covid-chestxray - مجموعه داده) [۲۹] تهیه شده توسط کوهن JP برای جمع‌آوری تصاویر اشعه ایکس کووید-۱۹ استفاده شده است که تصاویر را از منابع مختلف باز در نظر گرفته و به‌طور منظم به‌روز می‌شود. در حالی که تصاویر اشعه ایکس قفسه سینه از طبقه نرمال از یک مخزن GitHub1 که شامل ۵۰۰ تصویر انتخاب شده از مجموعه داده ChestX-ray8 جمع‌آوری شده است [۳۰]. در آزمایش ما، ۲۰۳ عکس اشعه ایکس قفسه سینه با نمای پیشانی کووید-۱۹ از مجموعه داده covid-chestxray انتخاب شده است. برای مقابله با مشکل عدم تعادل داده‌ها، همین ۲۰۳ عکس اشعه ایکس قفسه سینه از ریه‌های سالم از نظر جلویی به‌طور تصادفی از [۳۰] انتخاب شده است. نمونه‌ای از تصاویر اشعه ایکس قفسه سینه از هر دو رده



شکل ۲: بررسی اجمالی روش تشخیص خودکار کووید-۱۹ با استفاده از تصاویر اشعه ایکس قفسه سینه با نمای جلو.

## ۲-۲-۲- پیش‌بینی کووید-۱۹ با استفاده از مدل‌های

### CNN از پیش آموزش دیده

ثابت شده است که مدل‌های CNN در طیف وسیعی از کاربردهای پردازش تصویر پزشکی نتایج برتری دارند. با این حال، آموزش این مدل‌ها از ابتدا به دلیل محدودیت در دسترس بودن نمونه‌های اشعه X برای پیش‌بینی موارد کووید-۱۹ دشوار است. استفاده از مدل‌های از پیش آموزش دیده با استفاده از مفهوم یادگیری انتقال<sup>۹</sup> (TL) در چنین شرایطی می‌تواند مفید باشد. در TL، دانش حاصل از یک مدل DL آموزش دیده از یک مجموعه داده بزرگ برای حل یک کار مرتبط با یک مجموعه داده نسبتاً کوچکتر استفاده می‌شود. این امر در از بین بردن نیاز برای یک مجموعه داده بزرگ و زمان یادگیری طولانی‌تر طبق روش DL که از ابتدا آموزش داده می‌شوند، کمک می‌کند [۱۱، ۳۲، ۳۳]. در این مطالعه، هشت مدل قبل از آموزش مانند AlexNet [۳۴]، VGG-16 [۳۵]، GoogleNet [۳۶]، Mo-biNet-V2 [۳۷]، SqueezeNet [۳۸]، ResNet-34 [۳۹]، ResNet-50 [۳۹] و Inception-V3 [۴۰] برای طبقه‌بندی کووید-۱۹ از موارد عادی استفاده شده است. این شبکه‌ها در طیف گسترده‌ای از مشکلات بینایی و تجزیه و تحلیل تصویر پزشکی رایانه به موفقیت چشمگیری دست یافته‌اند و از این رو در این مطالعه برای تشخیص عفونت کووید-۱۹ از موارد عادی انتخاب شده‌اند. در اینجا شایان ذکر است که این مدل‌ها در ابتدا بر روی مجموعه داده‌ای با برچسب در مقیاس بزرگ به نام ImageNet [۳۴] آموزش داده شدند و

پیکسل، بازسازی مجدد حاصل می‌شود.

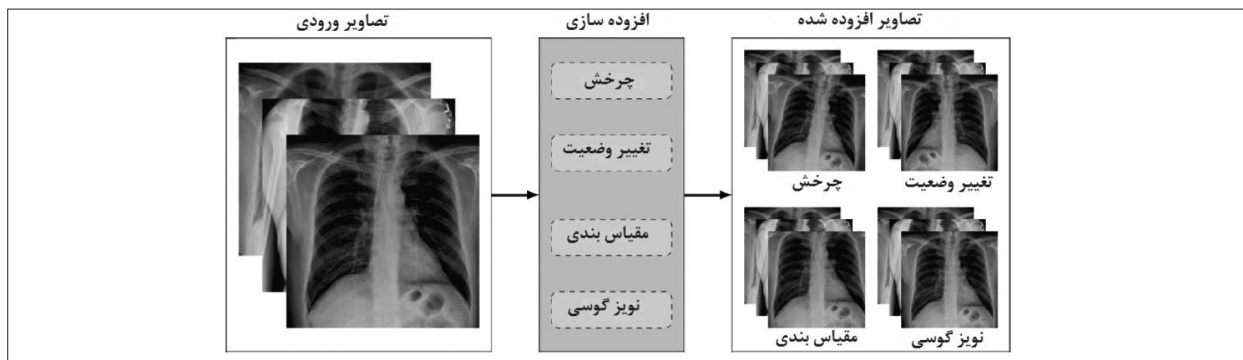
داده‌افزایی: مدل‌های CNN برای آموزش مؤثرتر به مقدار زیادی داده نیاز دارند و نشان داده‌اند که در مجموعه داده‌های بزرگتر عملکرد بهتری دارند [۱۱، ۱۳]. با این حال، تصاویر آموزش اشعه ایکس موجود در مجموعه داده در نظر گرفته شده بسیار کمتر است (به عنوان مثال، ۲۸۶ عکس اشعه ایکس). این مسئله در هنگام انجام تجزیه و تحلیل تصاویر پزشکی با استفاده از الگوریتم‌های DL یکی از نگرانی‌های عمده بوده است زیرا جمع‌آوری اطلاعات پزشکی کار سختی است. برای مقابله با این مشکل، روش افزایش داده به‌طور گسترده‌ای استفاده شده است که به شما در گسترش تعداد تصاویر با استفاده از مجموعه‌ای از تحولات و حفظ برچسب‌های کلاس کمک می‌کند [۳۲]. تکنیک‌های اتخاذ شده در این مطالعه برای افزایش تصاویر آموزشی در شکل ۳ نشان داده شده است. تصاویر با استفاده از تکنیک‌های زیر افزوده می‌شوند (۱) تصاویر با زاویه ۵ درجه در جهت عقربه‌های ساعت چرخانده می‌شوند، (۲) تصاویر با اندازه گیری ۱۵٪ مقیاس‌بندی می‌شوند، (۳) تصاویر به صورت افقی انجام می‌شوند و (۴) تصاویر نوبه‌گوسی با میانگین صفر و واریانس ۰/۲۵ اضافه می‌شوند. شایان ذکر است که تمام این تکنیک‌ها بر روی نمونه‌های آموزشی به کار رفته‌اند و نتایج مثال هر یک از تکنیک‌ها در شکل ۴ نشان داده شده است. سرانجام، یک مجموعه آموزش بزرگتر حاوی ۱۴۳۰ تصویر به دست آمد که ۵ برابر بیشتر از تصاویر آموزش تئوریک است.

بعداً بر روی تصاویر اشعه ایکس قفسه سینه تنظیم شدند. لایه TheLast در این مدل‌ها برداشته شده و یک لایه جدید کاملاً متصل (FC) با اندازه خروجی دو وارد شده است که نشان دهنده رده‌های دوقلو (طبیعی و کووید-۱۹) است. در این مدل‌های به دست آمده، فقط لایه نهایی FC آموزش داده می‌شود، در حالی که سایر لایه‌ها با وزنه‌های آموزش دیده اولیه شروع می‌شوند. ابرپارامترها برای تنظیم این مدل‌های DL نقش اساسی دارند و برای ایجاد یک مقایسه منصفانه ثابت نگه داشته می‌شوند. جزئیات تنظیمات پارامتر در بخش ۳،۱ بحث شده است. بررسی اجمالی معماری مدل‌های از پیش آموزش دیده CNN در جدول ۱ آورده شده است و اجزای اصلی هر شبکه در شکل ۵ نشان داده شده است. AlexNet شامل پنج لایه هم‌آمیخت و سه لایه FC است و بیش از ۱،۲ میلیون تصویر از ۱۰۰۰ مقوله آموزش دیده است [۲۴]. فعال‌سازی ReLU در این شبکه استفاده می‌شود. اولین و دومین لایه‌های FC دارای ۴۰۹۶ نورون هستند، در حالی که لایه نهایی FC دارای ۱۰۰۰ نورون است. در شبکه VGG-16، تعداد لایه‌های افزایش یافته به عنوان مثال، ۱۳ لایه هم‌آمیخت و سه لایه FC وجود دارد [۳۵]. فیلترهای این شبکه به  $3 \times 3$  با قدم زدن و پر کردن ۱ محدود می‌شوند. این مدل بیش از یک میلیون تصویر از ۱۰۰۰ دسته را آموزش دیده است. SqueezeNet عملکرد بهتری نسبت به AlexNet با پارامترهای نسبتاً کمتری دارد [۳۸]. این یک لایه هم‌آمیخت در آغاز و انتهای آن است و دارای هشت ماژول آتش در این بین است. ResNet-34 یک شبکه باقیمانده عمیق است و بر اساس مفهوم یادگیری باقیمانده طراحی شده است [۳۹]. این شامل یک هم‌آمیز مستقل و ۱۶ پسماند باقیمانده و به دنبال آن یک لایه FC است. این شبکه با معرفی اتصالات باقیمانده به‌طور عمده بر مشکل تخریب غلبه می‌کند. ResNet-50 نوع دیگری از ResNet است که از همان تعداد بلوک باقیمانده همانند ResNet-34 تشکیل شده است، اما ساختار بلوک باقیمانده متفاوت است [۳۹]. مدل ResNet-50 جایگزین هر بلوک باقیمانده دو لایه ResNet-34 با یک محفظه گلوگاه

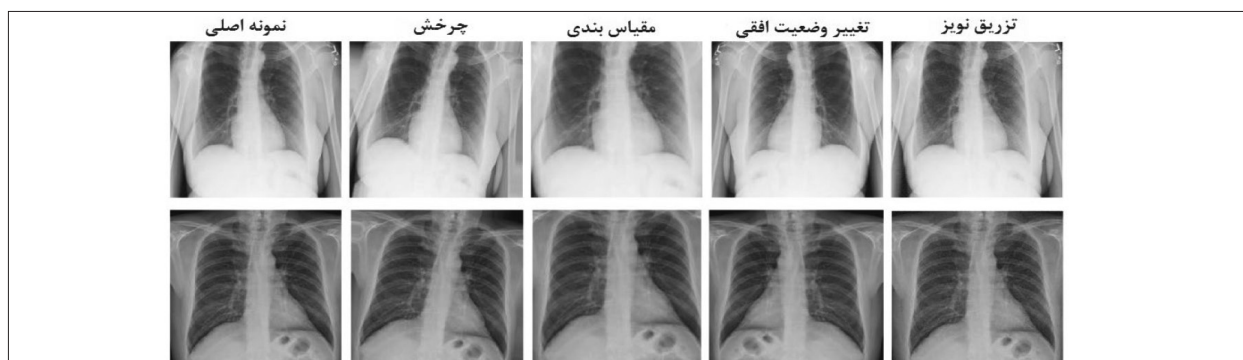
سه لایه می‌شود که از پیچیدگی‌های  $1 \times 1$  استفاده می‌کند. GoogleNet یک معماری عمیق ۲۲ لایه با ۵ میلیون پارامتر است که به‌طور قابل توجهی از پارامترهای استفاده شده در مدل‌های AlexNet و VGG است [۳۶]. ماژول آغازین پایه اصلی این مدل است که به پردازش همزمان فیلتر کردن چندین فیلتر کمک می‌کند. Inception-V3 یکی از انواع Inception-V2 است و از تنگناهای نمایندگی جلوگیری می‌کند [۴۰]. این با استفاده از تکنیک‌های عامل‌سازی از رایانه‌های موثرتری برخوردار است و در مقایسه با انواع قبلی آن به نرخ کمتری دست می‌یابد. این شبکه شامل ۴۲ لایه با اندازه تصویر ورودی  $299 \times 299$  است. MobileNet-V2 بر اساس ایده‌های MobileNet-V1 طراحی شده است که از پیچیدگی قابل تفکیک عمق به‌عنوان بلوک‌های ساختاری کارآمد استفاده می‌کند. اما، این نسخه ماژول لایه جدیدی را معرفی می‌کند که باقیمانده معکوس با گلوگاه خطی است [۳۷]. این یک معماری کوچک و مقرون به صرفه است که در دستیابی به عملکرد بالا با منابع محدود کمک می‌کند. دارای ۱۹ لایه گلوگاه باقی مانده است. هدف اصلی این تحقیق تعیین بهترین مدل DL برای غربالگری کووید-۱۹ است که می‌تواند محققان را به سمت توسعه راه‌حل‌های مبتنی بر AI موثرتر سوق دهد.

### ۳- آزمایش‌ها و نتایج

این بخش، نتایج حاصل از چندین آزمایش را ارائه می‌دهد. ما یک تجزیه و تحلیل تجربی جامع برای پیش‌بینی کووید-۱۹ از تصاویر اشعه X با استفاده از هشت مدل CNN از قبل آموزش دیده، یعنی، VGG-16، AlexNet، GoogleNet، MobileNet-V2، Squeezenet، ResNet-34، ResNet-50 و Inception-V3 انجام دادیم. تأثیر چند پارامتر مربوط به این مدل‌ها را تحلیل کردیم و تجزیه و تحلیل مقایسه‌ای را در بین هشت مدل CNN انجام دادیم. در آخر، بهترین مدل اجرا به دست می‌آید. همچنین نتایج را با رویکردهای پیشرفته اخیر مقایسه کردیم.



شکل ۳: نمایش تکنیک‌های مختلف داده افزایی که در این تحقیق استفاده شده است



شکل ۴: نتایج نمونه داده افزایی

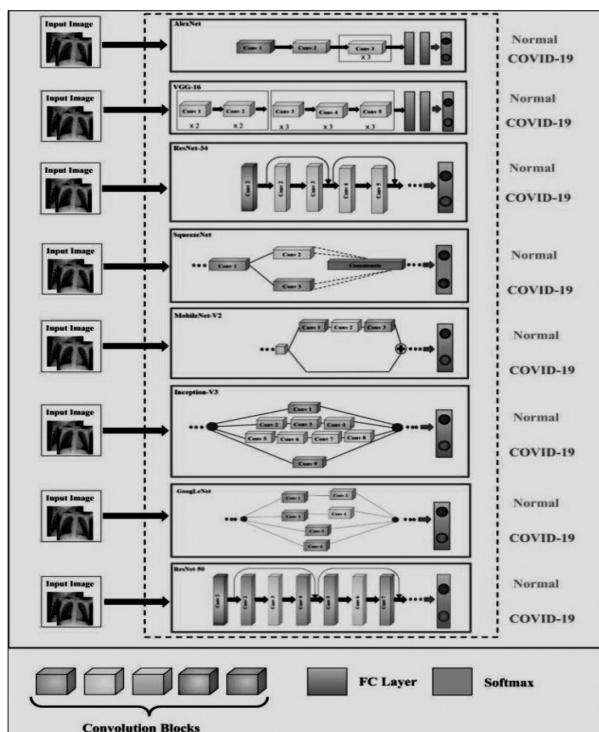
جدول ۱: توصیفات معماری از مدل‌های CNN از پیش آموزش دیده استفاده شده در این تحقیق

مدل	لایه‌ها	پارامترها (در میلیون)	اندازه لایه ورودی	اندازه لایه خروجی
AlexNet	۸	۶۰	(۲۲۴،۲۲۴،۳)	(۲،۱)
VGG-16	۱۶	۱۳۸	(۲۲۴،۲۲۴،۳)	(۲،۱)
GoogleNet	۲۲	۵	(۲۲۴،۲۲۴،۳)	(۲،۱)
MobileNet-V2	۵۳	۳،۴	(۲۲۴،۲۲۴،۳)	(۲،۱)
SqueezeNet	۱۸	۱،۲۵	(۲۲۴،۲۲۴،۳)	(۲،۱)
ResNet-34	۳۴	۲۱،۸	(۲۲۴،۲۲۴،۳)	(۲،۱)
ResNet-50	۵۰	۲۵،۶	(۲۲۴،۲۲۴،۳)	(۲،۱)
Inception-V3	۴۲	۲۴	(۲۹۹،۲۹۹،۳)	(۲،۱)

است. پس از انجام افزایش روی تصاویر آموزشی، ۱۴۳۰ تصویر اشعه ایکس به دست آمده است که با استفاده از نسبت تقسیم ۷۰٪ و ۳۰٪ به قطار و اعتبارسنجی تقسیم شده و بدین ترتیب، در نتیجه ۱۰۰۲ تصویر آموزش و ۴۲۸ تصویر اعتبارسنجی نشان داده شده است که در جدول ۲ نشان داده شده است. مجموعه اعتبارسنجی برای جلوگیری از نصب بیش از حد مدل و به دست آوردن یک مدل بهینه استفاده شده است. تصاویر اشعه X ورودی هنگام استفاده از AlexNet، VGG-16، GoogleNet،

### ۳-۱ راه‌اندازی آزمایشی و معیارهای عملکرد مورد استفاده

مدل‌های CNN با استفاده از نمونه‌های اشعه ایکس قفسه سینه جمع‌آوری شده از مجموعه داده COVID-19 chestxray [۲۹] و مجموعه داده ChestX-ray8 [۳۰] مورد ارزیابی قرار گرفتند. جزئیات تقسیم داده‌های مورد استفاده در مطالعه ما با و بدون افزایش در جدول ۲ نشان داده شده است. نمونه‌های تقویت شده برای تقویت مدل استفاده شده



شکل ۵. تصویر اجزای اصلی هشت مدل CNN از پیش آموزش دیده. بلوک‌های هم آمیخت با رنگ‌های مختلف فیلترهای اندازه مختلف را نشان می‌دهند

رده کووید-۱۹ برای هر دو مدل ResNet به‌طور چشمگیری بالاتر است (یعنی ۱۰۰٪). شبکه AlexNet دومین بهترین عملکرد برای پیش‌بینی کووید-۱۹ است که دارای دقت ۹۶٫۷۲، حساسیت ۹۸٫۳۳، ویژگی ۹۶٫۶۷، F1 نمره ۰٫۹۷۵۲، دقت ۹۷٫۵۰ و AUC ۰٫۹۶۴۲ است.

۲-۳-۱ مقایسه نتایج با روش‌های مختلف بهینه‌سازی بهینه‌ساز آدام [۴۳] برای آموزش آموزش همه شبکه‌ها انتخاب شده است. برای ارزیابی اثربخشی، نتایج آن با سایر روش‌های بهینه‌سازی کارآمد مانند SGD [۴۴]، Adadelta [۴۵] و RMSProp [۴۶] مقایسه شد. جدول ۴ نتایج طبقه‌بندی بهینه‌سازهای مختلف را برای دو مدل مختلف CNN متفاوت و با بهترین عملکرد مانند ResNet-34 و AlexNet ذکر کرده است. نتایج حاصل از مجموعه آزمون محاسبه شده است. مشاهده می‌شود که بهینه‌ساز آدام نسبت به سایر روش‌های بهینه‌سازی رقابتی عملکرد بهتری دارد.

### ۲-۳-۲ انتخاب نرخ یادگیری بهینه

برای تعیین میزان یادگیری مطلوب برای همه شبکه‌ها، نمودار بین نرخ یادگیری مختلف ممکن و افت اعتبار،

جدول ۲: جزئیات تقسیم داده‌ها با و بدون افزایش.

رده	مجموعه داده اصلی		مجموعه داده افزوده شده		
	آموزش	تست	آموزش	اعتبارسنجی	تست
کووید-۱۹	۱۴۳	۶۰	۵۰۱	۲۱۴	۶۰
نرمال	۱۴۳	۶۰	۵۰۱	۲۱۴	۶۰
جمع	۲۸۶	۱۲۰	۱۰۰۲	۴۲۸	۱۲۰

ResNet-50، ResNet-34، SqueezeNet، MobileNet-V2، استفاده از Inception-V3، به ۲۲۹ × ۲۲۹ تغییر یافتند. ما الگوریتم‌های خود را با استفاده از جعبه ابزار PyTorch پیاده‌سازی کردیم. برای TL، اندازه‌های دسته‌ای ۳۲ عنوان شده است. هر مدل برای ۵۰ دوره آموزش دیده است. اندازه دسته و تعداد دوره‌ها به صورت تجربی تعیین شده است. آموزش‌ها با استفاده از بهینه‌ساز آدام انجام شده و به‌طور تجربی میزان یادگیری تصمیم گرفته شده است. عملکرد هر مدل بر اساس معیارهای مختلف مانند نمره F1، ویژگی (Spe)، حساسیت (Sen)، دقت (Pre)، دقت (Acc) و منطقه تحت منحنی ROC (AUC) ارزیابی شد. این معیارها توسط پارامترهای مختلف ماتریس سردرگمی مانند مثبت واقعی (TP)، مثبت کاذب (TN)، True Negative (TN)، False Negative (FN) محاسبه شدند [۴۱، ۴۲].

### ۲-۳ نتایج

ماتریس‌های گیج‌کننده هر هشت مدل CNN روی داده‌های آزمایش در شکل ۶ ارائه شده است. می‌توان مشاهده کرد که روش پیشنهادی ما با ResNet-34 و ResNet-50 می‌تواند تمام موارد عفونت کووید-۱۹ را به‌طور دقیق طبقه‌بندی کند. منحنی‌های ROC تمام مدل‌ها در شکل ۷ نشان داده شده است. نتایج طبقه‌بندی دقیق به‌دست آمده از همه شبکه‌ها از نظر معیارهای مختلف مقایسه می‌شود و در جدول ۳ جدول‌بندی شده است. ملاحظه می‌شود که مدل ResNet-34 با دقت ۹۶٫۷۷٪، ویژگی ۹۶٫۶۷٪، F1-۹۸٫۹۸۰، امتیاز ۹۸٫۳۳٪، و AUC ۰٫۹۸۳۶ بالاترین عملکرد را به‌دست آورد. همچنین، توجه شده است که حساسیت به‌دست آمده برای



جدول ۳: مقایسه نتایج طبقه‌بندی هر هشت مدل CNN

مدل	(%) Pre	(%) Sen	(%) Spe	F1-score	(%) Acc	AUC
ResNet-34	۹۶.۷۷	۱۰۰.۰۰	۹۶.۶۷	۰.۹۸۳۶	۹۸.۳۳	۰.۹۸۳۶
ResNet-50	۹۵.۲۴	۱۰۰.۰۰	۹۵.۰۰	۹۷.۵۶	۹۷.۵۰	۰.۹۷۳۱
GoogleNet	۹۶.۶۷	۹۶.۶۷	۹۶.۶۷	۰.۹۶۶۷	۹۶.۶۷	۰.۹۶۹۶
VGG-16	۹۵.۰۸	۹۶.۶۷	۹۵.۰۰	۰.۹۵۸۷	۹۵.۸۳	۰.۹۴۸۷
AlexNet	۹۶.۷۲	۹۸.۳۳	۹۶.۶۷	۰.۹۷۵۲	۹۷.۵۰	۰.۹۶۴۲
MobileNet-V2	۹۸.۲۴	۹۸.۳۳	۹۸.۳۳	۰.۹۵۷۳	۹۵.۸۳	۰.۹۵۰۶
Inception-V3	۹۶.۳۶	۸۸.۳۳	۹۶.۶۷	۰.۹۲۱۷	۹۲.۵۰	۰.۹۳۴۲
SqueezeNet	۹۸.۲۷	۹۵.۰۰	۹۸.۳۳	۰.۹۶۶۱	۹۶.۶۷	۰.۹۷۰۵

جدول ۴: مقایسه عملکرد طبقه‌بندی (در %) در بین بهینه‌سازهای مختلف

مدل	بهینه‌ساز	(%) Pre	(%) Sen	(%) Spe	F1-score	(%) Acc
ResNet-34	SGD	۹۵.۰۰	۱۰۰.۰۰	۹۵.۲۴	۰.۹۷۴۰	۹۷.۵۰
	Adadelta	۹۵.۰۰	۹۳.۴۴	۹۴.۹۲	۰.۹۴۲۰	۹۴.۱۷
	RMSProp	۹۶.۶۷	۹۸.۳۱	۹۶.۷۲	۰.۹۷۴۸	۹۷.۵۰
	Adam	۹۶.۷۷	۱۰۰.۰۰	۹۶.۶۷	۰.۹۸۳۶	۹۸.۳۳
AlexNet	SGD	۹۸.۳۳	۹۳.۶۵	۹۸.۲۵	۰.۹۵۹۳	۹۵.۸۳
	Adadelta	۹۱.۶۷	۹۳.۲۲	۹۱.۸۰	۰.۹۲۴۰	۹۲.۵۰
	RMSProp	۹۵.۰۰	۹۸.۲۸	۹۵.۱۶	۰.۹۶۶۱	۹۶.۶۷
	Adam	۹۶.۷۲	۹۸.۳۳	۹۶.۶۷	۰.۹۷۵۲	۹۷.۵۰

۹ نشان داده شده است. طبقه‌بندی نادرست احتمالاً به دلیل ویژگی‌های تصویربرداری مشابه بین موارد عفونت طبیعی و کووید-۱۹ رخ داده است.

### ۳-۳- مقایسه با روش‌های پیشرفته

نتایج به دست آمده توسط بهترین مدل CNN با روش‌های پیشنهاد شده DL برای تشخیص خودکار کووید-۱۹ با استفاده از تصاویر اشعه X در جدول ۶ مقایسه شده است. می‌توان مشاهده کرد که روش پیشنهادی عملکرد بالاتری نسبت به سایر طرح‌های موجود به دست می‌آورد.

### ۳-۴ بحث

مطالعه تصاویر اشعه ایکس قفسه سینه برای پیش‌بینی دقیق عفونت کووید-۱۹ از زمان انتشار مجموعه داده توسعه یافته توسط کوهن توجه زیادی را به خود جلب

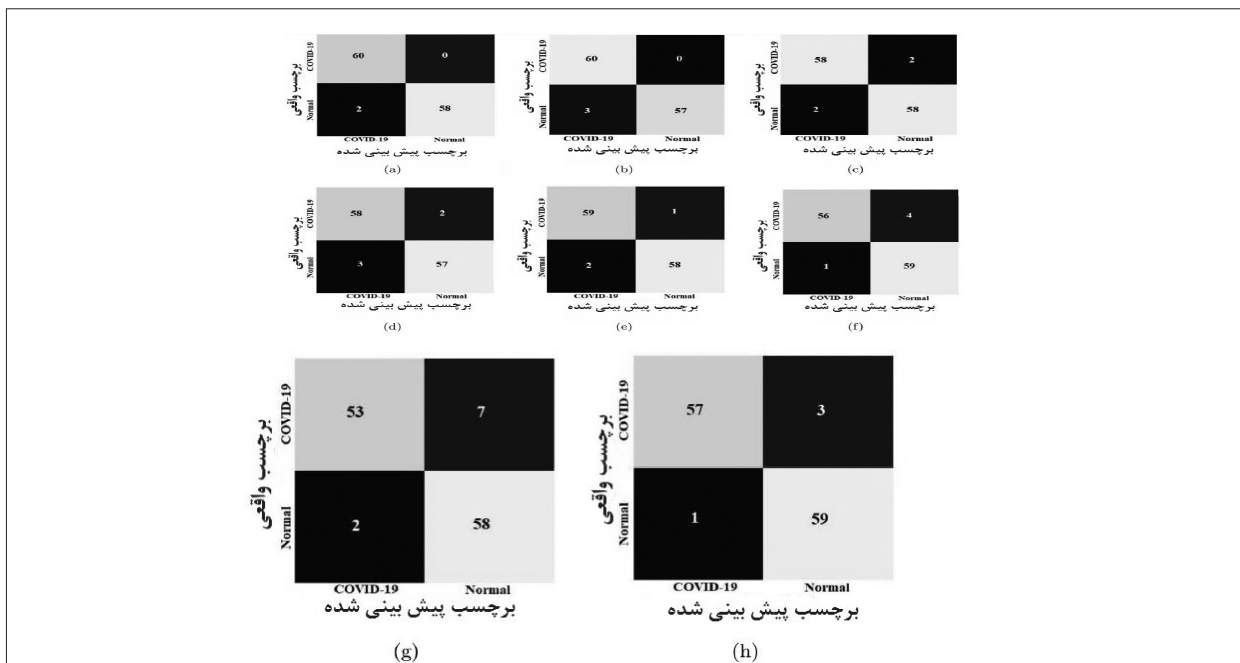
همان‌طور که در شکل ۸ نشان داده شده است، رسم شده است. بهترین نرخ یادگیری یک مدل براساس حداقل ضرر انتخاب شده است.

### ۳-۲-۳ مقایسه نتایج با اندازه‌های دسته‌ای مختلف

در این آزمایش، تأثیر اندازه دسته‌ای بر دقت تست مورد بررسی قرار می‌گیرد. جدول ۵ دقت آزمون همه شبکه‌ها را نشان می‌دهد که هنگام استفاده از اندازه‌های دسته‌ای مختلف مانند ۸، ۱۶ و ۳۲ آموزش دیده شده است. می‌توان مشاهده کرد که برای همه مدل‌های شبکه با اندازه دسته ۳۲ و از این دست، اندازه دسته ۳۲ در این آزمایش عملکرد آزمایش بالاتر و پایداری به دست آمده است.

### ۳-۲-۴ تجزیه و تحلیل نتایج طبقه‌بندی نادرست

نمونه‌های طبقه‌بندی نادرست که توسط دو مدل CNN با بهترین عملکرد پیش‌بینی شده است: و AlexNet در شکل



شکل ۶. ماتریس‌های درهم ریختگی برای مدل‌های مختلف CNN به دست آمده:

a) ResNet-34, (b) ResNet-50, (c) GoogleNet, (d) VGG-16, (e) AlexNet, (f) MobileNet-V2, (g) Inception-V3, and (h) SqueezeNet

جدول ۵: دقت تست (درصد) به دست آمده توسط مدل‌های CNN آموزش دیده با اندازه‌های دسته‌های مختلف

مدل	اندازه دسته		
	۸	۱۶	۳۲
ResNet-34	۹۸,۳۳	۹۸,۳۳	۹۸,۳۳
ResNet-50	۹۶,۶۷	۹۷,۵۰	۹۷,۵۰
GoogleNet	۹۵,۸۳	۹۵,۸۳	۹۶,۶۷
VGG-16	۹۶,۶۷	۹۵,۸۳	۹۵,۸۳
AlexNet	۹۶,۶۷	۹۶,۶۷	۹۷,۵۰
MobileNet-V2	۹۵,۰۰	۹۶,۶۷	۹۵,۸۳
Inception-V3	۹۲,۵۰	۹۱,۶۷	۹۲,۵۰
SqueezeNet	۹۶,۶۷	۹۵,۸۳	۹۶,۶۷

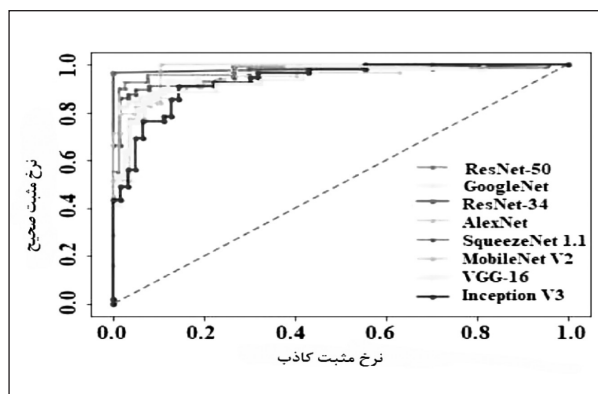
برای هر دو گروه انتخاب شده است. نتایج تجربی و تجزیه و تحلیل مقایسه‌ای دقیق در بین همه روش‌ها برتری مدل‌های ResNet را نشان داد. دقت و حساسیت ۹۸,۳۳٪ و ۱۰۰,۰۰٪ با شبکه ResNet-34 به دست آمد. این مدل مقرون به صرفه است و می‌تواند به رادیولوژیست کمک کند تا تصمیم‌های خود را تأیید کند. هدف اصلی این تحقیق تصمیم‌گیری سریع در مورد قرنطینه بیماران است که در نهایت می‌تواند به کاهش شیوع عفونت کووید-۱۹ کمک کند. ضعف عمده مطالعه پیشنهادی این است که با استفاده از مقدار محدودی

کرده است [۲۹]. پس از آن، چندین کار برای ایجاد یک مدل تشخیص قابل اعتماد با استفاده از تکنیک‌های DL انجام شده است. مفهوم یادگیری انتقال (TL) به‌طور گسترده‌ای در شبکه‌های مبتنی بر CNN استفاده شده است. با این حال، بسیاری از روش‌های قبلی با استفاده از تعداد محدودی از داده‌ها مورد ارزیابی قرار گرفتند. با این حال، بسیاری از روش‌های قبلی با استفاده از مقدار محدودی از داده‌ها ارزیابی شد. به‌علاوه، در برخی موارد، داده‌ها نامتعادل هستند. در این مطالعه، اثربخشی هشت مدل موثر CNN مانند، MobileNet-V2، VGG-16، AlexNet، ResNet-34، Squeezenet و Inception-V3 را برای پیش‌بینی عفونت‌های کووید-۱۹ در تصاویر اشعه ایکس ارزیابی کرده‌ایم. آزمایش‌های گسترده‌ای با در نظر گرفتن چندین عامل برای تعیین بهترین مدل برای غربالگری خودکار کووید-۱۹ بر روی یک مجموعه داده نسبتاً بزرگ انجام شد. تصاویر اشعه ایکس کووید-۱۹ و تصاویر اشعه ایکس طبیعی به ترتیب از دو منبع [۲۹] و [۳۰] گرفته شده‌اند. برای رسیدگی به مسئله عدم تعادل داده‌ها، داده‌های یکسانی

جدول ۶: مقایسه با پیشرفته ترین روش های تشخیص کووید-۱۹ با استفاده از تصاویر اشعه ایکس قفسه سینه

منبع	روش	کلاس ها	تعداد نمونه های اشعه ایکس	Acc (%)
Hemdan et al. [21]	COVIDX-Net	کووید-۱۹ Normal	50 25 N:، 25 C :	90.00
Narin et al. [24]	ResNet-50	کووید-۱۹ Normal	100 50 N:، 50 C :	98.00
Sethy and Behera [25]	ResNet-50 and SVM	کووید-۱۹ Normal	50 25 N:، 25 C :	95.38
Toğaçar et al. [27]	SqueezeNet and MobileNetV2SMO and SVM	کووید-۱۹ Normal Pneumonia	458 98 P: ،65 N:، 298C :	98.25
Wang and Wong [22]	COVID-Net	کووید-۱۹ Normal Pneumonia	13800 - P:،- N:، 183C :	92.60
Ucar and Korkmaz [26]	Bayes-SqueezeNet	کووید-۱۹ Normal Pneumonia	5949 4290P:،1583 N:،76C:	98.30
[28]Farooq and Hafeez	COVID-ResNet	کووید-۱۹ Normal Bacterial pneumonia pneumonia Viral	5941 -VP:،-BP:،- N:،68C:	96.23
Ozturk et al. [20]	DarkCovidNet	کووید-۱۹ Normal کووید-۱۹ Normal Pneumonia	625 500 N:،125C: 1125 500P:،500 N:،125C:	98.08 87.02
Proposed method	ResNet-34	کووید-۱۹ Normal	406 203 N:،203C:	98.33

N: Normal, P: Pneumonia, BP: Bacterial pneumonia, VP: Viral pneumonia , کووید-۱۹ :C



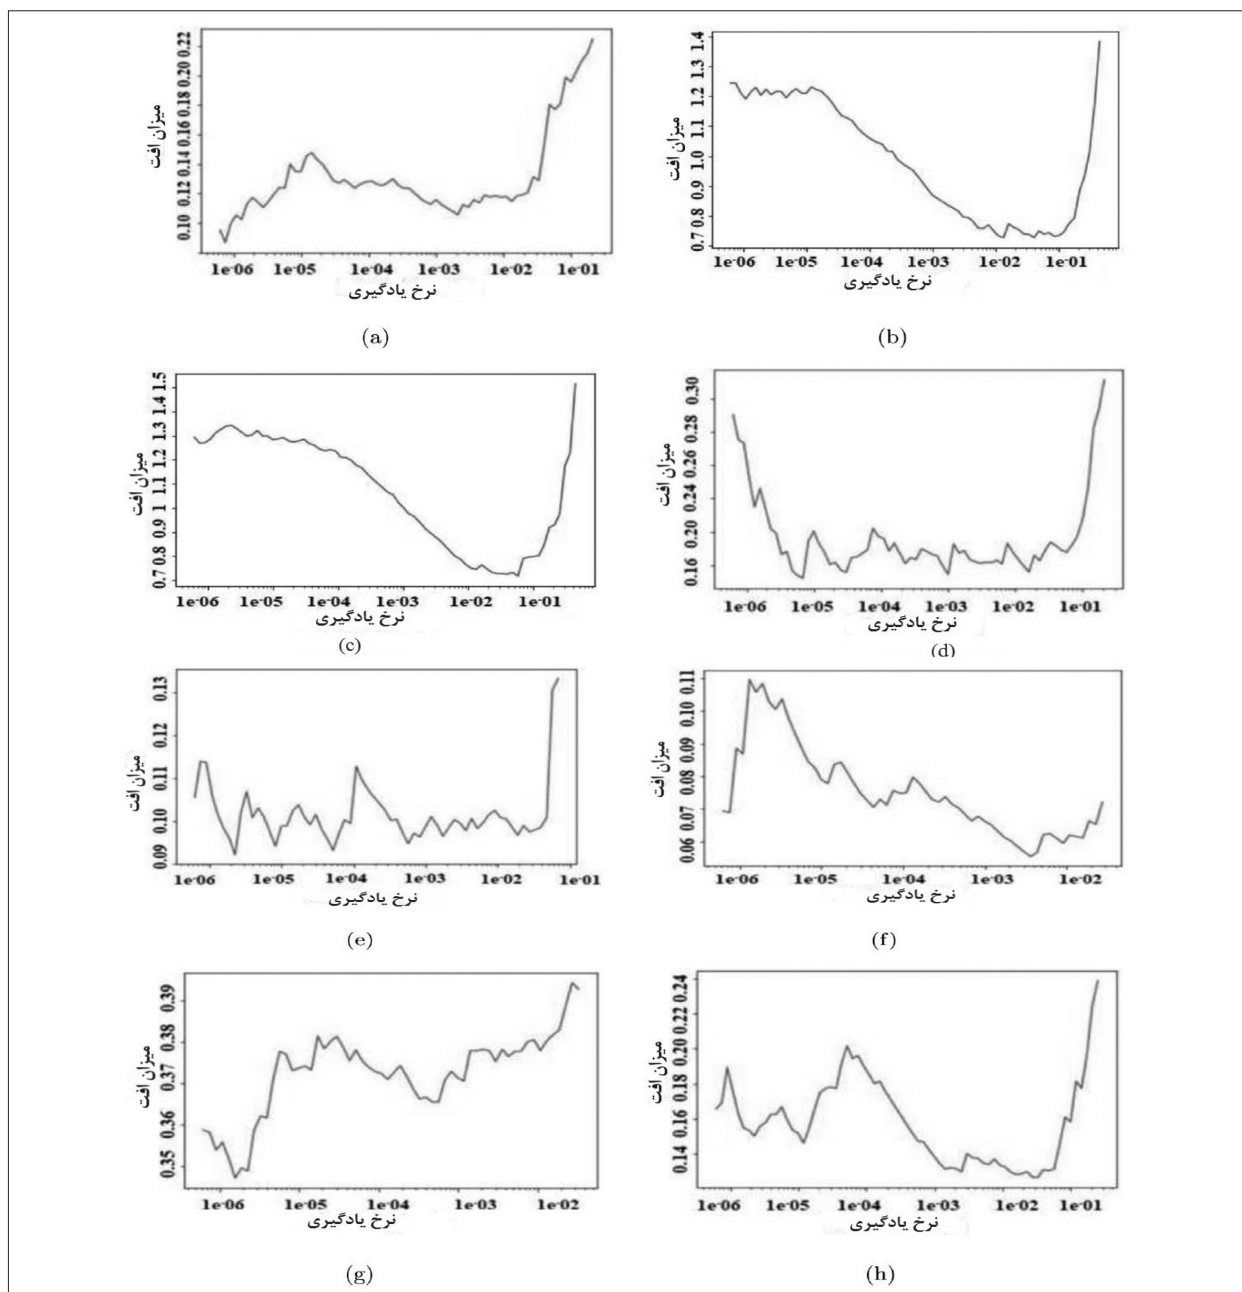
شکل ۷: منحنی ROC از هشت مدل مختلف CNN که در این مطالعه استفاده شده است.

از نمونه های کووید-۱۹ اعتبارسنجی می شود. تا به امروز، هیچ مجموعه داده بزرگی در دسترس عموم وجود ندارد،

جدول ۷: مقایسه عملکرد رده کووید-۱۹ با روش های پیشرفته

منبع	میزان حساسیت کلاس کووید-۱۹ (%)
Hemdan et al. [21]	100.00
Narin et al. [24]	96.00
Sethy and Behera [25]	NR
Toğaçar et al. [27]	99.32
Wang and Wong [22]	87.10
Ucar and Korkmaz [26]	100.00
Farooq and Hafeez [28]	100.00
Ozturk et al. [20]	90.65
Proposed method	100.00

NR: Not reported



شکل ۸: نمودار بین نرخ یادگیری و افت به دست آمده برای همه مدل‌ها:

(a) ResNet-34, (b) ResNet-50, (c) GoogleNet, (d) VGG-16, (e) AlexNet, (f) MobileNet-V2, (g) Inception-V3, and (h) SqueezeNet.

طبقه‌بندی اولیه موارد عفونت کووید-۱۹ از موارد عادی با استفاده از تصاویر اشعه ایکس قفسه سینه پیشنهاد شده است. چندین معماری CNN از قبل آموزش دیده با استفاده از مفهوم TL با در نظر گرفتن چندین عامل مهم مورد بررسی قرار گرفت و نتایج آن‌ها در مقایسه با مجموعه‌ای از نمونه‌های اشعه X در دسترس عموم مقایسه شد. نتایج

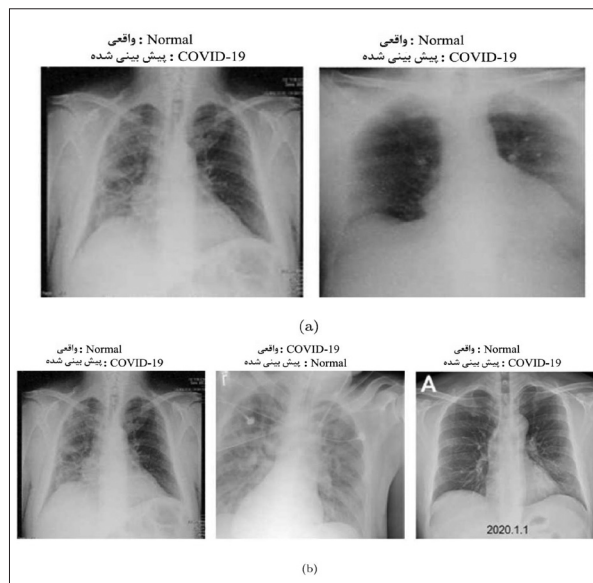
زیرا این یک بیماری همه‌گیر در حال انجام و جدید است. اما در آینده، ما برنامه خود را با استفاده از مجموعه داده‌های بزرگ در نظر می‌گیریم.

#### ۴- نتیجه گیری

در این مطالعه، یک روش خودکار مبتنی بر DL

## منابع:

- [1] WHO, Coronavirus disease 2019 (کووید-19) situation report – 127, 2020, [https://www.who.int/docs/default-source/coronaviruse/situation-reports/20200526--19-sitrep-127.pdf?sfvrsn=7b6655ab\\_8](https://www.who.int/docs/default-source/coronaviruse/situation-reports/20200526--19-sitrep-127.pdf?sfvrsn=7b6655ab_8).
- [2] C. Huang, Y. Wang, X. Li, L. Ren, J. Zhao, Y. Hu, L. Zhang, G. Fan, J. Xu, X. Gu, et al., Clinical features of patients infected with 2019 novel coronavirus in Wuhan, China, *The Lancet* 395 (10223) (2020) 497–506.
- [3] K. Elasnoui, Y. Chawki, Using X-ray images and deep learning for automated detection of coronavirus disease, *J. Biomol. Struct. Dyn.* (2020) 1–22.
- [4] F. Shi, J. Wang, J. Shi, Z. Wu, Q. Wang, Z. Tang, K. He, Y. Shi, D. Shen, Review of artificial intelligence techniques in imaging data acquisition, segmentation and diagnosis for COVID-19, *IEEE Rev. Biomed. Eng.* (2020) <http://dx.doi.org/10.1109/RBME.2020.2987975>.
- [5] Y. Fang, H. Zhang, J. Xie, M. Lin, L. Ying, P. Pang, W. Ji, Sensitivity of chest CT for COVID-19: comparison to RT-PCR, *Radiology* (2020) 200432.
- [6] D. Dong, Z. Tang, S. Wang, H. Hui, L. Gong, Y. Lu, Z. Xue, H. Liao, F. Chen, F. Yang, et al., The role of imaging in the detection and management of COVID-19: A review, *IEEE Rev. Biomed. Eng.* (2020) <http://dx.doi.org/10.1109/RBME.2020.2990959>.
- [7] Y. Oh, S. Park, J.C. Ye, Deep learning features on CXR using limited training data sets, *IEEE Trans. Med. Imaging* 39 (8) (2020) 2688–2700.
- [8] J.P. Kanne, B.P. Little, J.H. Chung, B.M. Elicker, L.H. Ketani, Essentials for radiologists on COVID-19: An update—radiology scientific expert panel, *Radiology* 296 (2) (2020) 1–2.
- [9] M. Chung, A. Bernheim, X. Mei, N. Zhang, M. Huang, X. Zeng, J. Cui, W. Xu, Y. Yang, Z.A. Fayad, et al., CT imaging features of 2019 novel coronavirus (2019-nCoV), *Radiology* 295 (1) (2020) 202–207.
- [10] J. Zhang, Y. Xie, Y. Li, C. Shen, Y. Xia, COVID-19 screening on chest X-ray images using deep learning based anomaly detection, 2020, arXiv preprint arXiv:2003.12338.
- [11] S. Hoo-Chang, H.R. Roth, M. Gao, L. Lu, Z. Xu, I. Nogueira, J. Yao, D. Mollura, R.M. Summers, Deep convolutional neural networks for computer-aided detection: CNN architectures, dataset characteristics and transfer learning, *IEEE Trans. Med. Imaging* 35 (5) (2016) 1285.
- [12] G. Litjens, T. Kooi, B.E. Bejnordi, A.A.A. Setio, F. Ciompi, M. Ghafoorian, J.A. van der Laak, B. Van Ginneken, C.I. S. J. Unchez, A survey on deep learning in medical image analysis, *Med. Image Anal.* 42 (2017) 60–88.
- [13] Y. LeCun, Y. Bengio, G. Hinton, Deep learning, *Nature* 521 (7553) (2015) 436.
- [14] D.R. Nayak, R. Dash, B. Majhi, R.B. Pachori, Y. Zhang, A deep stacked random vector functional link network autoencoder for diagnosis of brain abnormalities and breast cancer, *Biomed. Signal Process. Control* 58 (2020) 101860.
- [15] A. Ešteva, B. Kuprel, R.A. Novoa, J. Ko, S.M. Swetter, H.M. Blau, S. Thrun, Dermatologist-level classification of skin cancer with deep neural networks, *Nature* 542 (7639) (2017) 115–118.



شکل ۹: تصویر طبقه‌بندی نادرست نتایج حاصل از دو تا از بهترین شبکه‌ها را نشان می‌دهد:

(b) AlexNet و (a) ResNet-34

نشان داد که ResNet-34 با دقت ۹۸٫۳۳٪ عملکرد بهتری نسبت به سایر شبکه‌های رقابتی داشته و از این رو می‌تواند به‌عنوان یک مدل بالقوه برای پیش‌بینی عفونت کووید-۱۹ مورد توجه قرار گیرد. رادیولوژیست‌ها می‌توانند از این مدل برای بررسی غربالگری و در نتیجه استفاده از آن‌ها استفاده کنند، و باعث کاهش حجم کار آن‌ها می‌توانند. این مطالعه همچنین راه را برای توسعه بیشتر مدل‌های عمیق CNN (با استفاده از اتصالات باقیمانده) برای تشخیص دقیق‌تر عفونت کووید-۱۹ هموار می‌کند. مدل DL پیشنهادی برای به‌دست آوردن طبقه‌بندی ممنوع قابل توجه عملکرد (کووید-۱۹ در مقابل نرمال) ساخته شده است و تعداد محدودی از مطالعات تاکنون برای طبقه‌بندی چند طبقه (کووید در مقابل ذات‌الریه در مقابل طبیعی) ارائه شده است. از این رو، در مطالعات آینده، اثربخشی مدل پیشنهادی برای مسئله طبقه‌بندی چند طبقه تأیید می‌شود. علاوه بر این، ما قصد داریم استفاده از الگوریتم‌های بهینه‌سازی همراه با مدل‌های DL مورد استفاده در این مطالعه را برای طراحی یک مدل قابل اطمینان‌تر کشف کنیم.

- J. Lu, Brain tumor classification for MR images using transfer learning and fine-tuning, *Comput. Med. Imaging Graph.* 75 (2019) 34–46.
- [32] D.R. Nayak, R. Dash, B. Majhi, Automated diagnosis of multi-class brain abnormalities using MRI images: A deep convolutional neural network based method, *Pattern Recognit. Lett.* 138 (2020) 385–391.
- [33] M. Oquab, L. Bottou, I. Laptev, J. Sivic, Learning and transferring mid-level image representations using convolutional neural networks, in: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2014, pp. 1717–1724.
- [34] A. Krizhevsky, I. Sutskever, G.E. Hinton, ImageNet classification with deep convolutional neural networks, in: *Advances in Neural Information Processing Systems*, 2012, pp. 1097–1105.
- [35] K. Simonyan, A. Zisserman, Very deep convolutional networks for large-scale image recognition, 2014, arXiv preprint arXiv:1409.1556.
- [36] C. Szegedy, W. Liu, Y. Jia, P. Sermanet, S. Reed, D. Anguelov, D. Erhan, V. Vanhoucke, A. Rabinovich, Going deeper with convolutions, in: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2015, pp. 1–9.
- [37] M. Sandler, A. Howard, M. Zhu, A. Zhmoginov, L.-C. Chen, MobileNetV2: Inverted residuals and linear bottlenecks, in: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2018, pp. 4510–4520.
- [38] F.N. Iandola, S. Han, M.W. Moskewicz, K. Ashraf, W.J. Dally, K. Keutzer, SqueezeNet: Alexnet-level accuracy with 50x fewer parameters and <0.5 MB model size, 2016, arXiv preprint arXiv:1602.07360.
- [39] K. He, X. Zhang, S. Ren, J. Sun, Deep residual learning for image recognition, in: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2016, pp. 770–778.
- [40] C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens, Z. Wojna, Rethinking the inception architecture for computer vision, in: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2016, 2818–2826.
- [41] M. Toğaçar, B. Ergen, Z. Cmert, BrainMRNet: Brain tumor detection using magnetic resonance images with a novel convolutional neural network model, *Med. Hypotheses* 134 (2020) 109531.
- [42] M. Toğaçar, K.B. Zkurt, B. Ergen, Z. Cmert, BreastNet: A novel convolutional neural network model through histopathological images for the diagnosis of breast cancer, *Physica A* 545 (2020) 123592.
- [43] D.P. Kingma, J. Ba, Adam: A method for stochastic optimization, 2014, arXiv preprint arXiv:1412.6980.
- [44] I. Sutskever, J. Martens, G. Dahl, G. Hinton, On the importance of initialization and momentum in deep learning, in: *International Conference on Machine Learning*, 2013, pp. 1139–1147.
- [45] M.D. Zeiler, Adadelta: an adaptive learning rate method, 2012, arXiv preprint arXiv:1212.5701.
- [46] G. Hinton, N. Srivastava, K. Swersky, Lecture 6a overview of mini-batch gradient descent course, in: *Neural Networks for Machine Learning*, 2012.
- [16] X. Gu, L. Pan, H. Liang, R. Yang, Classification of bacterial and viral childhood pneumonia using deep learning in chest radiography, in: *Proceedings of the 3rd International Conference on Multimedia and Image Processing*, 2018, pp. 88–93.
- [17] V. Chouhan, S.K. Singh, A. Khamparia, D. Gupta, P. Tiwari, C. Moreira, R. Damaševičius, V.H.C. de Albuquerque, A novel transfer learning based approach for pneumonia detection in chest X-ray images, *Appl. Sci.* 10 (2) (2020) 559.
- [18] P. Lakhani, B. Sundaram, Deep learning at chest radiography: automated classification of pulmonary tuberculosis by using convolutional neural networks, *Radiology* 284 (2) (2017) 574–582.
- [19] P. Rajpurkar, J. Irvin, R.L. Ball, K. Zhu, B. Yang, H. Mehta, T. Duan, D. Ding, A. Bagul, C.P. Langlotz, et al., Deep learning for chest radiograph diagnosis: A retrospective comparison of the CheXNeXt algorithm to practicing radiologists, *PLoS Med.* 15 (11) (2018) e1002686.
- [20] T. Ozturk, M. Talo, E.A. Yildirim, U.B. Baloglu, O. Yildirim, U.R. Acharya, Automated detection of COVID-19 cases using deep neural networks with X-ray images, *Comput. Biol. Med.* (2020) 103792.
- [21] E.E.-D. Hemdan, M.A. Shouman, M.E. Karar, COVIDX-Net: A framework of deep learning classifiers to diagnose COVID-19 in X-ray images, 2020, arXiv preprint arXiv:2003.11055.
- [22] L. Wang, A. Wong, COVID-Net: A tailored deep convolutional neural network design for detection of COVID-19 cases from chest X-Ray images, 2020, arXiv preprint arXiv:2003.09871.
- [23] I.D. Apostolopoulos, T.A. Mpesiana, COVID-19: automatic detection from X-ray images utilizing transfer learning with convolutional neural networks, *Phys. Eng. Sci. Med.* (2020) 1.
- [24] A. Narin, C. Kaya, Z. Pamuk, Automatic detection of coronavirus disease (COVID-19) using X-ray images and deep convolutional neural networks, 2020, arXiv preprint arXiv:2003.10849.
- [25] P.K. Sethy, S.K. Behera, Detection of coronavirus disease (COVID-19) based on deep features, 2020, <http://dx.doi.org/10.20944/preprints202003.0300.v1>, Preprints.
- [26] F. Ucar, D. Korkmaz, COVIDiagnosis-Net: Deep Bayes-SqueezeNet based diagnosis of the coronavirus disease 2019 (COVID-19) from X-Ray images, *Med. Hypotheses* (2020) 109761.
- [27] M. Toğaçar, B. Ergen, Z. Cmert, COVID-19 detection using deep learning models to exploit social mimic optimization and structured chest X-ray images using fuzzy color and stacking approaches, *Comput. Biol. Med.* (2020) 103805.
- [28] M. Farooq, A. Hafeez, COVID-ResNet: A deep learning framework for screening of COVID19 from radiographs, 2020, arXiv preprint arXiv:2003.14395.
- [29] J.P. Cohen, P. Morrison, L. Dao, COVID-19 image data collection, 2020, <https://github.com/ieee8023/covid-chestxray-dataset>.
- [30] X. Wang, Y. Peng, L. Lu, Z. Lu, M. Bagheri, R.M. Summers, Chestx-ray8: Hospitalscale chest X-ray database and benchmarks on weakly-supervised classification and localization of common thorax diseases, in: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2017, pp. 2097–2106.
- [31] Z.N.K. Swati, Q. Zhao, M. Kabir, F. Ali, Z. Ali, S. Ahmed,