

## Diagnosis of COVID-19 Disease in X-ray Images Based on Deep Learning Methods and Combining Classifiers

Roustaei Mohammad<sup>1</sup>, Giveki Davar<sup>2\*</sup>

• Received: 21 Nov 2022

• Accepted: 10 Sep 2023

**Introduction:** COVID-19 is a new virus that causes infection in the upper respiratory tract and lungs, and the number of deaths due to the disease has increased daily on the scale of a global epidemic. Chest X-ray images have been useful for monitoring various lung diseases and have recently been used to monitor COVID-19 disease.

**Method:** In this research, a multi-stage process was used to recognize COVID-19 from X-ray images. In the first stage, pre-processing was done to normalize the data. In the second step, which is the most important step of the proposed method, feature extraction was done. The feature extraction operation was based on deep learning networks. After feature extraction, machine learning algorithms were used to classify images. The algorithms used in this section are support vector machine, nearest neighbor, and decision tree algorithms. The results of these categories are combined in the fourth step based on the majority vote.

**Results:** The parameters used in this research are among the classification parameters, including precision, accuracy, recall, and F-criterion, which were obtained as 96.5, 92.25, 94, and 93, respectively.

**Conclusion:** The results of the experiments show the acceptable efficiency of the proposed method because, in addition to reducing the calculations by the separable layer, the combination of categories and their weighting has been used to obtain the final result.

**Keywords:** COVID-19, X-ray Images, Feature Extraction, Deep Learning Networks, Machine Learning, Classification

• **Citation:** Roustaei M, Giveki M. Diagnosis of COVID-19 Disease in X-ray Images Based on Deep Learning Methods and Combining Classifiers. *Journal of Health and Biomedical Informatics* 2023; 10(2): 111-24. [In Persian] doi:10.34172/jhbmi.2023.18

1. B.Sc. Student in Computer Engineering, Department of Computer Engineering, Faculty of Engineering, Malayer University, Malayer, Iran

2. PhD in Computer Engineering, Assistant Professor, Department of Computer Engineering, Faculty of Engineering, Malayer University, Malayer, Iran

\***Corresponding Author:** Davar Giveki

**Address:** Faculty of Engineering, Malayer University, km 4 of Malayer-Arak road, Malayer

• **Tel:** 081-32456518 • **Email:** davood.giveki@gmail.com

## تشخیص بیماری کووید-۱۹ در تصاویر پرتو X مبتنی بر روش‌های یادگیری

## عمیق و ترکیب دسته‌بندها

محمد روستائی<sup>۱</sup>، داور گیوکی<sup>۲\*</sup>

• پذیرش مقاله: ۱۴۰۲/۶/۱۹

• دریافت مقاله: ۱۴۰۱/۸/۳۰

**مقدمه:** کووید-۱۹ یک ویروس جدید است که باعث عفونت در دستگاه تنفسی فوقانی و ریه‌ها می‌شود که تعداد موارد مرگ و میر به‌طور روزانه در مقیاس یک بیماری همه‌گیر جهانی افزایش یافته است. تصاویر اشعه ایکس قفسه سینه برای نظارت بر بیماری‌های مختلف ریه مفید بوده و اخیراً برای نظارت بر بیماری کووید-۱۹ استفاده شده است.

**روش:** در این پژوهش جهت بازشناسی کووید-۱۹ از روی تصاویر X از یک فرآیند چند مرحله‌ای بهره گرفته شده است که در مرحله نخست عملیات پیش‌پردازش با هدف نرمال‌سازی روی داده‌ها صورت گرفته است. در گام دوم که مهم‌ترین گام روش پیشنهادی می‌باشد، عملیات استخراج ویژگی صورت گرفته است. عملیات استخراج ویژگی براساس شبکه‌های یادگیری عمیق صورت گرفته است. بعد از عملیات استخراج ویژگی از الگوریتم‌های یادگیری ماشین جهت دسته‌بندی تصاویر بهره گرفته شده است. الگوریتم‌های مورد استفاده در این بخش الگوریتم‌های ماشین بردار پشتیبان، نزدیک‌ترین همسایه و درخت تصمیم می‌باشند. نتایج این دسته‌بندها در گام چهارم براساس رأی اکثریت ترکیب گردیده‌اند.

**نتایج:** پارامترهای به‌کاررفته در این پژوهش جزء پارامترهای دسته‌بندی می‌باشد که شامل: دقت، صحت، فراخوان و معیار F می‌باشند که به ترتیب مقادیر ۹۶/۵، ۹۲/۲۵، ۹۴ و ۹۳ به دست آمده است.

**نتیجه‌گیری:** نتایج آزمایش‌ها نشان‌دهنده کارایی قابل قبول روش پیشنهادی می‌باشد زیرا علاوه بر کاهش محاسبات توسط لایه جدا پذیر، از ترکیب دسته‌بندها و وزن‌دهی به آن‌ها برای به‌دست آوردن نتیجه نهایی استفاده گردیده است.

**کلیدواژه‌ها:** کووید-۱۹، تصاویر پرتو X، استخراج ویژگی، شبکه‌های یادگیری عمیق، یادگیری ماشین، دسته‌بندی

**ارجاع:** روستائی محمد، گیوکی داور. تشخیص بیماری کووید-۱۹ در تصاویر پرتو X مبتنی بر روش‌های یادگیری عمیق و ترکیب دسته‌بندها. مجله انفورماتیک سلامت و زیست پزشکی ۱۴۰۲؛ ۱۰(۲): ۱۱۱-۱۲۴. doi:10.34172/jhbmi.2023.18

۱. دانشجوی کارشناسی مهندسی کامپیوتر، گروه مهندسی کامپیوتر، دانشکده فنی مهندسی، دانشگاه ملایر، ملایر، ایران

۲. دکتری مهندسی کامپیوتر، استادیار، گروه مهندسی کامپیوتر، دانشکده فنی مهندسی، دانشگاه ملایر، ملایر، ایران

\* نویسنده مسئول: داور گیوکی

آدرس: ملایر، کیلومتر ۴ جاده ملایر-اراک، دانشگاه ملایر، دانشکده فنی مهندسی

• Email: davood.giveki@gmail.com

• شماره تماس: ۰۸۱-۳۲۴۵۶۵۱۸

## مقدمه

رشد سیستم تصویربرداری پزشکی، جامعه تحقیقاتی را به سمت روش‌های غیرتهاجمی بازشناسی بیماری سوق داده است [۱]. اهداف تجزیه و تحلیل تصویر پزشکی، ارائه فرآیند بازشناسی و درمان کارآمد برای رادیولوژیست‌ها و پزشکان است. دستگاه‌های تصویربرداری پزشکی مانند اشعه ایکس، (Computed Tomography) CT و (Magnetic Resonance Imaging) MRI می‌توانند اطلاعات بیماری، ناهنجاری و آناتومیک بدن انسان را به صورت غیر مخرب ارائه دهند. به دلیل حجم زیاد داده‌ها و تداخل صداها در تصاویر پزشکی، پردازش تصاویر و استخراج اطلاعات مؤثر از آن‌ها بسیار مهم است [۲]. پردازش تصویر پزشکی کمک زیادی در کاربردهای پزشکی کرده است. به عنوان مثال، تقسیم‌بندی تصویر، ثبت تصویر و جراحی با هدایت تصویر به طور گسترده‌ای در درمان پزشکی استفاده می‌شود [۳، ۴]. تصاویر اشعه ایکس قفسه سینه در نظارت و بررسی بیماری‌های مختلف ریه مانند سل، ذات‌الریه و التهاب ریه و بیماری‌های معده نقش به سزایی دارد [۵]. در ماه دسامبر سال ۲۰۱۹ (آذر ماه ۱۳۹۸) ویروس نوپدید کرونا که هم اکنون با نام کووید-۱۹ شناخته می‌شود و موجب نارسایی حاد تنفسی می‌شود، در شهر ووهان چین پدیدار گشت [۶]. اولین مورد از بیماری ویروس کرونا (کووید-۱۹) در اواخر دسامبر سال ۲۰۱۹ در ووهان، چین گزارش شد و عمدتاً دیده می‌شود که بر راه تنفسی تأثیر می‌گذارد و در نتیجه ریه‌های افراد آلوده را تحت تأثیر قرار می‌دهد [۷]. این ویروس از آن زمان به سرعت گسترش یافته و به یک بیماری همه‌گیر جهانی تبدیل شده است [۸]. تعداد موارد و مرگ و میر مرتبط با آن هنوز روزانه افزایش می‌یابد [۹]. تصاویر ایکس قفسه سینه برای پیگیری اثرات کووید-۱۹ بر بافت ریه [۱۰] مفید نشان داده شده‌اند. در نتیجه، تصاویر اشعه ایکس قفسه سینه نیز ممکن است در بازشناسی کووید-۱۹ استفاده شود. تصویربرداری رادیولوژیکی مانند اشعه ایکس قفسه سینه و سی‌تی‌اسکن قفسه سینه می‌تواند برای جدا کردن به موقع افراد آلوده و کنترل این وضعیت اپیدمی مفید باشد [۱۱]. این تکنیک‌ها به راحتی می‌توانند مشخصات رادیولوژیکی کووید ۱۹ را بازشناسی دهند. اولین انتخاب رادیولوژیست اشعه ایکس قفسه سینه است، زیرا بیشتر بیمارستان‌ها به دستگاه اشعه ایکس مجهز هستند [۱۲]. رویکردهای مختلفی مبتنی بر یادگیری عمیق وجود دارد که از تصاویر اشعه ایکس قفسه سینه برای بازشناسی بیماری استفاده می‌کنند. Kesim و همکاران، یک مدل جدید شبکه عصبی

کانولوشن (Convolutional Neural Network) را برای طبقه‌بندی تصویر اشعه قفسه سینه ارائه دادند. نویسندگان یک ساختار کوچک از CNN را به دلیل اینکه مدل‌های CNN با مشکلات موجود در کاربردهای عملی شناخته شده بودند، توسعه دادند [۱۳].

Singh و همکاران، برای دسته‌بندی بیماری کووید-۱۹ تصاویر توموگرافی کامپیوتری (CT) قفسه‌سینه را پیشنهاد کردند. آن‌ها، از یک شبکه عصبی کانولوشن (CNN) برای طبقه‌بندی بیماران آلوده به کووید-۱۹ به عنوان افراد آلوده یا غیر آلوده استفاده کرده‌اند. علاوه بر این، پارامترهای اولیه CNN با استفاده از تکامل افتراقی چندهدفه (Objective Differential Multi-Mode Evolution) تنظیم می‌شوند. مجموعه داده آموزشی برای ساخت مدل دسته‌بندی بیماری کووید-۱۹ مورد استفاده قرار می‌گیرد و نتایج گسترده تجربی نشان داد که مدل پیشنهادی بهتر از مدل‌های رقابتی است، بنابراین مدل پیشنهادی برای طبقه‌بندی بیماری کووید-۱۹ در زمان واقعی از تصاویر سی‌تی‌اسکن قفسه سینه مفید است [۱۴].

Hu و همکاران، یک استراتژی یادگیری عمیق نظارت ضعیف برای بازشناسی و طبقه‌بندی عفونت کووید-۱۹ از تصاویر CT پیشنهاد کردند. روش پیشنهادی می‌تواند الزامات برچسب‌گذاری دستی تصاویر CT را به حداقل برساند؛ اما همچنان قادر به بازشناسی دقیق عفونت و بازشناسی کووید-۱۹ از مورد غیر کووید-۱۹ است. چارچوب پیشنهادی توانست موارد کووید-۱۹ را به طور دقیق از بیماران (Community Acquired Pneumonia) CAP و (Non-Pneumonia) NP بازشناسی دهد. همچنین توانست موقعیت دقیق ضایعات یا التهاب‌های ناشی از کووید-۱۹ را مشخص کند، بنابراین می‌تواند به طور بالقوه توصیه‌هایی در مورد شدت بیمار برای راهنمایی ارزیابی و درمان ارائه دهد. نتایج شبیه‌سازی نشان داده‌اند که مدل پیشنهادی به دقت، صحت و (Area Under The Receiver Operating Characteristic Curve) AUC بالایی برای طبقه‌بندی و همچنین تجسم کیفی امیدوارکننده برای بازشناسی ضایعات دست یافته است [۱۵].

Abbas و همکاران (Decompose, Transfer, and Compose) DeTraC یک معماری یادگیری عمیق CNN را که به یک روش تجزیه کلاس برای طبقه‌بندی تصاویر کووید-۱۹ در یک مجموعه داده جامع از تصاویر CXR متکی است، اقتباس کردند. DeTraC راه‌حل‌های مؤثر و قوی برای

دسته‌بندی موارد کووید-۱۹ و توانایی آن برای مقابله با بی‌نظمی داده و تعداد محدودی از تصاویر آموزشی را نشان داد. آن‌ها DeTraC را با مدل‌های مختلف آموزش دیده شبکه عصبی کانولوشن، جایی که بالاترین دقت توسط VGG19 در DeTraC به دست آمده، تأیید کردند. نتایج شبیه‌سازی توانایی DeTraC را در بازشناسی موارد کووید-۱۹ از یک مجموعه داده تصویری جامع جمع‌آوری شده از چندین بیمارستان در سراسر جهان نشان داد. دقت بالای ۹۳/۱ درصد (با حساسیت ۱۰۰ درصد) توسط DeTraC در بازشناسی تصاویر اشعه ایکس کووید-۱۹ از موارد سندرم حاد تنفسی طبیعی و شدید به دست آمد [۱۶].

Makris و همکاران، ویروس کرونا را با استفاده از یک مدل یادگیری عمیق کانولوشن شناسایی کردند. مجموعه داده‌های آن‌ها شامل سه کلاس ویروس کرونا، ذات‌الریه و تصاویر اشعه ایکس طبیعی است. در این پژوهش، کلاس‌های داده با استفاده از تکنیک رنگ فازی به عنوان مرحله پیش‌پردازش و تصاویری که با تصاویر اصلی ساختار یافته بودند، بازسازی شدند. در مرحله بعدی، مجموعه داده انباشته شده با مدل‌های یادگیری عمیق (SqueezeNet، MobileNetV2) آموزش داده شد و مجموعه ویژگی‌های به دست آمده توسط مدل‌ها با استفاده از روش بهینه‌سازی اجتماعی Mimic پردازش شد. پس از آن، ویژگی‌های کارآمد با استفاده از ماشین‌های بردار پشتیبان (SVM) ترکیب و دسته‌بندی شدند. نرخ کلی دسته‌بندی به دست آمده با رویکرد پیشنهادی برابر با ۹۹/۲۷ درصد بود. با رویکرد پیشنهادی این پژوهش، بدیهی است که این مدل می‌تواند به طور مؤثر در بازشناسی بیماری

کووید-۱۹ نقش داشته باشد [۱۷].

Roy و همکاران یک چارچوب یادگیری عمیق نوآورانه را برای تشخیص بیماری کووید-۱۹ بر اساس انتقال یادگیری ارائه دادند. در این روش، از معماری شبکه عصبی پیچشی استفاده شده است که از شبکه‌های پیش‌آموزش دیده شده بر روی دیتاست‌های بزرگ دیگر استفاده می‌کند. این انتقال یادگیری بهبود قابل توجهی در دقت تشخیص بیماری داشته است [۱۹].

Farooq و Hafeez، یک چارچوب یادگیری عمیق با نام COVID-ResNet برای غربالگری بیماری کووید-۱۹ از تصاویر رادیوگرافی ارائه کردند. در این چارچوب، در مرحله اول، تصاویر رادیوگرافی با استفاده از روش‌های پیش‌پردازش مورد آماده‌سازی قرار می‌گیرند. سپس، شبکه عصبی ResNet با طبقه‌بندی چندکلاسه آموزش داده می‌شود تا بتواند تصاویر رادیوگرافی را به دو دسته کووید-۱۹ و غیر کووید-۱۹ (مانند عفونت‌های تنفسی عادی) تفکیک کند، یکی از نکات قابل توجه در این پژوهش استفاده از روش‌های بهینه‌سازی جهت بهبود عملکرد شبکه است. نویسندگان از الگوریتم بهینه‌سازی Adam استفاده می‌کنند که با ترکیب گرادینت‌های انطباقی و تکنیک‌های دیگر، به دقت بالاتر در تشخیص کووید-۱۹ کمک می‌کند [۲۰].

در این پژوهش، ما یک روش نوین و علمی برای تشخیص بیماری کووید-۱۹ ارائه می‌دهیم. در این روش، از مراحل مختلفی استفاده می‌شود تا اطلاعات مفید از تصاویر  $X$  استخراج شود. همچنین در جدول ۱ روش‌های پیشین در حوزه شناسایی بیماری کووید-۱۹ مبتنی بر یادگیری عمیق مورد مطالعه قرار گرفته و شرح داده شده است.

جدول ۱: مروری بر روش‌های پیشین

شماره منبع	روش پیشنهادی	مزایا	معایب
[۱۳]	یک مدل جدید شبکه عصبی کانولوشن را برای دسته‌بندی تصویر اشعه قفسه سینه ارائه دادند.	توسعه یک ساختار کوچک از CNN	گیر افتادن در بهینگی محلی
[۱۴]	یک مدل دسته‌بندی بیماری کووید ۱۹ برای دسته‌بندی بیماران مبتلا از تصاویر توموگرافی کامپیوتری قفسه‌سینه پیشنهاد کردند.	توانایی طبقه‌بندی تصاویر سی‌تی‌اسکن قفسه سینه با دقت بالا	گیر افتادن در بهینگی محلی
[۱۵]	یک استراتژی یادگیری عمیق نظارت ضعیف برای بازشناسی و طبقه‌بندی عفونت کووید ۱۹ از تصاویر CT پیشنهاد کردند.	دقت، صحت و AUC بالا برای بازشناسی ضایعات	شبکه‌ها را روی برش‌های جداگانه (تصاویر) آموزش داده‌اند
[۱۶]	یک معماری یادگیری عمیق CNN را که به یک روش تجزیه کلاس برای طبقه‌بندی تصاویر کووید ۱۹ در یک مجموعه داده جامع از تصاویر CXR متکی است.	دقت بالای ۹۳/۱ درصد روش پیشنهادی	عدم ارزیابی روی داده‌های بزرگ

جدول ۱: مروری بر روش‌های پیشین (ادامه)


[۱۷]	ویروس کرونا را با استفاده از یک مدل یادگیری عمیق، که یکی از زیر شاخه‌های هوش مصنوعی است، شناسایی کردند.	توانایی مؤثر در بازشناسی بیماری کووید ۱۹	عدم ارزیابی روی داده‌های بیشتر و همچنین معماری‌های بیشتر
[۱۹]	ارائه یک چارچوب یادگیری عمیق براساس یادگیری انتقالی	آموزش مدل روی داده‌های بزرگ	دقت پایین در تصاویر با پیچیدگی بالا
[۲۰]	ارائه یک چارچوب مبتنی بر معماری Resnet و بهبود آن توسط الگوریتم Adam	استفاده از الگوریتم بهینه سازی Adam	داده‌های کم آموزش و احتمال بیش برآزش مدل پیشنهادی

## روش

یک فرآیند چند مرحله‌ای بهره گرفته شد که این مراحل در شکل

۱ بیان گردیده است.

در این پژوهش جهت بازشناسی کووید-۱۹ از روی تصاویر X از




شکل ۱: مراحل روش پیشنهادی

تصمیم می‌باشد. نتایج این دسته‌بندها در گام چهارم براساس رأی اکثریت ترکیب می‌گردند و در نهایت براساس معیارهای ارزیابی نتایج گزارش می‌گردند.

## مجموعه داده

در این پژوهش قفسه سینه ۳۸۰ بیمار مورد بررسی و ارزیابی قرار گرفت که ۲۰۰ مورد شامل بیمارانی است که مشکل کووید-۱۹ را ندارند و ۱۸۰ بیمار دارای کووید-۱۹ می‌باشند [۱۸]. همچنین توزیع داده‌های این مجموعه به صورت نرمال بوده و چالش‌های مختلفی را در بر گرفته است. در شکل ۷ نمونه‌ای از تصاویر مربوط به قفسه سینه افراد سالم و بیمار آورده شده است.

همان‌طور که در شکل ۱ نشان داده شده است، روش پیشنهادی از پنج مرحله تشکیل گردیده است که در مرحله نخست عملیات پیش پردازش روی داده‌ها صورت گرفت. در این مرحله عملیات یکسان‌سازی تصاویر از نظر ابعاد، نرمال‌سازی تصاویر از نظر مقدار و تقسیم‌بندی تصاویر به داده‌های آموزش و آزمایش صورت گرفت. در گام دوم که مهم‌ترین گام روش پیشنهادی می‌باشد، عملیات استخراج ویژگی صورت گرفت. عملیات استخراج ویژگی براساس شبکه‌های یادگیری عمیق صورت می‌گیرد. بعد از عملیات استخراج ویژگی از الگوریتم‌های یادگیری ماشین جهت دسته‌بندی تصاویر بهره گرفته شد. الگوریتم‌های مورد استفاده در این بخش الگوریتم‌های ماشین بردار پشتیبان، نزدیک‌ترین همسایه و درخت



شکل ۷: تصاویر موجود در مجموعه داده

### پیش پردازش

در شکل ۲ عملیات پیش پردازش نشان داده شده است.



شکل ۲: مراحل پیش پردازش

عمیق صورت می گیرد. برای جلوگیری از رفع خطا و مشکل در کارکرد شبکه های یادگیری عمیق، ابعاد همه تصاویر یکسان می گردند.

#### نرمال سازی مقادیر تصاویر

یکی از بخش های مهم در شبکه های یادگیری عمیق که برای کاهش پیچیدگی این شبکه ها مورد استفاده قرار می گیرد؛ بهره گیری از عملیات نرمال سازی روی مقادیر تصاویر می باشد. در این پژوهش جهت نرمال سازی مقادیر از رابطه ۱ بهره گرفته شد.

$$X_{Norm} = \frac{X - a}{b - a} * (d - c) + c \quad (1)$$

مقدار تصویر قبل از عملیات نرمال سازی،  $b$  بیانگر حداکثر مقدار تصاویر قبل از عملیات نرمال سازی،  $c$  بیانگر حداقل مقدار

هدف از به کارگیری روش پیشنهادی، بهبود داده ها می باشد. در این بخش عملیاتی نظیر یکسان سازی تصاویر، نرمال سازی تصاویر و تقسیم بندی داده ها صورت می گیرد.

#### یکسان سازی تصاویر

هدف از این بخش یکسان سازی اندازه تصاویر می باشد. از آنجایی که تصاویر مجموعه داده دارای اندازه های متفاوتی می باشد، عملیات یکسان سازی تصاویر برای داشتن بردار ویژگی های یکسان روی تصاویر صورت می گیرد. از آنجایی که در این پژوهش عملیات استخراج ویژگی توسط شبکه های یادگیری

در رابطه ۱  $X_{Norm}$  بیانگر مقدار نرمال شده تصاویر،  $X$  بیانگر مقدار تصاویر قبل از عملیات نرمال سازی،  $a$  بیانگر حداقل

روش داده‌ها با درصد ۷۰ به ۳۰ به داده‌های آموزش و آزمایش دسته‌بندی شدند که در این حالت ۷۰ درصد داده‌ها جز داده‌های آموزش و ۳۰ درصد داده‌ها جزء داده‌های آزمایش می‌باشند.


### استخراج ویژگی

یکی از بخش‌های مهم روش پیشنهادی استخراج ویژگی می‌باشد. جهت استخراج ویژگی از تصاویر از شبکه‌های یادگیری عمیق بهره گرفته شد (شکل ۳).

تصاویر بعد از عملیات نرمال‌سازی و  $d$  بیانگر حداکثر مقدار تصاویر بعد از عملیات نرمال‌سازی می‌باشد.

### تقسیم‌بندی تصاویر

هدف از این بخش تقسیم‌بندی تصاویر به دو بخش آموزش و آزمایش می‌باشد. از داده‌های آموزش جهت یافتن الگوهای یادگیری استفاده می‌گردد و از داده‌های آزمایش جهت ارزیابی مدل آموزش داده شده استفاده می‌گردد. در این پژوهش جهت تقسیم‌بندی داده‌ها از روش تصادفی استفاده گردید. در این



شکل ۳: معماری شبکه یادگیری عمیق

• الگوریتم یادگیری وزن (Adam Algorithm)

• الگوریتم اصلاح وزن (Loss Function)

مهم‌ترین لایه به کار رفته در شبکه‌های یادگیری عمیق به لایه کانولوشن برمی‌گردد؛ زیرا این لایه وظیفه استخراج ویژگی‌ها را بر عهده دارد. در این پژوهش جهت استخراج ویژگی از لایه Separable بهره گرفته شد که این لایه نسبت به لایه کانولوشن معمولی تفاوت عمده‌ای در محاسبات دارد. در این لایه عملیات استخراج ویژگی همانند لایه کانولوشن معمولی از طریق فیلترها به دست می‌آید. تفاوت جایی هویدا می‌شود که لایه کانولوشن معمولی از ضرب ماتریس ورودی در ماتریس فیلتر انجام می‌گیرد، ولی در لایه Separable ابتدا ماتریس فیلتر به دو ماتریس تجزیه می‌گردد و بعد از تجزیه ماتریس فیلتر در ماتریس ورودی ضرب می‌گردد (شکل ۳).

همان طور که در شکل ۳ نشان داده شده است، جهت انجام عملیات استخراج ویژگی زیر استفاده می‌گردد که در ادامه بیان گردیده است.

• لایه کانولوشن (Separable Layer)

• لایه ادغام (Max Pooling)


• لایه تماماً متصل (Fully Connected Layer)

علاوه بر لایه‌های بیان گردیده در بالا، شبکه‌های یادگیری عمیق از اجزای دیگری نیز تشکیل گردیده است که اسامی آن در زیر بیان گردیده است.

• تابع محدودیت (ReLU Function)

• قطع و وصل کننده اتصالات (Drop Out)

• تابع دسته‌بند (Soft Max)



Basic CNN



Separable CNN

شکل ۴: محاسبات در شبکه‌های کانولوشن معمولی و Separable

ماتریس‌های ورودی توسط لایه تماماً متصل به بردارهای ویژگی تبدیل می‌گردند. برای محدود کردن خروجی شبکه‌های یادگیری عمیق از تابع محدودیت استفاده می‌گردد. تابع محدودیت به‌عنوان تابع انتقال نیز شناخته می‌شود و وظیفه آن تغییر مقادیر خروجی شبکه می‌باشد. مهم‌ترین مزیت این کار جلوگیری از همگرایی سریع الگوریتم می‌باشد.

#### دسته‌بندی

جهت عملیات دسته‌بندی از سه دسته‌بند نزدیک‌ترین همسایه [۳۰]، درخت تصمیم [۳۱] و ماشین بردار پشتیبان [۲۹] استفاده شد. هر سه الگوریتم دارای ویژگی‌های منحصربه‌فردی می‌باشند برای مثال الگوریتم نزدیک‌ترین همسایه به‌عنوان یک الگوریتم تنبل شناخته می‌شود و برای دسته‌بندی داده‌ها از معیار فاصله استفاده می‌کند. معیار به کار رفته در این الگوریتم برای دسته‌بندی داده‌ها، معیار فاصله اقلیدسی می‌باشد که رابطه آن در ادامه بیان گردیده است.

همان‌طور که در شکل ۴ نشان داده شده است، در لایه Separable لایه ماسک به دو بخش تقسیم می‌گردد و آن‌گاه روی تصویر اعمال می‌گردد. در این حالت میزان محاسبات کاهش پیدا می‌کند. کاهش محاسبات باعث افزایش سرعت الگوریتم‌های یادگیری عمیق در یافتن الگوها می‌گردد. همچنین در این حالت تعداد وزن‌ها جهت به‌روزرسانی نیز کاهش پیدا می‌کند. کاهش وزن‌های شبکه‌ها باعث کاهش پیچیدگی سیستم نیز می‌گردد از همین رو کارایی شبکه نیز افزایش پیدا می‌کند. بعد از استخراج ویژگی توسط لایه Separable برای کاهش ویژگی‌ها، از لایه نمونه‌برداری استفاده می‌گردد. لایه نمونه‌برداری به دو صورت میانگین و ماکزیمم مورد استفاده قرار می‌گیرد. در حالت ماکزیمم ویژگی‌های سراسری استخراج می‌گردد، ولی در روش میانگین ویژگی‌های محلی تصویر استخراج می‌گردد. در این پژوهش از روش ماکزیمم برای نمونه‌برداری استفاده می‌گردد. بعد از عملیات نمونه‌برداری،

$$ED(i, j) = \sqrt{\sum_{k=1}^{dim} (Instance_{ik} - Instance_{jk})^2} \quad (2)$$

الگوریتم درخت تصمیم برای دسته‌بندی نمونه‌ها از معیارهای آماری استفاده می‌کند. معیار به کار رفته در این الگوریتم معیار بهره اطلاعات می‌باشد. بهره اطلاعات شامل میزان اهمیت هر ویژگی در دسته‌بندی داده‌ها می‌باشد. در رابطه ۳ این معیار آورده شده است.

در رابطه ۲  $ED(i, j)$  بیانگر فاصله اقلیدسی بین نمونه  $i$ ام و نمونه  $j$ ام،  $Instance_{ik}$  بیانگر مقدار نمونه  $i$ ام در بُعد  $k$ ام،  $Instance_{jk}$  بیانگر مقدار نمونه  $j$ ام در بُعد  $k$ ام و  $dim$  بیانگر تعداد ویژگی می‌باشد.

$$IG(f) = E(D) - E_f(D) \quad (3)$$

$f$ ام در مجموعه داده می‌باشد. که در ادامه روابط آنتروپی آورده شده است.

در رابطه ۳  $IG(f)$  بیانگر بهره اطلاعات ویژگی  $f$ ام،  $E(D)$  بیانگر آنتروپی مجموعه داده،  $E_f(D)$  بیانگر آنتروپی ویژگی

$$E(D) = - \sum_{i=1}^c P_i \times \log_2(P_i) \quad (4)$$

$$E_f(D) = \sum_{j=1}^v \frac{|D_j|}{|D|} \times E(D_j) \quad (5)$$

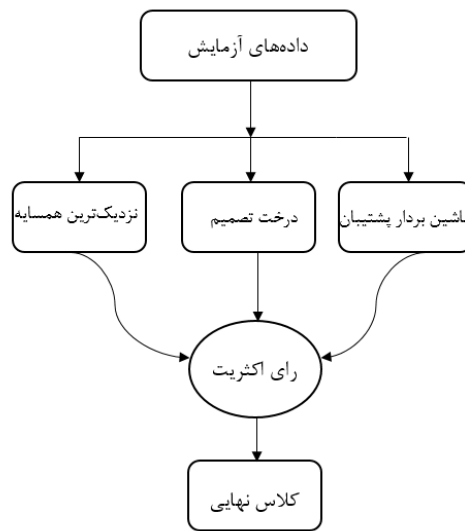


نسبت به نمونه‌های هر کلاس داشته باشد.

### ترکیب دسته‌بندی

در این پژوهش جهت دسته‌بندی نمونه‌ها از سه دسته‌بند ماشین بردار پشتیبان، درخت تصمیم و نزدیک‌ترین همسایه بهره گرفته شد از همین رو برای به‌دست آوردن نتایج نهایی از روش رأی اکثریت استفاده می‌گردد. در رأی اکثریت کلاسی به‌عنوان کلاس نهایی انتخاب می‌گردد که بیشتری رأی را آورده باشد. در شکل ۶ این عملیات نشان داده شده است.

در رابطه ۴ بیانگر احتمال تعداد نمونه‌هایی است که به کلاس  $P_i$  نام تعلق دارند،  $|D|$  بیانگر کل نمونه‌های مجموعه داده و  $|D_j|$  بیانگر تعداد نمونه‌هایی است که به کلاس  $j$  نام تعلق دارند. الگوریتم ماشین بردار پشتیبان جهت دسته‌بندی داده‌ها از روابط ریاضی استفاده می‌کند. مهم‌ترین مزیت الگوریتم ماشین بردار پشتیبان ایجاد بردارهای حاشیه می‌باشد. بردارهای حاشیه به بردارهایی گفته می‌شود که بین کلاس‌ها ایجاد می‌گردد و نمونه‌ها را به کلاس‌های مختلف دسته‌بندی می‌نماید. در الگوریتم ماشین بردار پشتیبان حاشیه‌ای انتخاب می‌گردد که بیشترین فاصله را



شکل ۵: رأی اکثریت

برای مثال نتایج روش پیشنهادی برای شکل ۶ به‌صورت زیر خواهد بود:



Svm: Covid  
KNN: Not Covid  
Tree: Covid

شکل ۶: نتایج دسته‌بندی برای تصاویر آزمایش

مناسب باشد، هر سه طبقه‌بند می‌توانند به‌درستی عملیات طبقه‌بندی را انجام دهند. یعنی تصاویر مورد استفاده باید ویژگی‌ها و جزئیات کافی را داشته باشند تا بتوان به‌درستی و به‌خوبی عملیات طبقه‌بندی را انجام داد. در مواردی که تصاویر پیچیده هستند یعنی جزئیات آن‌ها کم است یا موارد خاصی مانند نویز، تاری، تداخل و غیره دارند، که ممکن است عملکرد برخی از الگوریتم‌های

همان‌طور که در شکل ۶ نشان داده شده است، نتایج دسته‌بندی برای ماشین بردار پشتیبان برابر کووید، برای درخت تصمیم برابر کووید، ولی برای نزدیک‌ترین همسایه برابر غیر کووید شناسایی شده است. بنابراین نتیجه نهایی برابر کووید می‌باشد. یکی از مباحثی که در این بخش مورد توجه قرار می‌گیرد، بخش وزنی به طبقه‌بندی می‌باشد. در مواردی که پیچیدگی تصاویر

در مواجهه با تصاویر با پیچیدگی بالاتر دقت بهتری از خود نشان می‌دهد.

### نتایج

#### پارامترهای ارزیابی

پارامترهای به کار رفته در این پژوهش جزء پارامترهای دسته‌بندی می‌باشد که توسط ماتریس درهم‌ریختگی محاسبه می‌گردد. در شکل ۸ ماتریس درهم‌ریختگی نشان داده شده است.

طبقه‌بندی تحت‌تأثیر قرار گیرد. از جمله الگوریتم‌های طبقه‌بندی اشاره شده در متن، ماشین بردار پشتیبان (SVM) دارای دقت بیشتری در مواجهه با تصاویر پیچیده می‌باشد. به دلیل استفاده از روش ریاضی و پشتوانه ریاضی در SVM، این الگوریتم می‌تواند با پیچیدگی‌های تصاویر بهتر عمل کند و عملکرد بهتری نسبت به سایر الگوریتم‌های طبقه‌بندی داشته باشد. به همین دلیل وزن‌های تخصیص داده شده به طبقه‌بندها برای طبقه‌بندهای نزدیک‌ترین همسایه، درخت تصمیم و ماشین بردار پشتیبان به ترتیب برابر ۱، ۱ و ۲ می‌باشد که ماشین بردار پشتیبان بیشترین وزن را به خود اختصاص داده است، زیرا که این الگوریتم

		Predict	
		Normal	Covid
Real	Normal	TP	FN
	Covid	FP	TN

شکل ۸: ماتریس درهم‌ریختگی

استفاده شد. این پارامترها شامل دقت (Accuracy)، صحت (Precision)، بازخوانی (Recall) و F1-score می‌باشند، که با استفاده از ماتریس درهم‌ریختگی محاسبه می‌گردند. معیار دقت (Accuracy) نشان می‌دهد که چه درصدی از نمونه‌های تشخیص داده شده به درستی به دسته‌بندی صحیح تعلق دارند. معیار صحت (Precision) نسبت تعداد نمونه‌هایی است که به درستی به یک دسته مثبت تشخیص داده شده‌اند به کل تعداد نمونه‌هایی که به آن دسته مثبت تشخیص داده شده‌اند را نمایش می‌دهد. همچنین، معیار بازخوانی (Recall) نسبت تعداد نمونه‌هایی است که به درستی به یک دسته مثبت تشخیص داده شده‌اند به کل تعداد نمونه‌هایی که در واقع به آن دسته مثبت هستند را نمایش می‌دهد. در نهایت، معیار F1-score که معیار ترکیبی از صحت و بازخوانی است، برای ارزیابی جامع عملکرد روش پیشنهادی مورد استفاده قرار می‌گیرد.

در شکل ۸، TP (True Positive) بیانگر تعداد بیماری‌های است که نتیجه آزمایش آن‌ها سالم بوده و روش پیشنهادی نیز به درستی کلاس آن‌ها را سالم بازشناسی داده است. (False Positive) بیانگر تعداد بیماری‌های است که نتیجه آزمایش آن‌ها کووید-۱۹ بازشناسی داده شده است ولی روش پیشنهادی به اشتباه کلاس آن‌ها را سالم بازشناسی داده است. (False Negative) بیانگر تعداد بیماری‌های است که نتیجه آزمایش آن‌ها سالم بازشناسی داده شده است، ولی روش پیشنهادی به اشتباه کلاس آن‌ها را کووید-۱۹ بازشناسی داده است و TN (True Negative) بیانگر تعداد بیماری‌های است که نتیجه آزمایش آن‌ها کووید-۱۹ بوده و روش پیشنهادی نیز به درستی کلاس آن‌ها را کووید-۱۹ بازشناسی داده است. حال برای ارزیابی عملکرد روش پیشنهادی در بازشناسی بیماری کووید-۱۹ از تصاویر  $X$ ، از یک مجموعه پارامترهای ارزیابی

$$Accuracy = \frac{TP + TN}{TP + FP + FN + TN} * 100 \quad (۶)$$

$$Precision = \frac{TP}{TP + FP} * 100 \quad (۷)$$

$$Recall = \frac{TP}{TP + FN} * 100 \quad (۸)$$

$$F\ Measure = \frac{2 * Precision * Recall}{Precision + Recall} * 100 \quad (۹)$$

### بحث و نتیجه گیری

در این بخش نتایج روش پیشنهادی با نتایج بیان گردیده در مطالعه Ismael و Şengür [۱۸] براساس معیارهای ارزیابی مورد مقایسه قرار می‌گیرد که این نتایج در جدول ۲ آورده شده‌است.

با استفاده از این پارامترها و ماتریس درهم‌ریختگی، عملکرد روش پیشنهادی در بازشناسی بیماری کووید-۱۹ از تصاویر X-ray به‌طور دقیق و جامع ارزیابی می‌شود. این پارامترها اطلاعات کمی و کیفی در مورد قدرت تشخیص روش را ارائه می‌دهند و به محققان و پزشکان کمک می‌کنند تا بهبودهای لازم در روش پیشنهادی انجام دهند و در تصمیم‌گیری‌های بالینی بهتر راهنمایی کنند.

جدول ۲: نتایج روش پیشنهادی با روش‌های بیان گردیده در مطالعه Ismael و Şengür [۱۸]

روش مورد استفاده	مدل شبکه عصبی عمیق					
	SVM	ResNet18	ResNet50	ResNet101	VGG16	VGG19
کرنل خطی	۸۶/۳	۹۴/۷	۸۸/۴	۸۹/۵	۸۹/۵	۸۸/۴
کرنل درجه دوم	۸۷/۴	۹۱/۶	۹۱/۶	۸۹/۵	۸۹/۵	۸۷/۴
کرنل مکعبی	۸۹/۵	۹۰/۵	۹۱/۶	۹۰/۵	۹۰/۵	۸۹/۵
کرنل گوسی	۸۶/۳	۹۳/۷	۸۸/۴	۸۹/۵	۸۹/۵	۸۷/۴
		<b>دقت</b>	<b>صحت</b>	<b>بازخوانی</b>	<b>F معیار</b>	
	روش پیشنهادی ما (بدون وزن دهی به دسته‌بندها)	۹۶/۵۰	۹۲/۲۵	۹۴	۹۳	
	روش پیشنهادی ما (با وزن دهی به دسته‌بندها)	۹۷/۵۰	۹۵	۹۶	۹۵	

مختلفی جهت نشان دادن برتری روش پیشنهادی از رابطه زیر بهره گرفته شد:

همان‌طور که در جدول ۲ نشان داده شده است، کارایی روش پیشنهادی نسبت به روش‌های بیان گردیده در مطالعه Ismael و Şengür [۱۸] بیشتر می‌باشد. در این مطالعه از روش‌های

$$WR = \frac{ACC_{Our} - ACC_{Predict}}{ACC_{Our}} * 100 \quad (10)$$

داشته باشند. این لایه‌ها با کاهش تعداد پارامترها و محاسبات مورد نیاز، بهبود سرعت و کارایی مدل‌ها را فراهم می‌کنند. نتایج آزمایش‌های انجام شده در این پژوهش، کارآمدی و قدرت تشخیص بالایی روش پیشنهادی را تأیید می‌کنند. استفاده از لایه‌های Separable منجر به کاهش محاسبات و توان محاسباتی مورد نیاز می‌شود، در حالی که همچنان دقت و صحت تشخیص بالایی را ارائه می‌دهد. همچنین، ترکیب دسته‌بندها به‌عنوان یک روش ترکیبی، باعث بهبود قابل توجهی در نتایج نهایی می‌شود و قابلیت استفاده بهینه از قدرت تمام دسته‌بندها را فراهم می‌کند.

در نتیجه، این پژوهش بهبود قابل توجهی در تشخیص بیماری کووید-۱۹ از طریق تصاویر X-ray ارائه می‌دهد. با استفاده از روش پیشنهادی، علاوه بر بهبود کارایی و دقت، توان محاسباتی کاهش می‌یابد که به‌طور کلی مزایای قابل توجهی را در ارائه راهکاری علمی و کاربردی برای تشخیص این بیماری دارد.

پیشنهادی‌هایی هم در این زمینه ارائه می‌شود، استفاده از شبکه‌های عمیق پیشرفته‌تر: بررسی و استفاده از شبکه‌های یادگیری عمیق پیشرفته‌تر، مانند شبکه‌های ترن سفر دانش (Transfer Learning) و شبکه‌های مکانیسم توجه (Attention Mechanism)، می‌تواند بهبود قابل توجهی در دقت و عملکرد دسته‌بندی تصاویر ارائه دهد.

ترکیب اطلاعات: می‌توان اطلاعات دیگری مانند اطلاعات بالینی، سابقه پزشکی بیمار و داده‌های لابراتوار را با تصاویر اشعه ایکس قفسه سینه ترکیب کرده و از این ترکیب برای تشخیص دقیق‌تر و پیش‌بینی بهتر استفاده کرد.

استفاده از تصاویر سه‌بعدی: تصاویر سه‌بعدی از ریه‌ها و قفسه سینه را می‌توان برای تشخیص کووید-۱۹ استفاده کرد. این تصاویر اطلاعات بیشتری از حالت و شکل بیماری‌ها ارائه می‌دهند و می‌توانند دقت تشخیص را بهبود بخشند.

### تعارض منافع

این مطالعه به‌صورت مستقل و بدون حمایت مالی هیچ سازمانی انجام پذیرفت و هیچ‌گونه تعارض منافی در آن وجود ندارد.

در رابطه ۱۰،  $WR$  بیانگر میزان برتری روش پیشنهادی نسبت به روش ارزیابی،  $ACC_{Our}$  بیانگر دقت روش پیشنهادی این پژوهش و  $ACC_{Predict}$  بیانگر دقت روش ارزیابی می‌باشد. نتایج نشان داده است که روش پیشنهادی بهبود قابل توجهی در دقت نسبت به روش‌های قبلی داشته است. به‌عنوان مثال، در مقایسه با شبکه‌های Resnet با ۱۸، ۵۰ و ۱۰۱ لایه، روش پیشنهادی به ترتیب ۷، ۵ و ۴/۹ درصد برتری داشته است. همچنین، نسبت به شبکه‌های VGG با ۱۶ و ۱۹ لایه، به ترتیب ۶ و ۷ درصد برتری نیز داشته است.

نتایج حاکی از این است که ماشین بردار پشتیبان با هسته درجه سوم (مکعب) بهترین نتایج را نسبت به روش‌های دیگر به ارمغان آورده است. عملکرد بهتر ماشین بردار پشتیبان در مقایسه با سایر شبکه‌ها و الگوریتم‌ها، نشان از قدرت ریاضی این الگوریتم در بازشناسی تصاویر کووید-۱۹ می‌دهد.

همچنین با توجه به تحلیل بخش دوم جدول ۲، تلاش‌های انجام شده نشان داد که اضافه کردن مرحله وزن‌دهی به طبقه‌بندها منجر به بهبود عملکرد در تشخیص و شناسایی تصاویر مرتبط با کووید-۱۹ می‌شود. همچنین، نتایج حاکی از دقت بهتر نسبت به روش‌های قبلی است که این بهبود عملکرد به دلیل تخصیص وزن بیشتر به الگوریتم ماشین بردار پشتیبان صورت گرفته است. توجه به این نکته ضروری است که الگوریتم ماشین بردار پشتیبان به دلیل قابلیت ریاضی خاص خود، قادر به بهبود دقت در مقابل تصاویر پیچیده‌تر است. از این رو، بهبود عملکرد و دقت بالاتر در مقایسه با روش‌های قبلی مشاهده می‌شود.

در این پژوهش، برای بازشناسی بیماری کووید-۱۹ از طریق تصاویر X-ray، یک فرآیند چند مرحله‌ای مورد استفاده قرار گرفته است. این فرآیند شامل چهار فاز اصلی شامل پیش‌پردازش، استخراج ویژگی، دسته‌بندی و ترکیب دسته‌بندها می‌باشد. در بخش استخراج ویژگی، از شبکه‌های یادگیری عمیق با لایه‌های Separable استفاده شد. لایه‌های Separable یک روش پیشرفته برای انجام عملیات کانولوشن هستند که می‌توانند بهبود قابل توجهی در عملکرد مدل‌های یادگیری عمیق

## References

- Murphy A, Liszewski B. Artificial Intelligence and the Medical Radiation Profession: How Our Advocacy Must Inform Future Practice. *J Med Imaging Radiat Sci* 2019; 50(4):S15–9. doi: 10.1016/j.jmir.2019.09.001.
- Wu F, Zhao S, Yu B, Chen YM, Wang W, Song ZG, et al. A new coronavirus associated with human respiratory disease in China. *Nature* 2020;579(7798):265-9. doi: 10.1038/s41586-020-2008-3.
- Masood S, Sharif M, Masood A, Yasmin M, Raza M. A survey on medical image segmentation. *Current Medical Imaging* 2015;11(1):3-14.
- Lou A, Guan S, Loew M. DC-UNet: Rethinking the U-Net Architecture with Dual Channel Efficient CNN for Medical Images Segmentation. arXiv:2006.00414. <https://doi.org/10.48550/arXiv.2006.00414>
- Singh D, Kumar V, Vaishali, Kaur M. Classification of COVID-19 patients from chest CT images using multi-objective differential evolution-based convolutional neural networks. *European Journal of Clinical Microbiology & Infectious Diseases* 2020;39:1379-89.
- Pathak Y, Shukla PK, Tiwari A, Stalin S, Singh S. Deep transfer learning based classification model for COVID-19 disease. *IRBM* 2022;43(2):87-92. <https://doi.org/10.1016/j.irbm.2020.05.003>
- Zu ZY, Jiang MD, Xu PP, Chen W, Ni QQ, Lu GM, et al. Coronavirus disease 2019 (COVID-19): a perspective from China. *Radiology* 2020;296(2):E15-25. doi: 10.1148/radiol.2020200490.
- World Health Organization. Coronavirus disease (COVID-19) Pandemic; 2020. Available from: [cited 2021 Sep 2] <https://www.who.int/emergencies/diseases/novel-coronavirus-2019>.
- Worldmeter. (2020). COVID-19 Coronavirus Pandemic; 2020. [cited 2020 Mar 23]. Available from: <https://www.worldometers.info/coronavirus>.
- Radiology Assistant. X-ray Chest images; 2020. [cited 2020 Mar 23]. Available from: <https://radiologyassistant.nl/chest/lk-jg-1>.
- Gao J, Jiang Q, Zhou B, Chen D. Convolutional neural networks for computer-aided detection or diagnosis in medical image analysis: An overview. *Math Biosci Eng* 2019;16(6):6536-61. doi: 10.3934/mbe.2019326.
- Takahashi R, Kajikawa Y. Computer-aided diagnosis: A survey with bibliometric analysis. *Int J Med Inform* 2017;101:58-67. doi: 10.1016/j.ijmedinf.2017.02.004.
- Kesim E, Dokur Z, Olmez T. X-ray chest image classification by a small-sized convolutional neural network. *Scientific Meeting on Electrical-Electronics & Biomedical Engineering and Computer Science (EBBT)*; 2019 Apr 24-26; Istanbul, Turkey: IEEE; 2019. p. 1-5. doi: 10.1109/EBBT.2019.8742050
- Singh D, Kumar V, Vaishali, Kaur M. Classification of COVID-19 patients from chest CT images using multi-objective differential evolution-based convolutional neural networks. *Eur J Clin Microbiol Infect Dis* 2020; 39(7):1379–89. doi: 10.1007/s10096-020-03901-z.
- Hu S, Gao Y, Niu Z, Jiang Y, Li L, Xiao X, et al. Weakly supervised deep learning for covid-19 infection detection and classification from ct images. *IEEE Access* 2020;8:118869-83. doi: 10.1109/ACCESS.2020.3005510
- Abbas A, Abdelsamea MM, Gaber MM. Classification of COVID-19 in chest X-ray images using DeTraC deep convolutional neural network. *Appl Intell (Dordr)* 2021;51(2):854-64. doi: 10.1007/s10489-020-01829-7.
- Makris A, Kontopoulos I, Tserpes K. COVID-19 detection from chest X-Ray images using Deep Learning and Convolutional Neural Networks. medRxiv 2020. doi: <https://doi.org/10.1101/2020.05.22.20110817>
- Ismael AM, Şengür A. Deep learning approaches for COVID-19 detection based on chest X-ray images. *Expert Syst Appl* 2021; 164:114054. doi: 10.1016/j.eswa.2020.114054
- Roy I, Shai R, Ghosh A, Bej A, Pati SK. CoWarriorNet: A novel deep-learning framework for COVID-19 detection from chest X-ray images. *New Gener Comput* 2022;40(4):961-85. doi: 10.1007/s00354-021-00143-1.
- Farooq M, Hafeez A. Covid-resnet: A deep learning framework for screening of covid19 from radiographs. arXiv preprint arXiv:2003.14395. 2020. <https://doi.org/10.48550/arXiv.2003.14395>
- Goel T, Murugan R, Mirjalili S, Chakrabarty DK. OptCoNet: an optimized convolutional neural network for an automatic diagnosis of COVID-19. *Appl Intell (Dordr)* 2021;51(3):1351-66. doi: 10.1007/s10489-020-01904-z.
- Karim AM, Kaya H, Alcan V, Sen B, Hadimlioglu IA. New optimized deep learning application for COVID-19 detection in chest X-ray images. *Symmetry* 2022;14(5):1003. <https://doi.org/10.3390/sym14051003>
- Nagib AE, Saeed MM, El-Feky SF, Mohamed AK. Hyperparameters optimization of deep convolutional neural network for detecting COVID-19 using differential evolution. In *Decision Sciences for COVID-19: Learning Through Case Studies*. Cham: Springer International Publishing; 2022. p. 305-25.
- Louati H, Louati A, Bechikh S, Masmoudi F, Aldaej A, Kariri E. Topology optimization search of deep convolution neural networks for CT and X-ray image classification. *BMC Med Imaging* 2022;22(1):120. doi: 10.1186/s12880-022-00847-w
- Bekhet S, Alkinani MH, Tabares-Soto R, Hassaballah M. An Efficient Method for Covid-19 Detection Using Light Weight Convolutional Neural Network. *Computers, Materials & Continua* 2021;69(2):2475-91. <https://doi.org/10.32604/cmc.2021.018514>
- Cortes C, Vapnik V. Support-vector networks. *Machine Learning* 1995;20:273-97.

27. Wang L, Li M. An Efficient Image Retrieval Based on Fusion of Low-Level Visual Features. *Expert Systems with Applications* 2014; 41(4): 1584-92. <https://doi.org/10.48550/arXiv.1811.12695>
28. Li C, Xu C, Gui C, Fox MD. Distance regularized level set evolution and its application to image segmentation. *IEEE Transactions on Image Processing* 2010;19(12):3243-54. doi: 10.1109/TIP.2010.2069690
29. Boser BE, Guyon IM, Vapnik VN. A training algorithm for optimal margin classifiers. In *Proceedings of the fifth annual workshop on Computational Learning Theory*; 1992 Jul 27-29; New York NY, United States: Association for Computing Machinery; 1992. p. 144-52. <https://doi.org/10.1145/130385.130401>
30. Peterson LE. K-nearest neighbor. *Scholarpedia* 2009;4(2):1883.
31. Quinlan JR. Induction of decision trees. *Machine Learning* 1986;1(1): 81-106. <https://doi.org/10.1023/A:1022643204877>