CoviX-Net: سامانهٔ مبتنی بر یادگیری عمیق برای تشخیص و تمایز عفونت کوید-۱۹ و ذات‌الریه در تصاویر رادیوگرافی قفسهٔ سینه

وحید محمّدیان تکالو[۱و۲]، مهدی هاشم‌زاده[۱و۲*] و جلیل قویدل نیچران[۱و۲]

[۱]دانشکده فناوری اطلاعات و مهندسی کامپیوتر دانشگاه شهید مدنی آذربایجان، تبریز، ایران

[۲]آزمایشگاه تحقیقاتی هوش مصنوعی و یادگیری ماشین دانشگاه شهید مدنی آذربایجان، تبریز، ایران

چکیده

در این پژوهش، سامانه CoviX-Net مبتنی بر یادگیری عمیق برای تشخیص و تمایز بیماری کوید-۱۹ و انواع ذات‌الریه از روی تصاویر رادیوگرافی سینه ارائه می‌شود. معماری مدل یادگیری CoviX-Net، بر اساس معماری اِکسپشن چند لایه و متناسب با کاربرد مورد هدف طراحی شده‌است. در این سامانه، از یادگیری انتقالی برای رفع مشکل کمبود داده آموزشی استفاده می‌شود. همچنین برای فراهم‌کردن داده آموزشی کافی، یک پایگاه تصاویر جامع با بهره‌گیری مناسب از دو منبع مختلف از تصاویر قفسه سینه ایجاد و برای جلوگیری از مشکل بیش‌برازش، فنون افزایش داده، تَنزلِ وزن و تنظیم کننده‌های L2 استفاده شده‌است. نتایج ارزیابی‌ها نشان می‌دهد دقت CoviX-Net در حالت سه طبقه (کوید-۱۹، ذات‌الریه و ریه طبیعی) ٪۹۹/۲۵، و در حالت چهار طبقه (کوید-۱۹، ذات‌الریه باکتریایی، ذات‌الریه ویروسی و ریه طبیعی) ٪۹۵ است که در مقایسه با دیگر روش‌های طبقه‌بندی مبتنی بر یادگیری عمیق با ساختار مشابه، بهبود دقت ٪۵ و در مقایسه با روش مبتنی بر یادگیری عمیق انتقالی موازی، با ساختار پیچیده، بهبود دقت حدود نیم درصد را دارد. کلیه کدهای پیاده‌سازی CoviX-Net و مجموعه تصاویر گردآوری‌شده در دسترس عموم پژوهش‌گران قرار گرفته‌است.

واژگان کلیدی: بینایی ماشین - یادگیری عمیق - تشخیص کوید-۱۹ - ذات‌الریه - تصاویر رادیوگرافی قفسه سینه.

CoviX-Net: A Deep Learning-based System for Diagnosis and Differentiation of Covid-19 Infection and Pneumonia in Chest Radiography Images

Vahid Mohammadian Takaloo[1,2], Mahdi Hashemzadeh[*1,2] & Jalil Ghavidel Neycharan[1,2]

[1]Faculty of Information Technology and Computer Engineering, Azarbaijan Shahid Madani University, Tabriz, Iran

[2]Artificial Intelligence and Machine Learning Research Laboratory, Azarbaijan Shahid Madani University, Tabriz, Iran

Abstract

Coronavirus (Covid-19) is a new infectious disease with a very high rate of infection and mortality. Therefore, its early detection has become one of the vital measures of human society. This virus is commonly tested using sputum or blood samples, and the result is usually announced within hours or even days after the test. However, even an hour delay in announcing the test results can lead to many more people being infected. Another way to diagnose the virus is to take a chest X-ray (chest radiography images), which is much faster and cheaper than other tests. However, the rate of human diagnostic error from these images is high, and more importantly, it is very difficult to distinguish Covid-19 infection from other infections such as pneumonia. In this paper, an intelligent system, termed CoviX-Net, based on deep machine learning techniques, is presented to diagnose and differentiate Covid-19 disease and various types of pneumonia (bacterial or viral) using chest radiographs. The

* نویسندهٔ عهده‌دار مکاتبات

* Corresponding author

• تاریخ ارسال مقاله: ۱۴۰۰/۳/۱۲ • تاریخ پذیرش: ۱۴۰۲/۹/۲۰ • تاریخ انتشار: ۱۴۰۲/۱۰/۲۴ • نوع مطالعه: پژوهشی

سال ۱۴۰۲ شمارهٔ ۳ پیاپی ۵۷

[Downloaded from jsdp.rcisp.ac.ir on 2026-11-25]

[DOI: 10.61186/jsdp.20.3.27]

CoviX-Net learning model is based on the Xception architecture, the accuracy of which is improved by the use of transfer learning and data augmentation techniques. To provide adequate training data, a comprehensive database is created by integrating two different sources of chest X-ray images. The evaluations performed on the test images show that the accuracy of CoviX-Net diagnosis in the three-class mode (Covid-19, pneumonia, and normal lung) is %99.25, and in the four-class mode (Covid-19, bacterial pneumonia, viral pneumonia, and normal lung) is %95. Compared to other similar deep learning-based classification methods, the accuracy is improved by 5%, and compared to the transfer learning-based parallel deep learning method, with a complex structure, the accuracy is improved by about half a percent. These promising results demonstrate the superiority of CoviX-Net against the competitors, and suggest that CoviX-Net can be a useful tool to assist clinicians and radiologists in diagnosing patients with Covid-19. All the implementation source codes and collected dataset are made publicly available.

Keywords: Machine vision - Deep learning - Covid-19 diagnosis - Pneumonia - Chest radiography images.

۱- مقدمه

بیماری کرونا ویروس ۲۰۱۹ (کوید-۱۹[1])، ناشی از سندرم تنفسی حاد شدید کرونا ویروس ۲[2]، یک بیماری همه‌گیر جهانی است [1]. پس از مشاهده اولیه این ویروس در آذر ماه سال ۱۳۹۸ در شهر ووهان چین، به‌سرعت در سراسر جهان گسترش یافته و به یک بیماری همه‌گیر تبدیل شده‌است. سازمان بهداشت جهانی شیوع این بیماری را در تاریخ ۱۰ بهمن ماه ۱۳۹۸ به عنوان یک بحران بهداشت عمومی در حوزه بین‌الملل[3] اعلام کرد و ۲۱ اسفند ۱۳۹۸ آن را به عنوان یک بیماری همه‌گیر تشخیص داد. طبق آمار اعلام‌شده توسط سازمان بهداشت جهانی[4] در تاریخ ۱ خرداد ماه سال ۱۴۰۰، در جهان بیش از ۱۶۵ میلیون مورد ابتلا به کوید-۱۹ و حدود سه میلیون مورد منجر به مرگ گزارش شده‌است. این ویروس در بسیاری از کشورها، نظام‌های مراقبت بهداشتی را به چالش بسیار جدی کشیده‌است [1]. علائم مختلفی از جمله سرفه خشک، گلودرد، تب، نارسایی اندام، شوک سپتیک، ذات‌الریه شدید و سندرم حاد تنفسی[5] در بیماران مبتلا به این ویروس مشاهده می‌شود [2]؛ و به‌دلیل موجودنبودن داروی ویژه این بیماری، گسترش این بیماری به یک بحران جهانی تبدیل شده‌است [3].

یکی از عوارض اصلی ناشی از ویروس کوید-۱۹، نوع شدید ذات‌الریه است. ذات‌الریه عفونت بخشی از ریه (آلوئول، مجاری آلوئولار و برونشیول تنفسی) است، که مسئول انتقال گاز اکسیژن بوده و می‌تواند به‌وسیلهٔ اُرگانیسم‌های مختلف مانند ویروس‌ها، باکتری‌ها یا قارچ‌ها ایجاد شود. بیماری ذات‌الریه را نمی‌توان به عنوان یک بیماری واحد طبقه‌بندی کرد، بلکه به عنوان یک گروه از عفونت‌های مختلف با ویژگی‌های گوناگون طبقه‌بندی می‌شود.

در شکل (۱) انواع ذات‌الریه ناشی از میکرو اُرگانیسم‌ها[6] به‌صورت سلسله‌مراتبی نشان داده شده‌است. در این شکل، سیزده گره وجود دارد که شش مورد آنها گره برگ است؛ یعنی نوع واقعی ذات‌الریه هستند. بیماری ذات‌الریه توسط میکروأرگانیسم‌های سلولی یا غیرسلولی ایجاد می‌شود. ذات‌الریه غیرسلولی ویروسی[7] می‌تواند به کرونا ویروس یا واریسلا تقسیم شود. ذات‌الریه سلولی نیز می‌تواند به ذات‌الریه باکتریایی[8] و استرپتوکوک‌ها یا ذات‌الریه قارچی[9] و در نهایت پنوموسیستیس منجر شود. همچنین کرونا ویروس را می‌توان به سه دسته سارس، مرس یا کوید-۱۹ طبقه‌بندی کرد. این تقسیم‌بندی سلسله‌مراتبی مطابق با ساختار ارائه شده در دهمین نسخه از طبقه‌بندی آماری بین‌المللی بیماری‌ها و مشکلات مربوط به بهداشت[10] است [4]. نکته مهمی که در این ساختار سلسله‌مراتبی قابل برداشت است، این است که تشابه عفونت ناشی از بیماری کرونا با دیگر عفونت‌های ریه بسیار زیاد خواهد بود که عمل تشخیص و تمایز آنها را دشوار می‌کند [4].

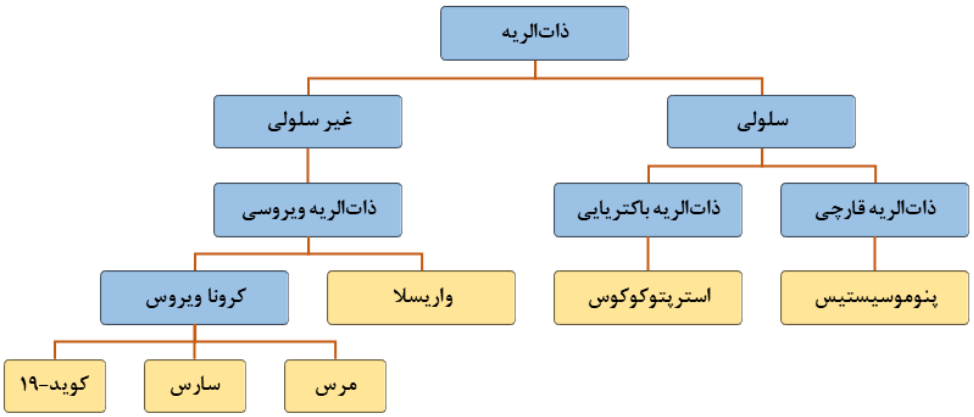
یک گام مهم در مبارزه با بیماری کوید-۱۹ غربالگری مؤثر بیماران آلوده است؛ به‌گونه‌ای که مبتلایان از بقیه افراد سالم جدا شده و تحت درمان و رسیدگی قرار گیرند. با توجه به اینکه میزان مرگ و میر ناشی از این بیماری به‌طور نگران‌کننده‌ای در سراسر جهان در حال افزایش است، نیاز به تشخیص سریع بیماری برای جلوگیری از شیوع آن، حیاتی به نظر می‌رسد.

[1] Covid-19
[2] SARS-CoV-2
[3] PHEIC
[4] World Health Organization
[5] ARDS

[6] Microorganisms
[7] Viral Pneumonia
[8] Bacterial Pneumonia
[9] Fungal Pneumonia
[10] ICD-10

[Downloaded from jsdp.rcisp.ac.ir on 2026-11-25]

[DOI: 10.61186/jsdp.20.3.27]



(شکل-۱): طبقه‌بندی سلسله‌مراتبی انواع ذات‌الریه ناشی از میکرو اُرگانیسم‌ها (برگردان شده از [4])

[4] (Figure-1): Hierarchical classification of types of pneumonia caused by microorganism

هم‌اکنون آزمایش آرتی-پی‌سی‌آر[1] به‌عنوان یک استاندارد مرسوم برای شناسایی بیماران کوید-۱۹ شناخته می‌شود؛ درحالی‌که این روش آزمایش در بسیاری از مناطق، به‌ویژه مناطقی که در هنگام شیوع اولیه این بیماری به‌شدت آسیب دیده‌اند، به‌تنهایی پاسخ‌گو و کافی نیست. همچنین میزان حساسیت این آزمایش آزمایشگاهی خیلی پایین است و نتایج مثبت کاذب و منفی کاذب زیادی دارد [5]. البته این حساسیت به عوامل متعددی مانند تهیه نمونه و کنترل کیفیت نیز بستگی دارد.

تجهیزات تصویربرداری پزشکی نظیر اشعه ایکس قفسه سینه[2] و سی‌تی‌اسکن قفسه سینه[3] نیز می‌توانند به‌عنوان ابزار شناسایی، به پزشکان برای تشخیص این بیماری کمک کنند؛ به‌طوری‌که پزشکان با بررسی وضعیت ریه افراد در تصاویر قفسه سینه می‌توانند عفونت ریه را تشخیص دهند. یک نظام تشخیص مبتنی بر تصاویر رادیوگرافی قفسه سینه می‌تواند مزایای زیادی نسبت به روش آرتی-پی‌سی‌آر داشته باشد. این روش سریع‌تر و ارزان‌تر است و امکان تجزیه و تحلیل همزمان چندین مورد وجود دارد. برخلاف آزمایش آرتی-پی‌سی‌آر، امروزه امکانات تصویربرداری اشعه ایکس قفسه سینه در اغلب بیمارستان‌ها موجود است [6]. البته در روش‌های تصویربرداری پزشکی، تصاویر سی‌تی‌اسکن دقیق‌تر از تصاویر اشعه ایکس هستند. با این حال، نسبت به روش اشعه ایکس گران‌تر و دسترسی عموم به آن نیز کمتر است [7]. برخی از دستگاه‌های سی‌تی‌اسکن ممکن است میلیون‌ها دلار هزینه داشته باشند؛ درحالی‌که هزینه دستگاه‌های اشعه ایکس بسیار کمتر از آن است؛ بنابراین، استفاده از تصاویر اشعه ایکس قفسه سینه برای تشخیص بیماری کوید-۱۹ گزینه ارزان‌تر و مناسب‌تری می‌تواند باشد. البته به شرط اینکه بتوان به‌دقت تشخیص مناسب بیماری با استفاده از این تصاویر دست یافت. چراکه به‌طورمعمول عوامل متعددی نظیر خطای دید انسانی، حالات مختلف عفونت ریه، وجود عفونت‌های دیگر ریه مانند انواع مختلف ذات‌الریه و غیره باعث می‌شوند پزشکان نتوانند با دقت قابل اطمینانی عفونت ناشی از کوید-۱۹ را تشخیص دهند و یا آن را با سایر عفونت‌های ریه متمایز کنند.

در برخی مواقع تشخیص این بیماری از روی تصاویر رادیوگرافی قفسه سینه حتی برای رادیولوژیست‌های باتجربه نیز می‌تواند دشوار باشد؛ ازاین‌رو، استفاده از راه‌کارهای مبتنی بر بینایی ماشین و جهت آنالیز هرچه دقیق‌تر تصاویر رادیوگرافی قفسه سینه می‌تواند برای کمک به تشخیص این بیماری، بسیار مفید واقع شود و پزشکان را در تشخیص سریع‌تر و کم هزینه‌تر این بیماری خطرناک یاری کند؛ همچنین چنین سامانه هوشمندی می‌تواند به‌طور قابل توجهی به خودکارشدن فرایند تشخیص کمک کند و کادر درمان را در معرض کمترین تماس با افراد مشکوک و مبتلا قرار دهد [8].

در این مقاله، سامانه **CoviX-Net**[4]، که یک روش مبتنی بر بینایی ماشین و یادگیری ماشین عمیق است، برای تشخیص و تمایز بیماری کوید-۱۹ و انواع ذات‌الریه (باکتریایی یا ویروسی) از روی تصاویر رادیوگرافی قفسه سینه ارائه می‌شود. با توجه به نیاز مبرم به تعداد داده آموزشی کافی در روش‌های مبتنی بر یادگیری عمیق، لازم است تعداد تصاویر قفسه سینه برچسب‌گذاری‌شدهٔ کافی در اختیار داشته باشیم. با رشد سریع و گسترش کوید-۱۹

[1] RT-PCR
[2] Chest X-ray
[3] Chest CT scan

[4] Covid-19 Xception Network

[Downloaded from jsdp.rcisp.ac.ir on 2026-11-25]
[DOI: 10.61186/jsdp.20.3.27]

در سطح جهانی، پژوهش‌گران با چالش‌های جدی در زمینه طراحی و اجرای سامانه‌های هوشمند برای تشخیص، تمایز و پیش‌بینی این بیماری روبه‌رو شده‌اند. مهم‌ترین چالش‌های مرتبط با کوید-۱۹ در دسترس‌نبودن داده‌ها و طراحی معماری مناسب روش‌های یادگیری ماشین برای تشخیص و تمایز بیماری کوید-۱۹ با انواع ذات‌الریه (باکتریایی و ویروسی) است.

به‌دلیل نوظهوربودن بیماری کوید-۱۹، پایگاه داده رادیوگرافی جامعی، که علاوه‌بر تصاویر بیماران مشکوک به کوید-۱۹، شامل تصاویر بیماران ذات‌الریه با انواع مختلف نیز باشد، در دسترس نیست. عدم دسترسی به چنین پایگاه داده منسجمی یک چالش اساسی برای پژوهش در این زمینه است؛ چرا که تمایز بیماران مبتلا به کوید-۱۹ از بیماران ذات‌الریه در تشخیص صحیح پزشکی از اهمیت زیادی برخوردار است؛ بنابراین، ارائه و جمع‌آوری یک پایگاه داده جامع از تصاویر اشعه ایکس قفسه سینه چهار طبقه برای پژوهش و اجرای سامانه‌های هوشمند برای پژوهش‌گران در زمینه یادگیری عمیق بسیار مهم است. برای جبران این نقیصه، در این پژوهش یک پایگاه تصاویر جامع برای آموزش مدل یادگیری **CoviX-Net** با بهره‌گیری مناسب از دو منبع مختلف از تصاویر قفسه سینه فراهم می‌شود.

دومین چالش موجود در این زمینه، طراحی و پیاده‌سازی یک معماری مناسب یادگیری عمیق برای تشخیص هر چه دقیق‌تر بیماری کوید-۱۹ و بویژه تمایز آن با انواع ذات‌الریه (باکتریایی و ویروسی) با کمترین میزان خطا است. بیشتر کارهای انجام‌شده در این حوزه، بر روی تشخیص بیماری کوید-۱۹ (طبقه‌بندی کننده دو طبقه) تمرکز کرده‌اند و تعداد بسیار کمی از آنان به تمایز بیماری کوید-۱۹ با انواع ذات‌الریه (باکتریایی و ویروسی) پرداخته‌اند. معدود کارهای موجود نیز دقت به‌نسبه پایینی دارند و اغلب بر روی یک پایگاه داده با تعداد تصاویر محدودی مورد آزمایش قرار گرفته‌اند که از قابلیت اطمینان کافی برخوردار نیستند.

مدل آموزشی **CoviX-Net**، ترکیب یک شبکه عصبی مصنوعی کانولوشنی با معماری انتقالی اکسپشن[1] [9] چند لایه است. این مدل می‌تواند وزن‌های آموزش دیده از مجموعه‌داده‌های بزرگ قبلی را به‌عنوان وزن‌های اولیه مدل جدید مورد استفاده قرار دهد و تا حدودی مشکل کمبود داده را جبران کند. برای جلوگیری از مشکل بیش‌برازش[2]، از فنون افزایش داده[3]، تنزل وزن[4] و تنظیم کننده‌های-ال۲[5] استفاده می‌شود. نتایج آزمایش‌ها و ارزیابی‌های انجام‌شده بر روی تصاویر آزمون نشان می‌دهد، دقت تشخیص **CoviX-Net** در حالت سه طبقه (کوید-۱۹، ذات‌الریه و ریه طبیعی) ۹۹/۲۵ درصد، و در حالت چهار طبقه (کوید-۱۹، ذات‌الریه باکتریایی، ذات‌الریه ویروسی و ریه طبیعی) ۹۵ درصد است. این نتایج نشان‌دهنده برتری **CoviX-Net** در مقایسه با دیگر روش‌های موجود است؛ که می‌تواند به عنوان ابزاری مفید برای پزشکان بالینی و رادیولوژیست‌ها در شناسایی مبتلایان بیماری کوید-۱۹ باشد.

در این پژوهش، ما از معماری اکسپشن که توسط فرانسوا شوله[6] در سال ۲۰۱۷ ارائه شد [9]، استفاده کرده‌ایم. اکسپشن دارای یک معماری ۷۱ لایه‌ای عمیق کانولوشنی است، که در آن از لایه‌های کانولوشن قابل تفکیک عمقی[7] استفاده شده‌است. این معماری، یادگیری ویژگی‌های کانال و فضا را از هم جدا می‌کند؛ علاوه بر این، اتصالات باقی‌مانده برای حل مشکل ناپدیدشدن گرادیان‌ها و گلوگاه‌های نمایشی با ایجاد میان‌بر در شبکه ترتیبی استفاده می‌شود. معماری اکسپشن با این ویژگی‌ها، در بیشتر چالش‌های طبقه‌بندی تصاویر عملکرد بهتری نسبت به معماری‌های **VGG-16**، **ResNet** و **Inception-V3** داشته است که از این حیث یک برتری مهم برای سامانه پیشنهادی محسوب می‌شود.

به‌اختصار نوآوری‌های این پژوهش را می‌توان در دو مورد زیر خلاصه کرد:

۱) گردآوری یک پایگاه تصاویر جامع چهار طبقه (شامل کوید-۱۹، ذات‌الریه باکتریایی، ذات‌الریه ویروسی و ریه سالم) برای آموزش و ارزیابی مدل‌های یادگیری ماشین با بهره‌گیری مناسب از دو منبع مختلف از تصاویر قفسه سینه. این پایگاه داده در دسترس عموم پژوهش‌گران قرار داده می‌شود.

۲) طراحی یک معماری یادگیری عمیق کانولوشنی متناسب با کاربرد مورد هدف و ترکیب آن با معماری انتقالی اکسپشن جهت انجام طبقه‌بندی چهار طبقه به‌طوری‌که با دقت عمل مناسبی بتواند نه تنها بیماری کوید-۱۹ را تشخیص دهد، بلکه موارد ناشی از ذات‌الریه را نیز متمایز کند.

ادامه مقاله به شرح زیر است: بخش ۲ کارهای مرتبط و مطالعات پیشین را ارائه می‌دهد. بخش ۳ جزئیات

[1] Xception
[2] Over-fitting

[3] Data Augmentation
[4] Weight Decay
[5] L2-Regularizers
[6] Francois Chollet
[7] Depthwise Separable Convolution

[Downloaded from jsdp.rcisp.ac.ir on 2026-11-25]
[DOI: 10.61186/jsdp.20.3.27]

مربوط به سامانه **CoviX-Net** را توضیح می‌دهد. بخش ۴ نتایج آزمایش‌ها و ارزیابی‌های صورت‌گرفته را ارائه می‌کند. و درنهایت بخش ۵ به نتیجه‌گیری و کارهای آینده می‌پردازد.

۲- کارهای پیشین

تاکنون موارد متعددی از سامانه‌های تشخیص رایانه‌ای[1]، با بهره‌گیری از یادگیری عمیق بر روی تصاویر رادیوگرافی سینه، برای تشخیص ابتلا به کوید-۱۹ در حالت دوطبقه (کوید-۱۹، ریه طبیعی) ارائه شده‌اند. برخی نیز برای حالت سه‌طبقه (کوید-۱۹، ذات‌الریه و ریه طبیعی) هستند. اما تشخیص حالت چهارطبقه (کوید-۱۹، ذات‌الریه باکتریایی، ذات‌الریه ویروسی و ریه طبیعی) به‌ندرت مورد مطالعه قرار گرفته است. درکل این روش‌ها را می‌توان به دو دسته روش‌های مبتنی بر قطعه‌بندی[2] و روش‌های مبتنی بر طبقه‌بندی[3] با استفاده از الگوریتم‌های یادگیری ماشین تقسیم کرد [10, 11].

روش قطعه‌بندی به معنای تقسیم تصاویر به مناطق معنی‌دار و استخراج قسمت‌های مورد نظر از آن‌ها است. برای قطعه‌بندی تصویر، روش‌های مختلفی وجود دارد که می‌توان آن‌ها را به دو دسته روش‌های مبتنی بر هیستوگرام[4] و مبتنی بر خوشه‌بندی[5] تقسیم کرد. در این روش‌ها تصاویر به نحوی قطعه‌بندی می‌شوند تا بخش‌هایی که در داخل یک قطعه قرار می‌گیرند دارای بیشترین شباهت به هم باشند. در میان مهم‌ترین مدل‌های قطعه‌بندی، انواع مختلف خوشه‌بندی فازی[6] [12] و روش‌های یادگیری عمیق مانند سِگ‌نت[7] [13]، رِس۲نت[8] [14] و یو-نت[9] [15] قابل ذکر هستند.

در روش مبتنی بر طبقه‌بندی با استفاده از الگوریتم‌های یادگیری ماشین، هدف استخراج یک مدل جهت شناسایی بیماران از افراد سالم است؛ که شامل مراحل استخراج ویژگی‌ها، انتخاب ویژگی‌ها و طبقه‌بندی با استفاده از الگوریتم‌های یادگیری ماشین است. در این دسته از روش‌ها، اخیراً شبکه‌های عصبی مصنوعی عمیق عملکرد خوبی از خود نشان داده‌اند. از انواع روش‌های مختلف یادگیری عمیق مورد استفاده برای تشخیص کوید-۱۹ می‌توان به شبکه‌های عصبی کانولوشنِ[10] [16] اَلکس‌نت[11] [17]، وی‌جی‌جی‌نت[12] [18]، گوگل‌نت[13] [19]، دِنس‌نت[14] [20]، اِکسپشن‌نت [9]، موبایل‌نت[15] [21]، اِسکوئیزنت[16] [22]، اینکپشن[17] [23]، رِس‌نت[18] [24]، کِپس‌نت[19] [25] و شافِل‌نت[20] [26] اشاره کرد. در ادامه، برخی از روش‌های موجود در پژوهش‌های اخیر که با روش پیشنهادی ارتباط بیشتری دارند، مورد بررسی قرار می‌گیرند.

در [27]، مطالعه‌ای مقایسه‌ای از هفت معماری مختلف یادگیری عمیق برای تشخیص علائم کوید-۱۹ در تصاویر اشعه ایکس قفسه سینه ارائه شده‌است. این مدل‌ها با بیش از ۶۰۸۷ تصویر آموزش دیده‌اند. در میان مدل‌های بررسی شده، مدل اینکپشن با دقّت طبقه‌بندی ۹۲/۱۸ درصد، بالاترین دقّت را در بین مدل‌های دیگر کسب کرده‌است. *لویی* و همکاران [28] یک روش یادگیری عمیق مبتنی بر گَن[21] برای تشخیص کوید-۱۹ با استفاده از تصاویر اشعه ایکس قفسه سینه پیشنهاد کردند. آن‌ها سه مدل اَلکس‌نت، گوگل‌نت و رِس‌نت-۱۸ را مورد بررسی قرار دادند. مدل گوگل‌نت در طبقه‌بندی سه‌طبقه و دوطبقه به‌ترتیب به بیشترین دقّت برابر با ۸۰/۶۰ درصد و ۹۹/۹۰ درصد رسیده‌است. در [29]، *آسیف* و همکاران با استفاده از تصاویر اشعه ایکس قفسه سینه، یک سامانهٔ تشخیص کوید-۱۹ ارائه دادند. آن‌ها از یک مدل یادگیری انتقالی بهره بردند. مدل آن‌ها بر روی ۱۳۴۱ تصویر طبیعی، ۱۳۴۵ ذات‌الریه ویروسی و ۸۶۴ تصویر کوید-۱۹ مورد آزمایش قرار گرفت که به‌دقّت تشخیص ۹۶ درصد دست یافت.

در [30]، *رحیم‌زاده* و همکاران یک شبکه کانولوشنی عمیق با پایگاه داده نامتوازن، شامل سه طبقه کوید-۱۹، ریه طبیعی و ذات‌الریه، پیشنهاد دادند. آنان یک شبکه از ترکیب دو معماری اِکسپشن و رِس‌نت۵۰-وی۲ ارائه کردند. دقّت شبکه سه طبقه آنان ۹۱/۴۰ درصد بود. در [31]، *مدهی* و همکاران یک شبکه عصبی کانولوشنی برای شناسایی و تشخیص عفونت کوید-۱۹ با استفاده از تصاویر اشعه ایکس قفسه سینه ارائه و مدل خود را بر روی ۱۵۰ مورد تأییدشده از مجموعه داده کگل[22] آزمایش کردند. دقّت مدل آن‌ها ۹۳ درصد بود.

[1] Computer Aided Diagnosis System
[2] Segmentation
[3] Classification
[4] Histogram Based
[5] Clustering Based
[6] Fuzzy Clustering
[7] SegNet
[8] Res2Net
[9] U-Net
[10] Convolutional Neural Network

[11] AlexNet
[12] VGGNet
[13] GoogleNet
[14] DenseNet
[15] MobileNet
[16] SqueezeNet
[17] Inception
[18] ResNet
[19] CapsNet
[20] ShuffleNet
[21] GAN
[22] Kaggle

[Downloaded from jsdp.rcisp.ac.ir on 2026-11-25]
[DOI: 10.61186/jsdp.20.3.27]

اوزتورک و همکارانش [32] نیز مدل دارک‌نت[1] برای تشخیص خودکار فرد آلوده با استفاده از تصاویر اشعه ایکس قفسه سینه ایجاد کردند. این مدل برای طبقه‌بندی حالت دوطبقه و چندطبقه کوید-۱۹ آزمایش شد. مدل آنها به ترتیب دقت طبقه‌بندی ۹۸/۰۸ درصد و ۸۷/۰۲ درصد را برای حالت دوطبقه و چندطبقه به دست آورد. در [33]، *میسیانا* و همکاران یک روش یادگیری انتقالی برای تشخیص ویروس کوید-۱۹ با استفاده از تصاویر اشعه ایکس قفسه سینه پیشنهاد کردند و از ۲۲۴ تصویر کوید-۱۹، ۷۱۴ تصویر ذات‌الریه ویروسی و ۵۰۴ تصویر ریه طبیعی استفاده کردند. دقت به‌دست آمده از این مدل برای حالت دوطبقه ۹۸/۷۵ درصد بود. در [34]، *کریم* و همکاران یک سامانه برای تشخیص علائم کوید-۱۹ با استفاده از تصاویر اشعه ایکس قفسه سینه ایجاد کردند. آن‌ها از یادگیری انتقالی نیز استفاده کردند و به دقّت طبقه‌بندی ۹۶/۱۲ درصد برای طبقه‌بندی رسیدند.

در [35]، *تنویر* و همکاران یک معماری مبتنی بر شبکه عصبی کانولوشنی پیشنهاد دادند، که از کانولوشن‌های عمیق با نرخ‌های اِتساع[2] مختلف برای استخراج مؤثر ویژگی‌های متنوع از تصاویر اشعه ایکس قفسه سینه استفاده می‌کرد. آنان از یک پایگاه داده چهار بقه شامل طبقه‌های کوید-۱۹، ریه طبیعی، ذات‌الریه باکتریایی و ذات‌الریه ویروسی با تعداد ۵,۸۵۶ تصویر استفاده کردند. مدل آن‌ها دقّت ۹۰/۳۰ درصد را به‌دست آورد. در [36]، *قوشال* و همکاران از یک شبکه عصبی کانولوشنی بیزی برای تشخیص کوید-۱۹ با استفاده از تصاویر اشعه ایکس استفاده کردند. دقّت طبقه‌بندی به دست آمده از روش آنها ۹۰ درصد بود. در [37]، از مدل رِس‌نت-۵۰ برای استخراج ویژگی‌های تصاویر بیماران استفاده کردند. آن‌ها از طبقه‌بند ماشین بردار پشتیبان[3] [38] نیز به عنوان طبقه‌بند نهایی استفاده کردند. دقّت طبقه‌بندی به‌دست‌آمده در این مدل ۹۵/۳۴ درصد بود.

در [39]، یک روش طبقه‌بندی تصویر مبتنی بر روش انتقال برای تشخیص بیماری کوید-۱۹ در تصاویر اشعه ایکس قفسه سینه پیشنهاد شده‌است که در آن چهار طبقه‌بند از پیش‌آموزش‌دیده شناخته‌شده الکس‌نت، رِس‌نت-۱۸، دِنس‌نت-۲۰۱ و اِسکوئیزنت به کار گرفته شده‌است. بالاترین دقّت طبقه‌بندی به‌دست آمده مربوط به اِسکوئیزنت با دقّت ۹۸/۳۰ درصد است. در [40]، *وانگ* و همکاران یک شبکه عصبی کانولوشنی عمیق با ۸۹ لایه کانولوشن، ۱۳,۹۷۵ تصویر اشعه ایکس قفسه سینه و ۱۲ میلیون پارامتر ارائه دادند. مدل آنها برای طبقه‌بندی سه‌طبقه کوید-۱۹، ریه طبیعی و ذات‌الریه ارائه شده‌است. شبکه پیشنهادی دقّت ۹۳/۳۰ درصد در طبقه‌بندی سه‌طبقه کسب کرده است. در [41]، *خان* و همکاران یک مدل مبتنی بر یادگیری انتقالی را ارائه کردند. این شبکه بر روی پایگاه داده‌ای شامل چهار طبقه و با ۱۳۰۰ تصویر به دقّت ۸۹/۶۰ درصد رسید. در [42]، *الکرانی* و همکاران مدل کویدیکشن-نت[4] را پیشنهاد دادند. کویدیکشن-نت از معماری اِسکوئیزنت و شافل‌نت برای استخراج ویژگی، و از ماشین‌های بردار پشتیبان چندطبقه[5] برای طبقه‌بندی تصاویر اشعه ایکس قفسه سینه استفاده می‌کند. دقّت مدل آن‌ها برای طبقه‌بندی چهارطبقه ۹۴/۴۴ درصد گزارش شد.

با توجه به نتایج امیدبخش به‌دست آمده در پژوهش‌های فوق، و مزایای مختلف استفاده از تصاویر اشعه ایکس قفسه سینه به همراه یادگیری عمیق در تشخیص بیماری کوید-۱۹، در این پژوهش نیز سعی شده‌است با طراحی یک روشی مبتنی بر شبکه عصبی کانولوشنی مناسب، علاوه بر تشخیص هرچه دقیق‌تر عفونت کوید-۱۹، انواع مختلف عفونت ذات‌الریه را نیز از روی تصاویر اشعه ایکس قفسه سینه تشخیص داد.

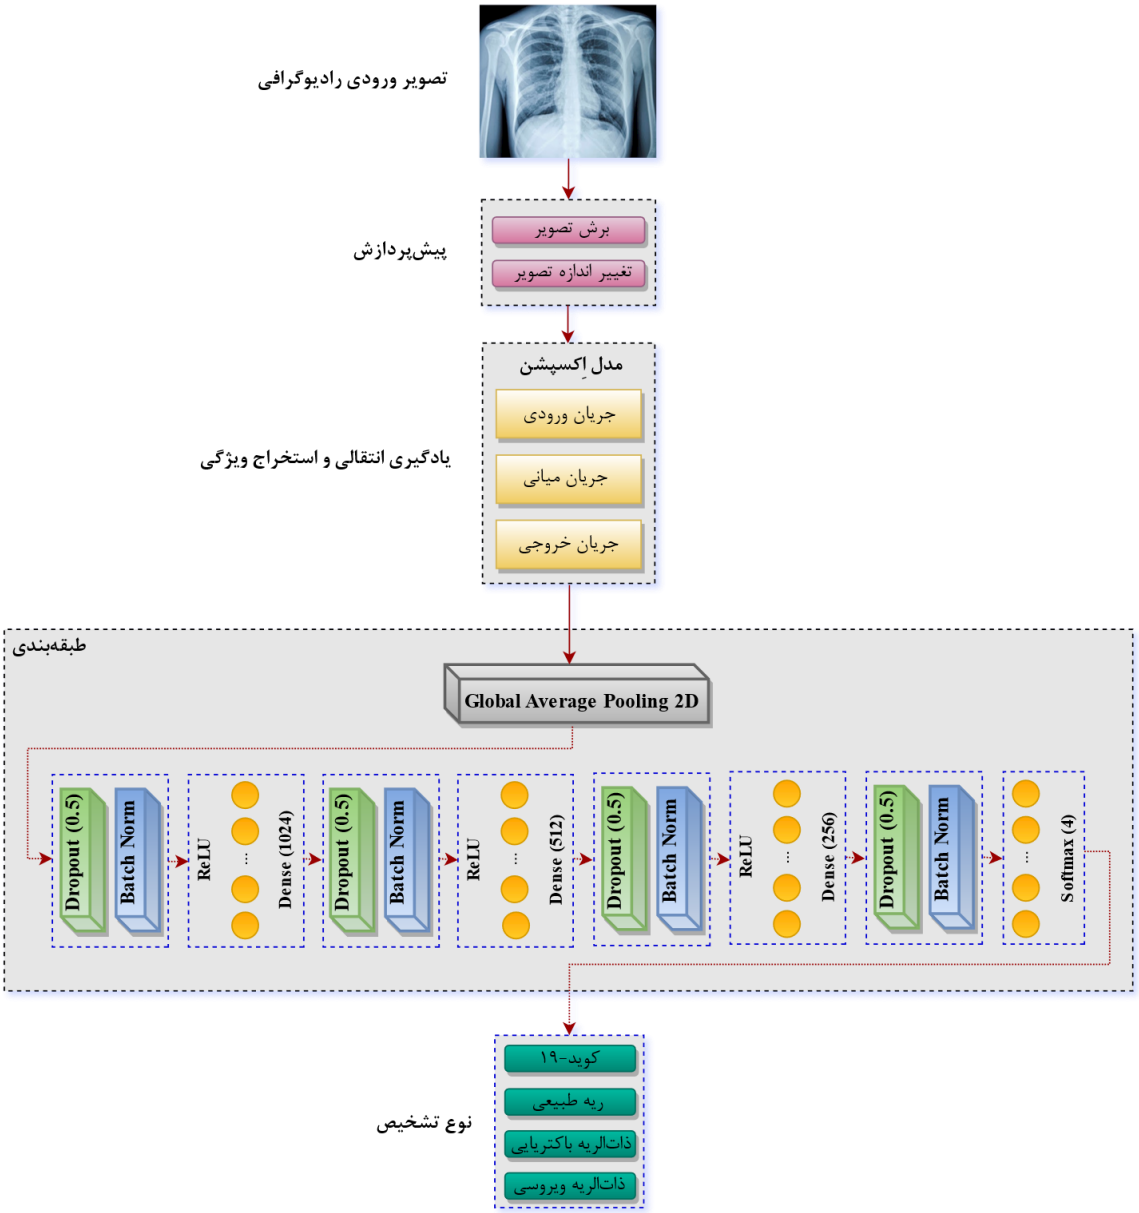
۳- روش پیشنهادی: CoviX-Net

۳-۱- ساختار کلی

ساختار کلّی روش پیشنهادی **(CoviX-Net)** در شکل (۲) نمایش داده شده‌است. **CoviX-Net** یک رویکرد مبتنی بر یادگیری انتقالی [43] است که از یک شبکه کانولوشنی با معماری اِکسپشن [9] چندلایه برای طبقه‌بندی تصاویر رادیوگرافی ریه (قفسه سینه) ورودی استفاده می‌کند. همان‌طورکه در شکل (۲) مشاهده می‌شود، **CoviX-Net** از سه بخش اصلی تشکیل شده‌است : بخش نخست تصویر ورودی را دریافت کرده و روی آن پیش‌پردازش[6] انجام می‌دهد. بخش دوم شامل شبکه انتقالی است و وظیفه استخراجِ ویژگی از تصاویرِ ورودی را بر عهده دارد؛ درنهایت بخش سوم با استفاده از ویژگی‌های استخراج شده در بخش دوم، طبقه‌بندی تصویر به یکی از چهارطبقه «کوید-۱۹»، «ذات‌الریه باکتریایی»، «ذات‌الریه ویروسی» و «ریه طبیعی» را انجام می‌دهد. در ادامه جزئیات مربوط به هر یک از بخش‌های ذکرشده ارائه می‌شوند.

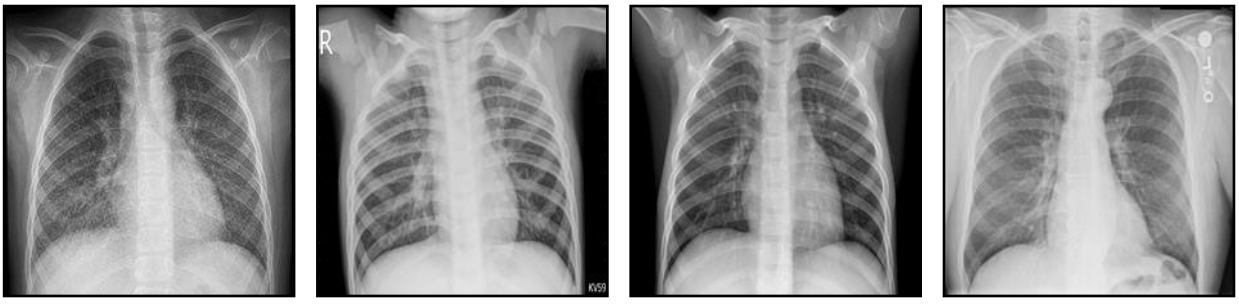
[1] DarkNet
[2] Dilation
[3] SVM
[4] COVIDetection-Net
[5] Multiclass Support Vector Machines (MSVM)
[6] Pre-processing

[Downloaded from jsdp.rcisp.ac.ir on 2026-11-25]
[DOI: 10.61186/jsdp.20.3.27]



(شکل-۲): ساختار کلی CoviX-Net

(Figure-2): General structure of CoviX-Net



(الف) (a) (ب) (b) (ج) (c) (د) (d)

(شکل-۳): نمونه‌هایی از تصاویر قفسه سینه پیش‌پردازش شده. الف) کوید-۱۹، ب) ریه طبیعی، ج) ذات‌الریه باکتریایی، و د) ذات‌الریه ویروسی

(Figure-3): Samples of Pre-processed chest radiography images. (a) Covid-19, (b) normal lung, (c) bacterial pneumonia, and (d) viral pneumonia

[Downloaded from jsdp.rcisp.ac.ir on 2026-11-25]

[DOI: 10.61186/jsdp.20.3.27]

۲-۳- پیش‌پردازش

در مرحله پیش‌پردازش، دو عمل برش[1] تصویر و تغییر اندازه آن انجام می‌شود. این عملیات برای آماده‌سازی تصاویر لازم است؛ چون تصاویر از پایگاه‌داده‌ها و دستگاه‌های اشعه ایکس مختلف جمع‌آوری می‌شوند و هر کدام دارای اندازه و ریزنمایی متفاوتی هستند. ازاین‌رو، ناحیه قفسه سینه تصاویر برش داده شده و همچنین همه تصاویر به ابعاد ۱۵۰×۱۵۰ پیکسل با وضوح ۹۶ **dpi**[2] تغییر اندازه می‌یابند؛ شکل (۳) نمونه‌هایی از تصاویر قفسه سینه پیش‌پردازش‌شده را نشان می‌دهد.

۳-۳- یادگیری انتقالی و استخراج ویژگی

۱-۳-۳- یادگیری انتقالی

یادگیری انتقالی[3] به معنای استفاده از دانش یک مدل آموزش‌دیده در یک کاربرد متفاوت، امّا مرتبط است [44]. در واقع هدف این است که از دانش و وزن‌هایی که در یک کاربرد به‌دست آمده است برای بهبود تعمیم‌پذیری در کاربردی دیگر استفاده شود. به‌طورمعمول درصورتی‌که داده آموزشی به اندازه کافی در دسترس باشد، می‌توان با افزایش تعداد لایه‌ها (یا وزن‌های) یک شبکه عصبی عمیق دقت آن را بهبود داد. امّا با توجه به نوظهور بودن بیماری کوید-۱۹ و کمبودِ تصاویر بیماران مبتلا به این ویروس، نمی‌توان شبکه‌های بزرگ را با این تعداد تصویر آموزش داد. یادگیری انتقالی روشی است که این مشکل را تا حدود زیادی می‌تواند مرتفع سازد.

در یادگیری انتقالی ابتدا یک شبکه روی داده‌های کاربردی متفاوت امّا مرتبط با کاربرد اصلی آموزش داده می‌شود؛ سپس وزن‌های شبکه آموزش داده شده به عنوان وزن‌های اوّلیه برای آموزش شبکه روی داده‌های مسئله اصلی مورد استفاده قرار می‌گیرند. این روش علاوه بر مرتفع ساختن نیاز به داده‌های بسیار زیاد، زمان آموزش شبکه را نیز تا حد زیادی کاهش می‌دهد. در طراحی **CoviX-Net** از مدل یادگیری انتقالی اکسپشن [9] استفاده می‌شود.

۲-۳-۳- مدل اِکسپشن

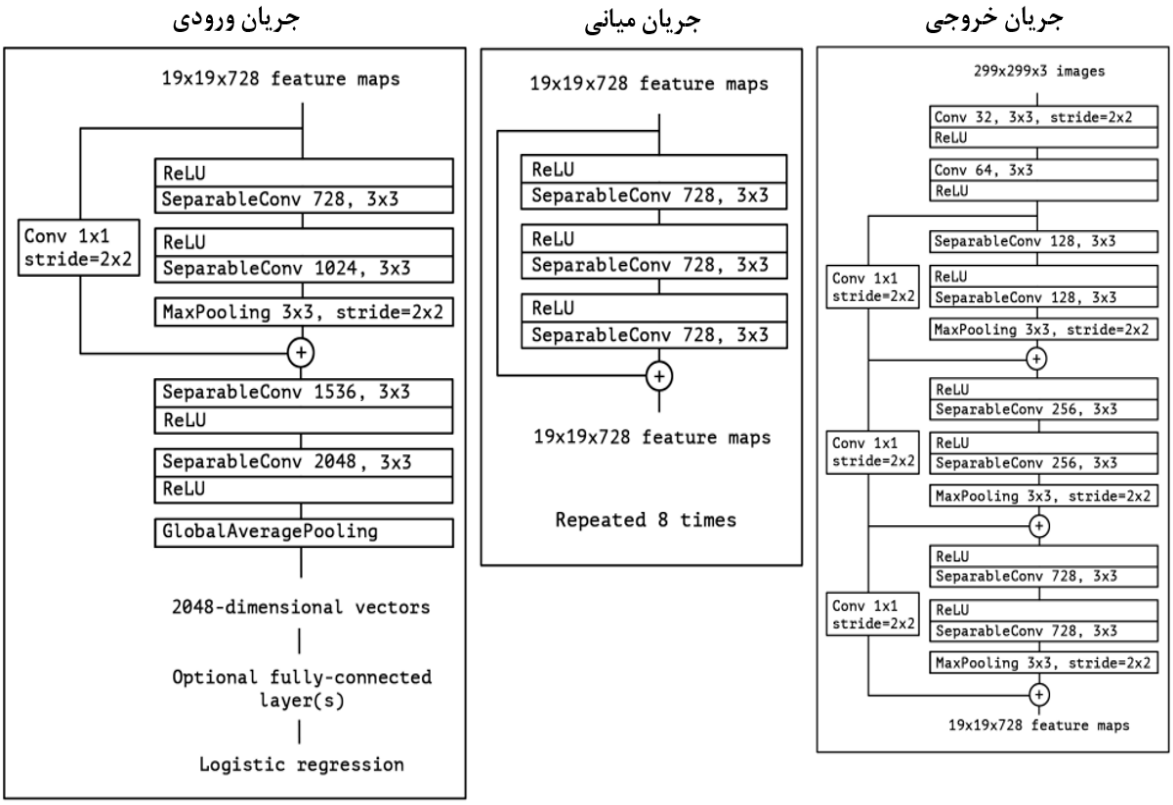
مدل اِکسپشن دارای یک معماری ۷۱ لایه‌ای عمیق کانولوشنی است که از قبل بر روی داده‌های **ImageNet** [45] آموزش دیده است. این معماری مجموعه‌ای خطی از لایه‌های کانولوشن جداپذیر عمقی با اتّصالاتِ باقی‌مانده[4] است. در این مدل به جای لایه‌های کانولوشن کلاسیک از لایه‌های کانولوشن جداپذیر عمقی[5] استفاده شده‌است. درواقع هدف این لایه‌ها جایگزین‌کردن عملیات کانولوشن کلاسیک $n \times n \times k$ با $1 \times 1 \times k$، برای کاهش تعداد پارامترها و ابعاد نقشه ویژگی است. در شکل (۴) معماری مدل اکسپشن به تصویر کشیده شده‌است. همان‌طور که در این شکل مشاهده می‌شود، این مدل شامل لایه‌های کانولوشنی، پولینگ و کاملاً متصل است که در ادامه توضیحات لازم در مورد هر یک از این لایه‌ها ارائه شده و کاربردشان در سامانه مورد هدف تشریح می‌شود. شبکه‌های کانولوشنی [46] مدلی از شبکه‌های عصبی مصنوعی است که همانند شبکه‌های عصبی معمولی از نورون‌ها، لایه‌ها و وزن‌ها تشکیل شده‌است. مهم‌ترین وجه تمایز این نوع از شبکه‌ها با مدل‌های دیگر قابلیت ویژه آن‌ها در استخراج ویژگی است. در دستگاه بینایی انسان، نواحی ادراکی که قشرِ بینایی در آن قرار دارد، همانند فیلترهای محلی بر روی اطّلاعات تصویر اعمال می‌شود؛ سلول‌های ساده‌تر برای تشخیص ویژگی‌های سطح پایین‌تر در نواحی ادراکی هم‌چون لبه‌ها کاربرد دارند؛ همچنین سلول‌های پیچیده قادر به تشخیص ویژگی‌های مهم‌تر و در سطوحِ بالاتر هستند. تشخیص ویژگی‌های سطحِ بالاتر با ترکیب ویژگی‌های سطحِ پایین صورت می‌گیرد. این عملکرد مغز با تغییرات بسیار گسترده الهام‌بخش شبکه‌های عمیق عصبی امروزی شده‌است.

شبکه عصبی کانولوشنی مدلی از شبکه‌های عصبی چند لایه است که به‌طورمعمول شامل لایه‌های کانولوشنی، پولینگ و کاملاًمتصل است. در یک شبکه عصبی معمولی، شبکه ورودی را دریافت می‌کند و آن را به تعدادی لایه مخفی می‌فرستد.

هر لایه مخفی از تعدادی نورون به شکل یک بردار تشکیل شده‌است که هر یک از آن‌ها به طور کامل به تمامی نورون‌های لایه قبلی خود متصل هستند. نورون‌ها در هر لایه به طور مستقل عمل می‌کنند و در ارتباطات و وزن‌ها با یکدیگر شریک نمی‌شوند. لایه آخر این شبکه، لایه خروجی بوده که مسئول نهایی تعیین طبقه داده‌ها است. امّا در شبکه‌های کانولوشنی، ورودی یک ماتریس چند لایه یا دارای عمق، مانند یک تصویر است و لایه‌های این شبکه بر خلاف شبکه‌های عصبی معمولی، متشکل از نورون‌هایی در سه بعد هستند، که در برخی از منابع به آن‌ها «تِنسور»[6] [47] نیز گفته می‌شود.

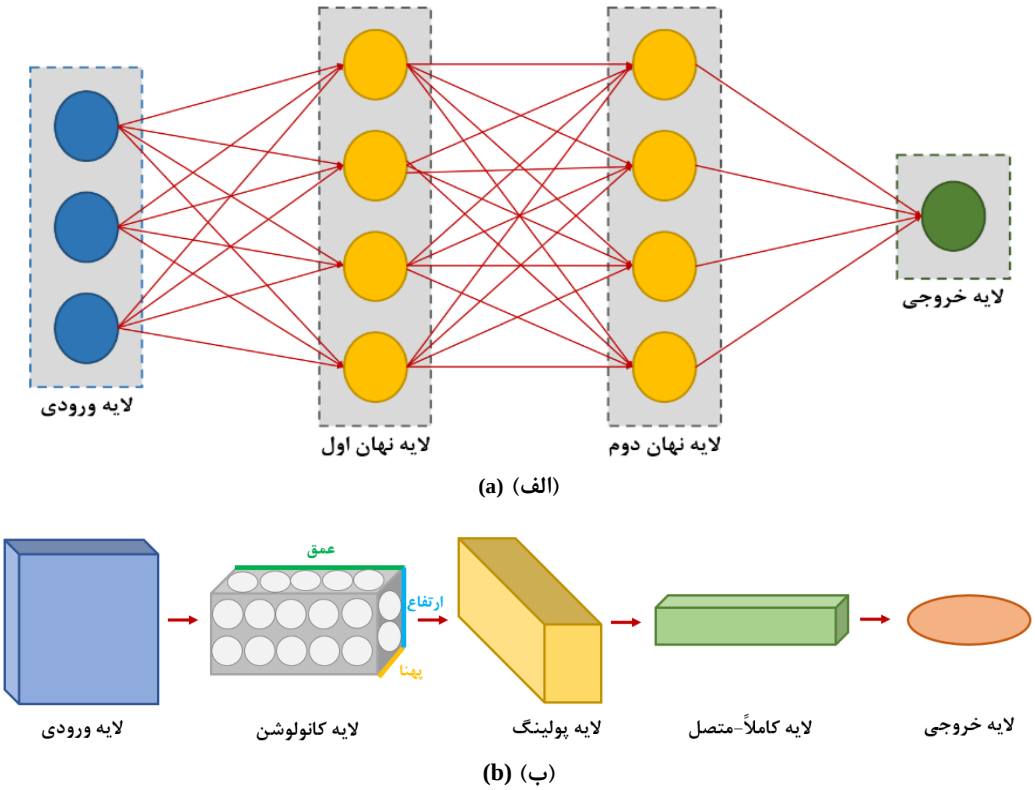
[1] Crop
[2] Dots per inch
[3] Transfer Learning
[4] Residual
[5] Depthwise Separable Convolution
[6] Tensor

[Downloaded from jsdp.rcisp.ac.ir on 2026-11-25]
[DOI: 10.61186/jsdp.20.3.27]



(شکل-۴): معماری اِکسپشن

[9] (Figure-4): Architecture of Xception



(شکل-۵): تفاوت شبکه‌های عصبی معمولی و شبکه عصبی کانولوشن. الف) شبکه عصبی معمولی، و ب) شبکه عصبی کانولوشن

(Figure-5): Difference of conventional neural networks and convolutional neural networks. (a) Conventional neural networks, and (b) convolutional neural network

[Downloaded from jsdp.rcisp.ac.ir on 2026-11-25]

[DOI: 10.61186/jsdp.20.3.27]

در این شبکه‌ها نورون‌های یک لایه تنها به ناحیه کوچکی از لایه قبلی متصل بوده و به تمامی لایه‌های قبلی متصل نیستند. در شکل (۵) تفاوت اصلی یک شبکه عصبی معمولی و شبکه عصبی کانولوشن نشان داده شده‌است. همان‌طورکه در شکل مشخص است؛ شبکه‌های عصبی معمولی فقط شامل لایه‌های کاملاًمتصل و تمامی نورون‌های یک لایه، به لایه بعدی متصل هستند. درحالی که در یک شبکه عصبی کانولوشنی، علاوه‌بر این لایه‌های کاملاًمتصل که در انتهای شبکه قرار می‌گیرند، لایه‌های کانولوشنی نیز مورد استفاده قرار می‌گیرند. این لایه‌ها عمل استخراجِ ویژگی از تصویر ورودی را متناسب با تصاویر ورودی یاد می‌گیرند و در زمان استفاده از شبکه آنرا به‌صورت خودکار انجام می‌دهند. درحالی‌که شبکه‌هایی که تنها از لایه‌های کاملاًمتصل استفاده می‌کنند، نیاز به مهندسی دستی ویژگی دارند و به‌طورمعمول به‌لحاظ دقت، در سطح بسیار پایین‌تری نسبت به شبکه‌های کانولوشنی قرار دارند.

لایه‌های کانولوشن به‌صورت متوالی فیلترهایی را بر روی داده‌ها اعمال می‌کنند تا ویژگی‌های سطح پایین و سطح بالا را از داده‌ها استخراج کنند. به مجموعه ویژگی‌های خروجی لایه‌های کانولوشن، نقشه فعّالیت[1] گفته می‌شود. در رابطه (۱) چگونگی انجام عمل کانولوشن نشان داده شده‌است. در این رابطه، I نشان‌دهنده ماتریس ورودی (تصویر)، K نشان‌دهنده فیلتر دو بعدی با اندازه $m \times n$ و F نشان‌دهنده نقشه ویژگی دوبعدی خروجی است. در این جا ورودی I با فیلتر K کانوالو می‌شود و نقشه ویژگی F را تولید می‌کند.

$$(i,j) = (I * K)(i,j) = \sum_m \sum_n I(i+m, j+n) K(m,n) \qquad (1)$$

۳-۴- طبقه‌بندی

همان‌طورکه در شکل (۲) نشان داده شده‌است ، گام طبقه‌بندی نهایی تصویر پس از بخش اکسپشن قرار گرفته و متشکل از لایه‌های پولینگِ میانگین کلّی دوبعدی[2]، نرمال‌سازی دسته‌ای[3]، حذفِ تصادفی[4] و کاملاًمتصل (متراکم)[5] است. آخرین لایه کاملاًمتصل با تابع فعّال‌ساز «سافت‌مَکس» برای پیش‌بینی طبقه‌ها ایجاد می‌شود. وزن‌های بدنه کانولوشنی اکسپشن نیز پس از مقداردهی اولیه با وزن‌های به‌دست‌آمده از آموزش روی **ImageNet**، همزمان با سایر بخش‌های شبکه روی داده‌های قفسه سینه آموزش می‌بینند. این تنظیمات به یادگیری بهتر مدل کمک می‌کند. معماری شبکه عصبیِ **CoviX-Net** در کل دارای ۲۳،۶۳۲،۱۷۲ پارامتر است، که ۲۳،۵۶۹،۹۶۴ پارامتر قابل آموزش و ۶۲،۲۰۸ پارامتر آن غیرقابل آموزش است. جزئیات معماری، پارامترهای لایه‌ای و شکل خروجی مدل **CoviX-Net** در جدول (۱) به تفصیل ارائه شده‌است.

(جدول-۱): جزئیات معماری CoviX-Net
(Table-1): Details of CoviX-Net architecture

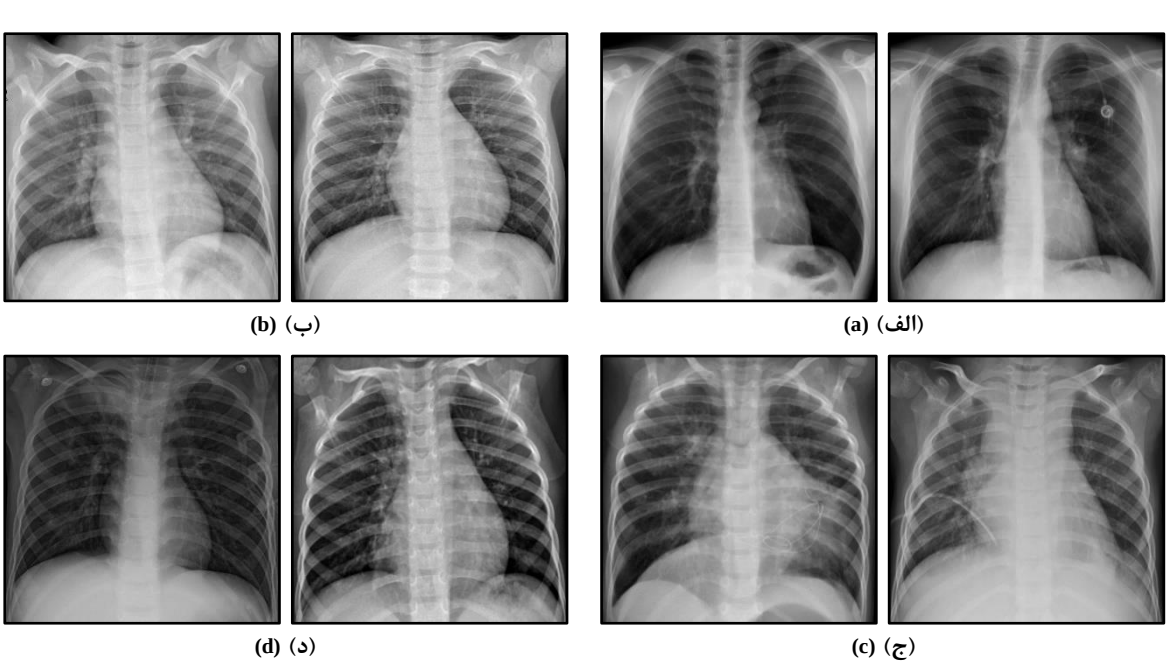
لایه	شکل خروجی
Xception	(8, 8, 2048)
GlobalAveragePooling2D	(2048)
BatchNormalization_1	(2048)
Dropout_1(0.5)	(2048)
Dense_1(1024)	(1024)
BatchNormalization_2	(1024)
Dropout_2(0.5)	(1024)
Dense_2(512)	(512)
BatchNormalization_3	(512)
Dropout_3(0.5)	(512)
Dense_3(256)	(256)
BatchNormalization_4	(256)
Dropout_4(0.5)	(256)
Dense_4(4)	(4)
Total Parameters	23,632,172
Trainable Parameters	23,569,964
Non-trainable Parameters	62,208

در **CoviX-Net**، لایه پولینگِ میانگین کلّی دو بعدی به منظور کاهش تعداد پارامترهای قابل آموزش شبکه بعد از چندین لایه کانولوشن استفاده می‌شود. با به کارگیری این لایه می‌توان علاوه بر کاهش محاسبات شبکه، از بیش‌برازش شبکه نیز تا حدی جلوگیری کرد. از لایه نرمال‌سازی دسته‌ای برای تنظیم مقادیر خروجی لایه‌ها استفاده می‌شود. لایه حذف تصادفی نرون‌هایی را به صورت تصادفی حذف می‌کند. هدف این لایه بهبود کلّیات است. در واقع با افزودن این لایه، شبکه را مجبور می‌کنیم تا با بهره‌برداری از نرون‌های مختلف، تا حد ممکن مفاهیم سطحِ بالا را آموزش ببینند. نرخ حذف برای این لایه به صورت تجربی پنجاه درصد در نظر گرفته می‌شود.

آخرین لایه شبکه عصبی، یک لایه کاملاًمتصل است که خروجی لایه قبلی را دریافت کرده و برداری را تولید می‌کند که هر یک از درایه‌های آن نشان‌دهنده احتمال تعلق به یک طبقه است. اندیس متناظر با بالاترین احتمال، بیان‌گر طبقه تولیدی شبکه برای تصویر ورودی است. بحث مهم در الگوریتم‌های یادگیری، در نظر گرفتن رابطه‌ای برای به‌دست‌آوردن خطای بین خروجی فعلی شبکه و خروجی مد نظر برای آن است.

[1] Activation Maps
[2] Global Average Pooling 2D
[3] Batch Normalization
[4] Dropout
[5] Dense

[Downloaded from jsdp.rcisp.ac.ir on 2026-11-25]
[DOI: 10.61186/jsdp.20.3.27]



(شکل-۶): نمونه‌هایی از تصاویر پایگاه داده گردآوری شده. الف) کوید-۱۹، ب) ریه طبیعی، ج) ذات‌الریه باکتریایی، و د) ذات‌الریه ویروسی

(Figure-6): Samples of images of collected dataset (a) Covid-19, (b) normal lung, (c) bacterial pneumonia, and (d) viral pneumonia

این رابطه با نام تابع لاس[1] شناخته می‌شود. ایده اساسی در آموزش شبکه، کمینه‌سازی تابع لاس «کراس-آنتروپی دسته‌ای»[2] با پیمودن گام‌های مناسب برای رسیدن به نتیجه بهتر است. با توجه به ماهیت مسئله، ما از الگوریتم بهینه‌سازی آدام[3] [48] استفاده می‌کنیم. این الگوریتم مزایای دو الگوریتم «کاهشِ شیبِ تصادفی»[4] [49] و «آدا-گراد»[5] [50] را با یکدیگر ترکیب می‌کند، که این امر باعث حفظ سرعت یادگیری هر پارامتر و بهبود عملکرد این روش در مواردی می‌شود که اندازه گرادیان کوچک است. نهایتاً با توجه به چهار طبقه بودن مسئله، در آخرین لایه شبکه از چهار نرون با تابع فعال‌سازی «سافت‌مَکس» استفاده می‌شود.

۳-۵- آموزش و ساخت مدل

برای آموزش شبکه عصبی عمیق سامانه و استخراج مدل مورد نظر، نیاز به مجموعه تصاویر مناسب و کافی است که در ادامه در خصوص نحوه گردآوری و افزایش آنها توضیح داده می‌شود.

۱-۳-۵- گردآوری مجموعه تصاویر آموزشی

به دلیل نوظهور بودن بیماری کوید-۱۹، در حال حاضر هیچ مجموعه داده‌ی یکپارچه‌ای که شامل تمامی بیماری‌های مورد مطالعه در این پژوهش باشد، در دسترس نیست. برای رفع این مشکل، ترکیبی از دو پایگاه داده متفاوت را استفاده می‌کنیم. پایگاه داده نخست شامل تصاویر رادیوگرافی از قفسه سینه بیماران مبتلا به «کوید-۱۹» است که در مخزن منبع باز گیت-هاب[6] توسط کوهن و همکاران [51] به اشتراک گذاشته شده‌است. پایگاه داده دوم شامل تصاویر رادیوگرافی سینه «افراد سالم»، بیماران «ذات‌الریه باکتریایی» و «ذات‌الریه ویروسی»، از مخزن کَگل [52] تهیه می‌شود؛ بنابراین مجموعه داده نهایی مورد استفاده برای آموزش **CoviX-Net** شامل چهار طبقه «کوید-۱۹»، «ریه طبیعی»، «ذات‌الریه باکتریایی» و «ذات‌الریه ویروسی» می‌شود که هر طبقه دارای ۳۰۰۰ نمونه است. شکل (۶) نمونه‌هایی از پایگاه تصاویر گردآوری‌شده را نشان می‌دهد. این مجموعه تصاویر در نشانی **https://github.com/Vahid-Mohammadian-Takaloo/CoviX-Net** در اختیار عموم پژوهش‌گران قرار می‌گیرد.

۲-۳-۵- افزایش تصاویر آموزشی

علاوه‌بر گردآوری مجموعه تصاویر مناسب برای آموزش مدل یادگیری، برای بهبود دقت مدل و جلوگیری از مشکل بیش‌برازش[7]، از فنون افزایش داده[8] استفاده

[1] Loss Function
[2] Categorical Crossentropy
[3] Adam
[4] Stochastic Gradient Descent
[5] Adagrad

[6] Git-hub
[7] Overfitting
[8] Data Augmentation

[Downloaded from jsdp.rcisp.ac.ir on 2026-11-25]
[DOI: 10.61186/jsdp.20.3.27]

می‌شود. این فنون پیش از هر تکرار الگوریتم آموزش شبکه عصبی، به انتخاب خود الگوریتم و بصورت تصادفی تغییراتی را روی تصاویر مورد استفاده در آن تکرار اعمال می‌کنند. در جدول (۲)، فهرست فنون استفاده‌شده بر روی مجموعه‌تصاویر آموزشی به همراه جزئیات پارامترهای هر فن ارائه شده‌است. گفتنی است که این فنون افزایش داده فقط بر روی مجموعه‌تصاویر آموزشی اعمال می‌شود.

با اعمال آنها، تعداد کل تصاویر آموزشی از ۸۴۰۰ تصویر، به ۲۶۲۵۰ تصویر افزایش پیدا می‌کند.

(جدول-۲): فنون افزایش داده استفاده‌شده
(Table-2): Applied data augmentation techniques

فن	دامنه تغییرات
بزرگ‌نمایی تصاویر	(0.15 و 0.0)
تغییر کنتراست تصاویر	(1.5 و 1.0)
تغییر عرض تصاویر	0.10
تغییر ارتفاع تصاویر	0.10
انعکاس افقی تصاویر	-

در فن بزرگ‌نمایی[1]، ابتدا ابعاد تصویر به‌صورت تصادفی بین صفر تا پانزده درصد ابعاد اولیه افزایش داده شده و سپس برش داده می‌شود تا اندازه اولیه تصویر تغییر نکند. فن افزایش داده دوم کنتراست[2] تصاویر را تغییر می‌دهد. با توجه به وجود دستگاه‌های متفاوت رادیوگرافی و جمع‌آوری تصاویر از پایگاه‌داده‌های متفاوت، کنتراست برخی تصاویر مطلوب نیست. بنابراین برای بهبود تصاویر، کنتراست تصاویر به صورت تصادفی بین ۱ تا ۱/۵ برابر کنتراست اولیه، در هر تکرار آموزش تغییر داده می‌شوند. با این کار، علاوه‌بر افزایش داده‌های آموزشی، کنتراست تصاویر در حالت مطلوب نیز به شبکه وارد می‌شود.

روش بعدی افزایش داده، تغییر عرض[3] و ارتفاع[4] تصاویر است؛ با این کار، عرض و ارتفاع تصویر به‌صورت تصادفی به مقدار حداکثر ده درصد از سمت چپ، راست، بالا و پایین شیفت داده می‌شود؛ سپس نواحی خالی‌شده با رنگ سیاه می‌شوند. آخرین روش افزایش داده‌ها، روش انعکاس افقی[5] تصاویر است که هر تصویر را به‌صورت افقی انعکاس می‌دهد. درواقع سمت چپ و راست تصویر را جابه‌جا می‌کند.

با اِعمال فنون افزایش دادهٔ یادشده بر روی تصاویر گردآوری‌شده، یک مجموعه غنی از تصاویر برای آموزش و استخراج مدل یادگیری مورد نظر حاصل می‌شود.

[1] Zoom_Range
[2] Contrast Range
[3] With Shift Range
[4] Height Shift Range
[5] Horizontal Flip

۴- آزمایش‌ها و نتایج به‌دست‌آمده

در این بخش، کارایی روش پیشنهادی ارزیابی می‌شود. ابتدا مدل‌های مختلف ارزیابی **CoviX-Net** معرفی می‌شوند. سپس معیارهای ارزیابی تعریف شده و درنهایت، نتایج آزمایش‌های انجام‌گرفته و مقایسه با سایر روش‌ها ارائه و بحث می‌شوند.

۴-۱- مدل‌های مختلف ارزیابی

با هدف بررسی تأثیر هر یک از عملیات به‌کار گرفته‌شده در **CoviX-Net** و ارزیابی کارایی آن در حالت‌های گوناگون، شش مدل مختلف برای آموزش و استخراج مدل یادگیری آن تعریف می‌کنیم. این مدل‌ها عبارتند از:

مدل ۱: چهار طبقه با استفاده از فنون افزایش داده بدون تغییر کنتراست تصاویر؛

مدل ۲: چهار طبقه با استفاده از تغییر کنتراست تصاویر و بدون سایر فنون افزایش داده؛

مدل ۳: چهار طبقه بدون استفاده از فنون افزایش داده؛

مدل ۴: چهار طبقه با استفاده از فنون افزایش داده و بدون استفاده از یادگیری انتقالی؛

مدل ۵: چهار طبقه با استفاده از فنون افزایش داده و با استفاده از یادگیری انتقالی؛

مدل ۶: سه طبقه (برای طبقه‌بندی تصاویر در طبقه‌های «کوید-۱۹»، ریه طبیعی و ذات‌الریه») با استفاده از فنون افزایش داده و یادگیری انتقالی (این مدل جهت مقایسه **CoviX-Net** با سایر روش‌های سه طبقه موجود در نظر گرفته شده‌است).

گفتنی است، همان‌طورکه پیش‌تر اشاره شد، از آنجایی‌که تصاویر قفسه سینه موجود از دستگاه‌های متفاوت رادیوگرافی و پایگاه داده‌های گوناگون به‌دست آمده‌اند و کنتراست برخی از آنها مناسب نیست، پیش‌بینی می‌شود فن افزایش داده «تغییر کنتراست تصاویر» تأثیر به‌سزایی در بهبود عملکرد سیستم داشته باشد؛ ازاین‌رو مدل‌های شماره ۱ و ۲ را برای ارزیابی این موضوع تعریف کردیم. همین‌طور مدل‌های شماره ۴ و ۵ به منظور ارزیابی تاثیر «یادگیری انتقالی» در کارایی سامانه در نظر می‌گیریم.

۴-۲- تنظیمات آزمایش‌ها و پارامترهای مدل

در این پژوهش، مشابه دیگر پژوهش‌های انجام شده [27-35, 41, 42]، پایگاه داده را به سه قسمت داده‌های آموزشی، اعتبارسنجی و آزمون تقسیم می‌کنیم. برای ساخت هر یک از مدل‌ها، ٪۷۰ از کل تصاویر پایگاه

[Downloaded from jsdp.rcisp.ac.ir on 2026-11-25]
[DOI: 10.61186/jsdp.20.3.27]

داده برای آموزش شبکه، ٪۱۵ برای اعتبارسنجی و تنظیم اَبَرپارامترهای شبکه، و ٪۱۵ نیز برای ارزیابی کارایی آن استفاده می‌شوند. تمامی پیاده‌سازی‌ها با استفاده از کتابخانه کراس[1] و بَک-اند[2] تنسورفلو[3] نسخه ۲.۷.۰ انجام می‌گیرند. یادگیری انتقالی روش پیشنهادی با استفاده از مجموعه داده **ImageNet** [45] انجام می‌شود. همچنین بهینه‌ساز آدام [53] با نرخ یادگیری[4] ۰/۰۰۰۳، اندازه دسته[5] ۳۲ و تعداد ۱۰۰ دوره[6] استفاده می‌شود.

برای جلوگیری از مشکل بیش‌برازش، علاوه بر فنون افزایش داده، از فن تَنزلِ وزن و تنظیم کننده‌های **L2** در لایه‌های انتهایی بخش کانولوشنی مدل با مقدار ۰/۰۰۰۳ استفاده می‌شود. لایه‌های بالایی مدل بصورت فریز[7] و بدون تغییر باقی ماندند، در حالیکه لایه‌های انتهایی کانولوشنی با وزن‌های جدید آموزش داده شدند. در مدل **CoviX-Net** از تابع خطای طبقه‌بندی متقابل[8] و تابع دقت برای ارزیابی نتایج بدست آمده استفاده می‌شود. تمامی آزمایش‌ها بر روی دستگاه رایانه با پردازنده اینتل کور-آی ۹[9] و با حافظه ۱۶ گیگا بایت انجام می‌شود. کلیه سورس کدهای پیاده‌سازی **CoviX-Net** در **https://github.com/Vahid-Mohammadian-Takaloo/CoviX-Net** قابل دسترس است.

۳-۴- معیارهای ارزیابی

برای ارزیابی کارایی مدل‌ها، از ماتریس درهم‌ریختگی[10] و معیارهای سنجش عملکرد دقت[11]، صحت[12]، پوشش[13]، حساسیت[14] و نمره-اِف[15] حاصل از ماتریس استفاده می‌شود.

۴-۴- نتایج آزمایش‌ها

۱-۴-۴- نتایج CoviX-Net با پنج مدل چهار طبقه و مقایسه با دیگر روش‌ها

در جدول (۳) معیارهای ارزیابی کارایی برای هر پنج مدل چهار طبقه **CoviX-Net** گزارش شده‌است. همانطور که در این جدول مشاهده می‌شود، مدل ۵ (با استفاده از فنون افزایش داده و با استفاده از یادگیری انتقالی) با مقدار دقت ۹۵ درصد، بهترین عملکرد را نسبت به مدل‌های دیگر به دست آورده است. در بین مدل‌های باقی مانده، به ترتیب مدل ۳ (بدون استفاده از فنون افزایش داده) و مدل ۴ (با استفاده از فنون افزایش داده و بدون استفاده از یادگیری انتقالی)، به ترتیب با دقت‌های ۹۳/۵۰ و ۸۹/۳۸ درصد، بیشترین و کمترین دقت را به‌دست آورده‌اند. مدل ۴ دقت بسیار پایین‌تری در مقایسه با مدل ۵ از خود نشان داده است که این موضوع قدرت و توانایی رویکرد یادگیری انتقالی را در بهبود کارایی سامانه تائید می‌کند.

در جدول (۳)، همچنین عملکرد سایر روش‌های چهار طبقه پیشین برای تمایز و تشخیص بین کوید-۱۹ و انواع ذات‌الریه ارائه شده‌است. نتایج مربوط به سایر روش‌ها از مراجع مربوطه بطور مستقیم گزارش شده‌اند. می‌توان مشاهده کرد، بطور کلی معماری چهار طبقه **CoviX-Net** در مقایسه با سایر معماری‌های قبلی عملکرد بهتری داشته است. در [35] تنویر و همکارانش، از یک معماری مبتنی بر شبکه عصبی کانولوشنی و محلی‌سازی متمایزکننده مبتنی بر گرادیان استفاده کرده‌اند. آن‌ها به‌جای استفاده از کانولوشن سنتی، از کانولوشن با نرخ اتساع[16] متفاوت استفاده کردند. روش آنها به دقت ۹۰/۲۰ درصد دست یافته است.

روش خان و همکارانش [41]، که از معماری یادگیری انتقالی اکسپشن با استفاده از پایگاه داده **ImageNet** استفاده کرده‌اند، به دقت ۸۹/۶۰ درصد رسیده است. الکرانی و همکارانش [42] یک معماری موازی با ترکیب دو معماری یادگیری انتقالی شافل‌نت و اسکوئیزنت ارائه کرده‌اند، که با توجه به اینکه از ترکیب دو معماری یادگیری انتقالی طراحی و اجرا شده‌است و دارای توان محاسباتی بالایی است، به دقت ۹۴/۴۵ درصد رسیده‌اند. با این حال روش پیشنهادی (**CoviX-Net** با مدل (۵) نتایج بهتری از آنها دارد. دلیل برتربودن روش پیشنهادی از روش‌های دیگر را می‌توان ناشی از استفاده از تصاویر پایگاه داده مناسب توأم با فنون افزایش داده کارآمد، معماری مناسب مدل و یادگیری انتقالی اِکسپشن دانست.

در رابطه با شباهت پایگاه داده‌های استفاده شده در پژوهش‌های مقایسه شده با روش پیشنهادی موجود در جدول (۳)، لازم به توضیح است که پایگاه داده‌های آزمایش‌شده دارای منابع مشترک هستند؛ به‌طوری‌که به‌دلیل نوظهوربودن بیماری کوید-۱۹، پایگاه داده‌های متنوع زیادی در دسترس نیست و تصاویر مربوط به طبقه کوید-۱۹ به‌طورتقریبی همگی از یک منبع مشخص استفاده شده‌اند که در بخش ۱-۵-۳ معرفی شده‌اند.

[1] Keras
[2] Back-End
[3] Tensorflow
[4] Learning Rate
[5] Batch Size
[6] Epoch
[7] Freez
[8] Categorical_Crossentropy
[9] Core i7
[10] Confusion Matrix
[11] Accuracy
[12] Precision
[13] Recall
[14] Sensitivity
[15] F-Measure
[16] Dilation Rates

[Downloaded from jsdp.rcisp.ac.ir on 2026-11-25]
[DOI: 10.61186/jsdp.20.3.27]

(جدول-۳): مقایسه کارایی CoviX-Net (در ۵ مدل چهار طبقه)

با روش‌های چهار طبقه پیشین

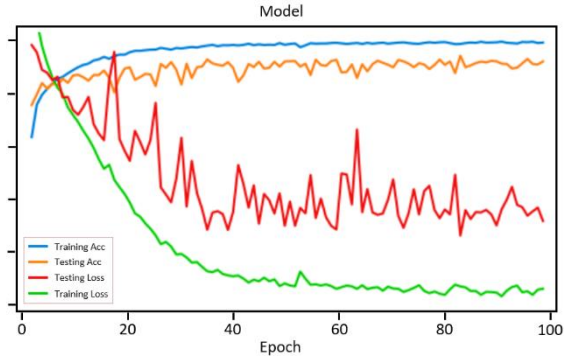
(Table-3): Performance comparison of CoviX-Net (using five models) with other methods

روش	صحت (٪)	پوشش (٪)	نمره-اف (٪)	دقت (٪)
[ ] (سال ۲۰۲۰)41خان و همکاران	90.00	89.92	89.80	89.60
[ ] (سال ۲۰۲۰)35تنویر و همکاران	90.80	89.90	90.40	90.20
[ ] (سال ۲۰۲۱)42الکرانی و همکاران	94.42	94.45	94.40	94.45
با مدل CoviX-Net۱	93.25	93.00	93.00	93.05
با مدل CoviX-Net۲	93.25	93.25	93.50	93.16
با مدل CoviX-Net۳	93.50	93.50	93.25	93.50
با مدل CoviX-Net۴	89.75	89.25	89.50	89.38
با مدل CoviX-Net۵	**95.00**	**95.25**	**94.75**	**95.00**

در رابطه با طبقات دیگر نیز بیش از پنجاه درصد از تصاویر استفاده‌شده دارای تصاویر مشترکی هستند.

ماتریس‌های درهم‌ریختگی پنج مدل روش پیشنهادی در شکل (۷) ارائه شده‌اند. در این ماتریس‌ها سطرها نشان‌دهنده طبقه واقعی و ستون‌ها طبقه پیش‌بینی‌شده به‌وسیلهٔ **CoviX-Net** را نشان می‌دهند. همان‌طورکه مشاهده می‌شود در مدل‌های ۱، ۲، ۳ و ۴، برای طبقه‌های کوید-۱۹ و ریه طبیعی، **CoviX-Net** عملکرد خوبی داشته است؛ ولی برای طبقه‌های ذات‌الریه باکتریایی و ذات‌الریه ویروسی، همان‌طورکه انتظار می‌رفت به‌دلیل تشابه زیاد تصاویر، چند مورد طبقه‌بندی نادرست انجام گرفته است. با این حال، عملکرد رضایت‌بخشی برای سایر موارد طبقه‌بندی به‌دست آمده است. بهترین نتیجه با مدل ۵ به‌دست آمده است. با مقایسه ماتریس‌های درهم‌ریختگی شکل (۷-د) و (۷-ی)، واضح است در حالت عدم استفاده از یادگیری انتقالی، نتایج پیش‌بینی برای دو طبقه ذات‌الریه افت می‌کند و این ناشی از کاهش قدرت مدل در طبقه‌بندی تصاویر است.

در شکل (۸) منحنی‌های خطا و دقّت داده‌های بخش آموزش و اعتبارسنجی بهترین مدل چهار طبقه (مدل ۵) نشان داده شده‌است. همان‌طورکه در این شکل مشاهده می‌شود، در ابتدای آموزش میزان خطای مدل بالا و میزان دقّت آن پایین است؛ ولی هنگامی که مدل تمام تصاویر ورودی را بارها و بارها برای هر دوره در طول آموزش بررسی می‌کند، این فراز و نشیب‌های سریع با شیب ملایم کاهش می‌یابد به‌گونه‌ای که رفته‌رفته به دقت عملکرد مناسبی هم بر روی تصاویر آموزشی و هم تصاویری اعتبارسنجی می‌رسد، کاهش ملایم شیب نمودار به‌صورت منظم در شکل (۸) حاکی از نبود مشکل بیش‌برازش در مرحلهٔ آموزش و آزمون است.



(شکل-۸): منحنی خطا و دقّت CoviX-Net روی مجموعه‌داده آموزشی و اعتبارسنجی در طی تکرارهای آموزش شبکه

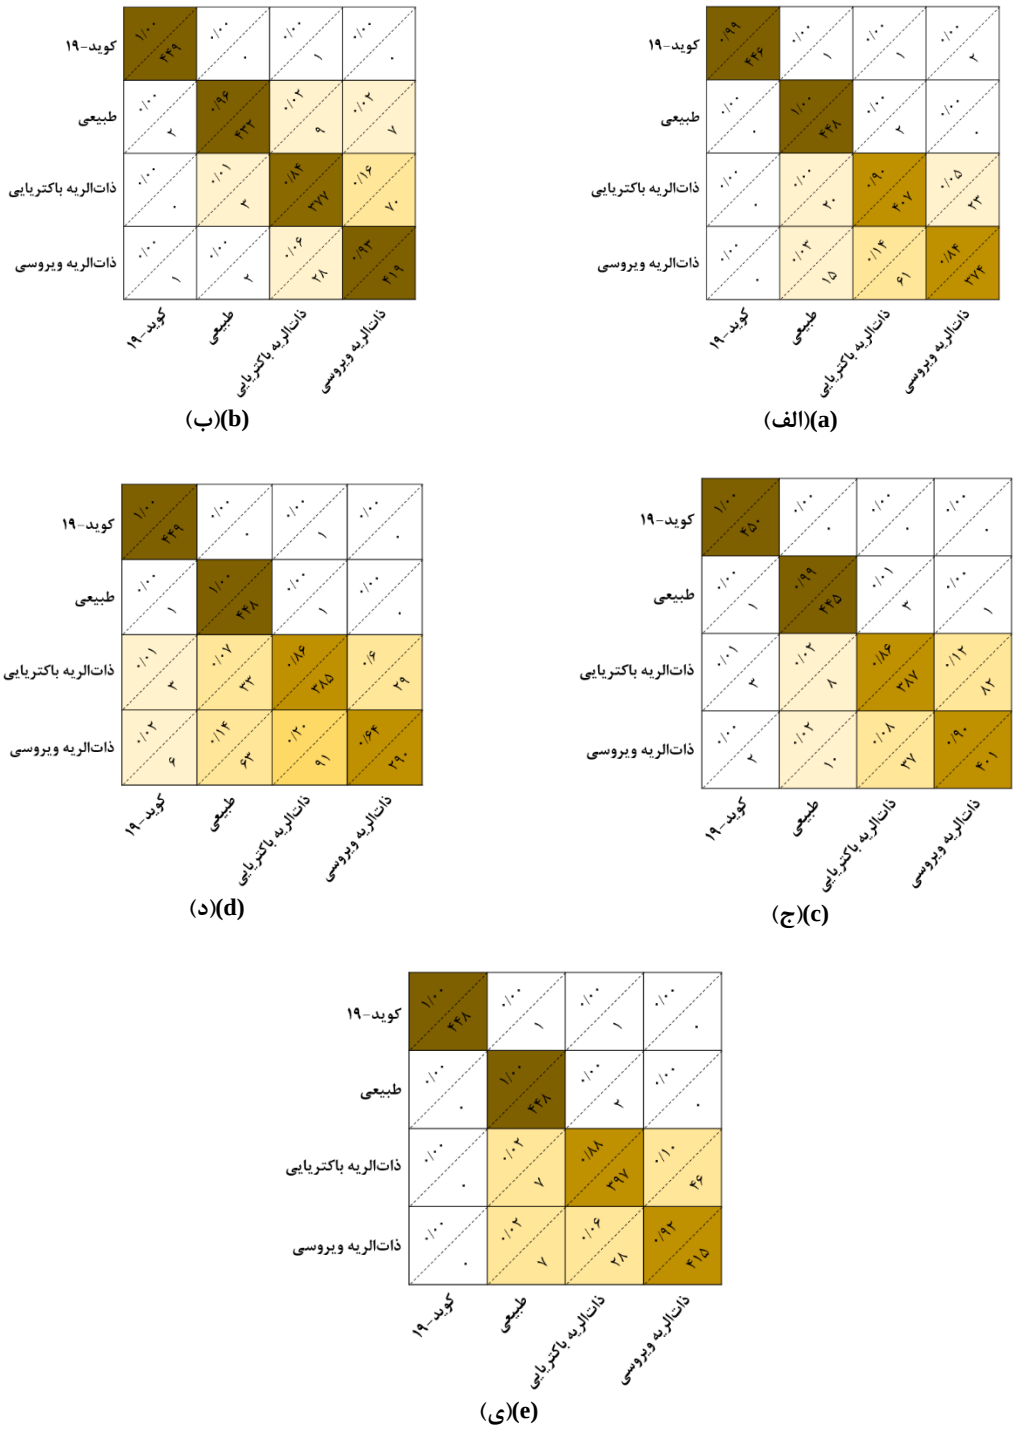
(Figure-8): CoviX-Net error and accuracy curve on training and validation dataset during network training epochs

۲-۴-۴- نتایج CoviX-Net با مدل سه طبقه و مقایسه با دیگر روش‌ها

در جدول (۴)، عملکرد حالت سه طبقه **CoviX-Net** (مدل ۶) با سایر روش‌های سه طبقه پیشین، برای تمایز و تشخیص بین کوید-۱۹ و ذات‌الریه مقایسه شده‌است. نتایج مربوط به دیگر روش‌ها به‌طور مستقیم از مراجع مربوطه گزارش شده‌اند. در این جدول نیز می‌توان مشاهده کرد که مدل سه طبقه **CoviX-Net** در مقایسه با سایر معماری‌های موجود عملکرد بهتری را در طبقه‌بندی تصاویر رادیوگرافی کوید-۱۹، طبیعی و ذات‌الریه دارد.

[Downloaded from jsdp.rcisp.ac.ir on 2026-11-25]

[DOI: 10.61186/jsdp.20.3.27]



(شکل-۷): ماتریس درهم‌ریختگی نتایج CoviX-Net با پنج مدل: الف) مدل ۱، ب) مدل ۲، ج) مدل ۳، د) مدل ۴، و ی) مدل ۵

(Figure-7): Confusion matrices of CoviX-Net's results with five models: (a) Model 1, (b) Model 2, (c) Model 3, (d) Model 4, and (e) Model 5

(جدول-۴): مقایسه کارایی روش پیشنهادی (در مدل سه طبقه) با روش‌های سه طبقه پیشین

(Table-4): Performance comparison of CoviX-Net (in triple class model) with other methods

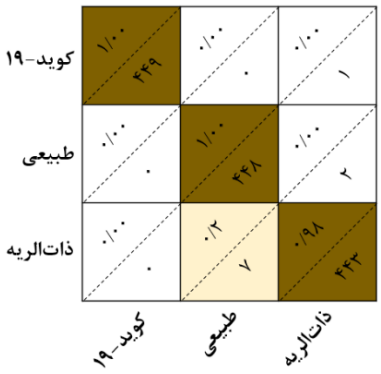
روش	صحت (٪)	پوشش (٪)	نمره-اف (٪)	دقت (٪)
[54] (سال ۲۰۲۰) اوزتورک و همکاران	85.35	89.96	87.37	87.02
[30] (سال ۲۰۲۰) رحیم‌زاده و همکاران	73.50	87.00	-	91.40
[55] (سال ۲۰۲۰) وانگ و همکاران	-	93.33	-	92.64
با مدل CoviX-Net۶	**99.00**	**93.33**	**99.50**	**99.25**

[Downloaded from jsdp.rcisp.ac.ir on 2026-11-25]

[DOI: 10.61186/jsdp.20.3.27]

همان‌گونه که مشاهده می‌شود، روش اوزتورک و همکاران [54]، که مبتنی بر شبکه عصبی عمیق بدون استفاده از راهبردهای یادگیری انتقالی است، با دقّت ۸۷/۰۲ درصد عملکرد بسیار ضعیف‌تری نسبت به **CoviX-Net** دارد. دو روش دیگر [30] و [55] نیز که از شبکه‌های سنتی با طرح یادگیری انتقالی از پایگاه داده **ImageNet** استفاده کرده‌اند، به‌ترتیب به دقّت ۹۱/۴۰ و ۹۲/۶۴ درصد دست یافته‌اند. نتایج به‌دست آمده به‌وسیلهٔ **CoviX-Net** به دلیل بهره‌گیری از روش یادگیری انتقالی و مجموعه داده آموزشی مناسب و کافی، نسبت به سایر روش‌ها بهتر است.

شکل (۹) ماتریس درهم‌ریختگی مدل سه طبقه **CoviX-Net** را نشان می‌دهد، که نتایج تشخیص بسیار خوبی برای هر سه طبقه مشاهده می‌شود.



(شکل-۹): ماتریس درهم‌ریختگی نتایج CoviX-Net با مدل ۶
(Figure-9): Confusion matrix of CoviX-Net's results with Model 6

۵- نتیجه‌گیری و محورهای توسعه و مطالعه بیشتر

در این پژوهش، سامانه هوشمند **CoviX-Net** برای تشخیص و تمایز خودکار بیماری کووید-۱۹ و دو نوع رایج ذات‌الریه از روی تصاویر رادیوگرافی قفسه سینه ارائه شد. با توجه به نوظهوربودن بیماری کووید-۱۹ و چالش کمبود تصاویر رادیوگرافی قفسه سینه، در طراحی **CoviX-Net** از شبکه انتقالی با معماری اِکسپشن استفاده شد که تا حدود زیادی مشکل کمبود داده آموزشی را جبران کند. رویکردهای یادگیری انتقالی عمیق قادر به آموزش شبکه‌ها در مجموعه داده‌های بسیار بزرگ و هم‌چنین تنظیم دقیق وزن شبکه‌های از قبل آموزش‌دیده بر روی مجموعه‌داده‌های کوچک و جدید هستند. معماری شبکه پیشنهادی بر روی ۱۲۰۰۰ تصویر رادیوگرافی شامل برچسب‌های کووید-۱۹، ذات‌الریه باکتریایی، ذات‌الریه ویروسی و ریه طبیعی جمع‌آوری‌شده از دو پایگاه داده مختلف آموزش داده شد. برای جلوگیری از مشکل بیش‌برازش، از فنون افزایش داده، تنزل وزن و تنظیم کننده‌های-اِل۲ استفاده شد. برای ارزیابی عملکرد روش پیشنهادی از معیارهای ارزیابی دقّت، صحت، پوشش، و نمره-اف استفاده شد. **CoviX-Net** در حالت سه طبقه (کووید-۱۹، ریه طبیعی و ذات‌الریه)، دقّت تشخیص ۹۹/۲۵ درصد را به‌دست آورد و در حالت چهار طبقه (کووید-۱۹، ریه طبیعی، ذات‌الریه باکتریایی و ذات‌الریه ویروسی)، دقّت تشخیص ۹۵ درصد را از خود نشان داد. نتایج آزمایش‌های به‌دست‌آمده حاکی از آن است که این سامانه می‌تواند برای تشخیص و تمایز سریع‌تر کووید-۱۹ و سایر عفونت‌های ذات‌الریه، ابزاری مناسب باشد و در مناطق دور افتاده که تحت تأثیر کووید-۱۹ قرار دارند، برای غلبه بر مشکل کمبود پزشکان و رادیولوژیست‌های متخصص استفاده شود.

به‌عنوان محورهای توسعه و مطالعه بیشتر در راستای این پژوهش، موارد زیر می‌تواند مورد نظر باشد:

- طراحی معماری شبکه عصبی عمیق سامانه بصورت دو یا چند معماری موازی یا سری، به جای استفاده از یک معماری؛ به منظور افزایش دقت تشخیص سامانه؛
- به‌دلیل عدم حاشیه‌نویسی از ناهنجاری‌های پاتولوژیک، مدل پیشنهادی نقشه‌های ویژگی طبقه را به روشی ضعیف (یعنی فقط توسط برچسب‌های طبقه در سطح تصویر) آموزش می‌بینند؛ که این موضوع منجر به عدم امکان محلی‌سازی آسیب شناسی‌ها و طبقه‌بندی تصاویر می‌شود. اتخاذ رویکردهای مناسب برای رفع این محدودیت می‌تواند راه‌گشای پژوهش‌های بیشتر باشد.
- تمامی عملیات و محاسبات انجام‌گرفته در این پژوهش بر پایه **CPU** است. برای بهبود سرعت عملکرد روش پیشنهادی در انجام محاسبات و همچنین امکان استفاده از تصاویر با اندازه بزرگ‌تر می‌توان از **GPU** برای انجام محاسبات استفاده کرد.
- طراحی و پیاده‌سازی مدل‌های یادگیری سبک‌تر، با مصرف حافظه و محاسبات کمتر، با الهام از مدل‌هایی که امروزه در حال توسعه هستند، می‌تواند سهولت به‌کارگیری سامانه پیشنهادی را بیشتر کنید.
- پارامترهای اولیه مدل پیشنهادی را می‌توان با استفاده از رویکردهای مختلف نظیر الگوریتم تکاملی

[Downloaded from jsdp.rcisp.ac.ir on 2026-11-25]
[DOI: 10.61186/jsdp.20.3.27]

پارتو قدرت موازی[1] [56]، الگوریتم ژنتیک مرتب‌سازی غیر-غالب[2] [57, 58]، تکامل دیفرانسیل ممتیک[3] [57, 58]، الگوریتم ژنتیک [59] و بهینه‌سازی ازدحام ذرات [60] مورد ارزیابی و آزمایش قرار داد. همچنین برخی از روش‌های پیش‌پردازش مانند فیلتر معنی‌دار یکپارچه [61, 62]، فیلتر گرادیان افزایشی [63]، می‌توانند برای بهبود تصاویر اشعه ایکس قفسه سینه آزمایش شود.

- درنهایت، استفاده از معماری یادگیری **CoviX-Net** در سایر کاربردهای تشخیصی پزشکی، نظیر انواع توده‌های سرطانی، ضایعات پوستی و دیگر موارد مشابه نیز می‌تواند بررسی و آزمایش شود.

۶- مراجع 6-Refrence

[1] C. Sohrabi *et al.*, "World Health Organization declares global emergency: A review of the 2019 novel coronavirus (COVID-19)," *International Journal of Surgery*, vol. 76, pp. 71-76, 2020/04/01/ 2020, doi: https://doi.org/10.1016/j.ijsu.2020.02.034.

[2] C.-C. Lai, T.-P. Shih, W.-C. Ko, H.-J. Tang, and P.-R. Hsueh, "Severe acute respiratory syndrome coronavirus 2 (SARS-CoV-2) and coronavirus disease-2019 (COVID-19): The epidemic and the challenges," *International Journal of Antimicrobial Agents*, vol. 55, no. 3, p. 105924, 2020/03/01/ 2020, doi: https://doi.org/10.1016/j.ijantimicag.2020.105924.

[3] H. A. Rothan and S. N. Byrareddy, "The epidemiology and pathogenesis of coronavirus disease (COVID-19) outbreak," *Journal of Autoimmunity*, vol. 109, p. 102433, 2020/05/01/ 2020, doi: https://doi.org/10.1016/j.jaut.2020.102433.

[4] R. M. Pereira, D. Bertolini, L. O. Teixeira, C. N. Silla, and Y. M. G. Costa, "COVID-19 identification in chest X-ray images on flat and hierarchical classification scenarios," *Computer Methods and Programs in Biomedicine*, vol. 194, p. 105532, 2020/10/01/ 2020, doi: https://doi.org/10.1016/j.cmpb.2020.105532.

[5] T. Franquet, "Imaging of Pulmonary Viral Pneumonia," *Radiology*, vol. 260, no. 1, pp. 18-39, 2011, doi: 10.1148/radiol.11092149.

[6] S. Latif *et al.*, "Leveraging Data Science to Combat COVID-19: A Comprehensive Review," *IEEE Transactions on Artificial Intelligence*, vol. 1, no. 1, pp. 85-103, 2020, doi: 10.1109/TAI.2020.3020521.

[7] G. D. Rubin *et al.*, "The Role of Chest Imaging in Patient Management During the COVID-19 Pandemic: A Multinational Consensus Statement From the Fleischner Society," *Chest*, vol. 158, no. 1, pp. 106-116, 2020/07/01/ 2020, doi: https://doi.org/10.1016/j.chest.2020.04.003.

[8] C. Long *et al.*, "Diagnosis of the Coronavirus disease (COVID-19): rRT-PCR or CT?," *European Journal of Radiology*, vol. 126, p. 108961, 2020/05/01/ 2020, doi: https://doi.org/10.1016/j.ejrad.2020.108961.

[9] F. Chollet, "Xception: Deep learning with depthwise separable convolutions," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2017, pp. 1251-1258.

[10] A. Shoeibi *et al.*, "Automated detection and forecasting of covid-19 using deep learning techniques: A review," *arXiv preprint arXiv:2007.10785*, 2020.

[11] R. Karthik, R. Menaka, M. Hariharan, and G. S. Kathiresan, "AI for COVID-19 Detection from Radiographs: Incisive Analysis of State of the Art Techniques, Key Challenges and Future Directions," *IRBM*, 2021/07/26/ 2021, doi: https://doi.org/10.1016/j.irbm.2021.07.002.

[12] M. S. Yang, "A survey of fuzzy clustering," *Mathematical and Computer Modelling*, vol. 18, no. 11, pp. 1-16, 1993/12/01/ 1993, doi: https://doi.org/10.1016/0895-7177(93)90202-A.

[13] V. Badrinarayanan, A. Kendall, and R. Cipolla, "SegNet: A Deep Convolutional Encoder-Decoder Architecture for Image Segmentation," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 39, no. 12, pp. 2481-2495, 2017, doi: 10.1109/TPAMI.2016.2644615.

[14] S. H. Gao, M. M. Cheng, K. Zhao, X. Y. Zhang, M. H. Yang, and P. Torr, "Res2Net: A New Multi-Scale Backbone Architecture," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 43, no. 2, pp. 652-662, 2021, doi: 10.1109/TPAMI.2019.2938758.

[15] O. Ronneberger, P. Fischer, and T. Brox, "U-Net: Convolutional Networks for Biomedical Image Segmentation," Cham, 2015: Springer International Publishing, in Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015, pp. 234-241.

[16] K. O Shea and R. Nash, "An Introduction to Convolutional Neural Networks," *ArXiv*, vol. abs/1511.08458, 2015.

[17] Z.-W. Yuan and J. Zhang, *Feature extraction and image retrieval based on AlexNet* (Eighth International Conference on Digital Image Processing (ICDIP 2016)). SPIE, 2016.

[18] S. Tammina, "Transfer learning using VGG-16 with deep convolutional neural network for classifying images," *International Journal of Scientific and Research Publications*, vol. 9, no. 10, pp. 143-150, 2019.

[19] P. Aswathy, Siddhartha, and D. Mishra, "Deep GoogLeNet Features for Visual Object

[1] Parallel Strength Pareto Evolutionary Algorithm
[2] Non-dominated Sorting Genetic Algorithm
[3] Memetic Differential Evolution

[Downloaded from jsdp.rcisp.ac.ir on 2026-11-25]

[DOI: 10.61186/jsdp.20.3.27]

[30] M. Rahimzadeh and A. Attar, "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*, vol. 19, p. 100360, 2020/01/01/ 2020, doi: https://doi.org/10.1016/j.imu.2020.100360.

[31] K. Medhi, M. Jamil, and M. I. Hussain, "Automatic Detection of COVID-19 Infection from Chest X-ray using Deep Learning," *medRxiv*, p. 2020.05.10.20097063, 2020, doi: 10.1101/2020.05.10.20097063.

[32] T. Ozturk, M. Talo, E. A. Yildirim, U. B. Baloglu, O. Yildirim, and U. Rajendra Acharya, "Automated detection of COVID-19 cases using deep neural networks with X-ray images," *Computers in Biology and Medicine*, vol. 121, p. 103792, 2020/06/01/ 2020, doi: https://doi.org/10.1016/j.compbiomed.2020.103792.

[33] I. D. Apostolopoulos and T. A. Mpesiana, "Covid-19: automatic detection from X-ray images utilizing transfer learning with convolutional neural networks," *Physical and Engineering Sciences in Medicine*, vol. 43, no. 2, pp. 635-640, 2020/06/01 2020, doi: 10.1007/s13246-020-00865-4.

[34] M. R. Karim, T. Döhmen, D. Rebholz-Schuhmann, S. Decker, M. Cochez, and O. Beyan, "DeepCOVIDExplainer: Explainable COVID-19 Predictions Based on Chest X-ray Images," *ArXiv*, vol. abs/2004.04582, 2020.

[35] T. Mahmud, M. A. Rahman, and S. A. Fattah, "CovXNet: A multi-dilation convolutional neural network for automatic COVID-19 and other pneumonia detection from chest X-ray images with transferable multi-receptive feature optimization," *Computers in Biology and Medicine*, vol. 122, p. 103869, 2020/07/01/ 2020, doi: https://doi.org/10.1016/j.compbiomed.2020.103869.

[36] B. Ghoshal and A. Tucker, "Estimating Uncertainty and Interpretability in Deep Learning for Coronavirus (COVID-19) Detection," *ArXiv*, vol. abs/2003.10769, 2020.

[37] P. K. Sethy, S. K. Behera, P. K. Ratha, and P. Biswas, "Detection of coronavirus disease (COVID-19) based on deep features and support vector machine," 2020.

[38] Y. Yujun, L. Jianping, and Y. Yimei, "The research of the fast SVM classifier method," in *2015 12th International Computer Conference on Wavelet Active Media Technology and Information Processing (ICCWAMTIP)*, 18-20 Dec. 2015 2015, pp. 121-124, doi: 10.1109/ICCWAMTIP.2015.7493959.

[39] M. E. H. Chowdhury *et al.*, "Can AI Help in Screening Viral and COVID-19 Pneumonia?," *IEEE Access*, vol. 8, pp. 132665-132676, 2020, doi: 10.1109/ACCESS.2020.3010287.

Tracking," in *2018 IEEE 13th International Conference on Industrial and Information Systems (ICIIS)*, 1-2 Dec. 2018 2018, pp. 60-66, doi: 10.1109/ICIINFS.2018.8721317.

[20] K. Zhang, Y. Guo, X. Wang, J. Yuan, and Q. Ding, "Multiple Feature Reweight DenseNet for Image Classification," *IEEE Access*, vol. 7, pp. 9872-9880, 2019, doi: 10.1109/ACCESS.2018.2890127.

[21] W. Wang, Y. Li, T. Zou, X. Wang, J. You, and Y. Luo, "A Novel Image Classification Approach via Dense-MobileNet Models," *Mobile Information Systems*, vol. 2020, p. 7602384, 2020/01/06 2020, doi: 10.1155/2020/7602384.

[22] F. Ucar and D. Korkmaz, "COVIDiagnosis-Net: Deep Bayes-SqueezeNet based diagnosis of the coronavirus disease 2019 (COVID-19) from X-ray images," *Medical Hypotheses*, vol. 140, p. 109761, 2020/07/01/ 2020, doi: https://doi.org/10.1016/j.mehy.2020.109761.

[23] C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens, and Z. Wojna, "Rethinking the inception architecture for computer vision," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2016, pp. 2818-2826.

[24] A. Mahajan and S. Chaudhary, "Categorical Image Classification Based On Representational Deep Network (RESNET)," in *2019 3rd International conference on Electronics, Communication and Aerospace Technology (ICECA)*, 12-14 June 2019 2019, pp. 327-330, doi: 10.1109/ICECA.2019.8822133.

[25] Z. Dong and S. Lin, "Research on image classification based on Capsnet," in *2019 IEEE 4th Advanced Information Technology, Electronic and Automation Control Conference (IAEAC)*, 20-22 Dec. 2019 2019, vol. 1, pp. 1023-1026, doi: 10.1109/IAEAC47372.2019.8997743.

[26] N. Ma, X. Zhang, H.-T. Zheng, and J. Sun, "Shufflenet v2: Practical guidelines for efficient cnn architecture design," in *Proceedings of the European conference on computer vision (ECCV)*, 2018, pp. 116-131.

[27] K. El Asnaoui and Y. Chawki, "Using X-ray images and deep learning for automated detection of coronavirus disease," *Journal of Biomolecular Structure and Dynamics*, pp. 1-12, 2020, doi: 10.1080/07391102.2020.1767212.

[28] M. Loey, F. Smarandache, and N. E. M. Khalifa, "Within the Lack of Chest COVID-19 X-ray Dataset: A Novel Detection Model Based on GAN and Deep Transfer Learning," *Symmetry*, vol. 12, no. 4, p. 651, 2020. [Online]. Available: https://www.mdpi.com/2073-8994/12/4/651.

[29] S. Asif, W. Yi, H. Jin, Y. Tao, and S. Jinhai, *Classification of COVID-19 from Chest X-ray images using Deep Convolutional Neural Networks*. 2020.

[Downloaded from jsdp.rcisp.ac.ir on 2026-11-25]

[DOI: 10.61186/jsdp.20.3.27]

[40] L. Wang, Z. Q. Lin, and A. Wong, "COVID-Net: a tailored deep convolutional neural network design for detection of COVID-19 cases from chest X-ray images," *Scientific Reports*, vol. 10, no. 1, p. 19549, 2020/11/11 2020, doi: 10.1038/s41598-020-76550-z.

[41] A. I. Khan, J. L. Shah, and M. M. Bhat, "CoroNet: A deep neural network for detection and diagnosis of COVID-19 from chest x-ray images," *Computer Methods and Programs in Biomedicine*, vol. 196, p. 105581, 2020/11/01/ 2020, doi: https://doi.org/10.1016/j.cmpb.2020.105581.

[42] A. S. Elkorany and Z. F. Elsharkawy, "COVIDetection-Net: A tailored COVID-19 detection from chest radiography images using deep learning," *Optik*, vol. 231, p. 166405, 2021/04/01/ 2021, doi: https://doi.org/10.1016/j.ijleo.2021.166405.

[43] R. Ribani and M. Marengoni, "A survey of transfer learning for convolutional neural networks," in *2019 32nd SIBGRAPI Conference on Graphics, Patterns and Images Tutorials (SIBGRAPI-T)*, 2019: IEEE, pp. 47-57.

[44] W. Pan and I. Hawrysiewycz, "Assisting learners to dynamically adjust learning processes through software agents," *International Journal of Intelligent Information Technologies (IJIIT)*, vol. 2, no. 2, pp. 1-15, 2006.

[45] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "Imagenet classification with deep convolutional neural networks," *Advances in neural information processing systems*, vol. 25, pp. 1097-1105, 2012.

[46] S. Mallat, "Understanding deep convolutional networks," *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, vol. 374, no. 2065, p. 20150203, 2016, doi: doi:10.1098/rsta.2015.0203.

[47] Y. Ji, Q. Wang, X. Li, and J. Liu, "A survey on tensor techniques and applications in machine learning," *IEEE Access*, vol. 7, pp. 162950-162990, 2019.

[48] D. P. Kingma and J. Ba, "Adam: A method for stochastic optimization," *arXiv preprint arXiv:1412.6980*, 2014.

[49] J. Zhang, "Gradient descent based optimization algorithms for deep learning models training," *arXiv preprint arXiv:1903.03614*, 2019.

[50] S. Ruder, "An overview of gradient descent optimization algorithms," *arXiv preprint arXiv:1609.04747*, 2016.

[51] "Chest X-ray images (covid-19)." https://github.com/ieee8023/covid-chestxray-dataset (accessed.

[52] "Chest X-ray images (pneumonia)." https://www.kaggle.com/chest-xray-pneumonia (accessed.

[53] F. Chollet, *Deep learning with Python*. Manning New York, 2018.

[54] T. Ozturk, M. Talo, E. A. Yildirim, U. B. Baloglu, O. Yildirim, and U. R. Acharya, "Automated detection of COVID-19 cases using deep neural networks with X-ray images," *Computers in biology and medicine*, vol. 121, p. 103792, 2020.

[55] L. Wang, Z. Q. Lin, and A. Wong, "Covid-net: A tailored deep convolutional neural network design for detection of covid-19 cases from chest x-ray images," *Scientific Reports*, vol. 10, no. 1, pp. 1-12, 2020.

[56] D. Singh and V. Kumar, "A Comprehensive Review of Computational Dehazing Techniques," *Archives of Computational Methods in Engineering*, vol. 26, no. 5, pp. 1395-1413, 2019/11/01 2019, doi: 10.1007/s11831-018-9294-z.

[57] A. Gupta, D. Singh, and M. Kaur, "An efficient image encryption using non-dominated sorting genetic algorithm-III based 4-D chaotic maps," *Journal of Ambient Intelligence and Humanized Computing*, vol. 11, no. 3, pp. 1309-1324, 2020/03/01 2020, doi: 10.1007/s12652-019-01493-x.

[58] M. Kaur, D. Singh, K. Sun, and U. Rawat, "Color image encryption using non-dominated sorting genetic algorithm with local chaotic search based 5D chaotic map," *Future Generation Computer Systems*, vol. 107, pp. 333-350, 2020/06/01/ 2020, doi: https://doi.org/10.1016/j.future.2020.02.029.

[59] M. Kaur and V. Kumar, "Beta chaotic map based image encryption using genetic algorithm," *International Journal of Bifurcation and Chaos*, vol. 28, no. 11, p. 1850132, 2018.

[60] H. S. Pannu, D. Singh, and A. K. Malhi, "Multi-objective particle swarm optimization-based adaptive neuro-fuzzy inference system for benzene monitoring," *Neural Computing and Applications*, vol. 31, no. 7, pp. 2195-2205, 2019/07/01 2019, doi: 10.1007/s00521-017-3181-7.

[61] D. Singh, V. Kumar, and M. Kaur, "Image dehazing using window-based integrated means filter," *Multimedia Tools and Applications*, vol. 79, no. 47, pp. 34771-34793, 2020/12/01 2020, doi: 10.1007/s11042-019-08286-6.

[62] D. Singh and V. Kumar, "Dehazing of outdoor images using notch based integral guided filter," *Multimedia Tools and Applications*, vol. 77, no. 20, pp. 27363-27386, 2018/10/01 2018, doi: 10.1007/s11042-018-5924-6.

[63] D. Singh, V. Kumar, and M. Kaur, "Single image dehazing using gradient channel prior," *Applied Intelligence*, vol. 49, no. 12, pp. 4276-4293, 2019/12/01 2019, doi: 10.1007/s10489-019-01504-6.

[Downloaded from jsdp.rcisp.ac.ir on 2026-11-25]

[DOI: 10.61186/jsdp.20.3.27]



وحید محمّدیان تکالو متولد ۱۳۷۵ در ارومیه است. مدرک کارشناسی و کارشناسی ارشد خود را در رشته مهندسی نرم‌افزار به‌ترتیب از دانشگاه تبریز و دانشگاه شهید مدنی آذربایجان دریافت کرده‌اند. ایشان از سال ۱۳۹۸ تاکنون عضو آزمایشگاه هوش مصنوعی و یادگیری ماشین دانشکدهٔ فناوری اطلاعات و مهندسی کامپیوتر دانشگاه شهید مدنی آذربایجان هستند. زمینه‌های پژوهشی نام‌برده عبارتند از: پردازش تصاویر پزشکی، بازشناخت الگو و یادگیری ماشین. نشانی رایانامهٔ ایشان عبارت است از:

vahid.mohammadian@azaruniv.ac.ir



مهدی هاشم‌زاده متولد ۱۳۵۸ در شهر تبریز است. ایشان درجهٔ کارشناسی و کارشناسی ارشد مهندسی کامپیوتر گرایش نرم‌افزار را به‌ترتیب در سال‌های ۱۳۸۰ و ۱۳۸۵ دریافت کرد و در سال ۱۳۹۲ دکترای تخصصی علوم کامپیوتر گرایش هوش مصنوعی و بینایی ماشین را از دانشگاه Zhejiang کشور چین دریافت کرد. ایشان از مهرماه سال ۱۳۹۲ تاکنون عضو هیئت علمی دانشکدهٔ فناوری اطلاعات و مهندسی کامپیوتر دانشگاه شهید مدنی آذربایجان است که در حال حاضر دارای مرتبه علمی دانشیاری هستند. همچنین ایشان مؤسس و مدیر آزمایشگاه هوش مصنوعی و یادگیری ماشین این دانشکده هستند. زمینه‌های پژوهشی نام‌برده عبارتند از: نظارت ویدئویی هوشمند، داده‌کاوی، بینایی ماشین، بازشناخت الگو، و یادگیری ماشین. نشانی رایانامهٔ ایشان عبارت است از:

hashemzadeh@azaruniv.ac.ir



جلیل قویدل نیچران در سال ۱۳۸۷ مدرک کارشناسی خود را در رشته مهندسی کامپیوتر گرایش نرم‌افزار دریافت کرد؛ سپس مدرک کارشناسی ارشد و دکترای خود را در رشته مهندسی کامپیوتر گرایش هوش مصنوعی به‌ترتیب از دانشگاه علم و صنعت ایران و دانشگاه صنعتی شاهرود در سال‌های ۱۳۹۰ و ۱۳۹۸ دریافت کرد. ایشان در حال حاضر به‌عنوان عضو هیئت علمی دانشکدهٔ فناوری اطلاعات و مهندسی کامپیوتر دانشگاه شهید مدنی آذربایجان مشغول فعالیت است. زمینه‌های پژوهشی مورد علاقه ایشان یادگیری ماشین، پردازش تصویر، بینایی ماشین، بازشناسی الگو و یادگیری عمیق است. نشانی رایانامهٔ ایشان عبارت است از:

j.ghavidel@azaruniv.ac.ir

[Downloaded from jsdp.rcisp.ac.ir on 2026-11-25]

[DOI: 10.61186/jsdp.20.3.27]