



وحید محمدیان تکالو^{۱،۲*}، مهدی هاشم‌زاده^{۱،۲*} و جلیل قویدل نیچران^{۱،۲}

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

^۲آزمایشگاه 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 اکسپشن 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 فراهم کردن 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، تنزل 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 گردآوری شده 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}

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

²Artificial 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

* Corresponding author

* نویسنده عهده‌دار مکاتبات

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.

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 ارگانیسم‌ها^۶ به صورت 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 میکروارگانیسم‌های سلولی یا غیرسلولی ایجاد می‌شود. ذات‌الریه غیرسلولی ویروسی^۷ می‌تواند به کرونا ویروس یا واریسلا تقسیم شود. ذات‌الریه سلولی نیز می‌تواند به ذات‌الریه باکتریایی^۸ و استرپتوکوک‌ها یا ذات‌الریه قارچی^۹ 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^{۱۰} 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؛ به گونه‌ای 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.

۱- مقدمه

بیماری کرونا ویروس ۲۰۱۹ (کوید-۱۹)، ناشی از سندرم تنفسی حاد شدید کرونا ویروس ۲۲، یک بیماری همه‌گیر جهانی است [1]. پس از مشاهده اولیه این ویروس در آذر ماه سال ۱۳۹۸ در شهر ووهان چین، به سرعت 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^۲ اعلام کرد و ۲۱ اسفند ۱۳۹۸ آن را به عنوان یک بیماری همه‌گیر تشخیص داد. طبق آمار اعلام‌شده توسط سازمان بهداشت جهانی^۴ 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^۵ در بیماران مبتلا به این ویروس مشاهده می‌شود [2]؛ و به دلیل 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 مسغول انتقال گاز اکسیژن بوده و می‌تواند به وسیله ارگانیسم‌های مختلف مانند ویروس‌ها، باکتری‌ها یا قارچ‌ها ایجاد شود. بیماری ذات‌الریه را نمی‌توان به عنوان یک

⁶ Microorganisms

⁷ Viral Pneumonia

⁸ Bacterial Pneumonia

⁹ Fungal Pneumonia

¹⁰ ICD-10


¹ Covid-19

² SARS-CoV-2

³ PHEIC

⁴ World Health Organization

⁵ ARDS



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

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

استفاده از تصاویر اشعه ایکس قفسه سینه برای تشخیص بیماری کوید-۱۹ گزینه ازرا نتر 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 کم‌هزینه‌تر 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^۴، 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 برچسب‌گذاری‌شده کافی در اختیار داشته باشیم. با رشد سریع و گسترش کوید-۱۹

هم‌اکنون آزمایش آر‌تی-پی‌سی‌آر^۱ 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^۲ و سی‌تی‌اسکن قفسه سینه^۳ 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،

¹ RT-PCR

² Chest X-ray

³ Chest CT scan

⁴ Covid-19 Xception Network

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 دسترس نبودن داده‌ها و طراحی معماری مناسب روش‌های یادگیری ماشین برای تشخیص و تمایز بیماری کوید-۱۹ با انواع ذات‌الریه (باکتریایی و ویروسی) است.

به دلیل نوظهور بودن بیماری کوید-۱۹، پایگاه داده رادیوگرافی جامعی، که علاوه بر 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 به‌نسب پائینی 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^۱ [9] چند لایه است. این مدل می‌تواند وزن‌های آموزش دیده از مجموعه داده‌های بزرگ قبلی را به عنوان وزن‌های اولیه مدل جدید مورد استفاده قرار دهد و تا حدودی مشکل کمبود داده را جبران کند. برای جلوگیری از مشکل بیش‌برازش^۲، از فنون افزایش داده^۳، تنزل وزن^۴ و

تنظیم کننده‌های لایه^۵ 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^۶ 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^۷ استفاده شده‌است. این معماری، یادگیری ویژگی‌های کانال و فضا را از هم جدا می‌کند؛ علاوه بر این، اتصالات باقی‌مانده برای حل مشکل ناپدید شدن گرادینت‌ها 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.

به اختصار 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

³ Data Augmentation

⁴ Weight Decay

⁵ L2-Regularizers

⁶ Francois Chollet

⁷ Depthwise Separable Convolution

¹ Xception

² Over-fitting

مربوط به سامانه CoviX-Net را توضیح می‌دهد. بخش ۴ نتایج آزمایش‌ها و ارزیابی‌های صورت گرفته را ارائه می‌کند. و در نهایت بخش ۵ به نتیجه‌گیری و کارهای آینده می‌پردازد.

۲- کارهای پیشین

تاکنون موارد متعددی از سامانه‌های تشخیص رایانه‌ای^۱، 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^۲ و روش‌های مبتنی بر طبقه‌بندی^۳ 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 تصاویر، روش‌های مختلفی وجود دارد که می‌توان آن‌ها را به دو دسته روش‌های مبتنی بر هیس‌گرام^۴ و مبتنی بر خوشه‌بندی^۵ 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^۶ [12] و روش‌های یادگیری عمیق مانند سیگ‌نت^۷ [13]، رس‌نت^۸ [14] و یو-نت^۹ [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 کانولوشن^{۱۰} [16]

آلکس‌نت^{۱۱} [17]، وی‌جی‌جی‌نت^{۱۲} [18]، گوگل‌نت^{۱۳} [19]، دنس‌نت^{۱۴} [20]، اکسپشن‌نت [9]، موبایل‌نت^{۱۵} [21]، اسکوییزنت^{۱۶} [22]، اینکپشن^{۱۷} [23]، رس‌نت^{۱۸} [24]، کپس‌نت^{۱۹} [25] و شافل‌نت^{۲۰} [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 دقت طبقه‌بندی ۹۲/۱۸ درصد، بالاترین دقت را در بین مدل‌های دیگر کسب کرده‌است. لویی و همکاران [28] یک روش یادگیری عمیق مبتنی بر گن^{۲۱} برای تشخیص کوید-۱۹ با استفاده از تصاویر اشعه ایکس قفسه سینه پیشنهاد کردند. آن‌ها سه مدل آلکس‌نت، گوگل‌نت و رس‌نت-۱۸ را مورد بررسی قرار دادند. مدل گوگل‌نت در طبقه‌بندی سه‌طبقه و دوطبقه به‌ترتیب به بیشترین دقت برابر با ۸۰/۶۰ درصد و ۹۹/۹۰ درصد رسیده‌است. در [29]، آسیف و همکاران با استفاده از تصاویر اشعه ایکس قفسه سینه، یک سامانه 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 به‌دقت 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 اکسپشن و رس‌نت-۵۰ وی^{۲۲} ارائه کردند. دقت 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^{۲۲} آزمایش کردند. دقت مدل آن‌ها ۹۳ درصد بود.

¹¹ AlexNet

¹² VGGNet

¹³ GoogleNet

¹⁴ DenseNet

¹⁵ MobileNet

¹⁶ SqueezeNet

¹⁷ Inception

¹⁸ ResNet

¹⁹ CapsNet

²⁰ ShuffleNet

²¹ GAN

²² Kaggle

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

/وزتورک و همکارانش [32] نیز مدل دارکنت^۱ 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]، مپسیانا 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 دقت 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 اتساع^۲ مختلف برای استخراج مؤثر ویژگی‌های متنوع از تصاویر اشعه ایکس قفسه سینه استفاده می‌کرد. آنان از یک پایگاه داده چهار بقیه شامل طبقه‌های کوید-۱۹، ریه طبیعی، ذات‌الریه باکتریایی و ذات‌الریه ویروسی با تعداد ۵,۸۵۶ تصویر استفاده کردند. مدل آن‌ها دقت ۹۰/۳۰ درصد را به‌دست آورد. در [36]، قوشال و همکاران از یک شبکه عصبی کانولوشنی پیزی برای تشخیص کوید-۱۹ با استفاده از تصاویر اشعه ایکس استفاده کردند. دقت طبقه‌بندی به دست آمده از روش آنها ۹۰ درصد بود. در [37]، از مدل رسنت-۵۰ برای استخراج ویژگی‌های تصاویر بیماران استفاده کردند. آن‌ها از طبقه‌بند ماشین بردار پشتیبان^۳ [38] نیز به عنوان طبقه‌بند نهایی استفاده کردند. دقت طبقه‌بندی به‌دست آمده 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، رسنت-۱۸، دینسنت-۲۰۱ و اسکویزنت به کار گرفته شده‌است. بالاترین دقت طبقه‌بندی به‌دست آمده مربوط به اسکویزنت با دقت 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 دقت 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 دقت ۸۹/۶۰ درصد رسید. در [42]، لکرنی و همکاران مدل کویدیکشن-نت^۴ را پیشنهاد دادند. کویدیکشن-نت از معماری اسکویزنت و شافلنت برای استخراج ویژگی، و از ماشین‌های بردار پشتیبان چندطبقه^۵ برای طبقه‌بندی تصاویر اشعه ایکس قفسه سینه استفاده می‌کند. دقت 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 کلی 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 اکسپشن [9] چندلایه برای طبقه‌بندی تصاویر رادیوگرافی ریه (قفسه سینه) ورودی استفاده می‌کند. همان‌طور که در شکل (۲) مشاهده می‌شود، CoviX-Net از سه بخش اصلی تشکیل شده‌است: بخش نخست تصویر ورودی را دریافت کرده و روی آن پیش‌پردازش^۶ انجام می‌دهد. بخش دوم شامل شبکه انتقالی است و وظیفه استخراج ویژگی از تصاویر ورودی را بر عهده دارد؛ در نهایت بخش سوم با استفاده از ویژگی‌های استخراج شده در بخش دوم، طبقه‌بندی تصویر به یکی از چهار طبقه «کوید-۱۹»، «ذات‌الریه باکتریایی»، «ذات‌الریه ویروسی» و «ریه طبیعی» را انجام می‌دهد. در ادامه جزئیات مربوط به هر یک از بخش‌های ذکرشده ارائه می‌شوند.

⁴ COVIDetection-Net


⁵ Multiclass Support Vector Machines (MSVM)

⁶ Pre-processing

¹ DarkNet

² Dilation

³ SVM



۲-۳- پیش پردازش

در مرحله پیش پردازش، دو عمل برش^۱ تصویر و تغییر اندازه آن انجام می شود. این عملیات برای آماده سازی تصاویر لازم است؛ چون تصاویر از پایگاه داده ها و دستگاه های اشعه ایکس مختلف جمع آوری می شوند و هر کدام دارای اندازه و ریزنمایی متفاوتی هستند. از این رو، ناحیه قفسه سینه تصاویر برش داده شده و همچنین همه تصاویر به ابعاد 150×150 پیکسل با وضوح ۹۶ dpi^۲ تغییر اندازه می یابند؛ شکل (۳) نمونه هایی از تصاویر قفسه سینه پیش پردازش شده را نشان می دهد.

۳-۳- یادگیری انتقالی و استخراج ویژگی

۱-۳-۳- یادگیری انتقالی

یادگیری انتقالی^۳ به معنای استفاده از دانش یک مدل آموزش دیده در یک کاربرد متفاوت، اما مرتبط است [44]. در واقع هدف این است که از دانش و وزن هایی که در یک کاربرد به دست آمده است برای بهبود تعمیم پذیری در کاربردی دیگر استفاده شود. به طور معمول در صورتی که داده آموزشی به اندازه کافی در دسترس باشد، می توان با افزایش تعداد لایه ها (یا وزن های) یک شبکه عصبی عمیق دقت آن را بهبود داد. اما با توجه به نوظهور بودن بیماری کوید-۱۹ و کمبود تصاویر بیماران مبتلا به این ویروس، نمی توان شبکه های بزرگ را با این تعداد تصویر آموزش داد. یادگیری انتقالی روشی است که این مشکل را تا حدود زیادی می تواند مرتفع سازد.

در یادگیری انتقالی ابتدا یک شبکه روی داده های کاربردی متفاوت اما مرتبط با کاربرد اصلی آموزش داده می شود؛ سپس وزن های شبکه آموزش داده شده به عنوان وزن های اولیه برای آموزش شبکه روی داده های مسئله اصلی مورد استفاده قرار می گیرند. این روش علاوه بر مرتفع ساختن نیاز به داده های بسیار زیاد، زمان آموزش شبکه را نیز تا حد زیادی کاهش می دهد. در طراحی CoviX-Net از مدل یادگیری انتقالی اکسپشن [9] استفاده می شود.

۲-۳-۳- مدل اکسپشن

مدل اکسپشن دارای یک معماری ۷۱ لایه ای عمیق کانولوشنی است که از قبل بر روی داده های ImageNet [45] آموزش دیده است. این معماری مجموعه ای خطی از لایه های کانولوشن جداپذیر عمقی با اتصالات

باقی مانده^۴ است. در این مدل به جای لایه های کانولوشن کلاسیک از لایه های کانولوشن جداپذیر عمقی^۵ استفاده شده است. در واقع هدف این لایه ها جایگزین کردن 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 شده است. همان طور که در این شکل مشاهده می شود، این مدل شامل لایه های کانولوشنی، پولینگ و کاملاً متصل است که در ادامه توضیحات لازم در مورد هر یک از این لایه ها ارائه شده و کاربردها در سامانه مورد هدف تشریح می شود. شبکه های کانولوشنی [46] مدلی از شبکه های عصبی مصنوعی است که همانند شبکه های عصبی معمولی از نورون ها، لایه ها و وزن ها تشکیل شده است. مهم ترین وجه تمایز این نوع از شبکه ها با مدل های دیگر قابلیت ویژه آن ها در استخراج ویژگی است. در دستگاه بینایی انسان، نواحی ادراکی که قشر بینایی در آن قرار دارد، همانند فیلترهای محلی بر روی اطلاعات تصویر اعمال می شود؛ سلول های ساده تر برای تشخیص ویژگی های سطح پایین تر در نواحی ادراکی هم چون لبه ها کاربرد دارند؛ همچنین سلول های پیچیده قادر به تشخیص ویژگی های مهم تر و در سطوح بالاتر هستند. تشخیص ویژگی های سطح بالاتر با ترکیب ویژگی های سطح پایین صورت می گیرد. این عملکرد مغز با تغییرات بسیار گسترده الهام بخش شبکه های عمیق عصبی امروزی شده است.

شبکه عصبی کانولوشنی مدلی از شبکه های عصبی چند لایه است که به طور معمول شامل لایه های کانولوشنی، پولینگ و کاملاً متصل است. در یک شبکه عصبی معمولی، شبکه ورودی را دریافت می کند و آن را به تعدادی لایه مخفی می فرستد.

هر لایه مخفی از تعدادی نورون به شکل یک بردار تشکیل شده است که هر یک از آن ها به طور کامل به تمامی نورون های لایه قبلی خود متصل هستند. نورون ها در هر لایه به طور مستقل عمل می کنند و در ارتباطات و وزن ها با یکدیگر شریک نمی شوند. لایه آخر این شبکه، لایه خروجی بوده که مسئول نهایی تعیین طبقه داده ها است. اما در شبکه های کانولوشنی، ورودی یک ماتریس چند لایه یا دارای عمق، مانند یک تصویر است و لایه های این شبکه بر خلاف شبکه های عصبی معمولی، متشکل از نورون هایی در سه بعد هستند، که در برخی از منابع به آن ها «تِنسور»^۶ [47] نیز گفته می شود.

^۴ Residual


^۵ Depthwise Separable Convolution

^۶ Tensor


^۱ Crop

^۲ Dots per inch

^۳ Transfer Learning



(شکل-۴): معماری اکسپشن
[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

همزمان با سایر بخش‌های شبکه روی داده‌های قفسه سینه آموزش می‌بینند. این تنظیمات به یادگیری بهتر مدل کمک می‌کند. معماری شبکه عصبی 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

شکل خروجی	لایه
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 پولینگ میانگین کلی 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 کلیات است. در واقع با افزودن این لایه، شبکه را مجبور می‌کنیم تا با بهره‌برداری از نرون‌های مختلف، تا حد ممکن مفاهیم سطح بالا را آموزش ببیند. 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.

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. همان‌طور که 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، علاوه بر این لایه‌های کاملاًمتصل که در انتهای شبکه قرار می‌گیرند، لایه‌های کانولوشنی نیز مورد استفاده قرار می‌گیرند. این لایه‌ها عمل استخراج ویژگی از تصویر ورودی را متناسب با تصاویر ورودی یاد می‌گیرند و در زمان استفاده از شبکه آنرا به‌صورت خودکار انجام می‌دهند. درحالی که 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 فعالیت^۱ 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.

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

۳-۴- طبقه‌بندی

همان‌طور که در شکل (۲) نشان داده شده‌است، گام طبقه‌بندی نهایی تصویر پس از بخش اکسپشن قرار گرفته و متشکل از لایه‌های پولینگ میانگین کلی دوبعدی^۲، نرمال‌سازی دسته‌ای^۳، حذف تصادفی^۴ و کاملاًمتصل (متراکم)^۵ است. آخرین لایه کاملاًمتصل با تابع فعال‌ساز «سافت‌مکس» برای پیش‌بینی طبقه‌ها ایجاد می‌شود. وزن‌های بدنه کانولوشنی اکسپشن نیز پس از مقداردهی اولیه با وزن‌های به‌دست‌آمده از آموزش روی ImageNet.

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



(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

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^۶ 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 گگل [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 نشانی <https://github.com/Vahid-Mohammadian-Takaloo/CoviX-Net> در اختیار عموم پژوهش‌گران قرار می‌گیرد.

۵-۳-۲- افزایش تصاویر آموزشی

علاوه بر گردآوری مجموعه تصاویر مناسب برای آموزش مدل یادگیری، برای بهبود دقت مدل و جلوگیری از مشکل بیش‌برازش^۷، از فنون افزایش داده^۸ استفاده

این رابطه با نام تابع لاس^۱ شناخته می‌شود. ایده اساسی در آموزش شبکه، کمینه‌سازی تابع لاس «کراس-آنتروپی دسته‌ای»^۲ با پیمودن گام‌های مناسب برای رسیدن به نتیجه بهتر است. با توجه به ماهیت مسئله، ما از الگوریتم بهینه‌سازی آدام^۳ [48] استفاده می‌کنیم. این الگوریتم مزایای دو الگوریتم «کاهش شیب تصادفی»^۴ [49] و «آدا-گراد»^۵ [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 «سافت‌مکس» استفاده می‌شود.

۵-۳-۱- 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.

۵-۳-۱- گردآوری مجموعه تصاویر آموزشی

به دلیل نوظهور بودن بیماری کوید-۱۹، در حال حاضر هیچ مجموعه داده‌ی یکپارچه‌ای که شامل تمامی

¹ Loss Function

² Categorical Crossentropy

³ Adam

⁴ Stochastic Gradient Descent

⁵ Adagrad

⁶ Git-hub

⁷ Overfitting

⁸ Data Augmentation

۴- آزمایش‌ها و نتایج به دست آمده

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

۴-۱- مدل‌های مختلف ارزیابی

با هدف بررسی تأثیر هر یک از عملیات به کار گرفته شده 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 شده است).

گفتنی است، همان‌طور که پیش‌تر اشاره شد، از آنجایی که تصاویر قفسه سینه موجود از دستگاه‌های متفاوت رادیوگرافی و پایگاه داده‌های گوناگون به دست آمده‌اند و کنتراست برخی از آنها مناسب نیست، پیش‌بینی می‌شود فن افزایش داده «تغییر کنتراست تصاویر» تأثیر به‌سزایی در بهبود عملکرد سیستم داشته باشد؛ از این‌رو مدل‌های شماره ۱ و ۲ را برای ارزیابی این موضوع تعریف کردیم. همین‌طور مدل‌های شماره ۴ و ۵ به منظور ارزیابی تأثیر «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

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 استفاده شده بر روی مجموعه تصاویر آموزشی به همراه جزئیات پارامترهای هر فن ارائه شده است. گفتنی است که این فنون افزایش داده فقط بر روی مجموعه تصاویر آموزشی اعمال می‌شود. با اعمال آنها، تعداد کل تصاویر آموزشی از ۸۴۰۰ تصویر، به ۲۶۲۵۰ تصویر افزایش پیدا می‌کند.

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

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

در فن بزرگ‌نمایی^۱، ابتدا ابعاد تصویر به صورت 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^۲ تصاویر را تغییر می‌دهد. با توجه به وجود دستگاه‌های متفاوت رادیوگرافی و جمع‌آوری تصاویر از پایگاه داده‌های 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، علاوه بر افزایش داده‌های آموزشی، کنتراست تصاویر در حالت مطلوب نیز به شبکه وارد می‌شود.

روش بعدی افزایش داده، تغییر عرض^۳ و ارتفاع^۴ تصاویر است؛ با این کار، عرض و ارتفاع تصویر به صورت تصادفی به مقدار حداکثر ده درصد از سمت چپ، راست، بالا و پایین شیفت داده می‌شود؛ سپس نواحی خالی شده با رنگ سیاه می‌شوند. آخرین روش افزایش داده‌ها، روش انعکاس افقی^۵ تصاویر است که هر تصویر را به صورت افقی انعکاس می‌دهد. درواقع سمت چپ و راست تصویر را جابه‌جا می‌کند.

با اعمال فنون افزایش داده یاد شده بر روی تصاویر گردآوری شده، 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

داده برای آموزش شبکه، ۱۵٪ برای اعتبارسنجی و تنظیم ابرپارامترهای شبکه، و ۱۵٪ نیز برای ارزیابی کارایی آن استفاده می‌شوند. تمامی پیاده‌سازی‌ها با استفاده از کتابخانه کراس^۱ و بک-اند^۲ تنسورفلو^۳ 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^۴ ۰/۰۰۰۳، اندازه دسته^۵ ۳۲ و تعداد ۱۰۰ دوره^۶ استفاده می‌شود.

برای جلوگیری از مشکل بیش‌برازش، علاوه بر فنون افزایش داده، از فن تَنزَلِ وزن و تنظیم کننده‌های L2 در لایه‌های انتهایی بخش کانولوشنی مدل با مقدار ۰/۰۰۰۳ استفاده می‌شود. لایه‌های بالایی مدل بصورت فریز^۷ 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^۸ و تابع دقت برای ارزیابی نتایج بدست آمده استفاده می‌شود. تمامی آزمایش‌ها بر روی دستگاه رایانه با پردازنده اینتل کور-آی ۹۷^۹ 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^{۱۰} و معیارهای سنجش عملکرد دقت^{۱۱}، صحت^{۱۲}، پوشش^{۱۳}، حساسیت^{۱۴} و نمره-F^{۱۵} حاصل از ماتریس استفاده می‌شود.

۴-۴- نتایج آزمایش‌ها

۴-۴-۱- 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 آورده‌است. 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 به دست 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 تأیید 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 به جای استفاده از کانولوشن سنتی، از کانولوشن با نرخ اتساع^{۱۶} 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 اسکویزنت 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 برتر بودن 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 اکسپشن 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 آزمایش شده دارای منابع مشترک هستند؛ به‌طوری‌که به دلیل نوظهور بودن بیماری کوید-۱۹، پایگاه داده‌های متنوع زیادی در دسترس نیست و تصاویر مربوط به طبقه کوید-۱۹ به‌طور تقریبی همگی از یک منبع مشخص استفاده شده‌اند که در بخش ۱-۵-۳ معرفی شده‌اند.

¹⁶ Dilation Rates

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

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

دقت (%)	نمره-اف (%)	پوشش (%)	صحت (%)	روش
89.60	89.80	89.92	90.00	[(سال ۲۰۲۰) ۴۱ خان و همکاران]
90.20	90.40	89.90	90.80	[(سال ۲۰۲۰) ۳۵ تنویر و همکاران]
94.45	94.40	94.45	94.42	[(سال ۲۰۲۱) ۴۲ الکرانی و همکاران]
93.05	93.00	93.00	93.25	با مدل ۱ CoviX-Net
93.16	93.50	93.25	93.25	با مدل ۲ CoviX-Net
93.50	93.25	93.50	93.50	با مدل ۳ CoviX-Net
89.38	89.50	89.25	89.75	با مدل ۴ CoviX-Net
95.00	94.75	95.25	95.00	با مدل ۵ CoviX-Net

عملکرد مناسبی هم بر روی تصاویر آموزشی و هم تصاویری اعتبارسنجی می‌رسد، کاهش ملایم شیب نمودار به صورت منظم در شکل (۸) حاکی از نبود مشکل بیش‌برازش در مرحله آموزش و آزمون است.



(شکل ۸-): منحنی خطا و دقت CoviX-Net روی مجموعه داده

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 به طور 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.

در رابطه با طبقات دیگر نیز بیش از پنجاه درصد از تصاویر استفاده شده 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 پیش‌بینی شده به وسیله CoviX-Net را نشان می‌دهند. همان‌طور که 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، همان‌طور که انتظار می‌رفت به دلیل تشابه زیاد تصاویر، چند مورد طبقه‌بندی نادرست انجام گرفته است. با این حال، عملکرد رضایت‌بخشی برای سایر موارد طبقه‌بندی به دست آمده است. بهترین نتیجه با مدل ۵ به دست 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 دقت داده‌های بخش آموزش و اعتبارسنجی بهترین مدل چهار طبقه (مدل ۵) نشان داده شده‌است. همان‌طور که در این شکل مشاهده می‌شود، در ابتدای آموزش میزان خطای مدل بالا و میزان دقت 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 به گونه‌ای که رفته‌رفته به دقت



(شکل-۷): ماتریس درهم‌ریختگی نتایج با CoviX-Net (پنج مدل: الف) مدل ۱، (ب) مدل ۲، (ج) مدل ۳، (د) مدل ۴، و (ه) 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 (%)
[(سال ۲۰۲۰) 54 آوزتورک و همکاران]	85.35	89.96	87.37	87.02
[(سال ۲۰۲۰) 30 رحیم‌زاده و همکاران]	73.50	87.00	-	91.40
[(سال ۲۰۲۰) 55 وانگ و همکاران]	-	93.33	-	92.64
با مدل CoviX-Net ۶	99.00	93.33	99.50	99.25

همان گونه که مشاهده می شود، روش اوزتورک و همکاران [54]، که مبتنی بر شبکه عصبی عمیق بدون استفاده از راهبردهای یادگیری انتقالی است، با دقت ۸۷/۰۲ درصد عملکرد بسیار ضعیف تری نسبت به CoviX-Net دارد. دو روش دیگر [30] و [55] نیز که از شبکه های سنتی با طرح یادگیری انتقالی از پایگاه داده ImageNet استفاده کرده اند، به ترتیب به دقت ۹۱/۴۰ و ۹۲/۶۴ درصد دست یافته اند. نتایج به دست آمده به وسیله CoviX-Net به دلیل بهره گیری از روش یادگیری انتقالی و مجموعه داده آموزشی مناسب و کافی، نسبت به سایر روش ها بهتر است. شکل (۹) ماتریس درهم ریختگی مدل سه طبقه CoviX-Net را نشان می دهد، که نتایج تشخیص بسیار خوبی برای هر سه طبقه مشاهده می شود.

کویید-۱۹	۱۱۰۰	۰۰۰	۰۰۰
طبیعی	۰۰۰	۱۱۰۰	۰۰۰
ذات الریه	۰۰۰	۰۲	۰۹۸
	۴۴۹	۴۴۸	۴۴۳
	کویید-۱۹	طبیعی	ذات الریه

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

۵- نتیجه گیری و محورهای توسعه و مطالعه بیشتر

در این پژوهش، سامانه هوشمند CoviX-Net برای تشخیص و تمایز خودکار بیماری کویید-۱۹ و دو نوع رایج ذات الریه از روی تصاویر رادیوگرافی قفسه سینه ارائه شد. با توجه به نوظهور بودن بیماری کویید-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 شبکه ها در مجموعه داده های بسیار بزرگ و همچنین تنظیم دقیق وزن شبکه های از قبل آموزش دیده بر روی مجموعه داده های کوچک و جدید هستند. معماری شبکه پیشنهادی بر روی ۱۲۰۰۰ تصویر رادیوگرافی شامل برچسب های کویید-۱۹، ذات الریه باکتریایی، ذات الریه ویروسی و ریه طبیعی جمع آوری شده از دو پایگاه داده

مختلف آموزش داده شد. برای جلوگیری از مشکل بیش برازش، از فنون افزایش داده، تنزل وزن و تنظیم کننده های ال-۲ استفاده شد. برای ارزیابی عملکرد روش پیشنهادی از معیارهای ارزیابی دقت، صحت، پوشش، و نمره-اف استفاده شد. CoviX-Net در حالت سه طبقه (کویید-۱۹، ریه طبیعی و ذات الریه)، دقت تشخیص ۹۹/۲۵ درصد را به دست آورد و در حالت چهار طبقه (کویید-۱۹، ریه طبیعی، ذات الریه باکتریایی و ذات الریه ویروسی)، دقت تشخیص ۹۵ درصد را از خود نشان داد. نتایج آزمایش های به دست آمده حاکی از آن است که این سامانه می تواند برای تشخیص و تمایز سریع تر کویید-۱۹ و سایر عفونت های ذات الریه، ابزاری مناسب باشد و در مناطق دور افتاده که تحت تأثیر کویید-۱۹ قرار دارند، برای غلبه بر مشکل کمبود پزشکان و رادیولوژیست های متخصص استفاده شود.

به عنوان محورهای توسعه و مطالعه بیشتر در راستای این پژوهش، موارد زیر می تواند 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؛
- به دلیل عدم حاشیه نویسی از ناهنجاری های پاتولوژیک، مدل پیشنهادی نقشه های ویژگی طبقه را به روشی ضعیف (یعنی فقط توسط برچسب های طبقه در سطح تصویر) آموزش می بیند؛ که این موضوع منجر به عدم امکان محلی سازی آسیب شناسی ها و طبقه بندی تصاویر می شود. اتخاذ رویکردهای مناسب برای رفع این محدودیت می تواند راه گشای پژوهش های بیشتر باشد.
- تمامی عملیات و محاسبات انجام گرفته در این پژوهش بر پایه CPU است. برای بهبود سرعت عملکرد روش پیشنهادی در انجام محاسبات و همچنین امکان استفاده از تصاویر با اندازه بزرگ تر می توان از GPU برای انجام محاسبات استفاده کرد.
- طراحی و پیاده سازی مدل های یادگیری سبک تر، با مصرف حافظه و محاسبات کمتر، با الهام از مدل هایی که امروزه در حال توسعه هستند، می تواند سهولت به کارگیری سامانه پیشنهادی را بیشتر کنید.
- پارامترهای اولیه مدل پیشنهادی را می توان با استفاده از رویکردهای مختلف نظیر الگوریتم تکاملی

- 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](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

پارتو قدرت موازی^۱ [56]، الگوریتم ژنتیک مرتب‌سازی غیر-غالب^۲ [57، 58]، تکامل دیفرانسیل ممیتیک^۳ [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]، 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.

6-Refrence

۶- مراجع

- [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

¹ Parallel Strength Pareto Evolutionary Algorithm

² Non-dominated Sorting Genetic Algorithm

³ Memetic Differential Evolution

- [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.

- [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.
- [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. Hawrysiwycz, "Assisting learners to dynamically adjust learning processes through software agents," *International Journal of Intelligent Information Technologies (IJIT)*, 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: 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).

علمی دانشکده 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 رایانامه ایشان عبارت است از: j.ghavidel@azaruniv.ac.ir



وحید محمدیان 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 دانشکده فناوری اطلاعات و مهندسی کامپیوتر دانشگاه شهید مدنی آذربایجان هستند. زمینه‌های پژوهشی نام‌برده عبارتند از: پردازش تصاویر پزشکی، بازشناخت الگو و یادگیری ماشین. نشانی رایانامه ایشان عبارت است از:

vahid.mohammadian@azaruniv.ac.ir



مهدی هاشم‌زاده متولد ۱۳۵۸ در شهر تبریز است. ایشان درجه 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 دانشکده 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 رایانامه 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