

A Convolutional Neural Network Model for Detection of COVID-19 Disease and Pneumonia

Mousavi Seyed Mohammad¹, Hosseini Soodeh^{2*}

• Received: 14 Dec 2022

• Accepted: 13 Mar 2023

Introduction: COVID-19 has had a devastating impact on public health around the world. Since early diagnosis and timely treatment have an impact on reducing mortality due to infection with COVID-19 and existing diagnostic methods such as RT-PCR test are prone to error, the alternative solution is to use artificial intelligence and image processing techniques. The overall goal is to introduce an intelligent model based on deep learning and convolutional neural network to identify cases of COVID-19 and pneumonia for the purpose of subsequent treatment measures with the help of lung medical images.

Method: The proposed model includes two datasets of radiography and CT-scan. These datasets are pre-processed and the data enhancement process is applied to the images. In the next step, three architectures EfficientNetB4, InceptionV3, and InceptionResNetV2 are used using transfer learning method.

Results: The best result obtained for CT-scan images belongs to the InceptionResNetV2 architecture with an accuracy of 99.366% and for radiology images related to the InceptionV3 architecture with an accuracy of 96.943%. In addition, the results indicate that CT-scan images have more features than radiographic images, and disease diagnosis is performed more accurately on this type of data.

Conclusion: The proposed model based on a convolutional neural network has higher accuracy than other similar models. Also, this method by generating instant results can help in the initial evaluation of patients in medical centers, especially during the peak of epidemics, when medical centers face various challenges, such as lacking specialists and medical staffs.

Keywords: Image Processing, Artificial Intelligence, COVID-19, Convolutional Neural Network

• **Citation:** Mousavi SM, Hosseini S. A Convolutional Neural Network Model for Detection of COVID-19 Disease and Pneumonia. *Journal of Health and Biomedical Informatics* 2023; 10(1): 41-56. [In Persian] doi: 10.34172/jhbmi.2023.13

1. M.Sc of Computer Science, Department of Computer Science, Faculty of Mathematics and Computer, Shahid Bahonar University of Kerman, Kerman, Iran

2. PhD of Computer Engineering, Associate Professor, Department of Computer Science, Faculty of Mathematics and Computer, Shahid Bahonar University of Kerman, Kerman, Iran

*Corresponding Author: Soodeh Hosseini

Address: Pajooheh Sq, Imam Khomeni Highway, Kerman

• Tel: 03431322486

• Email: so_hosseini@uk.ac.ir

© 2023 The Author(s); Published by Kerman University of Medical Sciences. This is an open-access article distributed under the terms of the Creative Commons Attribution License (<http://creativecommons.org/licenses/by/4.0/>), which permits unrestricted use, distribution, and reproduction in any medium, provided the original work is properly cite

مدل شبکه عصبی پیچشی برای شناسایی بیماری COVID-19 و ذات الریه

سید محمد موسوی^۱، سوده حسینی^{۲*}

• پذیرش مقاله: ۱۴۰۱/۱۲/۲۲

• دریافت مقاله: ۱۴۰۱/۹/۲۳

مقدمه: COVID-19 تأثیرات مخربی بر سلامت عمومی در سراسر جهان ایجاد کرده است. از آنجایی که تشخیص زودهنگام و درمان به موقع بر کاهش مرگ و میر بر اثر ابتلاء به COVID-19 تأثیرگذار است و روش‌های تشخیصی موجود از جمله آزمایش RT-PCR مستعد خطا است، راه حل جایگزین استفاده از تکنیک‌های هوش مصنوعی و پردازش تصویر است. هدف کلی معرفی مدل هوشمند مبتنی بر یادگیری عمیق و شبکه عصبی پیچشی برای شناسایی موارد مبتلا به COVID-19 و ذات‌الریه به منظور اقدامات درمانی بعدی به کمک تصاویر پزشکی ریه است.

روش: مدل پیشنهادی شامل دو مجموعه داده رادیوگرافی و CT-scan است. تصاویر مجموعه داده مورد پیش‌پردازش قرار می‌گیرند و فرآیند تقویت داده روی تصاویر اعمال می‌شود. در مرحله بعد از سه معماری EfficientNetB4, InceptionV3 و InceptionResNetV2 با استفاده از روش یادگیری انتقالی استفاده می‌شود.

نتایج: بهترین نتیجه به دست آمده برای تصاویر CT-scan متعلق به معماری InceptionResNetV2 با دقت ۹۹/۳۶۶٪ و برای تصاویر رادیولوژی مربوط به معماری InceptionV3 با دقت ۹۶/۹۴۳٪ می‌باشد. علاوه بر آن نتایج حاکی از آن است که تصاویر CT-scan از ویژگی‌های بیشتری نسبت به تصاویر رادیوگرافی برخوردار بوده و تشخیص بیماری روی این نوع داده‌ها با دقت بیشتری انجام می‌پذیرد.

نتیجه‌گیری: مدل پیشنهادی مبتنی بر شبکه عصبی پیچشی دقت بالاتری نسبت به سایر مدل‌های مشابه دارد. همچنین با اعلام نتایج آنی می‌تواند در ارزیابی اولیه مراجعان به مراکز درمانی به خصوص در زمان اوج همه‌گیری‌ها که مراکز درمانی با چالش‌هایی مانند کمبود نیرو متخصص و کادر درمان مواجه می‌شوند کمک نماید.

کلیدواژه‌ها: پردازش تصویر، هوش مصنوعی، کووید-۱۹، شبکه عصبی پیچشی

• **ارجاع:** موسوی سید محمد، حسینی سوده. مدل شبکه عصبی پیچشی برای شناسایی بیماری COVID-19 و ذات الریه. مجله انفورماتیک سلامت و زیست پزشکی ۱۴۰۲؛

(۱۱): ۴۱-۵۶. doi: 10.34172/jhbmi.2023.13

۱. کارشناس ارشد علوم کامپیوتر، بخش علوم کامپیوتر، دانشکده ریاضی و کامپیوتر، دانشگاه شهید باهنر کرمان، کرمان، ایران
۲. دکتری مهندسی کامپیوتر، دانشیار، بخش علوم کامپیوتر، دانشکده ریاضی و کامپیوتر، دانشگاه شهید باهنر کرمان، کرمان، ایران

* نویسنده مسئول: سوده حسینی

آدرس: کرمان، میدان پژوهش، دانشگاه شهید باهنر کرمان، دانشکده ریاضی و کامپیوتر

• Email: so_hosseini@uk.ac.ir

• شماره تماس: ۰۳۴۳۱۳۲۲۴۸۶

مقدمه

ویروس کرونا (Corona Virus) اولین بار در شهر ووهان چین اواخر سال ۲۰۱۹ میلادی مشاهده شد. از ماه می ۲۰۲۱ COVID-19 توسط سازمان بهداشت جهانی یک همه‌گیری اعلام شد [۱]، از آنجا که COVID-19 یک بیماری واگیردار و به‌راحتی قابل انتقال است زندگی میلیاردها نفر در سراسر جهان را تحت تأثیر قرار داده است. تشخیص زودهنگام و دقیق COVID-19 برای کنترل شیوع بیماری و کاهش مرگ و میر آن از اهمیت زیادی برخوردار است.

امروزه محققان از روش‌های مختلف یادگیری ماشین و یادگیری عمیق (Deep Learning) همراه با هوش مصنوعی برای تجزیه و تحلیل تصاویر پزشکی استفاده می‌کنند [۲]. این روش‌های توسعه‌یافته برای شناسایی بیماری‌هایی استفاده می‌شوند که ممکن است به متخصصان پزشکی در تشخیص بیماری‌ها در مراحل اولیه و ارائه نتایج دقیق، مؤثر و سریع و کاهش میزان مرگ‌ومیر کمک کنند [۲،۳]، همچنین کمبود کارکنان بهداشتی برای مراقبت از همه بیماران وجود دارد [۴]؛ بنابراین توسعه یک روش هوشمند خودکار که نتایج فوری و با دقت بالا را ارائه می‌کند و امکان آزمایش را در هر مکان و هر زمان ممکن سازد، بسیار مهم است [۵].

داده‌های بازبازی شده را می‌توان با استفاده از روش‌های هوش مصنوعی برای تشخیص، تجزیه و تحلیل کرد. حتی اگر مراکز تصویربرداری پزشکی در مناطق دور افتاده تأسیس شده باشد، در دسترس بودن رادیولوژیست‌ها همچنان مشکل است. کشورهای درحال توسعه یا توسعه نیافته در تلاش برای بهبود قابلیت‌های تشخیص خود هستند. از این رو، یک سیستم تشخیص از راه دور که به راحتی قابل دسترس باشد و برای غربالگری فوری در اختیار افراد قرار گیرد، ضروری است. طبق آمار منتشر شده از سازمان بهداشت جهانی تا آوریل ۲۰۲۳، تعداد کل موارد تأیید شده COVID-19 در سراسر جهان بیش از ۷۲۵ میلیون نفر بوده است [۳]. برای مقابله با این شیوع، محققان به دنبال طیف گسترده‌ای از تکنولوژی‌ها مانند هوش مصنوعی و فراداده (Big data) هستند که می‌تواند به غلبه بر چالش‌های ناشی از COVID-19 کمک کند [۴].

علاوه بر آزمایش RT-PCR، اخیراً چندین روش مبتنی بر هوش مصنوعی پیشنهاد شده است که از رادیوگرافی قفسه سینه [۴-۱۲] و CT Scan [۶-۸] برای تشخیص شاخص‌های بصری عفونت ویروسی COVID-19 استفاده می‌کنند. در عین

حال، برای استفاده از RT-PCR, CT Scan و رادیوگرافی برای تشخیص، مراجعه به مراکز بالینی مجهز ضروری است.

مطالعات متعددی به تشخیص بیماران مبتلا به COVID19 با استفاده از اطلاعات پزشکی به خصوص تصاویر پزشکی پرداخته‌اند. از جمله: Ahmed و همکاران [۲] یک سیستم مراقبت بهداشتی هوشمند برای شناسایی و طبقه‌بندی تصاویر اشعه ایکس قفسه سینه به سه کلاس کرونا، ذات‌الریه و سالم معرفی کردند. در مرحله اول پس از پیش پردازش عملیات تقویت داده برای افزایش تنوع مجموعه داده اعمال شده، سپس داده‌ها به دو مجموعه آموزش و آزمایش تقسیم‌بندی می‌شوند و از دو معماری از پیش آموزش دیده VGG19 و InceptionV3 به منظور طبقه‌بندی استفاده شده است. از ۴۵۰۰ تصویر اشعه ایکس استفاده گردید که در نهایت دقت ۹۷٪ ثبت شد.

Deb و همکاران [۳] چارچوبی را پیشنهاد دادند که ویژگی‌های سطح پایین از تصاویر رادیوگرافی با استفاده از مجموعه‌ای از چهار معماری شبکه عصبی پیچشی از پیش‌آموزش دیده به نام‌های NASNet, VGGNet, GoofleNet و DenseNet استخراج کرده و توسط لایه‌های کاملاً متصل طبقه‌بندی انجام شده است. چارچوب پیشنهادی بر روی دو مجموعه داده ارزیابی شده و نشان داده شد که معماری ترکیبی چند مدل شبکه عصبی پیچشی بهتر از طبقه‌بندی‌های تک مدلی عمل می‌کند. Islam و Nahiduzzaman [۴] از تکنیک CLAHE به عنوان یک مرحله پیش‌پردازش برای تصاویر CT Scan استفاده کردند آن‌ها صد ویژگی توسط شبکه عصبی پیچشی استخراج کردند و سپس با استفاده از الگوریتم‌های مختلف یادگیری ماشین طبقه‌بندی روی تصاویر انجام شد و در انتها یک مدل ترکیبی برای طبقه‌بندی تصاویر CT Scan پیشنهاد گردید.

Kavya و همکاران [۵] با استفاده از ۱۵۱۵۳ تصویر رادیولوژی به کمک دو مدل شبکه عصبی پیچشی VGG16 و ResNet50 طبقه‌بندی را انجام دادند که در نهایت مدل ResNet50 با دقت ۹۱٪ بهترین نتیجه را داد. Thakur و Kumar [۶] از یک شبکه عصبی پیچشی پیشنهاد شده برای طبقه‌بندی تصاویر CXR (Chest X-Ray) و (Computed Tomography) CT scan استفاده کردند و از دو سناریو طبقه‌بندی دو کلاسه و چند کلاسه با استفاده از ۱۱۰۹۵ تصویر استفاده نمودند. در نهایت بهترین دقت در طبقه‌بندی دو کلاسه ۹۹/۶٪ و در طبقه‌بندی چند کلاسه ۹۸/۲٪ گزارش شد.

کردند و از مجموعه داده‌ای شامل ۱۸۰ تصویر COVID-19 و ۲۰۰ تصویر سالم استفاده شد و به منظور استخراج ویژگی‌های عمیق مدل‌های شبکه عصبی پیچشی از پیش آموزش دیده (VGG16, VGG19, ReseNet101, ReseNet50, ReseNet18) را به کار بردند. در نهایت ویژگی‌های عمیق استخراج شده از مدل ReseNet50 به کمک SVM دقت ۹۴/۷٪ را ثبت کرد که بالاترین امتیاز در بین تمام نتایج به دست آمده است. برای محدود کردن رشد تصاعدی موارد COVID-19، یک راه حل این است که مدلی طراحی شود که بتواند آزمایش‌های بیولوژیکی را بدون دخالت افراد زیادی انجام دهد.

هدف اصلی این پژوهش پیشنهاد یک سیستم تشخیص خودکار موارد مبتلا به COVID-19 و ذات‌الریه است. این مدل با استفاده از سه شبکه عصبی پیچشی از پیش آموزش دیده به کمک تکنیک یادگیری انتقالی، موارد مبتلا به COVID-19 و ذات‌الریه را تشخیص می‌دهد. مدل پیشنهادی از تصاویر رادیولوژی و CT Scan قفسه سینه به این منظور استفاده می‌کند.

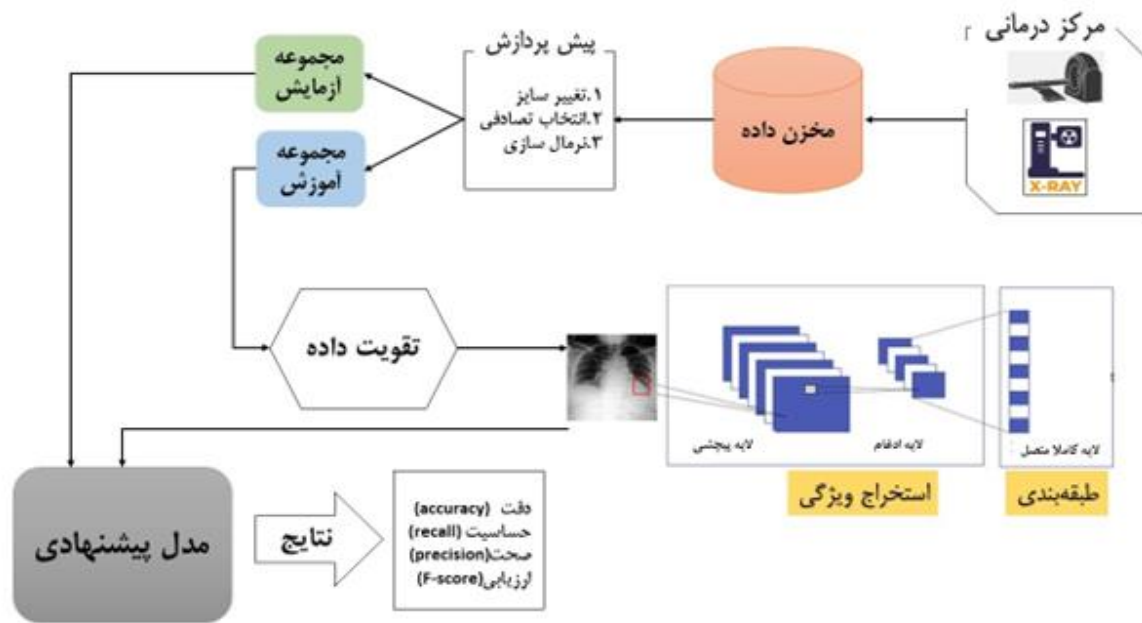
روش

در این مطالعه چارچوب مدل پیشنهادی مبتنی بر مدل‌های شبکه عصبی پیچشی برای تشخیص خودکار افراد مبتلا به COVID-19 شرح داده شد. ابتدا تصاویر پزشکی به مخزن داده ارسال شدند، سپس با استفاده از الگوریتم‌های یادگیری عمیق، داده‌ها به منظور استخراج دانش پردازش شدند. از سه مدل شبکه عصبی پیچشی از پیش آموزش دیده شده با استفاده از یادگیری انتقالی برای تشخیص موارد مبتلا به COVID-19 از تصاویر اشعه ایکس قفسه سینه و CT-scan استفاده شد. در یک طبقه‌بندی چند کلاسه هدف اصلی طبقه‌بندی و تشخیص صحیح تصاویر به سه کلاس بیمار (کرونا) و بیمار ذات‌الریه (غیر کرونا) و سالم است. دلیل استفاده از طبقه‌بندی سه کلاسه تصاویر پزشکی کمک به متخصصان رادیولوژی برای اولویت‌بندی بیماران COVID-19 به منظور جلوگیری از شیوع بیشتر بیماری همچنین درمان مؤثر و سریع افراد مبتلا و حفاظت از سلامت جامعه است. چارچوب روش پیشنهادی در شکل ۱ نشان داده شده است.

Elpeltagy و Sallam [۷] از تصاویر اشعه ایکس و CT scan برای پیش‌بینی موارد مبتلا به COVID-19 براساس مدل‌های AlexNet, GoogleNet, ReseNet, VGG Network (Visual Geometry DenseNet, Inception V3, Group)، به همراه یک مدل پیشنهادی استفاده کردند. بالاترین دقت به دست آمده با استفاده از تصاویر اشعه ایکس ۹۷/۷٪ و با استفاده از تصاویر CT، ۹۷/۱٪ گزارش گردید.

Owais و همکاران [۸] با استفاده از سه مدل شبکه عصبی mobile net، shuffleNet و mobshufnet طبقه‌بندی روی دو مجموعه داده رادیولوژی و CT scan را انجام دادند که در نهایت بهترین دقت برای مجموعه داده رادیولوژی ۹۵٪ و برای مجموعه CT scan برابر با ۹۴٪ گزارش شد. Lorencin و همکاران [۹] از تصاویر اشعه ایکس قفسه سینه برای طبقه‌بندی افراد آلوده به COVID-19 به وسیله یادگیری عمیق و با استفاده از یادگیری انتقالی (Transfer learning) استفاده کردند. همچنین به بررسی پنج مدل مبتنی بر شبکه‌های عصبی پیچشی از پیش آموزش دیده (AlexNet, VGG16, ReseNet50, ReseNet101, ReseNet152) بر روی ۱۸۵ تصویر اشعه ایکس شامل چهار کلاس پرداختند. با توجه به تعداد کم تصاویر در مجموعه داده، از فرآیند تقویت داده (Augmentation) از جمله چرخش ۹۰، ۱۸۰ و ۲۷۰ درجه در محورهای مختلف استفاده شد. همچنین افزایش روشنایی به منظور بهبود عملکرد طبقه‌بندی استفاده شده است. بهترین نتایج در صورتی حاصل می‌شود که معماری از قبل آموزش دیده شده ReseNet152 با استفاده از دسته‌های بزرگ‌تر داده در تعداد متوسط دوره‌های آموزش با استفاده از تابع بهینه‌ساز Nadam آموزش داده شود.

Ismael و Şengür [۱۰] از مدل‌های مبتنی بر یادگیری عمیق، یعنی استخراج ویژگی‌های عمیق (Deep feature extraction) و تنظیم دقیق (Fine-tuning) شبکه‌های عصبی پیچشی از پیش آموزش دیده و آموزش انتها به انتها (End-to-end)، یک مدل توسعه یافته شبکه عصبی پیچشی متشکل از ۲۱ لایه شامل لایه‌های کانولوشن، ادغام حداکثر و لایه‌های کاملاً متصل و لایه طبقه‌بندی نهایی به همراه نرمال‌سازی دسته‌ای و لایه‌های ReLU به منظور طبقه‌بندی تصاویر اشعه ایکس قفسه سینه COVID-19 و سالم استفاده



شکل ۱: چارچوب مدل پیشنهادی

برای ایجاد مجموعه داده CT-scan، دو مجموعه داده تصاویر CT-scan جمع‌آوری شده از منابع مختلف ترکیب شدند [۱۲، ۱۳]. همان‌طور که در شکل ۱ نشان داده شده است تعداد ۵۲۰۳ تصویر مربوط به بیماری COVID-19 و ۲۴۱۸ تصویر مربوط به افراد سالم است. همچنین به منظور عملکرد بهتر مدل پیشنهادی در دنیای واقعی، تعداد ۲۶۱۸ تصویر ذات‌الریه اکتسابی از جامعه (Community-Acquired Pneumonia) به مجموعه داده اول اضافه شد. در نهایت مجموعه داده CT-scan شامل ۱۰۲۳۹ تصویر است.


مجموعه داده رادیوگرافی

تصاویر رادیوگرافی به سه دسته بیماران COVID-19، بیماران ذات‌الریه غیر COVID-19 و افراد عادی طبقه‌بندی شده است. [۱۴]، تمامی تصاویر در سایز ۲۵۶*۲۵۶ تغییر سایز داده شده‌اند. در مجموع ۵۲۲۸ تصویر اشعه ایکس قفسه سینه استفاده شد. شکل ۲ توزیع داده‌های مجموعه داده اشعه ایکس را نشان می‌دهد.

مجموعه داده‌های تصاویر پزشکی

در این مطالعه از دو نوع مجموعه داده از تصاویر پزشکی استفاده شد. مجموعه داده‌های عمومی مختلفی از جمله تصاویر اشعه ایکس [۵-۱۱] و تصاویر CT Scan [۶-۹] که برای تشخیص موارد مبتلا به COVID-19 توسط محققان حوزه پردازش تصویر به کار گرفته شده است. تحقیقات نشان می‌دهد که تشخیص موارد مبتلا از طریق تصاویر CT Scan با دقت بالاتری نسبت به تصاویر اشعه ایکس صورت می‌پذیرد [۷-۹]؛ هرچند بیمار دوز تابشی اشعه کمتری در حین تصویر برداری اشعه ایکس نسبت به CT scan دریافت می‌کند. این امر شاید در تعداد آزمایش‌های کم قابل چشم‌پوشی باشد؛ اما برای مادران باردار و همچنین کودکان از اهمیت بالایی برخوردار است. در این پژوهش از دو مجموعه داده تصاویر پزشکی رادیوگرافی و CT Scan استفاده شد تا امکان استفاده از انواع تصاویر پزشکی را برای چارچوب پیشنهادی فراهم شود.

مجموعه داده CT-scan




شکل ۲: ساختار مجموعه داده تصاویر پزشکی

گرفته شد. این فرآیند با هدف افزایش مصنوعی مجموعه داده‌های آموزشی انجام شد و مجموعه داده آزمایش ثابت باقی ماند. مجموعه‌ای از عملیات‌های هندسی متفاوتی به منظور افزایش مجموعه داده قابل استفاده است. در روش پیشنهادی از پشت و رو کردن افقی تصاویر و همچنین بزرگ‌نمایی استفاده شد. شکل ۳ برخی از تصاویر هر سه کلاس پس از اعمال پیش‌پردازش و فرآیند تقویت داده جهت آموزش بهتر مدل پیشنهادی را نمایش می‌دهد. علاوه بر داده‌های اصلی به کار رفته در این پژوهش امکان انتقال دیگر داده‌های بیومتریک بیماران به مخزن اصلی داده‌ها به منظور تجزیه و تحلیل و استخراج دانش بدون این که کارکنان مراقبت‌های درمانی را در معرض عفونت قرار دهند، وجود دارد.

پیش‌پردازش و تقویت داده

یکی از مراحل پیچیده در مدل‌سازی سیستم‌های غیرخطی، پیش‌پردازش پارامترهای ورودی است. پیش‌پردازش داده‌ها سبب کاهش مراحل سعی و خطا، رسیدن به همگرایی در تعداد مراحل آموزش کمتر و شناخت مهم‌ترین پارامترهای مؤثر بر پدیده مورد نظر جهت مدل‌سازی با استفاده از روش‌های هوشمند می‌شود. در روش پیشنهادی، به منظور پردازش بهتر ابتدا تمام تصاویر به سایز ورودی مدل‌های به کار رفته تغییر سایز داده شدند و مقادیر هر پیکسل از بازه (۰-۲۵۵) به بازه (۰-۱) تغییر داده شد. سپس با استفاده از روش انتخاب تصادفی، داده‌ها به سه مجموعه آموزش، ارزیابی و آزمایش تقسیم شدند. حجم عظیم تصاویر آموزشی یکی از الزامات یادگیری عمیق است در همین راستا فرآیند تقویت داده به منظور افزایش عملکرد طبقه‌بندی به کار



شکل ۳: نمونه‌هایی از تصاویر مجموعه داده بعد از اعمال فرآیند تقویت داده

طبقه‌بندی تصاویر پزشکی

در این مطالعه با استفاده از تکنیک یادگیری انتقالی به بررسی سه دسته از مراجعان مراکز درمانی مشکوک به کرونا به صورت: ۱- افراد مبتلا به کرونا، ۲- افراد مبتلا به ذات الریه و ۳- افراد سالم پرداخته شد که به کمک سه مدل شبکه عصبی عمیق با استفاده از دو نوع داده تصویر پزشکی رادیوگرافی قفسه سینه و CT-Scan قفسه سینه این روند اتفاق می‌افتد. این دسته بندی علاوه بر غربالگری مراجعان به مراکز درمانی به کادر درمان به خصوص در شرایط اوج همه‌گیری و تشخیص دقیق با کمترین تماس فیزیکی با افراد مبتلا کمک کرده و در تعیین روند درمان

بیماران تأثیرگذار است. معماری پیشنهادی شامل چهار مرحله است. ابتدا تصاویر پزشکی قفسه سینه افراد مشکوک به COVID-19 که به مراکز درمانی جهت عکس‌برداری مراجعه می‌کنند به مجموعه داده ارسال شدند. سپس تصاویر مجموعه داده مورد پیش‌پردازش قرار گرفتند و فرآیند تقویت داده روی تصاویر اعمال شد. در مرحله بعد توسط شبکه عصبی پیچشی فرآیند آموزش صورت گرفت. در این مرحله از سه معماری EfficientNetB4، InceptionV3 و InceptionResNetV2 [۱۶] با استفاده از روش یادگیری انتقالی برای استخراج بهترین ویژگی‌ها استفاده شد. همچنین در

تولید شدند. باتوجه به روند آموزش از نرخ یادگیری کاهشی نیز استفاده شد. در طول فرآیند آموزش، نقطه‌ای وجود دارد که خروجی مدل بهبود نمی‌یابد به همین منظور از تکنیک توقف زود هنگام بر اساس کمترین میزان خطای اعتبارسنجی استفاده شد. ساختار مدل‌های پیشنهادی EfficientNetB4 در جدول ۱ و InceptionNetV3 در جدول ۲ و InceptionResNetV2 در جدول ۳ قابل مشاهده است.

انتهای هر معماری برای طبقه‌بندی داده‌ها از یک لایه GlobalAveragePooling2D و سپس سه لایه کاملاً متصل استفاده شد. همچنین به منظور جلوگیری از بیش برآزش (overfitting) لایه Dropout(0.5) استفاده شد. در مرحله آخر شبکه‌های پیشنهادی توسط تصاویر مجموعه داده آزمایش مورد بررسی و ارزیابی قرار گرفتند. علاوه بر این از توابع فعال‌سازی ReLU و Softmax در این شبکه استفاده شد و وزن‌ها با استفاده از بهینه‌ساز adam با نرخ یادگیری اولیه ۰/۰۰۳

جدول ۱: انواع لایه‌ها و تعداد پارامترهای به کار رفته در شبکه پیشنهادی EfficientNetB4

| تعداد پارامتر | خروجی | نوع لایه |
|---------------|--------------------|--------------------------|
| ۱۷۶۷۳۸۲۳ | (None, ۷, ۷, ۱۷۹۲) | efficientnetb4 |
| . | (None, ۱۷۹۲) | global_average_pooling2d |
| . | (None, ۱۷۹۲) | flatten |
| . | (None, ۱۷۹۲) | dropout_1 |
| ۱۸۳۶۰۳۲ | (None, ۱۰۲۴) | dense_1 |
| ۱۰۴۹۶۰۰ | (None, ۱۰۲۴) | dense_2 |
| . | (None, ۱۰۲۴) | dropout_2 |
| ۳۰۷۵ | (None, ۳) | dense_3 |

تعداد کل پارامترها: ۲۰۵۶۲۵۶۰
پارامترهای آموزش پذیر: ۲۸۸۸۷۳۷
پارامترهای غیر قابل آموزش: ۱۷۶۷۳۸۲۳

جدول ۲: انواع لایه‌ها و تعداد پارامترهای به کار رفته در شبکه InceptionNetV3

| تعداد پارامتر | خروجی | نوع لایه |
|---------------|--------------------|--------------------------|
| ۲۱۸۰۲۷۸۴ | (None, ۵, ۵, ۲۰۴۸) | inception_v3 |
| . | (None, ۲۰۴۸) | global_average_pooling2d |
| . | (None, ۲۰۴۸) | flatten |
| . | (None, ۲۰۴۸) | dropout_1 |
| ۲۰۹۸۱۷۶ | (None, ۱۰۲۴) | dense_1 |
| ۱۰۴۹۶۰۰ | (None, ۱۰۲۴) | dense_2 |
| . | (None, ۱۰۲۴) | dropout_2 |
| ۳۰۷۵ | (None, ۳) | dense_3 |

تعداد کل پارامترها: ۲۴۹۵۳۶۶۵
پارامترهای آموزش پذیر: ۳۱۵۰۸۸۱

جدول ۲: انواع لایه‌ها و تعداد پارامترهای به کار رفته در شبکه InceptionResNetV2

| تعداد پارامتر | خروجی | نوع لایه |
|---------------|--------------------|--------------------------|
| ۵۴۳۳۶۷۳۶ | (None, ۵, ۵, ۱۵۳۶) | inception_resnet_v2 |
| . | (None, ۱۵۳۶) | global_average_pooling2d |
| . | (None, ۱۵۳۶) | flatten |
| . | (None, ۱۵۳۶) | dropout_1 |
| ۱۵۷۳۸۸۸ | (None, ۱۰۲۴) | dense_1 |
| ۱۰۴۹۶۰۰ | (None, ۱۰۲۴) | dense_2 |
| . | (None, ۱۰۲۴) | dropout_2 |
| ۳۰۷۵ | (None, ۳) | dense_3 |

تعداد کل پارامترها: ۵۶۹۶۳۳۲۹
پارامترهای آموزش پذیر: ۲۶۲۶۵۹۳
پارامترهای غیر قابل آموزش: ۵۴۳۳۶۷۳۶

نتایج

نتایج پژوهش در سه بخش مجزا، شامل معرفی معیارهای ارزیابی، مقایسه نتایج ارزیابی سه مدل به کار رفته در مدل پیشنهادی در دو مجموعه تصاویر CT و رادیوگرافی و مقایسه نتایج به دست آمده توسط مدل پیشنهادی با کارهای مشابه این حوزه ارائه می‌شود.

معیارهای ارزیابی

برای ارزیابی نتایج روش پیشنهادی و بررسی کیفیت آن از معیارهای ارزیابی مانند دقت (Accuracy)، صحت (Precision)، حساسیت (Recall) و معیار (F-Score) F، استفاده شد که فرمول‌های آن‌ها به ترتیب در زیر آورده شده است [۱۵]. در فرمول‌ها T (True) و F (False) به ترتیب داده‌های طبقه بندی شده به طور صحیح یا ناصحیح را نشان می‌دهند. به عبارتی آیا طبقه بندی بیماری کرونا صحیح انجام شده است یا خیر؟ P (Positive) و N (Negative) به ترتیب نتایج پیش بینی سیستم تشخیص را به عنوان داده‌های مثبت (شخص بیمار و دارای بیماری کرونا) یا منفی (شخص سالم) نشان

می‌دهند. همه داده‌های ورودی باید در هر یک از چهار دسته TP (True Positive)، TN (True Negative)، FP (False Positive) و FN (False Negative) دسته بندی شوند که TP نشان می‌دهد نتیجه طبقه بندی مدل پیشنهادی از داده‌های مورد بررسی، به درستی دسته بندی شده است یعنی شخص بیماری کرونا داشته و طبقه بند نیز آن را درست دسته بندی کرده است و در مقابل FP نشان می‌دهد که مدل پیشنهادی، داده‌ها را به اشتباه در این کلاس قرار داده است. یعنی شخص سالم بوده، ولی طبقه بند به اشتباه آن را در دسته کرونا قرار داده است. همچنین TN نشان می‌دهد داده به درستی در کلاس منفی قرار گرفته است یعنی شخص سالم بوده و به درستی در این کلاس گذاشته شده است و در FN داده به اشتباهی در کلاس منفی قرار داده شده است. یعنی شخص کرونا داشته و به اشتباه در گروه افراد سالم قرار داده شده است.

- **دقت:** تعداد نمونه‌های درست پیش بینی شده به تعداد کل نمونه‌ها است.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

است.

- **صحت:** تعداد نمونه‌های مثبت واقعی سیستم بر تعداد کل مثبت‌های پیش بینی شده توسط سیستم

$$Precision = \frac{(TP)}{(TP + FP)} \quad (2)$$

• **حساسیت:** تعداد نمونه های مثبت واقعی سیستم بر تعداد کل نمونه های مثبت واقعی است.

$$Recall = \frac{(TP)}{(TP + FN)} \quad (3)$$

• **معیار F:** این پارامتر به منظور ارزیابی عملکرد سیستمها استفاده می شود و میانگین بین پارامتر دقت و پارامتر بازخوانی است.

$$F - Measure = \frac{2 * (precision * recall)}{(precision + recall)} \quad (4)$$

ارزیابی نتایج

نتایج بر اساس پارامترهای صحت، دقت، حساسیت و معیار F مورد ارزیابی قرار گرفتند. در این طبقه بندی سه نوع داده وجود دارد: ۱- بیماران مبتلا به COVID-19، ۲- بیماران ذات الریه و ۳- افراد سالم. سه مدل شبکه عصبی پیچشی به نام های EfficientNetB4, InceptionV3 و InceptionResNetV2 با استفاده از روش یادگیری انتقالی روی دو مجموعه داده تصاویر رادیوگرافی و CT-scan آموزش داده شدند. به منظور بهبود عملکرد شبکه پس از پیش پردازش داده ها از روش تقویت داده نیز استفاده شد. ۷۰٪ داده ها برای آموزش (Train) شبکه، ۲۰٪ به منظور آزمایش (Test) و ۱۰٪ باقی مانده برای اعتبار سنجی (Validation) مورد استفاده قرار گرفتند. آموزش در ۳۰ مرحله (Epoch) و با استفاده از نرخ یادگیری کاهش یافته به همراه توقف زودهنگام براساس کمترین میزان خطای اعتبار سنجی انجام شد. برای جلوگیری از مشکل بیش برآزش از روش تعمیم پذیری (Generalization) نیز استفاده شد. علاوه بر آن برای به دست آوردن بهترین دقت به تنظیم دقیق

ابریارامترها (Hyper Parameter) روی مدل های پیشنهادی پرداخته شد. نتایج به دست آمده روی سه مدل شبکه عصبی پیچشی در جدول ۴ و برای هر کلاس در جدول ۵ قابل مشاهده است. بهترین عملکرد برای مجموعه داده رادیوگرافی مربوط به معماری InceptionV3 با دقت ۹۶/۹۴۳٪ می باشد و برای مجموعه داده CT-scan متعلق به معماری InceptionResnetV2 با دقت ۹۹/۳۶۶٪ است که نشان دهنده کارایی بالای چارچوب مدل پیشنهادی برای کمک رسانی به کادر درمان در شناسایی موارد مبتلا در مراحل اولیه بیماری است. همچنین باتوجه به نتایج به دست آمده از دو مجموعه داده می توان نتیجه گرفت تصاویر CT-scan از جزئیات بیشتری نسبت به تصاویر اشعه ایکس به منظور تشخیص بیماری های ریوی برخوردار هستند علاوه بر آن مدل InceptionV3 سریع تر از دیگر مدل ها همگرا شده است و به نقطه پایان زودهنگام رسیده و نیازمند دوره های آموزش کمتری می باشد. شکل ۴ نیز نتایج طبقه بندی تصاویر اشعه ایکس را در قالب ماتریس آشفتگی (Confusion Matrix) نشان می دهد و شکل ۵ مربوط به تصاویر CT-scan می باشد.


جدول ۴: نتایج به دست آمده روی مجموعه داده‌های X-ray و CT-scan

| Accuracy | F-score | Recall | Precision | مدل شبکه عصبی عمیق | نوع داده |
|----------|---------|--------|-----------|--------------------|----------|
| ۰/۹۴/۷۴۶ | ۰/۹۴ | ۰/۹۴ | ۰/۹۵ | EfficientNet-B4 | X-ray |
| ۰/۹۵/۹۸۸ | ۰/۹۵ | ۰/۹۵ | ۰/۹۷ | InceptionResNetV2 | |
| ۰/۹۶/۹۴۳ | ۰/۹۷ | ۰/۹۷ | ۰/۹۷ | InceptionV3 | |
| ۰/۹۹/۰۷۳ | ۰/۹۹ | ۰/۹۹ | ۰/۹۹ | EfficientNet-B4 | CT-scan |
| ۰/۹۹/۳۶۶ | ۰/۹۹ | ۰/۹۹ | ۰/۹۹ | InceptionResNetV2 | |
| ۰/۹۹/۱۷۱ | ۰/۹۹ | ۰/۹۹ | ۰/۹۹ | InceptionV3 | |

جدول ۵: نتایج به دست آمده به ازای هر کلاس با استفاده از مدل‌های پیشنهادی


| F-score | Recall | Precision | کلاس | مدل شبکه عصبی عمیق | نوع داده |
|---------|--------|-----------|-----------|--------------------|----------|
| ۰/۹۹ | ۰/۹۸ | ۱/۰۰ | COVID-19 | EfficientNet-B4 | X-ray |
| ۰/۹۶ | ۰/۹۹ | ۰/۹۹ | Pneumonia | | |
| ۰/۹۵ | ۰/۹۲ | ۰/۹۲ | Normal | | |
| ۰/۹۸ | ۰/۹۸ | ۰/۹۹ | COVID-19 | InceptionResNetV2 | |
| ۰/۹۴ | ۰/۸۹ | ۰/۸۹ | Pneumonia | | |
| ۰/۹۵ | ۰/۹۸ | ۰/۹۸ | Normal | | |
| ۰/۹۹ | ۰/۹۸ | ۱/۰۰ | COVID-19 | InceptionV3 | |
| ۰/۹۶ | ۰/۹۴ | ۰/۹۴ | Pneumonia | | |
| ۰/۹۶ | ۰/۹۸ | ۰/۹۸ | Normal | | |
| ۰/۹۹ | ۰/۹۹ | ۰/۹۹ | COVID-19 | EfficientNet-B4 | CT-scan |
| ۱/۰۰ | ۱/۰۰ | ۱/۰۰ | CAP* | | |
| ۰/۹۸ | ۰/۹۹ | ۰/۹۸ | Normal | | |
| ۰/۹۹ | ۰/۹۹ | ۰/۹۹ | COVID-19 | InceptionResNetV2 | |
| ۱/۰۰ | ۰/۹۹ | ۱/۰۰ | CAP | | |
| ۰/۹۹ | ۰/۹۸ | ۰/۹۹ | Normal | | |
| ۰/۹۹ | ۰/۹۹ | ۰/۹۹ | COVID-19 | InceptionV3 | |
| ۱/۰۰ | ۰/۹۹ | ۱/۰۰ | CAP | | |
| ۰/۹۸ | ۰/۹۷ | ۰/۹۸ | Normal | | |

*(Community-acquired pneumonia)




InceptionresNetV2 network (ب)

EfficientNet-B4 network (الف)



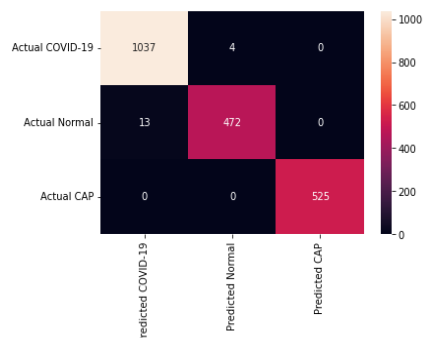
InceptionV3 network (ج)

شکل ۴: ماتریس درهم‌ریختگی مبتنی بر مجموعه داده‌های آزمایش رادیوگرافی



InceptionresNetV2 network (ب)

EfficientNet-B4 network (الف)



InceptionV3 network (ج)

شکل ۵: ماتریس درهم‌ریختگی مبتنی بر مجموعه داده‌های آزمایش CT-scan

بحث و نتیجه گیری

تشخیص COVID-19 از طریق تصاویر قفسه سینه یک مسئله چالش برانگیز است و هنوز باید بر بسیاری از مشکلات غلبه کرد. در مطالعه حاضر، یک سیستم مراقبت بهداشتی هوشمند پیشنهاد شد که ارزیابی اولیه افراد مستعد نسبت به بیماری COVID-19 و ذات‌الریه را با استفاده از سه شبکه عصبی پیچشی EfficientNet, InceptionV3 و InceptionResNetV2 به کمک تصاویر پزشکی قفسه سینه انجام داد. داده‌ها در مخزن داده ذخیره شده و برای ارزیابی وضعیت بیماران استفاده شد. ابتدا در مرحله اول تصاویر پزشکی قفسه سینه پس از مراجعه افراد مستعد به مراکز درمانی به مخزن داده ارسال شدند. سپس در مرحله بعد تصاویر پزشکی به منظور استخراج دانش پیش‌پردازش شده و به شبکه یادگیری عمیق فرستاده شد تا موارد بیمار از غیر بیمار تشخیص داده شود. استفاده از ظرفیت‌های تکنولوژی‌هایی مانند هوش مصنوعی در شرایط بحرانی همچون همه‌گیری COVID-19 با توجه به کمبود کادر درمان در مقایسه با مراجعات روزانه و همچنین کاهش نرخ همه‌گیری این ویروس و حفظ سلامت جامعه سالم از اهمیت بالایی برخوردار است. توجه به این نکته مهم است که معماری‌های شبکه عصبی پیچشی عمیق زمانی که با تعداد دوره‌های بیشتری آموزش داده می‌شوند تمایل به بیش‌برازش (Overfitting) دارند. به منظور جلوگیری از بیش‌برازش از روش‌هایی مانند توقف زود هنگام و تقویت داده استفاده شد. مدل

پیشنهادی بهترین دقت ۹۶/۹۴۳٪ برای تصاویر رادیوگرافی قفسه سینه پزشکی و ۹۹/۳۶۰٪ برای تصاویر CT scan ارائه کرد. می‌توان نتیجه گرفت تشخیص بیماری COVID-19 و ذات‌الریه با استفاده از تصاویر CT scan نسبت به تصاویر رادیوگرافی قفسه سینه با دقت بیشتری همراه بود.

مقایسه نتایج با پژوهش‌های مشابه نشان داد در میان شبکه‌های به کار گرفته شده، شبکه عصبی پیچشی InceptionResNetV2 در مواجهه با تصاویر CT scan و شبکه عصبی پیچشی InceptionV3 در مواجهه با تصاویر رادیوگرافی قفسه سینه عملکرد بهتری را نشان می‌دهند. این نتایج در جداول ۵، ۶ و ۷ به صورت کامل شرح داده شد. هرچند مجموعه داده‌های موجود هنوز قوی نیستند؛ اما دانش تجربی در مورد برنامه‌های کاربردی شبکه‌های عصبی پیچشی بیان می‌کند افزایش تعداد نمونه‌ها و کیفیت مجموعه داده تأثیر مستقیم بر دقت به دست آمده دارد. روش پیشنهادی مبتنی بر یادگیری عمیق در تحقیقات تشخیص پزشکی و سیستم‌های مراقبت‌های بهداشتی مفید خواهد بود. همچنین ابزار دقیقی برای کارشناسان پزشکی به منظور غربالگری COVID-19 می‌باشد و منجر به نظر ثانویه پزشکی می‌شود.

نتایج به دست آمده توسط سیستم پیشنهادی با استفاده از تصاویر رادیوگرافی و CT Scan با برخی از روش‌ها در کارهای مرتبط [۲، ۳، ۱۰-۵] مقایسه و در جدول ۶ نشان داده شده است.

جدول ۶: مقایسه نتایج حاصل از مجموعه داده تصاویر رادیوگرافی و CT-scan با دیگر کارهای مرتبط

| منابع مقایسه شده با مدل پیشنهادی | مدل شبکه عصبی عمیق | مجموعه داده تصاویر رادیوگرافی (CXR) و CT-scan | تعداد داده‌های به کار رفته در مدل شبکه عصبی عمیق | نتایج دقت مدل |
|----------------------------------|--------------------------|---|--|---------------|
| [۲] | VGG19 | CXR | ۴۵۰۰ | ٪۸۶ |
| | InceptionV3 | | | ٪۹۵ |
| [۳] | یک مدل ترکیبی (ensemble) | CXR | ۱۵۶۸۸ | ٪۸۸ |
| | AlexNet | | | ٪۸۶ |
| | VGG16 | | | ٪۸۷ |
| [۹] | ResNet50 | CXR | ۵۴۳۶ | ٪۹۱ |
| | ResNet101 | | | ٪۹۳ |
| | ResNet152 | | | ٪۹۵ |
| | VGG16 | | | ٪۸۵ |
| | VGG19 | | | ٪۸۹ |
| [۱۰] | ResNet18 | CXR | ۳۸۰ | ٪۸۸ |
| | ResNet50+SVM | | | ٪۹۴ |
| | ResNet101 | | | ٪۸۷ |

جدول ۶: مقایسه نتایج حاصل از مجموعه داده تصاویر رادیوگرافی و CT-scan با دیگر کارهای مرتبط (ادامه)

| | | | | |
|-------|-------|---------|--------------------------|--------------|
| ٪۹۸ | ۱۵۷۶۰ | CXR | یک مدل ترکیبی (ensemble) | [۵] |
| ٪۹۴/۷ | | | EfficientNet | |
| ٪۹۶/۹ | ۵۲۲۸ | CXR | InceptionV3 | مدل پیشنهادی |
| ٪۹۵/۹ | | | InceptionResNetV2 | |
| ٪۹۸ | ۶۳۵۴ | CT-scan | یک مدل معرفی شده | [۶] |
| ٪۹۷ | | | یک مدل معرفی شده | |
| ٪۹۶ | | | ResNet50 | |
| ٪۹۵ | ۸۰۵۵ | CT-scan | ResNet101 | [۷] |
| ٪۹۶ | | | GoogleNet | |
| ٪۹۳ | | | AlexNet | |
| ٪۹۶ | | | DenseNet201 | |
| ٪۹۱ | | | ShuffleNet | |
| ٪۹۲ | ۵۴۷۱ | CT-scan | MobileNet | [۸] |
| ٪۹۳ | | | MobShufNet | |
| ٪۹۹ | | | EfficientNet | |
| ٪۹۹/۱ | ۱۰۲۳۹ | CT-scan | InceptionV3 | مدل پیشنهادی |
| ٪۹۹/۳ | | | InceptionResNetV2 | |

پیشنهادی به‌طور دقیق تصاویر را در همه کلاس‌ها به‌عنوان COVID19، ذات‌الریه و افراد سالم را طبقه‌بندی نمود؛ بنابراین تنظیم دقیق معماری CNN از قبل آموزش دیده می‌تواند به عنوان یکی از روش‌های مفید در زمینه پزشکی برای طبقه‌بندی تصاویر اشعه ایکس قفسه سینه به کار گرفته شود.

مجموعه داده استفاده شده در این مطالعه روی برخی شبکه‌های به کار رفته در کارهای مرتبط آموزش داده و نتایج حاصل را برای مجموعه تصاویر رادیوگرافی در جدول ۷ و برای مجموعه تصاویر CT scan در جدول ۸ با نتایج به دست آمده از مدل‌های پیشنهادی مقایسه شد. از نتایج، می‌توان نتیجه گرفت که مدل

جدول ۷: مقایسه نتایج به دست آمده با استفاده از مجموعه داده رادیوگرافی با استفاده از برخی مدل‌های یادگیری عمیق

| نتیجه | تعداد پارامتر | تعداد لایه | مدل شبکه عصبی عمیق | منبع |
|-------|-------------------|------------|--------------------|--------------|
| ٪۹۶/۴ | بیش از ۱۳۸ میلیون | ۱۶ | VGG16 | [۵] |
| ٪۹۴/۴ | بیش از ۱۴۳ میلیون | ۱۹ | VGG19 | [۲] |
| ٪۹۴/۶ | بیش از ۲۳ میلیون | ۵۰ | ResNet50 | [۷] |
| ٪۹۴/۵ | بیش از ۶۰ میلیون | ۱۵۲ | ResNet152 | [۹] |
| ٪۹۴/۷ | بیش از ۱۹ میلیون | ۲۵۸ | EfficientNet | |
| ٪۹۶/۹ | بیش از ۲۳ میلیون | ۱۸۹ | InceptionV3 | مدل پیشنهادی |
| ٪۹۵/۹ | بیش از ۵۵ میلیون | ۴۴۹ | InceptionResNetV2 | |

جدول ۸: مقایسه نتایج به دست آمده با استفاده از مجموعه داده CT-scan با استفاده از برخی مدل‌های یادگیری عمیق

| نتیجه | تعداد پارامتر | تعداد لایه | مدل شبکه عصبی عمیق | منبع |
|-------|-------------------|------------|--------------------|--------------|
| ٪۹۱/۷ | بیش از ۱۳۸ میلیون | ۱۶ | VGG16 | |
| ٪۹۸/۷ | بیش از ۱۴۳ میلیون | ۱۹ | VGG19 | [۷] |
| ٪۹۹ | بیش از ۲۳ میلیون | ۵۰ | ResNet50 | |
| ٪۹۹ | بیش از ۱۹ میلیون | ۲۵۸ | EfficientNet | |
| ٪۹۹/۱ | بیش از ۲۳ میلیون | ۱۸۹ | InceptionV3 | مدل پیشنهادی |
| ٪۹۹/۳ | بیش از ۵۵ میلیون | ۴۴۹ | InceptionResNetV2 | |

علم پزشکی خواهد بود که علاوه بر کاهش ارتباطات غیر ضروری کادر درمان با افراد مبتلا کمک به تصمیم‌گیری دقیق‌تر بیماری و در نتیجه تشخیص دقیق پزشکان خواهد انجامید. داده‌های به کار رفته در انواع مدل‌های یادگیری عمیق به اندازه کافی بزرگ نبوده و به دلیل وضعیت اضطراری بهداشت عمومی فعلی، گردآوری مجموعه داده‌های گسترده برای آموزش مدل یادگیری عمیق از اهمیت زیادی برخوردار است. علاوه بر این سایر بیماری‌های ریوی نیز در مطالعات آینده گنجانده خواهد شد همچنین توسعه یک رابط گرافیکی برای کمک به متخصصان رادیولوژی در شناسایی COVID-19 می‌تواند هدف مطالعات آینده باشد.

تعارض منافع

نویسندگان این مقاله اعلام می‌کنند که این پژوهش هیچ‌گونه تعارض منافی ندارد.

References

1. Sohrabi C, Alsafi Z, O'Neill N, Khan M, Kerwan A, Al-Jabir A, et al. World Health Organization declares global emergency: A review of the 2019 novel coronavirus (COVID-19). *International Journal of Surgery* 2020;76:71-6. <https://doi.org/10.1016/j.ijssu.2020.02.034>
2. Ahmed I, Jeon G, Chehri A. An IoT-enabled smart health care system for screening of COVID-19 with multi layers features fusion and selection. *Computing* 2022; 105(1):1-8. doi:10.1007/s00607-021-00992-0
3. Deb SD, Jha RK, Jha K, Tripathi PS. A multi model ensemble based deep convolution neural network structure for detection of COVID19. *Biomed Signal Process Control* 2022; 71: 103126. doi: 10.1016/j.bspc.2021.103126
4. Islam MR, Nahiduzzaman M. Complex features extraction with deep learning model for the detection of COVID19 from CT scan images using ensemble based machine learning approach. *Expert Systems with Applications* 2022;195:116554. <https://doi.org/10.1016/j.eswa.2022.116554>
5. Kavya NS, Veeranjanyulu N, Priya DD. Detecting Covid19 and pneumonia from chest X-ray images using deep convolutional neural networks. *Materials Today: Proceedings* 2022;64:737-43. <https://doi.org/10.1016/j.matpr.2022.05.199>
6. Thakur S, Kumar A. X-ray and CT-scan-based automated detection and classification of covid-19 using convolutional neural networks (CNN). *Biomedical Signal Processing and Control* 2021;69:102920. <https://doi.org/10.1016/j.bspc.2021.102920>

در کارهای آینده تصاویر بیشتری جمع‌آوری خواهد شد و مدل‌های عمیق‌تری برای تشخیص COVID-19 مورد بررسی قرار خواهد گرفت. منابع موجود در سطح اینترنت برای آموزش یک مدل یادگیری عمیق به منظور استفاده در محیط بیمارستانی و در شرایط اوج همه‌گیری کرونا به اندازه کافی بزرگ نبوده و به عنوان کارهای پیش رو باید مورد توجه محققان قرار گیرد. از طرف دیگر در این پژوهش به بررسی تعداد محدودی از معماری‌های از پیش آموزش دیده به کمک یادگیری انتقالی پرداخته شد. استفاده از سایر مدل‌های یادگیری عمیق با معماری‌های متفاوت، انواع لایه‌های متفاوت و حتی استفاده از روش‌های ترکیبی برای بهبود دقت و کیفیت مدل نهایی پیشنهاد می‌شود.

استفاده از یک سیستم مراقبت بهداشتی هوشمند که ارزیابی اولیه افراد مستعد نسبت به بیماری COVID-19 و ذات‌الریه را با استفاده مدل‌های یادگیری عمیق به کمک تصاویر پزشکی قفسه سینه انجام دهد نقطه عطفی در استفاده از هوش مصنوعی در

7. Elpeltagy M, Sallam H. Automatic prediction of COVID-19 from chest images using modified ResNet50. *Multimed Tools Appl* 2021; 80(17): 26451-63. doi: 10.1007/s11042-021-10783-6
8. Owais M, Yoon HS, Mahmood T, Haider A, Sultan H, Park KR. Light-weighted ensemble network with multilevel activation visualization for robust diagnosis of COVID19 pneumonia from large-scale chest radiographic database. *Applied Soft Computing* 2021;108:107490. <https://doi.org/10.1016/j.asoc.2021.107490>
9. Lorencin I, Baressi Šegota S, Anđelić N, Blagojević A, Šušteršić T, Protić A, et al. Automatic evaluation of the lung condition of COVID-19 patients using X-ray images and convolutional neural networks. *J Pers Med* 2021;11(1):28. <https://doi.org/10.3390/jpm11010028>
10. Ismael AM, Şengür A. Deep learning approaches for COVID-19 detection based on chest X-ray images. *Expert Systems with Applications* 2021;164:114054. <https://doi.org/10.1016/j.eswa.2020.114054>
11. Ouyang X, Huo J, Xia L, Shan F, Liu J, Mo Z, et al. Dual-sampling attention network for diagnosis of COVID-19 from community acquired pneumonia. *IEEE Transactions on Medical Imaging* 2020;39(8):2595-605. doi: 10.1109/TMI.2020.2995508
12. McFee B, Raffel C, Liang D, Ellis DP, McVicar M, Battenberg E, Nieto O. librosa: Audio and music signal analysis in python. 14th Python in Science Conference; 2015 Jul 6-12; Sci Py: Austin, Texas; 2015; p. 18-25. doi:10.25080/MAJORA-7B98E3ED-003
13. Lou L, Liang H, Wang Z. Deep-Learning-Based COVID-19 Diagnosis and Implementation in Embedded

Edge-Computing Device. *Diagnostics* 2023;13(7):1329. <https://doi.org/10.3390/diagnostics13071329>

14. Hamdi S, Oussalah M, Moussaoui A, Saidi M. Attention-based hybrid CNN-LSTM and spectral data augmentation for COVID-19 diagnosis from cough sound. *Journal of Intelligent Information Systems* 2022;59(2):367-89.

15. Laguarda J, Hueto F, Subirana B. COVID-19 artificial intelligence diagnosis using only cough

recordings. *IEEE Open J Eng Med Biol* 2020; 1: 275–81. doi: 10.1109/OJEMB.2020.3026928

16. Li Z, Liu F, Yang W, Peng S, Zhou J. A survey of convolutional neural networks: analysis, applications, and prospects. *IEEE transactions on neural networks and learning systems*. *Transactions on Neural Networks and Learning Systems* 2021; 33(12): 6999 - 7019. doi: 10.1109/TNNLS.2021.3084827