

# Using Ensemble Deep Learning to Improve the Accuracy of CT-Scan Lung Image Detection of Covid-19 Patients

Mahdi Sarchahi<sup>1</sup>, Master Student of Software Engineering Elham Mahdipour<sup>2\*</sup>, Assistant Professor

<sup>1</sup> Master Student, Department of Computer Engineering, Khavaran Institute of Higher Education, Mashhad, Iran, sm2249@yahoo.com

<sup>2</sup> Department of Computer Engineering, Khavaran Institute of Higher Education, Mashhad, Iran, mahdipour\_e@khavaran.ac.ir

**Abstract:** Coronavirus disease 2019 (Coronavirus disease 2019) or Covid-19 (Covid-19) is an infectious disease caused by the acute respiratory syndrome virus (SARS-Cov-2) and has spread worldwide as an epidemic. After the rapid spread of the disease in 2019, the World Health Organization declared a public health emergency; and Human society saw a massive increase in deaths caused by its various mutations. Clinical symptoms include fever, cough, shortness of breath, and loss of smell. Fortunately, recently researchers have been able to achieve many successes in preventing the spread and speeding up its treatment by using different diagnostic methods. The aim of this research is to diagnose the disease of covid-19 by processing CT scan images of people's lungs using ensemble deep learning techniques based on convolutional neural networks (CNN). In this regard, two data sets of CT scan images of people's lungs obtained from Kaggle and GitHub are used. The convolutional neural network architectures used in this research include VGG16, VGG19, Inception v3, ResNet50, DenseNet169, and CtNet10. In the first step, we added multiple dense (fully connected) layers to each of these models and evaluated their effect. Afterward, to achieve higher accuracy and efficiency, the proposed ensemble method, which is a combination of VGG16, DenseNet169, and ResNet50 architectures, has been used. The experimental results show that the proposed ensemble method is able to achieve an accuracy of 98% to 100% on the investigated data set and significantly improve the performance of deep neural networks in multi-classification prediction tasks.

**Keywords:** *Coronavirus; Deep neural network; Convolution; Ensemble deep learning; CT scan.*

\* Corresponding author, mahdipour\_e@khavaran.ac.ir

## ارائه راهکاری بر پایه یادگیری عمیق ترکیبی جهت بهبود دقت شناسایی

### تصاویر سی تی - اسکن ریه بیماران کووید-۱۹

مهدی سرچاهی<sup>۱</sup>، دانشجوی کارشناسی ارشد مهندسی کامپیوتر- نرم افزار، الهام مهدی پور<sup>۲\*</sup>، استادیار

۱- گروه مهندسی کامپیوتر- موسسه آموزش عالی خاوران- مشهد- ایران - sm2249@yahoo.com

۲\* هیئت علمی گروه مهندسی کامپیوتر- موسسه آموزش عالی خاوران- مشهد- ایران - mahdipour\_e@khavaran.ac.ir

چکیده: بیماری کرونا ویروس ۲۰۱۹ (Coronavirus disease 2019) یا کووید-۱۹ (Covid-19)، بیماری عفونی است که بر اثر ویروس سندروم حاد تنفسی (SARS-Cov-2) ایجاد می شود و بصورت همه گیری در سطح جهان شیوع پیدا کرده است. پس از آغاز انتشار سریع این بیماری در سال ۲۰۱۹، یک وضعیت اورژانسی سلامت عمومی از سوی سازمان بهداشت جهانی اعلام شد و جامعه بشری شاهد افزایش بسیار زیاد مرگ و میر ناشی از جهش های مختلف آن بود. از جمله علائم بالینی می توان به تب، سرفه، تنگی نفس و نابویایی اشاره کرد. خوشبختانه محققان در این اواخر توانسته اند با استفاده از روش های مختلف تشخیص در جلوگیری از انتشار و تسریع در درمان آن موفقیت های بسیاری را بدست آورند. هدف از این پژوهش تشخیص بیماری کووید-۱۹ با پردازش تصاویر سی تی اسکن ریه افراد با استفاده از الگوریتم های ترکیبی یادگیری عمیق بر پایه شبکه های عصبی کانولوشن (CNN) است. در این راستا از دو مجموعه داده تصاویر سی تی اسکن ریه افراد که از داده های Kaggle و GitHub بدست آمده استفاده می گردد. معماری های شبکه های عصبی کانولوشن بکار رفته در این پژوهش شامل VGG16، VGG19، Inception v3، ResNet50، DenseNet169 و CtNet10 است که در مرحله اول اثر اضافه کردن دو لایه Dense به هر کدام از این مدل ها بررسی و ارزیابی شد. سپس برای رسیدن به دقت و کارایی بالاتر از روش Ensemble پیشنهادی یعنی ترکیب معماری های VGG16، DenseNet169 و ResNet50 استفاده شده است. نتایج حاصل از پیاده سازی نشان می دهد که روش ترکیبی پیشنهادی قادر است روی مجموعه داده های مورد بررسی به دقت بالای ۹۸ درصد تا ۱۰۰ درصد دست یابد و بطور قابل توجهی عملکرد شبکه های عصبی عمیق را در کارهای پیش بینی دو یا چند دسته ای بهبود بخشد.

کلمات کلیدی: کرونا ویروس، شبکه عصبی عمیق، کانولوشن، یادگیری عمیق ترکیبی، سی تی اسکن.

## ۱. مقدمه

سال ۲۰۱۹ شاهد شیوع یک ذات‌الریه ویروسی بود که از منبعی ناشناخته در ووهان چین سرچشمه می‌گرفت. این ویروس توسط سازمان بهداشت جهانی ۱-۳ سندرم تنفسی حاد شدید کرونا ۲ (SARS-CoV-2) نامیده شد و پنومونی ناشی از آن بیماری کروناویروس ۲۰۱۹ (COVID-19) نامیده شد [۱].

شایع‌ترین علائم عبارتند از تب، خستگی، سرفه خشک، از دست دادن اشتها، بدن درد و مخاط. برخی از علائم غیر اختصاصی ممکن است شامل گلودرد، سردرد، لرز همراه با لرزش، از دست دادن بویایی یا چشایی، آبریزش بینی، استفراغ یا اسهال باشد. ظهور علائم معمولاً ممکن است پس از تماس فرد با ویروس ۵ تا ۶ روز طول بکشد. افرادی که علائم خفیف دارند ممکن است خود به خود بهبود یابند. افرادی که از بیماری‌های دیگر مانند دیابت یا مشکلات قلبی رنج می‌برند ممکن است از علائم جدی‌تری رنج ببرند [۲].

در حال حاضر، روش تشخیصی رایج مورد استفاده، تشخیص واکنش زنجیره ای پلیمراز رونویسی معکوس در زمان واقعی (RT-PCR) RNA ویروسی از خلط یا سواب نازوفارنکس است. با این حال، این آزمایش‌ها نیاز به مداخله انسانی دارند، میزان مثبت پایینی در مراحل اولیه عفونت نشان می‌دهند و تا ۶ ساعت زمان نیاز دارند تا نتایج را ارائه کنند. بنابراین، برای سرعت بخشیدن به کنترل این بیماری همه‌گیر، نیاز به ابزارهای تشخیص سریع و زود هنگام است، به ویژه اینکه برای دراز مدت، زمانی که اقدامات قرنطینه به طور کامل برداشته می‌شود، آزمایش‌ها باید در مقیاس وسیع انجام شود تا از بازگشت مجدد این بیماری همه‌گیر جلوگیری شود [۳].

در فرآیند تشخیص افراد مبتلا به ویروس کرونا، تصویربرداری سی‌تی‌اسکن قفسه سینه از دقت و حساسیت بالاتری نسبت به کیت‌های تشخیصی برخوردار است. سی‌تی‌اسکن قفسه سینه یک ابزار تصویربرداری استاندارد برای تشخیص ذات‌الریه است. به طور کلی، لکه‌های سفید روی تصویر ریه نشان‌دهنده درگیری ویروس کرونا است که با تصویربرداری می‌توان آن را به دقت تشخیص داد. در سی‌تی‌اسکن قفسه سینه، میزان تصاویر با کیفیت از بافت ریه بالا است

و رادیولوژیست می‌تواند به سرعت میزان درگیری ریه را با این بیماری تعیین کند [۴].

اسکن توموگرافی کامپیوتری یا سی‌تی‌اسکن، تصاویر دقیقی از اندام‌ها، استخوان‌ها، بافت‌های نرم و رگ‌های خونی ایجاد می‌کند. تصاویر سی‌تی‌اسکن به پزشکان اجازه می‌دهد تا ساختارهای داخلی را شناسایی کرده و شکل، اندازه، تراکم و بافت آنها را ببینند. متفاوت از اشعه ایکس معمولی، سی‌تی‌اسکن مجموعه‌ای از برش‌ها را از یک ناحیه معین از بدن بدون پوشاندن ساختارهای مختلف بدن تولید می‌کند. بنابراین، سی‌تی‌اسکن تصویر بسیار دقیق‌تری از وضعیت بیمار نسبت به اشعه ایکس معمولی ارائه می‌دهد [۵].

در این راستا پژوهش حاضر جهت رسیدن به دقت بالاتر به پردازش تصاویر سی‌تی‌اسکن با استفاده از الگوریتم‌های ترکیبی یادگیری عمیق پرداخته است. بر این اساس ابتدا مدل‌های مختلف یادگیری عمیق پیاده‌سازی، سپس مدل‌های ترکیبی پیشنهادی بررسی می‌گردد.

ساختار کلی پژوهش حاضر بدین صورت است که در ابتدا کارهای مرتبط انجام شده در زمینه سی‌تی‌اسکن را بررسی نموده، سپس مروری کلی بر ساختار شبکه‌های عصبی عمیق در تشخیص کووید-۱۹ داشته و مجموعه داده‌های استفاده شده در این پژوهش شرح داده می‌شود. پس از آن راهکارهای پیشنهادی بر پایه مدل‌های شبکه عصبی کانولوشن را مورد بررسی قرار می‌دهد. در نهایت نیز نتایج تجربی و ارزیابی آن‌ها بیان می‌گردد.

## ۲. پیشینه پژوهش

بعد از پیدایش بیماری کووید-۱۹، پژوهش‌ها و کارهای بسیار زیادی در زمینه تشخیص این بیماری از روی تصاویر اشعه ایکس ریه انجام شده است و به نسبت، پژوهش‌های کمتری به پردازش سی‌تی‌اسکن ریه افراد با استفاده از مدل‌های شبکه‌های عصبی کانولوشن پرداختند که هر کدام با مدل‌ها و مجموعه داده‌هایی که در اختیار داشته‌اند به دقت‌های مختلفی رسیده‌اند.

طبق مطالعه‌ای که توسط ویرودهی شاه و همکاران [۲] انجام شده، بر اساس یک شبکه عصبی کانولوشن (CNN)، با توجه به تمایز تصاویر سی‌تی‌اسکن COVID-19 و غیر COVID-19 در

۰,۹۹۸۴ برای تصاویر سی تی اسکن و دقت ۰,۹۶۸۱ برای تصاویر با اشعه ایکس دست یابد.

کاپیل گوپتا و همکارش [۱۰]، جهت تشخیص و غربالگری خودکار COVID-19 با استفاده از تصاویر سی تی اسکن قفسه سینه و تکنیک‌های مبتنی بر یادگیری عمیق بر روی یک مجموعه داده تصویر سی تی اسکن در دسترس عموم (شامل ۱۲۵۲ تصویر CT قفسه سینه COVID-19 و ۱۲۳۰ غیر کووید)، دو مدل یادگیری عمیق (DLM) از پیش آموزش دیده یعنی MobileNetV2 و DarkNet19، و یک مدل جدید طراحی شده کار کردند و به بالاترین دقت طبقه‌بندی ۹۸,۹۱٪ با استفاده از DarkNet19 آموزش داده شده با انتقال دست یافتند.

حسین کاهیل و همکاران [۳]، پلتفرمی را پیشنهاد کردند که چندین سطح از تجزیه و تحلیل و طبقه‌بندی جنبه‌های طبیعی و غیرطبیعی COVID-19 را با بررسی تصاویر سی تی اسکن قفسه سینه پوشش می‌دهد. آن‌ها پس از انتخاب بهترین ماژول مناسب برای مطالعه، الگوریتم‌های هوش مصنوعی را ترکیب کرده و در نهایت، پس از بکارگیری معماری‌های InfNet, UNet, UNet++, Dense-UNet, Attention-UNet، با مقایسه اثربخشی تکنیک‌های موجود در پژوهش نتایج به دست آمده نشان داد که دقت معماری InfNet پیشنهادی ۹۵ درصد و بهتر از سایر روش‌ها است.

سوگاتیا و همکارش [۱۱]، مجموعه‌ای از یادگیری عمیق چند نمونه‌ای (DMIL) بر روی تصاویر سی تی اسکن را استفاده نمود و از Mask R-CNN برای آموزش یک طبقه‌بندی سطح تصویر استفاده کرد که تصویر ورودی را به عنوان پنومونی معمولی یا پنومونی Covid برچسب گذاری می‌کند. از این مجموعه مدل‌های DMIL با Mask R-CNN به دقت ۹۸,۹۶٪ رسید.

عالیوی و همکاران [۱۲]، تصاویر سی تی را با در نظر گرفتن موارد مختلف (سی تی طبیعی قفسه سینه، ذات‌الریه، علل ویروسی معمولی و موارد کووید-۱۹) بر اساس یک روش DL پیشرفته برای مقابله با مسائل تقسیم بندی معنایی قفسه سینه ارائه دادند. این رویکرد از یک نسخه اصلاح شده از U-net برای فعال کردن و پشتیبانی از تشخیص Covid-19 از تصاویر مورد

یک مجموعه داده با ۷۳۸ تصویر سی تی اسکن با استفاده از تکنیک‌های مختلف یادگیری عمیق تمرکز بر یک مدل به نام CtNet10 برای تشخیص COVID-19 طراحی شده است که دقت آن ۸۲,۱٪ است. همچنین آن‌ها مدل‌های دیگری را بررسی کردند که عبارتند از DenseNet169, VGG16, ResNet50, Inception v3 و VGG19. نتایج آن‌ها نشان داد مدل VGG19 با دقت ۹۴,۵۲ درصد در مقایسه با سایر مدل‌های یادگیری عمیق دقت بهتری داشته است.

تانگ و همکارانش [۶] EDL-COVID که یک مدل یادگیری عمیق ترکیبی بر پایه یادگیری عمیق و یادگیری ترکیبی است را پیشنهاد کردند. مدل EDL-COVID چندین مدل عکس فوری COVID-Net، که یک شبکه عصبی عمیق برای تشخیص COVID-19 با تصاویر اشعه ایکس قفسه سینه است را با روش میانگین وزنی پیشنهادی تانگ و همکاران ترکیب می‌کند. نتایج تجربی نشان می‌دهد که EDL-COVID می‌تواند COVID-19 را با دقت ۹۵٪ تشخیص دهد که بهتر از دقت ۹۳,۳٪ شبکه COVID-Net است.

متئو پولسینلی و همکاران [۷]، با طراحی یک شبکه عصبی کانولوشنال سبک (CNN) بر اساس مدل SqueezeNet برای تشخیص تمایز تصاویر COVID-19 CT نسبت به تصاویر CT سالم به دقت ۸۵,۰۳٪ رسیده‌اند.

سوارز و همکاران [۸]، مجموعه دیگری از سی تی اسکن را در دسترس عموم قرار دادند که شامل ۲۴۸۲ سی تی اسکن است و از بیمارستان‌های شهر ساوث‌پائولو، برزیل گرفته شده است. آن‌ها با بکارگیری مدل XDNN, Accuracy, Recall و Precision را به ترتیب ۹۷,۳۸٪، ۹۵,۵۳٪ و ۹۹,۱۶٪ گزارش کرده‌اند.

غفاری سلیک [۹]، مدلی را برای تشخیص کووید-۱۹ و سایر موارد ذات‌الریه از تصاویر سی تی و تصاویر قفسه سینه با اشعه ایکس با استفاده از یادگیری عمیق پیشنهاد کرد. او معماری جدیدی به نام CovidDWNNet پیشنهاد کرد که بر اساس واحدهای بلاک باقیمانده استفاده مجدد از ویژگی (FRB) و کانولوشن‌های وسیع شده عمقی (DDC) است. عملکرد مدل جدید با ارائه ترکیبی از معماری پیشنهادی و الگوریتم تقویت گرادیان (CovidDWNNet+GB) به دست آمده است و توانست به دقت

مطالعه استفاده می‌کند و توانستند به دقت ۰,۹۳۳، حساسیت ۰,۹۶۸۸ و صحت ۰,۹۰۹۶ دست یابند.

عمران احمد و همکارانش [۱۳]، با بکارگیری یادگیری عمیق برای تقسیم خودکار تصاویر COVID-19 در تصاویر سی تی اسکن ریه از یک مدل تقسیم‌بندی به نام U-Net را استفاده کردند که در نهایت به دقت ۰,۹۳ دست یافتند.

داندی یانگ و همکاران [۱۴]، از چهار مدل قدرتمند CNN از پیش آموزش دیده، VGG16، DenseNet121، ResNet50 و ResNet152 برای کار طبقه‌بندی باینری CT اسکن COVID-19 استفاده کردند. طبقه‌بندی باینری و چند کلاسه وظایف تصاویر اشعه ایکس با استفاده از معماری یادگیری انتقال عمیق VGG16 پیشرفته انجام شده است و دقت بالای ۹۹٪ با بهبود VGG16 در تشخیص تصاویر اشعه ایکس از COVID-19 و ذات‌الریه به دست آمد.

ابنزر جانگام و همکاران [۱۵]، با ترکیب مدل‌های یادگیری عمیق از پیش آموزش دیده VGG19 و DenseNet169، و با پیاده سازی بر روی ۵ مجموعه داده مختلف به نتایج مطلوبی دست یافت که برای مجموعه داده اول F1 Score=0.8545، مجموعه داده دوم Accuracy=0.93، مجموعه داده سوم Accuracy=0.99، مجموعه داده چهارم Accuracy=0.9975 و مجموعه داده پنجم Accuracy=0.915 را بدست آوردند.

تجلال چودھری و همکاران [۱۶]، یک روش مهم یادگیری انتقال فقط وزن را برای طبقه‌بندی تصاویر سی تی اسکن به عنوان آلوده یا غیرآلوده به کووید-۱۹ پیشنهاد کردند. در روش پیشنهادی آنها، مدل‌های از پیش آموزش دیده با هرس کردن پارامترهای وزنی کم اهمیت‌تر مدل، با دستگاه‌های مراقبت نقطه‌ای سازگار می‌شوند. آنها آزمایش‌هایی را بر روی دو مدل محبوب VGG16 و ResNet34 انجام دادند که برای مدل ResNet34 هرس شده F-sensitivity=0.9216، Accuracy=95.47%، score=0.9567 و specificity=0.9942 با ۴۱,۹۶٪ FLOP های کمتر و ۲۰,۶۴٪ پارامترهای وزنی کمتر در مجموعه داده‌های سی تی اسکن SARS-CoV-2 دست یافتند. نتایج آزمایش‌های آنها نشان داد که روش پیشنهادی به طور قابل توجهی الزامات منابع زمان

اجرای مدل‌های محاسباتی فشرده را کاهش می‌دهد و آنها را برای استفاده در دستگاه‌های نقطه مراقبت<sup>۱</sup> آماده می‌کند.

اس.وی. کویگلاوانی و همکارانش [۱۷]، از روش‌های یادگیری عمیق زیادی برای COVID-19 پیشنهاد شده است. کار پیشنهادی از معماری‌های CNN مانند VGG16، DenseNet121، MobileNet، NASNet، Xception و EfficientNet و از مجموعه داده‌ای شامل ۳۸۷۳ تصویر سی تی اسکن با «COVID» و «Non-COVID» استفاده کردند. در انتها به دقت‌های VGG16=0.9768، DenseNet121=0.9753، MobileNet=0.9638، NASNet=0.8951، Xception=0.9247 و EfficientNet=0.8019 دست یافتند و از تحلیل به دست آمده، نتایج نشان داد که معماری VGG16 در مقایسه با سایر معماری‌ها دقت بهتری را ارائه داده است.

ویپول کومار سینگ و همکارش [۱۸]، از یک مدل یادگیری عمیق تنظیم شده با الهام از معماری مدل MobileNet V2 برای تشخیص بیماری کووید-۱۹ بر روی تصاویر سی تی اسکن بکار گرفتند. آنها همچنین مدل توسعه یافته را از نظر اندازه و پیچیدگی بهینه‌سازی کردند تا با دستگاه‌های موبایل و لبه سازگار شود. نتایج آزمایش‌های گسترده انجام شده بر روی یک مجموعه داده واقعی متشکل از ۲۴۸۲ تصویر اسکن توموگرافی کامپیوتری قفسه سینه، به دقت طبقه‌بندی ۰,۹۶۴۰ با زمان پاسخ‌دهی کوتاه‌تر از مدل‌های یادگیری عمیق رایج دست یافتند.

سرتان سرت و همکارش [۱۹]، از مدل یادگیری عمیق ResNet50 برای پیش‌بینی COVID-19 در هر تصویر CT از یک سی تی اسکن سه بعدی استفاده کردند. آنها توانستند دقت AUC=0.96 برای تشخیص COVID-19 در اسکن‌های CT ارائه کنند.

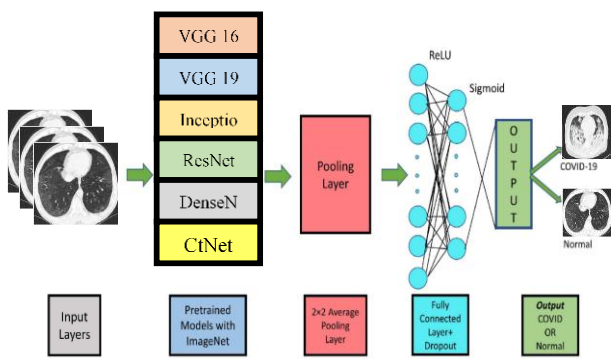
عباس اکرمی و همکارش [۲۰]، در پژوهشی یک مدل اپیدمیکی فازی ریاضی برای انتشار ویروس کرونا در یک جمعیت، که با توجه به عامل‌های واکنش‌ناهیون، درمان، اجرای پروتکل‌های بهداشتی و میران ویروس کرونا ساخته شده است را مورد بررسی قرار داده‌اند. آنها از پارامترهای فازی برای نرخ سرایت، نرخ بهبودی و نرخ مرگ‌ومیر در این بیماری و در

<sup>1</sup> point-of-care devices

### ۳. مجموعه داده و شبکه عصبی کانولوشن در

#### تشخیص بیماری COVID-19

فرآیند تشخیص بیماری COVID-19 از تصاویر سی تی اسکن ریه افراد شامل بخش‌های جمع آوری مجموعه داده‌ها، پیش پردازش داده‌ها، طبقه‌بندی مجموعه داده‌ها، آموزش مدل و ارزیابی و تجزیه و تحلیل مدل است. معماری کامل سیستم برای تشخیص COVID-19 برای روش‌های برپایه CNN که در این پژوهش استفاده شده است در شکل ۱ نشان داده شده است. ابتدا تصاویر سی تی اسکن به عنوان مجموعه داده مورد نیاز برای آموزش و اعتبارسنجی به مدل‌های یادگیری عمیق برای تشخیص COVID-19 داده می‌شود تا تصاویر سی تی اسکن را به عنوان COVID-19 مثبت یا COVID-19 منفی طبقه‌بندی کند. در انتها نیز چهار معیار مهم شامل Precision، Recall، F1-score، Accuracy نمایش داده می‌شوند.



شکل (۱): نمودار گردش کار مدل‌های از پیش آموزش دیده برای

تشخیص کووید-۱۹ [۲۳]

#### ۱.۳. مجموعه داده

این پژوهش برای پیاده‌سازی مدل‌های شبکه عصبی کانولوشن مورد نظر از دو مجموعه داده شامل تصاویر سی تی اسکن استفاده کرده است. اولین مجموعه داده از سایت Kaggle به نشانی <https://www.kaggle.com/datasets/plameneduardo/sarscov2-ctscan-dataset> دریافت شده است. این مجموعه داده شامل ۲۴۸۱ عدد تصویر سی تی اسکن ریه افراد است که خود به دو بخش COVID با ۱۲۵۲ سی تی اسکن مثبت برای عفونت COVID-19 SARS-CoV-2 و NON-COVID با ۱۲۲۹ سی تی اسکن برای بیماران غیر آلوده به SARS-CoV-2 تقسیم می‌شود.

تحلیل مدل از روش ایجاد ماتریس برای محاسبه عدد مولد پایه و پایداری نقاط تعادل مدل استفاده کرده‌اند. بر اساس نتایج شبیه‌سازی آن‌ها، مشاهده شد که اجرای پروتکل‌های بهداشتی و واکسیناسیون تاثیر بسزایی در کاهش یا توقف انتشار بیماری کرونا در یک جمعیت دارند.

امیرحسین یداللهی و همکارش [۲۱]، برای شبیه‌سازی انتشار ویروس کوید-۱۹ بر اساس زنجیره مارکوف گسسته زمان مدلی ارائه کردند. آن‌ها با دریافت پارامترهای داده شده رفتار بیماری را در شرایط مختلف تقلید نمودند. نتایج مختلف شبیه‌سازی آن‌ها تاثیر تک‌تک پارامترهای مختلف را بر عملکرد مدل در تقلید رفتار انتشار ویروس کوید-۱۹ نشان می‌دهد که با نتایج و رفتار این ویروس در دنیای واقعی مطابقت دارد. به طور کلی در مطالعه آن‌ها مدلی جامع برای شبیه‌سازی انتشار ویروس کوید-۱۹ ارائه گردید که با توجه به پارامتری بودن و در صورت کالیبره کردن ضرایب آن می‌تواند برای شبیه‌سازی رفتار انواع سویه‌های کوید-۱۹ و حتی سایر بیماری‌های واگیردار بکار گرفته شود.

سیدمحمد موسوی و همکارانش [۲۲]، یک سیستم تشخیص خودکار موارد مبتلا به کوید-۱۹ مبتنی بر اینترنت اشیا پیشنهاد کردند. در مدل پیشنهادی آن‌ها ابتدا با استفاده از فن‌آوری اینترنت اشیا تصاویر پزشکی مستقیم پس از مراجعه فرد مشکوک از طریق تجهیزات پزشکی مجهز به اینترنت اشیا به مخزن داده ارسال می‌شود. سپس آن‌ها به منظور کمک به متخصصین رادیولوژی برای تفسیر هرچه بهتر تصاویر پزشکی از چهار مدل شبکه عصبی پیچشی از پیش آموزش دیده به نام‌های Inception V3، InceptionResNet V2، ResNet152 و VGG19 مجموعه داده تصاویر پزشکی رادیولوژی قفسه سینه و CT Scan در یک طبقه‌بندی سه کلاسه برای پیش‌بینی دقیق موارد مبتلا به کوید-۱۹ استفاده کردند. در نهایت بهترین نتیجه بدست آمده آن‌ها برای تصاویر سی تی اسکن متعلق به معماری InceptionResNet V2 با دقت ۹۹٫۳۶۶٪ و برای تصاویر رادیولوژی مربوط به معماری Inception V3 با دقت ۹۶٫۹۴۳٪ می‌باشد.

معماری پیشنهادی با ترکیب مدل‌های VGG16, DenseNet169, ResNet50 به عنوان مدل Ensemble ارائه می‌گردد و نتایج در تشخیص بیماری کووید-۱۹ با استفاده از تصاویر سی تی اسکن ارزیابی می‌شود. بر این اساس در ادامه مدل‌های یادگیری عمیق بکارگرفته شده در این پژوهش معرفی و نتایج بدست آمده از هر یک به تنهایی بر روی مجموعه داده‌های اول و دوم بررسی می‌شود.

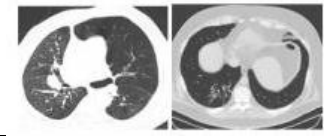
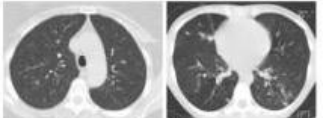
#### ۱.۴. VGG16

طبق تحقیقات یکی از شبکه‌های یادگیری عمیقی که دقت نسبتاً خوبی در شناسایی تصاویر سی تی اسکن دارد VGG16 است لذا اولین مدلی که در این پژوهش بکار گرفته شده است، مدل VGG16 است. در این مدل اندازه ورودی تصاویر به صورت  $224 \times 224 \times 3$  داده شده است. بعد از تعریف مدل شبکه فریز شد تا فرآیند آموزش برای این قسمت انجام نشده و از وزن‌های بدست آمده در طول آموزش با استفاده از دیتاست ImageNet استفاده شود سپس لایه‌های موردنیاز برای کلاس‌بندی داده‌ها اضافه شد. جهت ارزیابی کارایی مدل از دو تابع فعال‌ساز sigmoid و softmax با epochهای ۵۰ و ۱۰۰ استفاده گردید.

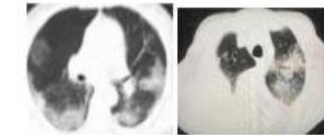
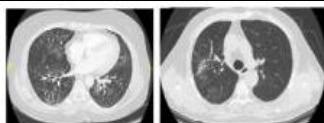
شبکه VGG16، شامل دو لایه کانولوشنی با ۶۴ فیلتر  $3 \times 3$  هست که پشت سر هم قرار گرفته‌اند. سپس، یک لایه ادغام حداکثری  $2 \times 2$  با پرش (Stride) به اندازه ۲ قرار گرفته است. این لایه ادغام علاوه بر نمونه‌برداری، وظیفه کاهش بعد ویژگی‌ها به نصف را هم دارد. در ادامه، دو لایه کانولوشنی دیگر با ۱۲۸ فیلتر  $3 \times 3$  و یک لایه ادغام  $2 \times 2$  و پرش ۲ قرار گرفته‌اند. به طور مشابه، سه لایه کانولوشنی با ۲۵۶ فیلتر  $3 \times 3$  و یک لایه ادغام  $2 \times 2$  با پرش ۲ قرار گرفته‌اند. سه لایه کانولوشنی با ۵۱۲ فیلتر  $3 \times 3$  و یک لایه ادغام ادامه این شبکه هست که البته دو بار تکرار می‌شود. در نهایت، ویژگی‌ها تبدیل به یک بردار ویژگی می‌شوند تا در اختیار لایه‌های نورونی یا تمام‌اتصال یا Fully Connected قرار گیرند.

در کل سی تی اسکن این داده‌ها از بیماران واقعی در بیمارستان‌های سائوپائولو، برزیل جمع‌آوری شده است [۸]. مجموعه داده دوم مورد استفاده در این پژوهش به نشانی <https://github.com/UCSD-AI4H/COVID-CT> شامل ۷۴۶ تصویر سی تی اسکن ریه افراد است. این تصاویر به دو بخش COVID با ۳۴۹ تصویر CT مثبت برای COVID-19 متعلق به ۲۱۶ بیمار و ۳۹۷ تصویر CT که برای COVID-19 منفی است. جدول ۲ مشخصات این مجموعه داده را نشان می‌دهد [۲۴].

جدول (۱): مجموعه داده اول

Total Sample	2481	Image	
COVID	1252		
Non-COVID	1229		

جدول (۲): مجموعه داده دوم

Total Sample	746	Image	
COVID	349		
Non-COVID	397		

جهت ارزیابی دقیق مدل‌های یادگیری داده‌ها به سه دسته Train, test, validation تقسیم شد. این تقسیم‌بندی به صورت ۸۰٪ برای بخش Train، ۱۰٪ برای بخش Test و ۱۰٪ برای بخش Validation انجام شد.

#### ۴. مروری بر مدل‌های یادگیری عمیق


در این پژوهش روش انجام کار به شرح زیر است: ابتدا مدل‌های VGG16, VGG19, Inception v3, ResNet50, DenseNet169, CtNet10 بر روی مجموعه داده‌ها پیاده سازی شده و کارایی هر مدل بر روی مجموعه داده‌ها ارزیابی شده و سپس جهت بدست آوردن نتایج مطلوب‌تر، لایه‌های Dense به انتهای هر مدل اضافه شده و عملکرد مدل‌های پیشنهادی بررسی می‌گردد. پس از آن

<sup>1</sup> Max pooling

## ۲.۴. VGG19

در پیکربندی معماری VGG19، مدل با یک تصویر ورودی به اندازه  $224 \times 224 \times 3$  تغذیه می‌شود. در مجموع ۵ بلوک کانولوشن وجود دارد که از یکی از لایه‌های کانولوشن و یک رمپ به ابعاد  $224 \times 224 \times 64$  عبور می‌کند. سپس از لایه ادغام و کانولوشن بعدی به ابعاد  $128 \times 128 \times 128$  عبور می‌کند. سپس دوباره از دو لایه ترکیبی به ابعاد  $128 \times 128 \times 256$  و  $128 \times 128 \times 512$  عبور می‌کند. این بیشتر از طریق لایه متوالی به ابعاد  $14 \times 14 \times 512$  و یک لایه ترکیبی  $7 \times 7 \times 512$  عبور داده می‌شود. سپس از طریق  $25088$  نورون از لایه مسطح عبور داده می‌شود، که به طور متوالی از یک لایه FC متشکل از  $4096$  نورون عبور می‌کند، که در هر یک از این لایه‌ها از لایه حذف استفاده شده است. در انتها تصاویر سی تی اسکن پس از عبور از یک تابع فعال‌ساز sigmoid و یا softmax، به عنوان COVID-19 مثبت یا منفی طبقه‌بندی می‌شوند (شکل ۲).


- فاکتورسازی فضایی به پیچیدگی‌های نامتقارن
  - کاربرد طبقه‌بندی‌کننده‌های کمکی
  - کاهش اندازه شبکه کارآمد
- Inception v3 از یک شبکه عصبی عمیق ۴۲ لایه تشکیل شده است. مدل Inception v3 متشکل از بلوک‌های ساختمانی متقارن و نامتقارن، از جمله کانولوشن‌ها، لایه‌های Max pooling، Average pooling، dropouts و لایه‌های fully connected است. معماری Inception v3 در شکل ۳ نشان داده شده است [۲۵].



شکل (۳): معماری مدل Inception v3 [۲۵]

## ۴.۴. ResNet50

ResNet مخفف Residual Network است و نوع خاصی از شبکه عصبی کانولوشنال (CNN) است. ResNet50 یک شبکه عصبی کانولوشن ۵۰ لایه است (۴۸ لایه کانولوشن، یک لایه MaxPool و یک لایه Flattening). شبکه‌های عصبی ResNet نوعی شبکه عصبی مصنوعی (ANN) هستند که با چیدن بلوک‌های Residual، شبکه‌ها را تشکیل می‌دهند (شکل ۴).



شکل (۲): پیکربندی مدل VGG19 [۲]


معماری ResNet50 شامل عناصر زیر است:

- یک لایه کانولوشن  $7 \times 7 \times 64$  با یک گام ۲.
- یک لایه ترکیبی حداکثر با گام ۲.
- ۹ لایه کانولوشن دیگر. ۳ لایه  $3 \times 3 \times 64$ ،  $1 \times 1 \times 64$  و  $1 \times 1 \times 256$ ، که این ۳ لایه ۳ بار تکرار می‌شوند.
- ۱۲ لایه دیگر  $1 \times 1 \times 128$ ،  $3 \times 3 \times 128$  و  $1 \times 1 \times 512$ ، که ۴ بار تکرار شده است.
- ۱۸ لایه دیگر با  $1 \times 1 \times 256$  و ۲ هسته  $3 \times 3 \times 256$ .
- $1 \times 1 \times 1025$ ، که ۶ بار تکرار شده است.
- ۹ لایه دیگر با  $1 \times 1 \times 512$ ،  $3 \times 3 \times 512$  و  $1 \times 1 \times 2048$  که ۳ بار تکرار شده است [۲۶].

## ۳.۴. Inception v3

معماری Inception v3 سومین نسخه از معماری Inception است که در ابتدا برای مدل GoogLeNet توسعه پیدا کرده بود. طراحی Inception v3 برای اجازه دادن به عمیق‌تر شدن شبکه‌ها در نظر گرفته شده بود و در عین حال از افزایش بیش از حد تعداد پارامترها جلوگیری می‌کرد. مدل Inception v3 درصد خطای کمتری نسبت به مدل‌های قبلی خود دارد. تغییرات عمده انجام شده در مدل Inception v3 عبارتند از:


- فاکتورسازی به پیچیدگی‌های کوچکتر



شکل (۴): معماری مدل ResNet50



## ۵.۴. DenseNet169



شکل (۵): معماری مدل CtNet10 [۲]

مدل‌های شبکه عصبی فوق که در تحقیقات پیشین استفاده شده‌اند با در نظر گرفتن دو دسته پارامتر و هایپرپارامتر با مشخصات زیر، مجدد پیاده‌سازی گشتند: epoch=50 و epoch=100، توابع فعال‌ساز sigmoid و softmax، تابع بهینه‌ساز optimizer=adam. در مرحله بعد همان‌طور که در ادامه شرح داده خواهد شد اثر اضافه نمودن دو لایه Dense به هر کدام از مدل‌های فوق بررسی شده است که در آنجا نیز برای ایجاد شرایط یکسان جهت مقایسه هایپرپارامترهای ذکر شده فوق به شکل یکسان تنظیم شده‌اند. در جدول‌های ۳ و ۴ نمودارهای Accuracy و تابع Loss مربوط به هر مدل بر روی مجموعه داده اول و دوم رسم شده است.

## ۵. روش پیشنهادی

در این پژوهش دو راهکار جهت بهبود دقت شناسایی COVID-19 از روی تصاویر سی‌تی‌اسکن ارائه شده است. در این بخش هر یک از این راهکارها شرح داده می‌شود.

### ۱.۵. افزودن لایه‌های Dense به انتهای معماری‌های از

#### پیش‌تعلیم داده شده

پس از پیاده‌سازی و اجرای معماری‌های شبکه عصبی در این پژوهش و کسب نتایج و دقت‌های بدست آمده، جهت افزایش و بهبود کارایی و ارتقای مدل‌های از پیش‌تعلیم داده شده، در انتهای هر مدل، لایه‌های Dense اضافه گردید که در برخی از آن‌ها نتایج بهتری بدست آمده است.

در واقع به جای آخرین لایه یک شبکه، یک لایه ReDense اضافه شده تا عملکرد شبکه را همان‌طور که در شکل ۴ نشان داده شده است، بهبود بخشد. در این حالت، ترکیبی از وزن‌های تصادفی و توابع فعال‌ساز ReLU استفاده شده است تا از نظر تئوری کاهش زمان آموزش تضمین گردد. مشابه فناوری‌های

معماری لایه‌های DenseNet169 یکی از معماری‌های خانواده DenseNet با ۱۶۹ لایه است و یک معماری پرکاربرد برای کارهای طبقه‌بندی یادگیری عمیق است. در مقایسه با معماری‌های DenseNet با لایه‌های کمتر، پارامترهای آموزش‌پذیر بسیار کمتری دارد. DenseNet169 و دیگر معماری‌های DenseNet توانایی غلبه بر مشکل ناپدید شدن گرادیان را دارند، استراتژی انتشار ویژگی قوی دارند، تعداد پارامترهای قابل آموزش را به حداقل می‌رسانند و استفاده مجدد از ویژگی‌ها را تشویق می‌کنند، بنابراین آنها به خانواده‌ای از معماری‌های DL بسیار قابل اعتماد تبدیل شدند.

مدل‌های DenseNet را می‌توان در Keras (Tensorflow) و PyTorch پیدا کرد. معماری شامل لایه‌های کانولوشن، لایه‌های maxpool، لایه‌های متراکم (fully connected layers) و لایه‌های انتقال است. لایه‌های کانولوشن ویژگی‌های موجود در تصویر را استخراج می‌کنند و لایه‌های maxpool ابعاد ورودی‌های خود را کاهش می‌دهند. لایه‌های متصل از لایه مسطح پیروی می‌کنند که به عنوان یک شبکه عصبی مصنوعی با ورودی آرایه منفرد از لایه مسطح عمل می‌کند [۲۷].

## ۶.۴. CtNet10

در این مدل ابتدا یک تصویر ورودی به اندازه  $128 \times 128 \times 3$  داده می‌شود. در مجموع ۴ بلوک کانولوشن وجود دارد. از ۲ بلوک کانولوشن با ابعاد  $124 \times 124 \times 32$ ،  $126 \times 126 \times 32$  عبور می‌کند. سپس از یک تجمع حداکثری با ابعاد  $62 \times 62 \times 32$  و به دنبال آن ۲ لایه کانولوشن با ابعاد  $60 \times 60 \times 32$ ،  $58 \times 58 \times 32$  عبور می‌کند و بیشتر از طریق یک لایه ترکیبی به ابعاد  $29 \times 29 \times 32$  عبور داده می‌شود. سپس از میان ۲۶۹۱۲ نورون لایه مسطح عبور داده می‌شود، که بیشتر از لایه‌های متراکم و رها شده تشکیل شده و از هر کدام ۲۵۶ نورون عبور می‌کند. پس از عبور آن از یک نورون منفرد از یک لایه متراکم، تصاویر سی‌تی‌اسکن به عنوان COVID-19 مثبت یا منفی طبقه‌بندی می‌شوند (شکل ۵) [۲].

لایه Dense به دقت‌های Train=0.99 و Test=0.9197 دست یافت.


همان‌گونه که نتایج فوق نشان می‌دهد افزودن لایه‌های Dense باعث بهبود عملکرد معماری شده است. حال سوال اینجاست که چرا این ایده به ذهن ما رسید؟ در پاسخ باید گفت زمان اجرای معماری‌های یادگیری عمیق زیاد است هر چه تعداد لایه‌ها کاهش یابد بهتر است. برای مثال در خیلی از کاربردها دیده شده است که وقتی با VGG19 به جواب ایده‌آل نرسیدند بدنیاال مدل پیچیده‌تر مانند ResNet50 یا

DenseNet169 هستند؛ بنابراین تعداد لایه از ۱۹ به ۵۰ یا ۱۶۹ افزایش می‌یابد که آموزش را زمان‌برتر می‌سازد. اکنون شاید بتوان گفت بهتر است قبل از روی آوردن به مدل‌های پیچیده‌تر، افزودن یک یا دو لایه Dense یا تمام متصل را تست کنید شاید با توجه به کاربرد بتوان جواب بهتری بدست آورد. در ادامه حالت‌های دیگری که معماری‌ها و اثر افزودن لایه تمام متصل را تست می‌کند آورده شده است.

برای مجموعه داده اول با تابع فعال‌ساز sigmoid و تعداد تکرار ۵۰، اثر افزودن دو لایه Dense با ۴۰۹۶ و ۱۰۷۲ نورون به هر معماری در زیر آورده شده است:

- مدل پایه معماری VGG16 به ترتیب به دقت‌های Train=0.9 و Test=0.8916 دست یافت که با اضافه کردن دو لایه Dense به دقت‌های Train=0.94 و Test=0.9115 رسید.
- مدل پایه معماری VGG19 به ترتیب به دقت‌های Train=0.88 و Test=0.8614 دست یافت که با اضافه کردن دو لایه Dense به دقت‌های Train=0.9 و Test=0.8735 رسید.
- مدل پایه معماری Inception v3 به ترتیب به دقت‌های Train=1 و Test=0.99 دست یافت که با افزودن دو لایه Dense به دقت‌های Train=0.99 و Test=0.9578 دست یافت.

یادگیری انتقال، تمام لایه‌های قبلی شبکه فریز می‌شود و فقط لایه ReDense آموزش می‌بیند تا زمان آموزش کمتری حاصل شود [۲۸].



شکل (۶): تصویرسازی آموزش ReDense [۲۵]

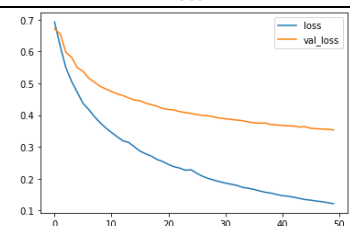
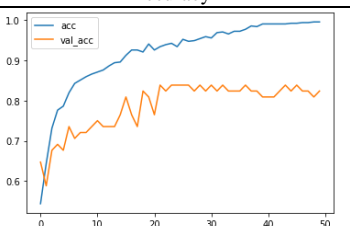
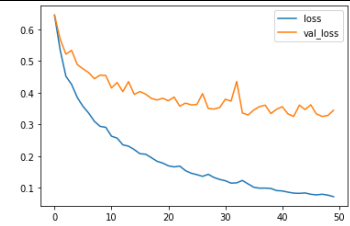
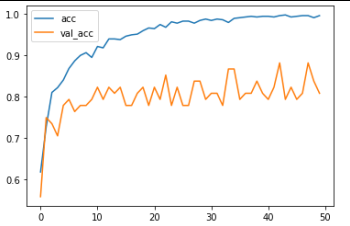
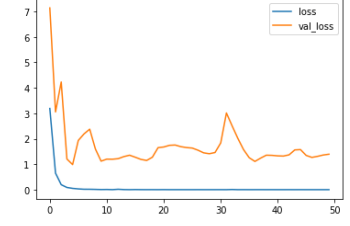
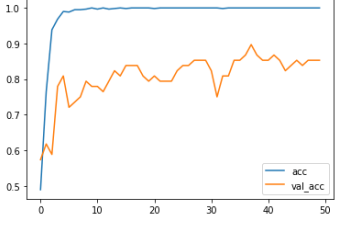
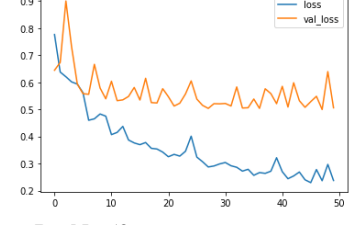
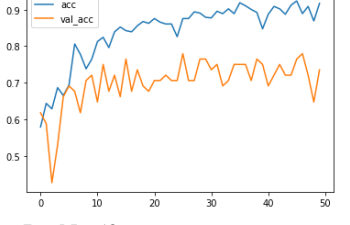
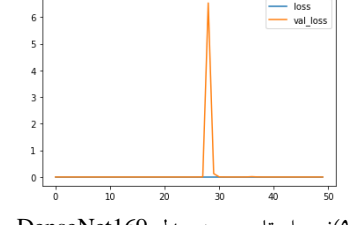
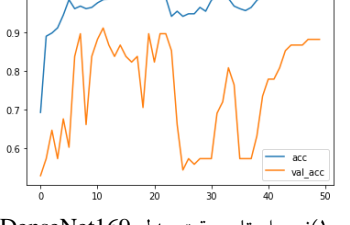
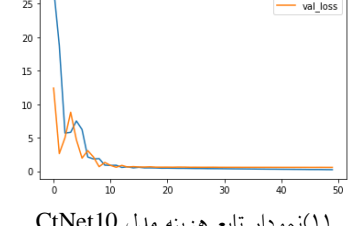
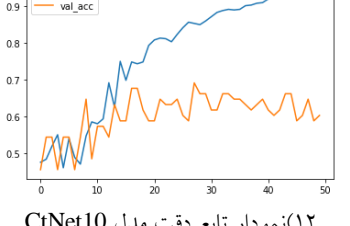
برای مجموعه داده اول با تابع فعال‌ساز softmax و تعداد تکرار ۱۰۰، اثر افزودن دو لایه Dense با ۴۰۹۶ و ۱۰۷۲ نورون به هر معماری در زیر آورده شده است:

- مدل پایه معماری VGG16 به ترتیب به دقت‌های Train=0.8835 و Test=0.93 دست یافته است که با افزودن دو لایه Dense به دقت‌های Train=0.95 و Test=0.9076 دست یافت.
- مدل پایه معماری VGG19 به ترتیب به دقت‌های Train=0.91 و Test=0.8695 دست یافته است که با افزودن دو لایه Dense به دقت‌های Train=0.93 و Test=0.9036 دست یافت.
- مدل پایه معماری Inception v3 به ترتیب به دقت‌های Train=1 و Test=0.99 دست یافته است که با افزودن دو لایه Dense به دقت‌های Train=0.99 و Test=0.9739 دست یافت.
- مدل پایه معماری ResNet50 به ترتیب به دقت‌های Train=0.99 و Test=0.95 دست یافته است که با اضافه کردن دو لایه Dense به دقت‌های Train=0.99 و Test=0.9598 دست یافت.
- مدل پایه معماری DenseNet169 به ترتیب به دقت‌های Train=0.99 و Test=0.98 دست یافته است که با اضافه کردن دو لایه Dense به دقت‌های Train=1 و Test=0.9980 دست یافت.

- مدل پایه معماری CtNet10 به ترتیب به دقت‌های Train=0.98 و Test=0.91 دست یافته است که با افزودن دو لایه Dense به دقت‌های Train=0.99 و Test=0.9578 دست یافت.

مدل	Train=0.98 و Test=0.91 دست یافته است که با افزودن دو لایه Dense به دقت‌های Train=0.99 و Test=0.9578 دست یافت.	
	Loss	Accuracy
VGG16 [2][14][17]	<p>(۱) نمودار تابع هزینه مدل VGG16</p>	<p>(۲) نمودار تابع دقت مدل VGG16</p>

جدول (۴): منحنی Loss و Accuracy برای مجموعه داده دوم

مدل	مجموعه داده اول	
	Loss	Accuracy
VGG16 [2][14] [17]	 <p>(۱) نمودار تابع هزینه مدل VGG16</p>	 <p>(۲) نمودار تابع دقت مدل VGG16</p>
VGG19 [2]	 <p>(۳) نمودار تابع هزینه مدل VGG19</p>	 <p>(۴) نمودار تابع دقت مدل VGG19</p>
Inception v3 [2]	 <p>(۵) نمودار تابع هزینه مدل Inception v3</p>	 <p>(۶) نمودار تابع دقت مدل Inception v3</p>
ResNet50 [2][14] [19]	 <p>(۷) نمودار تابع هزینه مدل ResNet50</p>	 <p>(۸) نمودار تابع دقت مدل ResNet50</p>
DenseNet 169 [2]	 <p>(۹) نمودار تابع هزینه مدل DenseNet169</p>	 <p>(۱۰) نمودار تابع دقت مدل DenseNet169</p>
CtNet10 [2]	 <p>(۱۱) نمودار تابع هزینه مدل CtNet10</p>	 <p>(۱۲) نمودار تابع دقت مدل CtNet10</p>

دولایه Dense با تعداد نورون‌های ۵۱۲ و ۲۵۶ به دقت‌های Train=0.98 و Test=0.8933 رسید و عملکرد معماری را بهبود بخشید.

• مدل پایه معماری CtNet10 به ترتیب به دقت‌های Train=0.91 و Test=0.7467 دست یافت که با اضافه کردن دولایه Dense با تعداد نورون‌های ۵۱۲ و ۲۵۶ به دقت‌های Train=0.91 و Test=0.7733 رسید و عملکرد معماری را بهبود بخشید.

برای مجموعه داده دوم نیز با تابع فعال‌ساز softmax و تعداد تکرار ۱۰۰ برای تمامی معماری‌های VGG16، VGG19، Inception v3، ResNet50، DenseNet169 و CtNet10 به ترتیب به دقت‌های Train=0.49 و Test=0.4286 دست یافت که با اضافه کردن دولایه Dense با تعداد نورون‌های ۴۰۹۶ و ۱۰۷۲ به دقت‌های Train=0.49 و Test=0.4286 دست یافت.

جهت مقایسه بهتر، در بخش نتایج تجربی، خلاصه نتایج فوق در قالب جدول‌های ۵ تا ۸ آورده شده است.

## ۲.۵. معماری پیشنهادی بر پایه یادگیری عمیق ترکیبی

مدل یادگیری ترکیبی پیشنهادی با ترکیب چندین مدل یادگیری عمیق، می‌تواند نتایج دقیق‌تر و بالاتری نسبت به یک مدل واحد تولید کند. معماری‌های استفاده شده در این پژوهش به تنهایی دقت نسبتاً مطلوبی دارند اما هدف بالا بردن دقت برای اغلب مجموعه داده‌هاست. جهت ترکیب مدل‌ها ابتدا باید مطمئن شد که چه مدل‌هایی برای ترکیب مناسب است. در راهکار پیشنهادی، Ensemble Deep Learning برای تشخیص COVID-19 ترکیب مدل‌های VGG16، ResNet50 و DenseNet169 از طریق یک استراتژی Ensemble بررسی می‌گردد. علت انتخاب VGG16 بجای VGG19 و انتخاب ResNet50 و DenseNet169 بجای Inception v3 ساده‌تر بودن ساختار آن‌ها و در نتیجه پیچیدگی کمتر مدل‌ها است.

بدلیل وجود نویز در داده‌های آموزشی و تصادفی بودن وزن‌ها در الگوریتم یادگیری عمیق، این شبکه‌ها معمولاً از مشکل واریانس بالا و خطای تعمیم رنج می‌برند. اگرچه برخی از تکنیک‌های رایج مانند افزایش داده‌ها و منظم‌سازی وجود

• مدل پایه معماری ResNet50 به ترتیب به دقت‌های Train=0.99 و Test=0.9558 دست یافت که با اضافه کردن دولایه Dense به دقت‌های Train=0.99 و Test=0.9618 رسید.

• مدل پایه معماری DenseNet169 به ترتیب به دقت‌های Train=1 و Test=0.992 دست یافته است که با افزودن دو لایه Dense به دقت‌های Train=0.91 و Test=0.8695 دست یافت.

• مدل پایه معماری CtNet10 به ترتیب به دقت‌های Train=0.98 و Test=0.8815 دست یافت که با اضافه کردن دولایه Dense با تعداد نورون‌های ۵۱۲ و ۲۵۶ به دقت‌های Train=0.98 و Test=0.8936 دست یافت و عملکرد معماری را بهبود بخشید.

برای مجموعه داده دوم نیز با تابع فعال‌ساز sigmoid و تعداد تکرار ۵۰ بهبودهای زیر حاصل شده است:

• مدل پایه معماری VGG16 به ترتیب به دقت‌های Train=0.97 و Test=0.8933 دست یافت که با اضافه کردن دولایه Dense با تعداد نورون‌های ۴۰۹۶ و ۱۰۷۲ به دقت‌های Train=0.99 و Test=0.92 دست یافت.

• مدل پایه معماری VGG19 به ترتیب به دقت‌های Train=0.98 و Test=0.8933 دست یافت که با اضافه کردن دولایه Dense با تعداد نورون‌های ۴۰۹۶ و ۱۰۷۲ به دقت‌های Train=0.99 و Test=0.8933 رسید.

• مدل پایه معماری Inception v3 به ترتیب به دقت‌های Train=0.96 و Test=0.9067 دست یافت که با اضافه کردن دولایه Dense با تعداد نورون‌های ۴۰۹۶ و ۱۰۷۲ به دقت‌های Train=0.97 و Test=0.9467 رسید.

• مدل پایه معماری ResNet50 به ترتیب به دقت‌های Train=0.94 و Test=0.8133 دست یافت که با اضافه کردن دولایه Dense با تعداد نورون‌های ۵۱۲ و ۲۵۶ به دقت‌های Train=0.8 و Test=0.7333 رسید و عملکرد معماری را بهبود بخشید.

• مدل پایه معماری DenseNet169 به ترتیب به دقت‌های Train=0.99 و Test=0.9333 دست یافت که با اضافه کردن

- ۳- تغییراندازه تصاویر به  $224 \times 224$ .
- ۴- مجموعه نمونه‌های Train، Test و Validation ایجاد می‌شوند.
- ۵- طبقه‌بندهای جداگانه VGG16، ResNet50 و DenseNet169 با پیش آموزش شبکه از طریق یادگیری انتقال تولید می‌شوند.
- ۶- فراخوانی طبقه‌بندی‌کننده Ensemble. استفاده از روش رای‌گیری اکثریت نسبی برای ادغام سه طبقه‌بند جداگانه. شکل ۷ نمودار جریان الگوریتم را نشان می‌دهد.

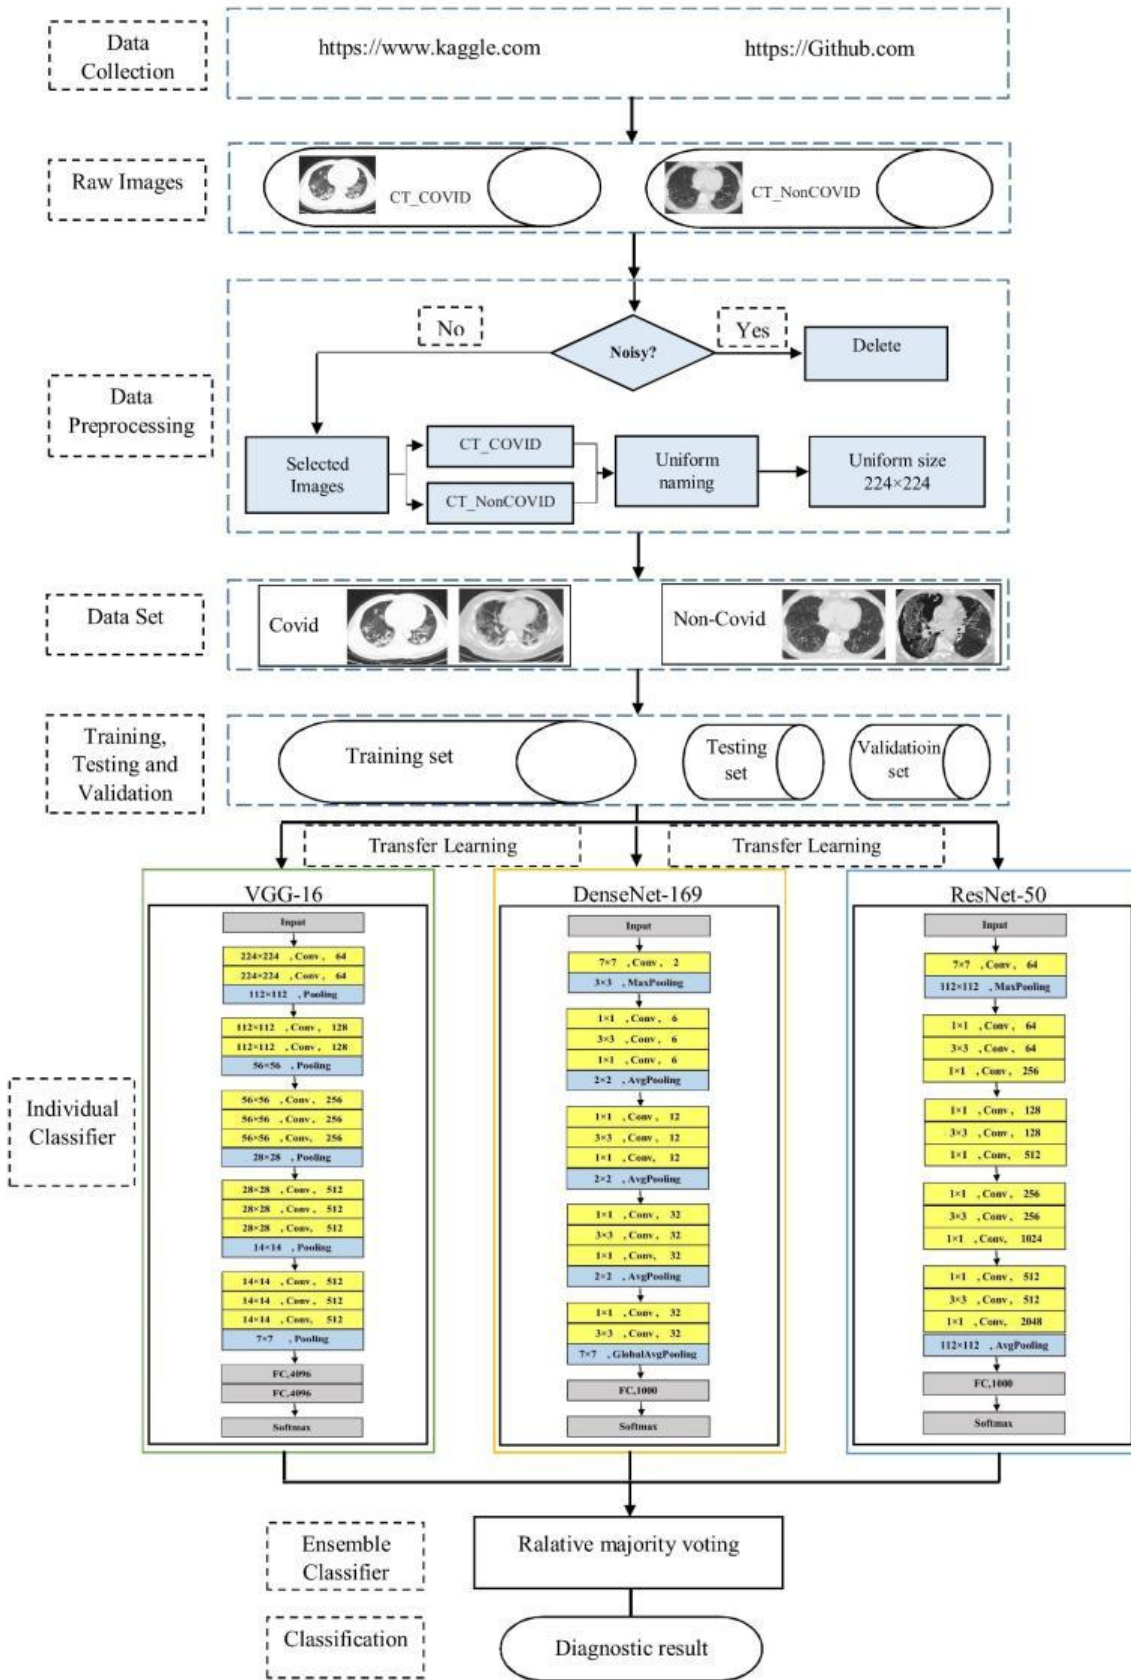
## ۶. نتایج تجربی

همان‌گونه که ذکر شد کارایی دو راهکار پیشنهادی این پژوهش بر روی دو مجموعه داده دریافتی از پایگاه داده‌های Kaggle و Github بررسی و با معماری‌های از پیش تعلیم داده شده مقایسه گشته است. لازم به ذکر است، ما مدل‌های پایه‌ای که در تحقیقات [۲، ۱۴، ۱۷، ۱۹] استفاده شده‌اند را مجدد پیاده‌سازی و بر روی مجموعه داده‌های خودمان تست نمودیم. سپس روش پیشنهادی Add Denselayer خود را با آنها مقایسه نمودیم که نتایج در جدول‌های ۵ تا ۸ آورده شده است.

دارد، اما مشکلات هنوز به خوبی برای مدل‌های یادگیری عمیق حل نشده‌اند. برای غلبه بر این مشکلات برای یک مدل یادگیری ماشین واحد، Ensemble learning به عنوان یک رویکرد موثر فرض می‌شود. این یک الگوی یادگیری ترکیبی است که قادر است با ترکیب هوشمندانه چندین مدل یادگیری ماشین، نتایج پیش بینی دقیق تر و قوی تری نسبت به یک مدل واحد تولید کند. استراتژی‌های Ensemble مختلفی از جمله random، averaging، boosting، forest و stacking در دسترس هستند [۶].

این پژوهش یک مدل یادگیری عمیق Ensemble را برای تشخیص COVID-19 بر روی تصاویر CT پیشنهاد می‌کند. نمای کلی مدل به شرح زیر است:

- ۱- جمع‌آوری داده‌ها. مجموعه داده اول شامل ۲۴۸۱ تصویر سی‌تی اسکن ریه و مجموعه داده دوم شامل ۷۴۶ تصویر سی‌تی اسکن ریه افراد است.
- ۲- دسته‌بندی تصاویر سی‌تی اسکن. مجموعه داده اول که خود به دو بخش COVID با ۱۲۵۲ سی‌تی اسکن مثبت برای عفونت (COVID-19) SARS-CoV-2 و NON-COVID با ۱۲۲۹ سی‌تی اسکن برای بیماران غیر آلوده به SARS-CoV-2 تقسیم می‌شود. مجموعه داده دوم نیز تصاویر به دو بخش COVID با ۳۴۹ تصویر CT مثبت برای COVID-19 متعلق به ۲۱۶ بیمار و ۳۹۷ تصویر CT که برای COVID-19 منفی است.



شکل (۷): نمودار جریان الگوریتم مدل یادگیری عمیق ترکیبی

در جدول ۷ نیز، نتایج حاصل از اجرا بر روی مجموعه داده اول با ۵۰ تکرار مشاهده می‌شود. با توجه به پارامترهای استفاده شده نتایج نشان می‌دهد که کارایی مدل VGG16 و VGG19 با افزودن لایه Dense برای Train و Test دقت کمتری بدست می‌آورد. برای مدل Inception v3 و DenseNet169 با افزودن لایه Dense برای Train و Test دقت کمتری بدست آمده است. برای مدل ResNet50 و CtNet10 برای Train دقت تغییری نکرده اما برای Test دقت بیشتر شده است.

طبق جدول ۸، نتایج حاصل از اجرا بر روی مجموعه داده دوم نیز با توجه به پارامترهای استفاده شده نشان می‌دهد که کارایی مدل VGG16، VGG19 و Inception v3 با افزودن لایه Dense برای Train و Test دقت کمتری بدست می‌آورد. برای مدل‌های ResNet50 و DenseNet169 با افزودن لایه Dense برای Train و Test دقت کمتر شده است. برای مدل CtNet10 با افزودن لایه Dense برای Train دقت تغییری نکرده و برای Test دقت بهتر شده است.

همانطور که در جدول ۵ مشاهده می‌کنید، نتایج حاصل از اجرا بر روی مجموعه داده اول با توجه به پارامترهای استفاده شده نشان می‌دهد که کارایی مدل VGG16 با افزودن لایه Dense برای Train بهتر شده اما برای Test دقت کمتری بدست آمده است. برای مدل VGG19 با افزودن لایه Dense برای Train و Test دقت کمتری بدست آمده است. برای مدل Inception v3 با افزودن لایه Dense برای Train و Test دقت کمتری بدست آمده است. برای مدل ResNet50 دقت برای Train و Test تغییری نکرده است. برای مدل DenseNet169 دقت برای Train و Test دقت بیشتر شده است. برای مدل CtNet10 دقت برای Train بیشتر شده اما برای Test دقت تغییری نکرده است.

با توجه به جدول ۶، نتایج حاصل از اجرا بر روی مجموعه داده دوم با پارامترهای بکارگرفته شده نشان می‌دهد که در کارایی تمامی مدل‌ها با افزودن لایه Dense برای Train مقدار دقت ۰,۴۹ و برای Test نیز مقدار دقت ۰,۴۲۸۶ تکرار شده است.

این امر نشان می‌دهد که افزودن لایه Dense در همه کاربردها و مجموعه داده‌ها راهگشا نیست لذا در بخش ۵-۱ نیز ذکر شده است با توجه به کاربرد شاید بتوان نتایج را بهتر کرد.

جدول (۵): مقایسه مدل‌های شبکه عصبی عمیق پایه و افزودن لایه تمام متصل بر اساس پارامترهای epoch=100, optimizer=adam,

Activation=softmax روی مجموعه داده اول

معماری‌های پایه					added Dense layer پیشنهادی							
Model	Train	Time	Test	Time	Confusion Matrix		Train	Time	Test	Time	Confusion Matrix	
					Train	Test					Train	Test
VGG16 [2][14] [17]	0.883	5s	0.93	11s	[943 49 89 911]	[221 25 33 219]	0.95	11s	0.91	4s	[944 47 47 954]	[225 22 24 227]
VGG19 [2]	0.91	12s	0.87	3s	[874 118 60 940]	[204 42 23 229]	0.93	12s	0.90	3s	[913 78 58 943]	[217 30 18 233]
Inception v3 [2]	1	5s	99	2s	[989 3 5 995]	[243 3 2 250]	0.99	5s	0.97	2s	[990 1 11 990]	[245 2 11 240]
ResNet50 [2][14] [19]	0.99	6s	0.95	2s	[984 8 14 986]	[234 12 12 240]	0.99	6s	0.96	2s	[982 9 17 984]	[235 12 8 243]
DenseNet 169 [2]	0.99	8s	0.98	4s	[985 7 6 994]	[241 5 4 248]	1	8s	0.99	4s	[989 2 3 998]	[246 1 0 251]
CtNet10 [2]	0.98	1s	0.91	39ms	[998 18 18 984]	[109 8 14 118]	0.99	1s	0.92	18ms	[998 8 12 990]	[108 9 11 121]

جدول(۶): مقایسه مدل‌های شبکه عصبی عمیق پایه و افزودن لایه تمام متصل بر اساس پارامترهای **epoch=100, optimizer=adam**

روشنی پیشنهادی **Activation=softmax** روی مجموعه داده دوم

معماری‌های پایه					روشنی پیشنهادی added Dense layer							
Model	Train	Time	Test	Time	Confusion Matrix		Train	Time	Test	Time	Confusion Matrix	
					Train	Test					Train	Test
VGG16 [2][14][17]	0.49	5s	0.43	4s	$\begin{bmatrix} 0 & 353 \\ 0 & 334 \end{bmatrix}$	$\begin{bmatrix} 0 & 44 \\ 0 & 33 \end{bmatrix}$	0.49	5s	0.43	5s	$\begin{bmatrix} 0 & 353 \\ 0 & 334 \end{bmatrix}$	$\begin{bmatrix} 0 & 44 \\ 0 & 33 \end{bmatrix}$
VGG19 [2]	0.49	4s	0.43	1s	$\begin{bmatrix} 0 & 353 \\ 0 & 334 \end{bmatrix}$	$\begin{bmatrix} 0 & 44 \\ 0 & 33 \end{bmatrix}$	0.49	4s	0.43	1s	$\begin{bmatrix} 0 & 353 \\ 0 & 334 \end{bmatrix}$	$\begin{bmatrix} 0 & 44 \\ 0 & 33 \end{bmatrix}$
Inception v3 [2]	0.49	2s	0.43	2s	$\begin{bmatrix} 0 & 353 \\ 0 & 334 \end{bmatrix}$	$\begin{bmatrix} 0 & 44 \\ 0 & 33 \end{bmatrix}$	0.49	3s	0.43	2s	$\begin{bmatrix} 0 & 353 \\ 0 & 334 \end{bmatrix}$	$\begin{bmatrix} 0 & 44 \\ 0 & 33 \end{bmatrix}$
ResNet50 [2][14][19]	0.49	3s	0.43	1s	$\begin{bmatrix} 0 & 353 \\ 0 & 334 \end{bmatrix}$	$\begin{bmatrix} 0 & 44 \\ 0 & 33 \end{bmatrix}$	0.49	3s	0.43	1s	$\begin{bmatrix} 0 & 353 \\ 0 & 334 \end{bmatrix}$	$\begin{bmatrix} 0 & 44 \\ 0 & 33 \end{bmatrix}$
DenseNet169 [2]	0.49	4s	0.43	2s	$\begin{bmatrix} 0 & 353 \\ 0 & 334 \end{bmatrix}$	$\begin{bmatrix} 0 & 44 \\ 0 & 33 \end{bmatrix}$	0.49	4s	0.43	2s	$\begin{bmatrix} 0 & 353 \\ 0 & 334 \end{bmatrix}$	$\begin{bmatrix} 0 & 44 \\ 0 & 33 \end{bmatrix}$
CtNet10 [2]	0.49	17ms	0.43	62ms	$\begin{bmatrix} 0 & 353 \\ 0 & 334 \end{bmatrix}$	$\begin{bmatrix} 0 & 44 \\ 0 & 33 \end{bmatrix}$	0.49	13ms	0.43	58ms	$\begin{bmatrix} 0 & 353 \\ 0 & 334 \end{bmatrix}$	$\begin{bmatrix} 0 & 44 \\ 0 & 33 \end{bmatrix}$

جدول(۷): مقایسه مدل‌های شبکه عصبی عمیق پایه و افزودن لایه تمام متصل بر اساس پارامترهای **epoch=50, optimizer=adam**

روشنی پیشنهادی **Activation=sigmoid** روی مجموعه داده اول

معماری‌های پایه					روشنی پیشنهادی added Dense layer							
Model	Train	Time	Test	Time	Confusion Matrix		Train	Time	Test	Time	Confusion Matrix	
					Train	Test					Train	Test
VGG16 [2][14][17]	0.9	12s	0.892	5s	$\begin{bmatrix} 905 & 75 \\ 117 & 895 \end{bmatrix}$	$\begin{bmatrix} 231 & 27 \\ 27 & 213 \end{bmatrix}$	0.94	10s	0.912	4s	$\begin{bmatrix} 895 & 86 \\ 28 & 975 \end{bmatrix}$	$\begin{bmatrix} 219 & 29 \\ 15 & 234 \end{bmatrix}$
VGG19 [2]	0.88	13s	0.861	3s	$\begin{bmatrix} 880 & 100 \\ 133 & 879 \end{bmatrix}$	$\begin{bmatrix} 219 & 39 \\ 30 & 210 \end{bmatrix}$	0.9	13s	0.874	5s	$\begin{bmatrix} 868 & 107 \\ 93 & 924 \end{bmatrix}$	$\begin{bmatrix} 223 & 40 \\ 23 & 212 \end{bmatrix}$
Inception v3 [2]	1	5s	0.99	2s	$\begin{bmatrix} 977 & 3 \\ 4 & 1008 \end{bmatrix}$	$\begin{bmatrix} 257 & 1 \\ 4 & 236 \end{bmatrix}$	0.99	6s	0.958	2s	$\begin{bmatrix} 972 & 3 \\ 14 & 1003 \end{bmatrix}$	$\begin{bmatrix} 256 & 7 \\ 14 & 221 \end{bmatrix}$
ResNet50 [2][14][19]	0.99	7s	0.956	2s	$\begin{bmatrix} 960 & 20 \\ 4 & 1008 \end{bmatrix}$	$\begin{bmatrix} 242 & 16 \\ 6 & 234 \end{bmatrix}$	0.99	6s	0.962	2s	$\begin{bmatrix} 970 & 5 \\ 8 & 1009 \end{bmatrix}$	$\begin{bmatrix} 250 & 13 \\ 6 & 229 \end{bmatrix}$
DenseNet169 [2]	1	9s	0.992	4s	$\begin{bmatrix} 978 & 2 \\ 1 & 1011 \end{bmatrix}$	$\begin{bmatrix} 256 & 2 \\ 2 & 238 \end{bmatrix}$	0.91	8s	0.87	4s	$\begin{bmatrix} 971 & 4 \\ 185 & 832 \end{bmatrix}$	$\begin{bmatrix} 256 & 7 \\ 58 & 177 \end{bmatrix}$
CtNet10 [2]	0.98	1s	0.882	22ms	$\begin{bmatrix} 905 & 75 \\ 117 & 895 \end{bmatrix}$	$\begin{bmatrix} 242 & 16 \\ 43 & 197 \end{bmatrix}$	0.98	1s	0.894	1s	$\begin{bmatrix} 972 & 23 \\ 22 & 975 \end{bmatrix}$	$\begin{bmatrix} 219 & 29 \\ 15 & 234 \end{bmatrix}$

جدول(۸): مقایسه مدل‌های شبکه عصبی عمیق پایه و افزودن لایه تمام متصل بر اساس پارامترهای **epoch=50, optimizer=adam**

روشنی پیشنهادی **Activation=sigmoid** روی مجموعه داده دوم

معماری‌های پایه					روشنی پیشنهادی added Dense layer							
Model	Train	Time	Test	Time	Confusion Matrix		Train	Time	Test	Time	Confusion Matrix	
					Train	Test					Train	Test
VGG16 [2][14][17]	0.97	3s	0.893	122ms	$\begin{bmatrix} 355 & 8 \\ 11 & 297 \end{bmatrix}$	$\begin{bmatrix} 32 & 2 \\ 6 & 35 \end{bmatrix}$	0.99	6s	0.92	4s	$\begin{bmatrix} 357 & 6 \\ 2 & 306 \end{bmatrix}$	$\begin{bmatrix} 32 & 2 \\ 4 & 37 \end{bmatrix}$
VGG19 [2]	0.98	4s	0.893	1s	$\begin{bmatrix} 360 & 3 \\ 9 & 299 \end{bmatrix}$	$\begin{bmatrix} 32 & 2 \\ 6 & 35 \end{bmatrix}$	0.99	3s	0.893	1s	$\begin{bmatrix} 358 & 5 \\ 5 & 303 \end{bmatrix}$	$\begin{bmatrix} 31 & 3 \\ 5 & 36 \end{bmatrix}$
Inception v3 [2]	0.96	3s	0.907	2s	$\begin{bmatrix} 344 & 19 \\ 7 & 301 \end{bmatrix}$	$\begin{bmatrix} 30 & 4 \\ 3 & 38 \end{bmatrix}$	0.97	1s	0.947	71ms	$\begin{bmatrix} 346 & 17 \\ 3 & 305 \end{bmatrix}$	$\begin{bmatrix} 31 & 3 \\ 1 & 40 \end{bmatrix}$
ResNet50 [2][14][19]	0.94	3s	0.813	1s	$\begin{bmatrix} 348 & 15 \\ 27 & 281 \end{bmatrix}$	$\begin{bmatrix} 30 & 4 \\ 10 & 31 \end{bmatrix}$	0.8	2s	0.733	83ms	$\begin{bmatrix} 327 & 36 \\ 101 & 207 \end{bmatrix}$	$\begin{bmatrix} 31 & 3 \\ 17 & 24 \end{bmatrix}$
DenseNet169 [2]	0.99	2s	0.933	89ms	$\begin{bmatrix} 358 & 5 \\ 3 & 305 \end{bmatrix}$	$\begin{bmatrix} 31 & 3 \\ 2 & 39 \end{bmatrix}$	0.98	4s	0.893	2s	$\begin{bmatrix} 361 & 2 \\ 12 & 296 \end{bmatrix}$	$\begin{bmatrix} 32 & 2 \\ 6 & 35 \end{bmatrix}$
CtNet10 [2]	0.91	1s	0.747	11ms	$\begin{bmatrix} 335 & 28 \\ 33 & 275 \end{bmatrix}$	$\begin{bmatrix} 32 & 2 \\ 6 & 35 \end{bmatrix}$	0.91	11ms	0.773	11ms	$\begin{bmatrix} 308 & 55 \\ 6 & 302 \end{bmatrix}$	$\begin{bmatrix} 32 & 2 \\ 4 & 37 \end{bmatrix}$



برای Train دقت ۱ و برای Test دقت ۰,۹۷۹۹ بدست آمده است.

همانطور که در جدول ۱۰ ملاحظه می کنید، نتایج حاصل از اجرا بر روی مجموعه داده دوم کارایی معماری ترکیبی Ensemble پیشنهادی با بکارگیری تابع فعال ساز sigmoid، برای Train و Test دقت ۱ یا صد در صد را نشان می دهد. همچنین با تابع فعال ساز softmax، برای Train دقت ۰,۹۸۱۲ و برای Test دقت ۰,۹۶۸۸ بدست آمده است.

در جدول های ۵ تا ۸ مشاهده گردید که کارایی مدل های شبکه عصبی عمیق با افزودن لایه های Dense برای برخی حالات بهتر و برای برخی کمتر شده است. از آنجایی که این پژوهش به دنبال راهکاری است که در اغلب حالات جواب مطلوبی بدست آورد طرح یادگیری عمیق ترکیبی پیشنهاد شد. نتایج حاصل از ترکیب مدل های VGG16، ResNet50 و DenseNet169 در ادامه آورده شده است.

طبق جدول ۹، نتایج حاصل از اجرا بر روی مجموعه داده اول کارایی معماری ترکیبی Ensemble پیشنهادی با بکارگیری تابع فعال ساز softmax، برای Train دقت ۱ و برای Test دقت ۰,۹۹۶۰ را نشان می دهد. همچنین با تابع فعال ساز sigmoid،

جدول (۹): مقایسه نتایج اجرای مدل ترکیبی پیشنهادی (Ensemble) بر روی مجموعه داده اول

Model	Train	Time	Test	Time	Confusion Matrix		Parameters
					Train	Test	
مدل [15]	-	-	0.9075	-	-	-	-
روش ترکیبی پیشنهادی	1	20s	0.9960	14s	$\begin{bmatrix} 988 & 0 \\ 0 & 1020 \end{bmatrix}$	$\begin{bmatrix} 119 & 1 \\ 0 & 129 \end{bmatrix}$	vgg16, DenseNet169, ResNet50, activation='softmax', epoch=100
(Ensemble)	1	20s	0.9799	13s	$\begin{bmatrix} 989 & 0 \\ 0 & 1019 \end{bmatrix}$	$\begin{bmatrix} 122 & 0 \\ 5 & 122 \end{bmatrix}$	vgg16, DenseNet169, ResNet50, activation='sigmoid', epoch=100

جدول (۱۰): مقایسه نتایج اجرای مدل ترکیبی پیشنهادی (Ensemble) بر روی مجموعه داده دوم

Model	Train	Time	Test	Time	Confusion Matrix		Parameters
					Train	Test	
مدل [15]	-	-	0.8473	-	-	-	-
روش ترکیبی پیشنهادی	1	23s	1	2s	$\begin{bmatrix} 958 & 0 \\ 0 & 854 \end{bmatrix}$	$\begin{bmatrix} 120 & 0 \\ 0 & 104 \end{bmatrix}$	vgg16, DenseNet169, ResNet50, activation='sigmoid', epoch=100
(Ensemble)	0.9812	20s	0.9688	3s	$\begin{bmatrix} 958 & 0 \\ 34 & 820 \end{bmatrix}$	$\begin{bmatrix} 120 & 0 \\ 7 & 97 \end{bmatrix}$	vgg16, DenseNet169, ResNet50, activation='softmax', epoch=100

بطوریکه در مجموعه داده دوم که افزودن لایه Dense مطلوب نبود مدل ترکیبی توانست به نتایج بالاتر و حتی دقت نزدیک به صد در صد دست یابد. نکته قابل توجه آن است که در تشخیص های پزشکی سلامت بیمار و صحت نتایج آزمایش ها از اهمیت بالایی برخوردار است. لذا هر چقدر دقت مدل های حاصل از الگوریتم های هوش مصنوعی بیشتر باشد احتمال خطا

همان گونه که نتایج جدول های ۹ و ۱۰ نشان می دهند<sup>۱</sup> ترکیب مدل ها توانسته است اثر بهبود بیشتری داشته باشد

<sup>۱</sup> نتایج تحقیق [۱۵] در جدول های ۹ و ۱۰ عینا برداشت شده است، زیرا مجموعه داده ها یکسان است. لازم به ذکر است فقط مقدار دقت داده تست در تحقیق ذکر شده و بقیه معیارها ذکر نشده است.

راهکارهای به نسبت کمتری در آن ارائه شده است و هنوز جای کار برای افزایش دقت شناسایی دارد، پردازش تصاویر سی تی اسکن ریه است.

این پژوهش بر اساس تحقیقات، اقدام به انتخاب معماری‌های برتر یادگیری عمیق در زمینه پردازش تصویر نمود و به پیاده‌سازی و بررسی نتایج حاصل از مدل‌های VGG16، VGG19، Inception v3، ResNet50، DenseNet169 و CtNet10 بر روی دو مجموعه داده از تصاویر سی تی اسکن ریه افراد که از سایت Kaggle و GitHub استخراج شده است پرداخت. جهت بهبود عملکرد روش‌های یادگیری عمیق ذکر شده ابتدا دو لایه Dense به انتهای هر یک از معماری‌های یادگیری عمیق فوق افزوده شد و اثر کارایی آن بررسی گردید. سپس راهکار ترکیبی نوینی بر پایه یادگیری عمیق جهت پردازش تصاویر سی تی اسکن ارائه شد.

بر اساس نتایج تجربی می‌توان گفت استفاده از راهکار ترکیبی یادگیری عمیق می‌تواند در شناسایی کووید-۱۹ به دقت بالاتر از ۹۸ درصد و حتی صد در صد دست یابد. این امر بیانگر آن است که استفاده از راهکارهای ترکیبی یادگیری عمیق در کارهایی همچون پردازش تصاویر پزشکی که نیازمند دقت بالایی است مفید خواهد بود زیرا سربار زمانی قابل ملاحظه‌ای ایجاد نمی‌کند اما می‌تواند به دقت بالاتری دست یابد که در تشخیص بیماری‌ها به پزشکان کمک بیشتری می‌نماید.

## مراجع

- [1] Zhao W., Jiang W., and Qiu X., "Deep learning for COVID-19 detection based on CT images." *Scientific Reports*, Vol.11, No.1, pp. 1-12, 2021.
- [2] Shah V., et al., "Diagnosis of COVID-19 using CT scan images and deep learning techniques." *Emergency radiology*, Vol.28, pp. 497-505, 2021.
- [3] Kaheel H., Hussein A., and Chehab A., "AI-based image processing for COVID-19 detection in chest CT scan images." *Frontiers in Communications and Networks*, Vol.2, p. 645040, 2021.
- [4] Safdarian N., and Jafarnia Dabanloo N., "Detection and classification of COVID-19 by lungs computed tomography scan image processing using intelligence algorithm." *Journal of Medical Signals and Sensors*, Vol.11, No.4, p. 274, 2021.
- [5] Silva P., et al., "COVID-19 detection in CT images with deep learning: A voting-based scheme and cross-datasets analysis." *Informatics in medicine unlocked*, Vol.20, pp. 100427, 2020.
- [6] Tang S., et al., "EDL-COVID: ensemble deep learning for COVID-19 case detection from chest x-ray images." *IEEE*

کمتر می‌گردد و امید است که در تسریع تشخیص و عملکرد درمانی پزشکان مفید واقع گردد.

بطور خلاصه می‌توان گفت معماری DenseNet169 برای مجموعه داده اول با دقت Train ۱ و دقت Test ۰,۹۹۲ و برای مجموعه داده دوم با دقت Train ۰,۹۹ و دقت Test ۰,۹۳۳۳ کارایی بهتری داشت. سپس جهت ارائه پیشنهاد با اضافه کردن دو لایه Dense با تعداد نوروں‌های متفاوت به هر کدام از معماری‌ها سعی بر افزایش و ارتقاء دقت نتایج بدست آمده شد و در انتها معماری DenseNet169 برای مجموعه داده اول با دقت Train ۱ و دقت Test ۰,۹۹۸۰ و معماری VGG16 برای مجموعه داده دوم با دقت Train ۰,۹۹ و دقت Test ۰,۹۲ کارایی بهتری داشت.

مدل ترکیبی پیشنهادی این پژوهش با استفاده از مدل Ensemble که ترکیبی از مدل‌های VGG16، ResNet50 و DenseNet169 است به نتایج بهتری دست یافت. پس از پیاده‌سازی مدل ترکیبی بر روی مجموعه داده اول با استفاده از تابع فعال‌ساز softmax برای Train به دقت ۱ و برای Test به دقت ۰,۹۹۶ و برای مجموعه داده دوم با استفاده از تابع فعال‌ساز sigmoid برای Train و Test به دقت ۱ دست یافت. بنابراین، پژوهش حاضر بر اساس نتایج تجربی بدست آمده استفاده از راهکار یادگیری عمیق ترکیبی را جهت پردازش تصاویر سی تی اسکن ریه در تشخیص بیماری کووید-۱۹ پیشنهاد می‌کند زیرا با مجموعه داده‌هایی که توزیع نمونه‌های متفاوتی داشتند بهبود عملکرد را نشان داد، که این می‌تواند به عنوان مزیت راهکارهای مبتنی بر یادگیری عمیق ترکیبی ذکر شود.

همچنین از آنجایی که از مدل‌های از پیش تعلیم داده شده استفاده می‌گردد اجرای راهکار پیشنهادی یادگیری عمیق ترکیبی از نظر زمانی سربار قابل ملاحظه‌ای تولید نمی‌کند و افزایش دقت آن اثر بارز و مطلوب‌تری در تشخیص بیماری خواهد داشت.

## ۷. نتیجه‌گیری

از سال ۲۰۱۹ تا کنون راهکارهای مختلفی جهت شناسایی بیماری کووید-۱۹ ارائه شده است. یکی از زمینه‌هایی که

- [23] Haque K.F., and Abdelgawad A., "A deep learning approach to detect COVID-19 patients from chest X-ray images." *AI*, Vol.1, No.3, p. 27, 2020.
- [24] Zhao J., et al. "Covid-ct-dataset: a ct scan dataset about covid-19.", 2020.
- [25] Demir A., Yilmaz F., and Kose O., "Early detection of skin cancer using deep learning architectures: resnet-101 and Inception v3." *2019 medical technologies congress (TIPEKNO)*, IEEE, 2019.
- [26] Mukti I.Z., and Biswas D., "Transfer learning based plant diseases detection using ResNet50." *2019 4th International conference on electrical information and communication technology (EICT)*. IEEE, 2019.
- [27] Vulli A., et al. "Fine-tuned DenseNet169 for breast cancer metastasis prediction using FastAI and 1-cycle policy." *Sensors*, Vol.22, No.8, p. 2988, 2022.
- [28] Javid A.M., et al. "A relu dense layer to improve the performance of neural networks." *ICASSP 2021-2021 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, IEEE, 2021.
- [7] Polsinelli M., Cinque L., and Placidi G., "A light CNN for detecting COVID-19 from CT scans of the chest." *Pattern recognition letters*, Vol.140, pp. 95-100, 2020.
- [8] Soares E., et al., "SARS-CoV-2 CT-scan dataset: A large dataset of real patients CT scans for SARS-CoV-2 identification." *MedRxiv*, pp. 2020-04, 2020.
- [9] Celik G., "Detection of Covid-19 and other pneumonia cases from CT and X-ray chest images using deep learning based on feature reuse residual block and depthwise dilated convolutions neural network." *Applied Soft Computing*, Vol.133, p.109906, 2023.
- [10] Gupta K., and Varun B., "Deep learning models-based CT-scan image classification for automated screening of COVID-19." *Biomedical Signal Processing and Control*, Vol.80, p.104268, 2023.
- [11] Suganya D., and Kalpana R., "Automated Detection of Covid-19 Waves with Computerized Tomography Scan Using Deep Learning." *Sustainable Computing: Transforming Industry 4.0 to Society 5.0*. Cham: Springer International Publishing, pp. 49-67, 2023.
- [12] Alliou H., Mourdi Y., and Sadgal M., "Strong semantic segmentation for Covid-19 detection: Evaluating the use of deep learning models as a performant tool in radiography." *Radiography*, Vol.29, No.1, pp. 109-118, 2023.
- [13] Ahmed I., Chehri A., and Jeon G., "A Sustainable Deep Learning-Based Framework for Automated Segmentation of COVID-19 Infected Regions: Using U-Net with an Attention Mechanism and Boundary Loss Function." *Electronics*, Vol.11, No.15, p. 2296, 2022.
- [14] Yang D., et al., "Detection and analysis of COVID-19 in medical images using deep learning techniques." *Scientific Reports*, Vol.11, No.1, p. 19638, 2021.
- [15] Jangam E., Barreto A.A.D, and Annavarapu C.S.R., "Automatic detection of COVID-19 from chest CT scan and chest X-Rays images using deep learning, transfer learning and stacking." *Applied Intelligence*, pp.1-17, 2022.
- [16] Choudhary T., et al., "Deep learning-based important weights-only transfer learning approach for COVID-19 CT-scan classification." *Applied Intelligence* 53.6 (2023): 7201-7215.
- [17] Kogilavani S.V., et al., "COVID-19 detection based on lung CT scan using deep learning techniques." *Computational and Mathematical Methods in Medicine 2022*, 2022.
- [18] Singh V.K., and Kolekar M.H., "Deep learning empowered COVID-19 diagnosis using chest CT scan images for collaborative edge-cloud computing platform." *Multimedia Tools and Applications*, Vol.81, No.1, pp. 3-30, 2022.
- [19] Serte S., and Demirel H., "Deep learning for diagnosis of COVID-19 using 3D CT scans." *Computers in biology and medicine*, Vol.132, p.104306, 2021.
- [۲۰] اکرمی ع، پارسامنش م، بررسی یک مدل اپیدمیک فازی ریاضی برای انتشار ویروس کرونا در یک جمعیت، *محاسبات نرم*، ۱۱(۱)، صص. ۲-۹، ۱۴۰۱. doi:10.22052/scj.2022.246053.1045
- [۲۱] یداللهی ا. ح، صباغیان بیدگلی ح، ارائه مدلی برای شبیه‌سازی انتشار ویروس کوید-۱۹ بر اساس زنجیره مارکوف گسسته زمان، *محاسبات نرم*، (۰)، ۱۴۰۲. doi: 10.22052/scj.2023.246527.1076
- [۲۲] موسوی م، حسینی س، امیدی م، الگوریتم شبکه عصبی عمیق بهبود یافته برای شناسایی بیماری کوید-۱۹ در اینترنت اشیا، *محاسبات نرم*، (۰)، ۱۴۰۲. doi: 10.22052/scj.2023.248686.1117