



University of Kashan

مجله محاسبات نرم

SOFT COMPUTING JOURNAL

تارنمای مجله: scj.kashanu.ac.ir



ارائه راهکاری بر پایه یادگیری عمیق ترکیبی جهت بهبود دقت شناسایی تصاویر سی تی اسکن ریه بیماران کووید-۱۹*

مهدی سرچاهی^۱، دانشجوی کارشناسی ارشد، الهام مهدی پور^{۱*}، استادیار

^۱ گروه مهندسی کامپیوتر، موسسه آموزش عالی خاوران، مشهد، ایران.

چکیده

اطلاعات مقاله

تاریخچه مقاله:

دریافت ۱ تیر ماه ۱۴۰۲

پذیرش ۹ شهریور ماه ۱۴۰۲

کلمات کلیدی:

کرونا ویروس

شبکه عصبی عمیق

کانولوشن

یادگیری عمیق ترکیبی

سی تی اسکن

بیماری کرونا ویروس ۲۰۱۹ یا کووید-۱۹، بیماری عفونی است که بر اثر ویروس سندروم حاد تنفسی (SARS-CoV-2) ایجاد می شود و به صورت 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 علایم 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 به دست 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 است. در این راستا، از دو مجموعه داده تصاویر سی تی اسکن ریه افراد که از داده های Kaggle و GitHub به دست 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 به طور قابل توجهی عملکرد شبکه های عصبی عمیق را در کارهای پیش بینی دو یا چند دسته ای بهبود بخشد.

© ۱۴۰۲ نویسندگان. مقاله با دسترسی آزاد تحت مجوز CC-BY

۱. مقدمه

ناشناخته در وهان چین سرچشمه می گرفت. 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 کرونا ویروس ۲۰۱۹ (COVID-19) نامیده شد [۱].

شایع ترین علایم در این بیماری شامل تب، خستگی، سرفه

سال ۲۰۱۹ شاهد شیوع یک ذات الریه ویروسی بود که از منبعی

* نوع مقاله: پژوهشی

* نویسنده مسئول

پست(های) الکترونیک: sm2249@yahoo.com (سرچاهی)

mahdipour_e@khavaran.ac.ir (مهدی پور)

نحوه ارجاع به مقاله: مهدی سرچاهی و الهام مهدی پور، «ارائه راهکاری بر پایه یادگیری عمیق ترکیبی جهت بهبود دقت شناسایی تصاویر سی تی اسکن ریه بیماران کووید-۱۹»، مجله محاسبات نرم، جلد ۱۲، شماره ۱، صفحات ۳۹-۲۰، بهار و تابستان ۱۴۰۳.

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 برای 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 کووید-۱۹ و غیر کووید-۱۹ در یک مجموعه داده با ۷۳۸ تصویر سی‌تی‌اسکن با استفاده از روش‌های مختلف یادگیری عمیق تمرکز بر یک مدل به نام CtNet10 برای تشخیص کووید-۱۹ طراحی شده است که دقت آن ۸۲/۱٪ است. همچنین آنها مدل‌های دیگری را بررسی کردند که عبارتند از Inception v3, ResNet50, VGG16, DenseNet169 و VGG19. نتایج آنها نشان داد مدل VGG19 با دقت ۹۴/۵۲ درصد در مقایسه با سایر مدل‌های یادگیری عمیق دقت بهتری

خشک، از دست دادن اشتها، بدن درد و مخاط هستند. برخی از علائم غیراختصاصی ممکن است شامل گلودرد، سردرد، لرز همراه با لرزش، از دست دادن بویایی یا چشایی، آبریزش بینی، استفراغ یا اسهال باشد. ظهور علائم به طور معمول ممکن است پس از تماس فرد با ویروس ۵ تا ۶ روز طول بکشد. افرادی که علائم خفیف دارند ممکن است خودبه‌خود 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 زنجیره‌ای پلیمرز رونویسی معکوس در زمان واقعی RNA (RT-PCR) 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 سی‌تی 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

داشته است.

تانگ و همکارانش [۶]، مدل 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 کووید-۱۹ 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 کووید-۱۹ 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 سی‌تی کووید-۱۹ نسبت به تصاویر سی‌تی سالم به دقت ۸۵/۰۳٪ رسیده‌اند.

سوارز و همکاران [۸]، مجموعه دیگری از سی‌تی‌اسکن را در دسترس عموم قرار دادند که شامل ۲۴۸۲ سی‌تی‌اسکن است و از بیمارستان‌های شهر سائوپائولو، 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 سی‌تی 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 ۹۹/۸۴٪ برای تصاویر سی‌تی‌اسکن و دقت ۹۶/۸۱٪ برای تصاویر با اشعه ایکس دست یابد.

کاپیل گوپتا و همکارش [۱۰]، جهت تشخیص و غربالگری خودکار کووید-۱۹ با استفاده از تصاویر سی‌تی‌اسکن قفسه سینه و رویکردهای مبتنی بر یادگیری عمیق بر روی یک مجموعه داده تصویر سی‌تی‌اسکن در دسترس عموم (شامل ۱۲۵۲ تصویر

سی‌تی قفسه سینه کووید-۱۹ و ۱۲۳۰ غیرکووید)، 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]، بستری را پیشنهاد کردند که چندین سطح از تجزیه و تحلیل و طبقه‌بندی جنبه‌های طبیعی و غیرطبیعی کووید-۱۹ را با بررسی تصاویر سی‌تی‌اسکن قفسه سینه پوشش می‌دهد. آنها پس از انتخاب بهترین پیمانه مناسب برای مطالعه، الگوریتم‌های هوش مصنوعی را ترکیب کرده و در نهایت، پس از بکارگیری معماری‌های UNet، InfNet، UNet++، Dense-UNet و Attention-UNet با مقایسه اثربخشی رویکردهای موجود در پژوهش نتایج به دست آمده نشان داد که دقت معماری InfNet پیشنهادی ۹۵ درصد و بهتر از سایر روش‌ها است.

سوغانیا و همکارش [۱۱]، مجموعه‌ای از یادگیری عمیق چند نمونه‌ای (DMIL) بر روی تصاویر سی‌تی‌اسکن 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 کووید برچسب‌گذاری می‌کند. از این مجموعه مدل‌های DMIL با Mask R-CNN به دقت ۹۸/۹۶٪ رسید.

عالیوی و همکاران [۱۲]، تصاویر سی‌تی را با در نظر گرفتن موارد مختلف (سی‌تی طبیعی قفسه سینه، ذات‌الریه، علل ویروسی معمولی و موارد کووید-۱۹) بر اساس یک روش یادگیری عمیق پیشرفته برای مقابله با مسائل تقسیم‌بندی معنایی قفسه سینه ارائه دادند. این رویکرد از یک نسخه اصلاح شده از U-net برای فعال کردن و پشتیبانی از تشخیص کووید-۱۹ از تصاویر مورد مطالعه استفاده می‌کند و توانستند به دقت ۹۳/۰٪، حساسیت ۹۶/۸۸٪ و صحت ۹۶/۹۰٪ دست یابند.

عمران احمد و همکارانش [۱۳]، با بکارگیری یادگیری عمیق برای تقسیم خودکار تصاویر کووید-۱۹ در تصاویر سی‌تی‌اسکن ریه از یک مدل تقسیم‌بندی به نام U-Net را استفاده کردند که در نهایت به دقت 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 سی تی اسکن کووید-۱۹ استفاده کردند. طبقه‌بندی باینری و چندکلاسه 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 کووید-۱۹ و ذات‌الریه به دست آمد.

ابنزر جانگام و همکاران [۱۵]، با ترکیب مدل‌های یادگیری عمیق از پیش آموزش دیده VGG19 و DenseNet169 و با پیاده‌سازی 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 به دست آوردند.

تجلال چودهری 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 متغیرهای وزنی کم‌اهمیت‌تر 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 F1-score=0.9567، sensitivity=0.9216، Accuracy=95.47% و specificity=0.9942 با ۴۱/۹۶٪ FLOP های کمتر و ۲۰/۶۴٪ متغیرهای 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^۱ آماده می‌کند.

اس‌وی کوگیلاوانی و همکارانش [۱۷]، از روش‌های یادگیری عمیق زیادی برای کووید-۱۹ استفاده کرده‌اند. کار پیشنهادی آنها از معماری‌های CNN مانند VGG16، DenseNet121،

MobileNet، NASNet، Xception و EfficientNet و از مجموعه داده‌ای شامل ۳۸۷۳ تصویر سی تی اسکن با برچسب «کووید» و «غیرکووید» 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]، یک مدل یادگیری عمیق تنظیم شده را با الهام از معماری مدل MobileNet V2 برای تشخیص بیماری کووید-۱۹ بر روی تصاویر سی تی اسکن بکار گرفتند. آنها همچنین مدل توسعه‌یافته را از نظر اندازه و پیچیدگی بهینه‌سازی کردند تا با دستگاه‌های موبایل و لبه سازگار شود. از نتایج آزمایش‌های گسترده انجام شده بر روی یک مجموعه داده واقعی متشکل از ۲۴۸۲ تصویر اسکن توموگرافی کامپیوتری قفسه سینه، آنها به دقت طبقه‌بندی ۹۶۴۰٪ با زمان پاسخ‌دهی کوتاه‌تر از مدل‌های یادگیری عمیق رایج دست یافتند.

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

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

¹ Point-of-care devices

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 متغیرهای داده شده رفتار بیماری را در شرایط مختلف تقلید نمودند. نتایج مختلف شبیه‌سازی آنها تاثیر هر یک متغیرهای 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 فناوری 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 VGG19، Inception v3، InceptionResNet v2 و ResNet152 دو مجموعه داده تصاویر پزشکی رادیولوژی قفسه سینه و سی‌تی‌اسکن در یک طبقه‌بندی سه کلاسه برای پیش‌بینی دقیق موارد مبتلا به کوید-۱۹ استفاده کردند. در نهایت بهترین نتیجه به دست آمده آنها برای تصاویر سی‌تی‌اسکن متعلق به معماری InceptionResNet v2 با دقت ۹۹/۳۶۶٪ و برای تصاویر رادیولوژی مربوط به معماری Inception v3 با دقت ۹۶/۹۴۳٪ می‌باشد.

۳. مجموعه داده و شبکه عصبی کانولوشن در

تشخیص بیماری کوید-۱۹

فرآیند تشخیص بیماری کوید-۱۹ از تصاویر سی‌تی‌اسکن ریه افراد شامل بخش‌های جمع‌آوری مجموعه داده‌ها، پیش‌پردازش

داده‌ها، طبقه‌بندی مجموعه داده‌ها، آموزش مدل و ارزیابی و تجزیه و تحلیل مدل است. معماری کامل سیستم برای تشخیص کوید-۱۹ برای روش‌های بر پایه CNN که در این پژوهش استفاده شده است، در شکل (۱) نشان داده شده است. ابتدا تصاویر سی‌تی‌اسکن به عنوان مجموعه داده مورد نیاز برای آموزش و اعتبارسنجی به مدل‌های یادگیری عمیق برای تشخیص کوید-۱۹ مثبت یا کوید-۱۹ منفی طبقه‌بندی کند. در انتها نیز چهار معیار مهم شامل F1-score، Recall، Precision، Accuracy نمایش داده می‌شوند.



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

تشخیص کوید-۱۹ [۲۳]

۱.۳. مجموعه داده



این پژوهش برای پیاده‌سازی مدل‌های شبکه عصبی کانولوشن مورد نظر از دو مجموعه داده شامل تصاویر سی‌تی‌اسکن 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 سی‌تی‌اسکن ریه افراد است که خود به دو بخش کوید با ۱۲۵۲ سی‌تی‌اسکن مثبت برای عفونت SARS-CoV-2 (COVID-19) و غیرکوید با ۱۲۲۹ سی‌تی‌اسکن برای بیماران غیرآلوده به SARS-CoV-2 تقسیم می‌شود. در کل سی‌تی‌اسکن این داده‌ها از بیماران واقعی در بیمارستان‌های سائوپائولو برزیل جمع‌آوری شده که جدول (۱) مشخصات این مجموعه داده را نشان می‌دهد [۸].

آوردن نتایج مطلوب تر، لایه های Dense به انتهای هر مدل اضافه شده و عملکرد مدل های پیشنهادی بررسی می گردد. پس از آن معماری پیشنهادی با ترکیب مدل های VGG16، DenseNet169 و ResNet50 به عنوان مدل Ensemble ارائه می گردد و نتایج در تشخیص بیماری کووید-۱۹ با استفاده از تصاویر سی تی اسکن ارزیابی می شود. بر این اساس در ادامه مدل های یادگیری عمیق بکارگرفته شده در این پژوهش معرفی و نتایج به دست آمده از هر یک به تنهایی بر روی مجموعه داده های اول و دوم بررسی می شود.

۱.۴. VGG16

طبق تحقیقات یکی از شبکه های یادگیری عمیقی که دقت به نسبت خوبی در شناسایی تصاویر سی تی اسکن دارد، VGG16 است لذا اولین مدلی که در این پژوهش بکار گرفته شده است، این مدل 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 وزن های به دست آمده در طول آموزش با استفاده از مجموعه داده ImageNet استفاده شود سپس لایه های مورد نیاز برای کلاس بندی داده ها اضافه شد. جهت ارزیابی کارایی مدل از دو تابع فعال ساز sigmoid و softmax با epoch های ۵۰ و ۱۰۰ استفاده گردید. شبکه VGG16، شامل دو لایه کانولوشنی با $64 \times 3 \times 3$ فیلتر هست که پشت سر هم قرار گرفته اند. سپس، یک لایه ادغام حداکثری 2×2 با پرش (Stride) به اندازه ۲ قرار گرفته است. این لایه ادغام علاوه بر نمونه برداری، وظیفه کاهش بعد ویژگی ها به نصف را هم دارد. در ادامه، دو لایه کانولوشنی دیگر با $128 \times 3 \times 3$ فیلتر و یک لایه ادغام 2×2 و پرش ۲ قرار گرفته اند. سپس و به طور مشابه، سه لایه کانولوشنی با $256 \times 3 \times 3$ فیلتر و یک لایه ادغام 2×2 با پرش ۲ قرار گرفته اند. سه لایه کانولوشنی با $512 \times 3 \times 3$ فیلتر و یک لایه ادغام 2×2 با پرش ۲ قرار گرفته اند. این شبکه هست که البته دو بار تکرار می شود. در نهایت، ویژگی ها تبدیل به یک بردار ویژگی می شوند تا در اختیار لایه های نورونی (تمام-اتصال یا Fully

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 کووید با ۳۴۹ تصویر سی تی مثبت برای کووید-۱۹ متعلق به ۲۱۶ بیمار و ۳۹۷ تصویر سی تی که برای کووید-۱۹ منفی است. جدول (۲) مشخصات این مجموعه داده را نشان می دهد [۲۴].

جدول (۱): مجموعه داده اول		
عکس	تعداد کل نمونه ها	
	۱۲۵۲	کووید
		
	۱۲۲۹	غیر کووید
		
جدول (۲): مجموعه داده دوم		
عکس	تعداد کل نمونه ها	
	۳۴۹	کووید
		
	۳۹۷	غیر کووید
		

جهت ارزیابی دقیق مدل های یادگیری داده ها به سه دسته Train، Test و Validation تقسیم شد. این تقسیم بندی به صورت ۸۰٪/۱۰٪/۱۰٪ برای بخش Train، ۱۰٪ برای بخش Test و ۱۰٪ برای بخش Validation انجام شد.

۴. مروری بر مدل های یادگیری عمیق

در این پژوهش روش انجام کار به شرح زیر است: ابتدا مدل های DenseNet169، ResNet50، Inception v3، VGG19، VGG16 و CtNet10 بر روی مجموعه داده ها پیاده سازی و کارایی هر مدل بر روی مجموعه داده ها ارزیابی شده و سپس برای به دست

¹ Max pooling


Connected که مخفف FC گفته می شود) قرار گیرند.

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 عمیق تر شدن شبکه ها در نظر گرفته شده بود و در عین حال از افزایش بیش از حد تعداد متغیرها جلوگیری می کرد. مدل Inception v3 درصد خطای کمتری نسبت به مدل های قبلی خود دارد. تغییرات عمده انجام شده در مدل Inception v3 عبارتند از:

- فاکتورسازی به پیچیدگی های کوچکتر
- فاکتورسازی فضایی به پیچیدگی های نامتقارن
- کاربرد طبقه بندی کننده های کمکی
- کاهش اندازه شبکه کارآمد

مدل Inception v3 از یک شبکه عصبی عمیق ۴۲ لایه تشکیل شده است. این مدل متشکل از بلوک های ساختمانی متقارن و نامتقارن، از جمله کانولوشن ها، لایه های Max pooling، Average pooling، dropouts و لایه های تمام-اتصال است. معماری Inception v3 در شکل (۳) نشان داده شده است [۲۵].



شکل (۲): پیکربندی مدل VGG19 [۲]



شکل (۳): معماری مدل INCEPTION v3 [۲۵]

۴.۴. ResNet50

از ویژگی‌ها را تشویق می‌کنند، بنابراین آنها به خانواده‌ای از معماری‌های یادگیری عمیق بسیار قابل اعتماد تبدیل شدند. مدل‌های DenseNet را می‌توان در Keras (Tensorflow) و PyTorch پیدا کرد. معماری شامل لایه‌های کانولوشن، لایه‌های MaxPool، لایه‌های تمام-اتصال (Fully Connected) و لایه‌های انتقال است. لایه‌های کانولوشن ویژگی‌های موجود در تصویر را استخراج می‌کنند و لایه‌های MaxPool ابعاد ورودی‌های خود را کاهش می‌دهند. لایه‌های تمام متصل از لایه سطح پیروی می‌کنند که به عنوان یک شبکه عصبی مصنوعی با ورودی آرایه منفرد از لایه سطح عمل می‌کند [۲۷].


۴.۴.۶. 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 دو بلوک کانولوشن با ابعاد $126 \times 126 \times 32$ ، $124 \times 124 \times 32$ عبور می‌کند. سپس از یک تجمع حداکثری با ابعاد $62 \times 62 \times 32$ و به دنبال آن دو لایه کانولوشن با ابعاد $60 \times 60 \times 32$ و $58 \times 58 \times 32$ عبور می‌کند و از طریق یک لایه ترکیبی به ابعاد $29 \times 29 \times 32$ عبور داده می‌شود. سپس از میان 26912 نورون لایه سطح عبور داده می‌شود، که بیشتر از لایه‌های مترام و رها شده تشکیل شده و از هر کدام 256 نورون عبور می‌کند. پس از عبور آن از یک نورون منفرد از یک لایه مترام، تصاویر سی تی اسکن به عنوان کووید-۱۹ مثبت یا منفی طبقه‌بندی می‌شوند (شکل (۵)) [۲].

مدل‌های شبکه عصبی فوق که در تحقیقات پیشین استفاده شده‌اند با در نظر گرفتن دو دسته متغیر و ابرمتغیر زیر شامل epoch برابر با ۵۰ و ۱۰۰، توابع فعال‌ساز sigmoid و softmax، تابع بهینه‌ساز adam مجدد پیاده‌سازی شدند. 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 ابرمتغیرهای 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.

ResNet مخفف Residual Network است و نوع خاصی از شبکه عصبی کانولوشنال (CNN) است. ResNet50 یک شبکه عصبی کانولوشن ۵۰ لایه شامل ۴۸ لایه کانولوشن، یک لایه MaxPool و یک لایه Flatting است. شبکه‌های عصبی ResNet نوعی شبکه عصبی مصنوعی (ANN) هستند که با چیدن بلوک Residual، شبکه‌ها را تشکیل می‌دهند (شکل (۴)) را مشاهده کنید). 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 شامل 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 شامل $1 \times 1 \times 128$ ، $3 \times 3 \times 128$ و $1 \times 1 \times 512$ ، که ۴ بار تکرار شده است.
- ۱۸ لایه دیگر با $1 \times 1 \times 256$ و ۲ هسته $3 \times 3 \times 256$ و $1 \times 1 \times 1025$ ، 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].



شکل (۴): معماری مدل RESNET50


۴.۵. DenseNet169

معماری لایه‌ای DenseNet169 یکی از معماری‌های خانواده DenseNet با ۱۶۹ لایه است و یک معماری پرکاربرد برای کارهای طبقه‌بندی یادگیری عمیق است. این معماری در مقایسه با معماری‌های DenseNet با لایه‌های کمتر، متغیرهای آموزش‌پذیر بسیار کمتری دارد. معماری DenseNet169 و دیگر معماری‌های DenseNet توانایی غلبه بر مشکل ناپدید شدن گرادین را دارند، استراتژی انتشار ویژگی قوی دارند، تعداد متغیرهای قابل آموزش را به حداقل می‌رسانند و استفاده مجدد




شکل (۵): معماری مدل CTNet10 [۲]

جدول (۳): منحنی Loss و Accuracy برای مجموعه داده اول



جدول (۴): منحنی LOSS و ACCURACY برای مجموعه داده دوم



۵. روش پیشنهادی

۱.۵. افزودن لایه‌های Dense به انتهای معماری‌های از

پیش آموزش داده شده

پس از پیاده‌سازی و اجرای معماری‌های شبکه عصبی در این پژوهش و کسب نتایج و دقت‌های به دست آمده، جهت افزایش

در این پژوهش دو راهکار جهت بهبود دقت شناسایی کووید-۱۹ از روی تصاویر سی تی اسکن ارائه شده است. در این بخش هر یک از این راهکارها شرح داده می‌شود.

کردن دو لایه Dense به دقت‌های $\text{Train}=0.99$ و $\text{Test}=0.9598$ دست یافت.


- مدل پایه معماری DenseNet169 به ترتیب به دقت‌های $\text{Train}=0.99$ و $\text{Test}=0.98$ دست یافته است که با اضافه کردن دو لایه Dense به دقت‌های $\text{Train}=1$ و $\text{Test}=0.9980$ دست یافت.
- مدل پایه معماری CtNet10 به ترتیب به دقت‌های $\text{Train}=0.98$ و $\text{Test}=0.91$ دست یافته است که با افزودن دو لایه Dense به دقت‌های $\text{Train}=0.99$ و $\text{Test}=0.9197$ 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 نویسندگان رسید؟ در پاسخ باید گفت زمان اجرای معماری‌های یادگیری عمیق زیاد است حال 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 به دنبال مدل پیچیده‌تر مانند ResNet50 یا DenseNet169 رفته‌اند؛ 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 بررسی کنید شاید با توجه به کاربرد بتوان جواب بهتری به دست آورد. در ادامه، حالت‌های دیگری که معماری‌ها و اثر افزودن لایه تمام متصل را بررسی 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 $\text{Train}=0.9$ و $\text{Test}=0.8916$ دست یافته است که با اضافه کردن دو لایه Dense به دقت‌های $\text{Train}=0.94$ و $\text{Test}=0.9115$ رسید.
- مدل پایه معماری VGG19 به ترتیب به دقت‌های $\text{Train}=0.88$ و $\text{Test}=0.8614$ دست یافته است که با اضافه

و بهبود کارایی و ارتقای مدل‌های از پیش آموزش 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 فعال‌سازی ReLU استفاده شده است تا از جنبه نظری کاهش زمان آموزش تضمین گردد. مشابه فناوری‌های یادگیری انتقال، تمام لایه‌های قبلی شبکه فریز می‌شود و فقط لایه ReDense آموزش می‌بیند تا زمان آموزش کمتری حاصل شود [۲۸].



شکل (۴): تصویرسازی آموزش ReDense [۲۸]

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 $\text{Train}=0.8835$ و $\text{Test}=0.93$ دست یافته است که با افزودن دو لایه Dense به دقت‌های $\text{Train}=0.95$ و $\text{Test}=0.9076$ دست یافت.
- مدل پایه معماری VGG19 به ترتیب به دقت‌های $\text{Train}=0.91$ و $\text{Test}=0.8695$ دست یافته است که با افزودن دو لایه Dense به دقت‌های $\text{Train}=0.93$ و $\text{Test}=0.9036$ دست یافت.
- مدل پایه معماری Inception v3 به ترتیب به دقت‌های $\text{Train}=1$ و $\text{Test}=0.99$ دست یافته است که با افزودن دو لایه Dense به دقت‌های $\text{Train}=0.99$ و $\text{Test}=0.9739$ دست یافت.
- مدل پایه معماری ResNet50 به ترتیب به دقت‌های $\text{Train}=0.99$ و $\text{Test}=0.95$ دست یافته است که با اضافه

- مدل پایه معماری ResNet50 به ترتیب به دقت‌های Train=0.94 و Test=0.8133 دست یافته است که با اضافه کردن دو لایه 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 یافته است که با اضافه کردن دو لایه 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 یافته است که با اضافه کردن دو لایه 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 دو لایه Dense با تعداد نورون‌های ۴۰۹۶ و ۱۰۷۲ به دقت‌های Train=0.49 و Test=0.4286 رسیدند. 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 به نسبت مطلوبی دارند اما هدف بالا بردن دقت برای اغلب مجموعه داده‌ها است. جهت ترکیب مدل‌ها ابتدا باید مطمئن شد که چه مدل‌هایی برای ترکیب مناسب هستند. در راهکار پیشنهادی، Ensemble Deep Learning برای تشخیص کووید-۱۹ ترکیب مدل‌های VGG16، ResNet50 و DenseNet169 از
 - 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 یافته است که با افزودن دو لایه Dense به دقت‌های Train=0.99 و Test=0.9578 دست یافت.
 - مدل پایه معماری ResNet50 به ترتیب به دقت‌های Train=0.99 و Test=0.9558 دست یافته است که با اضافه کردن دو لایه 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 دو لایه 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 یافته است که با اضافه کردن دو لایه 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 یافته است که با اضافه کردن دو لایه 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 یافته است که با اضافه کردن دو لایه Dense با تعداد نورون‌های ۴۰۹۶ و ۱۰۷۲ به دقت‌های Train=0.97 و Test=0.9467 رسید.

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.

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 آموزش داده شده مقایسه شده است. لازم به ذکر است، مدل‌های پایه‌ای که در تحقیقات [۲]، [۱۴]، [۱۷] و [۱۹] استفاده شده‌اند، مجدد پیاده‌سازی و بر روی مجموعه داده‌های این تحقیق بررسی شده‌اند. سپس روش پیشنهادی Add Denselayer با آنها مقایسه و نتایج به دست آمده از آن در جدول‌های (۵) تا (۸) آورده شده است.


همان‌طور که در جدول (۵) مشاهده می‌کنید، نتایج حاصل از اجرا بر روی مجموعه داده اول با توجه به متغیرهای استفاده شده نشان می‌دهد که کارایی مدل VGG16 با افزودن لایه Dense برای Train بهتر شده اما برای Test دقت کمتری به دست آمده است. برای مدل VGG19 با افزودن لایه Dense برای Train و Test دقت بهتری به دست آمده است. برای مدل Inception v3 با افزودن لایه Dense برای Train و Test دقت کمتری به دست 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 متغیرهای بکار گرفته 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 ۱.۵ نیز ذکر شده است با توجه به کاربرد شاید بتوان نتایج را بهتر کرد.

طریق یک استراتژی Ensemble بررسی می‌گردد. علت انتخاب مدل VGG16 بجای VGG19 و انتخاب معماری ResNet50 و DenseNet169 بجای Inception v3 ساده‌تر بودن ساختار آنها و در نتیجه پیچیدگی کمتر مدل‌ها است.

به دلیل وجود نویز در داده‌های آموزشی و تصادفی بودن وزن‌ها در الگوریتم یادگیری عمیق، این شبکه‌ها به طور معمول از مشکل واریانس بالا و خطای تعمیم رنج می‌برند. اگرچه برخی از رویکردهای رایج مانند افزایش داده‌ها و منظم‌سازی وجود 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 الگوی یادگیری ترکیبی است که قادر است با ترکیب هوشمندانه چندین مدل یادگیری ماشین، نتایج پیش‌بینی دقیق‌تر و قوی‌تری نسبت به یک مدل واحد تولید کند. با این همه، استراتژی‌های Ensemble مختلفی مانند Averaging, Random Forest, Boosting و Stacking در دسترس هستند [۶]. این پژوهش یک مدل یادگیری عمیق Ensemble را به منظور تشخیص کووید-۱۹ بر روی تصاویر سی‌تی پیشنهاد می‌کند. نمای کلی مدل که در شکل (۷) نشان داده شده است، به شرح زیر است:

۱. جمع‌آوری داده‌ها. مجموعه داده اول شامل ۲۴۸۱ تصویر سی‌تی‌اسکن ریه و مجموعه داده دوم شامل ۷۴۶ تصویر سی‌تی‌اسکن ریه افراد است.
۲. دسته‌بندی تصاویر سی‌تی‌اسکن. مجموعه داده اول که خود به دو بخش کووید با ۱۲۵۲ سی‌تی‌اسکن مثبت برای عفونت SARS-CoV-2 و غیرکووید با ۱۲۲۹ سی‌تی‌اسکن برای بیماران غیرآلوده به SARS-CoV-2 تقسیم می‌شود. مجموعه داده دوم نیز تصاویر به دو بخش کووید با ۳۴۹ تصویر سی‌تی مثبت برای کووید-۱۹ متعلق به ۲۱۶ بیمار و ۳۹۷ تصویر سی‌تی که برای کووید-۱۹ منفی است.
۳. تغییراندازه تصاویر به ۲۲۴×۲۲۴.
۴. مجموعه نمونه‌های Train, Test و Validation ایجاد می‌شوند.



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

جدول (۵): مقایسه مدل‌های شبکه عصبی عمیق پایه و افزودن لایه تمام متصل بر اساس متغیرهای OPTIMIZER=ADAM.EPOCH=100 و ACTIVATION=SOFTMAX روی مجموعه داده اول

معماری های پایه					روش 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]	0.883	5s	0.93	11s	$\begin{bmatrix} 943 & 49 \\ 89 & 911 \end{bmatrix}$	$\begin{bmatrix} 221 & 25 \\ 33 & 219 \end{bmatrix}$	0.95	11s	0.91	4s	$\begin{bmatrix} 944 & 47 \\ 47 & 954 \end{bmatrix}$	$\begin{bmatrix} 225 & 22 \\ 24 & 227 \end{bmatrix}$				
VGG19 [2]	0.91	12s	0.87	3s	$\begin{bmatrix} 874 & 118 \\ 60 & 940 \end{bmatrix}$	$\begin{bmatrix} 204 & 42 \\ 23 & 229 \end{bmatrix}$	0.93	12s	0.90	3s	$\begin{bmatrix} 913 & 78 \\ 58 & 943 \end{bmatrix}$	$\begin{bmatrix} 217 & 30 \\ 18 & 233 \end{bmatrix}$				
Inception v3 [2]	1	5s	99	2s	$\begin{bmatrix} 989 & 3 \\ 5 & 995 \end{bmatrix}$	$\begin{bmatrix} 243 & 3 \\ 2 & 250 \end{bmatrix}$	0.99	5s	0.97	2s	$\begin{bmatrix} 990 & 1 \\ 11 & 990 \end{bmatrix}$	$\begin{bmatrix} 245 & 2 \\ 11 & 240 \end{bmatrix}$				
ResNet50 [2][14][19]	0.99	6s	0.95	2s	$\begin{bmatrix} 984 & 8 \\ 14 & 986 \end{bmatrix}$	$\begin{bmatrix} 234 & 12 \\ 12 & 240 \end{bmatrix}$	0.99	6s	0.96	2s	$\begin{bmatrix} 982 & 9 \\ 17 & 984 \end{bmatrix}$	$\begin{bmatrix} 235 & 12 \\ 8 & 243 \end{bmatrix}$				
DenseNet169 [2]	0.99	8s	0.98	4s	$\begin{bmatrix} 985 & 7 \\ 6 & 994 \end{bmatrix}$	$\begin{bmatrix} 241 & 5 \\ 4 & 248 \end{bmatrix}$	1	8s	0.99	4s	$\begin{bmatrix} 989 & 2 \\ 3 & 998 \end{bmatrix}$	$\begin{bmatrix} 246 & 1 \\ 0 & 251 \end{bmatrix}$				
CtNet10 [2]	0.98	1s	0.91	39ms	$\begin{bmatrix} 998 & 18 \\ 18 & 984 \end{bmatrix}$	$\begin{bmatrix} 109 & 8 \\ 14 & 118 \end{bmatrix}$	0.99	1s	0.92	18ms	$\begin{bmatrix} 998 & 8 \\ 12 & 990 \end{bmatrix}$	$\begin{bmatrix} 108 & 9 \\ 11 & 121 \end{bmatrix}$				

جدول (۶): مقایسه مدل‌های شبکه عصبی عمیق پایه و افزودن لایه تمام متصل بر اساس متغیرهای OPTIMIZER=ADAM.EPOCH=100 و ACTIVATION=SOFTMAX روی مجموعه داده دوم

معماری های پایه					added Dense layer روش پیشنهادی								
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	$\begin{bmatrix} 0 & 353 \\ 0 & 334 \end{bmatrix}$	$\begin{bmatrix} 0 & 44 \\ 0 & 33 \end{bmatrix}$	

طبق جدول (۸)، نتایج حاصل از اجرا بر روی مجموعه داده دوم نیز با توجه به متغیرهای استفاده شده نشان می‌دهد که کارایی مدل VGG16، VGG19 و Inception v3 با افزودن لایه Dense برای Train و Test دقت بهتری به دست 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.

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

جدول (۷): مقایسه مدل‌های شبکه عصبی عمیق پایه و افزودن لایه تمام متصل بر اساس متغیرهای OPTIMIZER=ADAM, EPOCH=50 و ACTIVATION=SIGMOID روی مجموعه داده اول

معماری های پایه					روش 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 متغیرهای OPTIMIZER=ADAM, EPOCH=50 و ACTIVATION=SIGMOID روی مجموعه داده دوم

معماری های پایه					روش 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	$\begin{bmatrix} 308 & 55 \\ 6 & 302 \end{bmatrix}$	$\begin{bmatrix} 32 & 2 \\ 4 & 37 \end{bmatrix}$				

ادامه آورده شده است.

طبق جدول (۹)، نتایج حاصل از اجرا بر روی مجموعه داده اول کارایی معماری ترکیبی Ensemble پیشنهادی با بکارگیری تابع فعال‌ساز softmax، برای Train دقت ۱ و برای Test دقت ۰/۹۹۶۰ را نشان می‌دهد. همچنین با تابع فعال‌ساز sigmoid، برای Train دقت ۱ و برای Test دقت ۰/۹۷۹۹ به دست آمده

در جدول‌های (۵) تا (۸) مشاهده گردید که کارایی مدل‌های شبکه عصبی عمیق با افزودن لایه‌های 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 به دست آورد طرح یادگیری عمیق ترکیبی پیشنهاد شد. نتایج حاصل از ترکیب مدل‌های VGG16، ResNet50 و DenseNet169 در

بر روی مجموعه داده اول با استفاده از تابع فعال‌ساز softmax برای Train به دقت ۱ و برای Test به دقت ۰/۹۹۶ 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 به دست آمده استفاده از راهکار یادگیری عمیق ترکیبی را جهت پردازش تصاویر سی‌تی‌اسکن 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 آموزش 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 راهکارهای به نسبت کمتری در آن ارائه شده است و هنوز جای کار برای افزایش دقت شناسایی دارد، پردازش تصاویر سی‌تی‌اسکن 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 DenseNet169, ResNet50, Inception v3, VGG19, VGG16 و CtNet10 بر روی دو مجموعه داده از تصاویر سی‌تی‌اسکن 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 سی‌تی‌اسکن ارائه شد.

است. همان‌طور که در جدول (۱۰) ملاحظه می‌کنید، نتایج حاصل از اجرا بر روی مجموعه داده دوم کارایی معماری ترکیبی Ensemble پیشنهادی با کارگیری تابع فعال‌ساز sigmoid، برای Train و Test دقت ۱ یا صد درصد را نشان می‌دهد. همچنین با تابع فعال‌ساز softmax، برای Train دقت ۰/۹۸۱۲ و برای Test دقت ۰/۹۶۸۸ به دست آمده است.

همان‌گونه که نتایج جدول‌های (۹) و (۱۰) نشان می‌دهند^۱ ترکیب مدل‌ها توانسته است اثر بهبود بیشتری داشته باشد به طوری که در مجموعه داده دوم که افزودن لایه Dense مطلوب نبود مدل ترکیبی توانست به نتایج بالاتر و حتی دقت نزدیک به صد درصد دست یابد. نکته قابل توجه آن است که در تشخیص‌های پزشکی سلامت بیمار و صحت نتایج آزمایش‌ها از اهمیت بالایی برخوردار است، بنابراین هر چقدر دقت مدل‌های حاصل از الگوریتم‌های هوش مصنوعی بیشتر باشد احتمال خطا کمتر می‌گردد و امید است که در تسریع تشخیص و عملکرد درمانی پزشکان مفید واقع گردد.

به طور خلاصه می‌توان گفت معماری DenseNet169 برای مجموعه داده اول با دقت Train برابر ۱ و دقت Test برابر ۰/۹۹۲ و برای مجموعه داده دوم با دقت Train برابر ۰/۹۹ و دقت Test برابر با ۰/۹۳۳۳ کارایی بهتری داشت. در ادامه جهت ارائه پیشنهاد با اضافه کردن دو لایه Dense با تعداد نورون‌های متفاوت به هر کدام از معماری‌ها سعی بر افزایش و ارتقا دقت نتایج به دست آمده شد و در انتها معماری DenseNet169 برای مجموعه داده اول با دقت Train برابر ۱ و دقت Test برابر با ۰/۹۹۸۰ و معماری VGG16 برای مجموعه داده دوم با دقت Train برابر با ۰/۹۹ و دقت Test برابر با ۰/۹۲ کارایی بهتری از خود نشان داد.

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

^۱ نتایج مرجع [۱۵] در جدول‌های (۹) و (۱۰) عیناً برداشت شده است، زیرا مجموعه داده‌ها یکسان است. لازم به ذکر است فقط مقدار دقت داده آزمون در تحقیق ذکر شده و بقیه معیارها ذکر نشده است.

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

Model	Train	Time	Test	Time	Confusion Matrix		Parameters
					Train	Test	
مرجع [15]	-	-	0.9075	-	-	-	-
روش ترکیبی پیشنهادی (Ensemble)	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
	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	
مرجع [15]	-	-	0.8473	-	-	-	-
روش ترکیبی پیشنهادی (Ensemble)	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
	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

اما می تواند به دقت بالاتری دست یابد که در تشخیص بیماری ها به پزشکان کمک بیشتری می نماید.

تعارض منافع: نویسندگان اعلام می کنند که هیچ تعارض منافعی ندارند.

بر اساس نتایج تجربی می توان گفت استفاده از راهکار ترکیبی یادگیری عمیق می تواند در شناسایی کووید-۱۹ به دقت بالاتر از ۹۸ درصد و حتی صد درصد 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 ملاحظه ای ایجاد نمی کند

مراجع

- [1] W. Zhao, W. Jiang, and X. Qiu, "Deep learning for COVID-19 detection based on CT images," Sci. Rep., vol. 11, p. 14353, 2021, doi: 10.1038/s41598-021-93832-2.
- [2] V. Shah, R. Keniya, A. Shridharani, M. Punjabi, J. Shah, and N. Mehendale, "Diagnosis of COVID-19 using CT scan images and deep learning techniques," Emerg. Radiol., vol. 28, no. 3, pp. 497-505, 2021, doi: 10.1007/s10140-020-01886-y.
- [3] H. Kaheel, A. Hussein, and A. Chehab, "AI-Based Image Processing for COVID-19 Detection in Chest CT Scan Images," Front. Comms. Net, vol. 2, p. 645040, 2021, doi: 10.3389/frcmn.2021.645040.
- [4] N. Safdarian and N. Jafarnia Dabanloo, "Detection and classification of COVID-19 by lungs computed tomography scan image processing using intelligence algorithm," J. Med. Signals Sens., vol. 11, no. 4, pp. 274-284, 2021, doi: 10.4103/jmss.JMSS_55_20.
- [5] Silva P., E. Luz, G. Silva, G. Moreira, R. Silva, D. Lucio, and D. Menotti, "COVID-19 detection in CT images with deep learning: A voting-based scheme and cross-datasets analysis," Informatics Med. Unlocked, vol. 20, p. 100427, 2020, doi: 10.1016/j.imu.2020.100427.
- [6] S. Tang, C. Wang, J. Nie, N. Kumar, Y. Zhang, Z. Xiong, and A. Barnawi, "EDL-COVID: ensemble deep learning for COVID-19 case detection from chest x-ray images," IEEE Trans. Ind. Informatics, vol. 17, no. 9, pp. 6539-6549, 2021, doi: 10.1109/TII.2021.3057683.

- [7] M. Polsinelli, L. Cinque, and G. Placidi, "A light CNN for detecting COVID-19 from CT scans of the chest," *Pattern Recognit. Lett.*, vol. 140, pp. 95-100, 2020, doi: 10.1016/j.patrec.2020.10.001.
- [8] E. Soares, P. Angelov, S. Biaso, M.H. Froes, and D.K. Abe, "SARS-CoV-2 CT-scan dataset: A large dataset of real patients CT scans for SARS-CoV-2 identification," *MedRxiv*, pp. 1-8, 2020, doi: 10.1101/2020.04.24.20078584.
- [9] G. Celik, "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," *Appl. Soft Comput.*, vol. 133, p. 109906, 2023, doi: 10.1016/j.asoc.2022.109906.
- [10] K. Gupta and V. Bajaj, "Deep learning models-based CT-scan image classification for automated screening of COVID-19," *Biomed. Signal Process. Control*, vol. 80, p. 104268, 2023, doi: 10.1016/j.bspc.2022.104268.
- [11] D. Suganya and R. Kalpana, "Automated Detection of Covid-19 Waves with Computerized Tomography Scan Using Deep Learning," in S. Awasthi, G. Sanyal, C.M. Travieso-Gonzalez, P. Kumar Srivastava, D.K. Singh, and R. Kant, (eds) *Sustainable Computing*, Springer, Cham, 2023, pp. 49-67, doi: 10.1007/978-3-031-13577-4_3.
- [12] H. Alliou, Y. Mourdi, and M. Sadgal, "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, doi: 10.1016/j.radi.2022.10.010.
- [13] I. Ahmed, A. Chehri, and G. Jeon, "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, doi: 10.3390/electronics11152296.
- [14] D. Yang, C. Martinez, L. Visuna, H. Khandhar, C. Bhatt, and J. Carretero, "Detection and analysis of COVID-19 in medical images using deep learning techniques," *Sci. Rep.*, vol. 11, no. 1, p. 19638, 2021, doi: 10.1038/s41598-021-99015-3.
- [15] E. Jangam, A.A.D. Barreto, and C.S.R. Annavarapu, "Automatic detection of COVID-19 from chest CT scan and chest X-Rays images using deep learning, transfer learning and stacking," *Appl. Intell.*, vol. 52, no. 2, pp. 2243-2259, 2022, doi: 10.1007/s10489-021-02393-4.
- [16] T. Choudhary, S. Gujar, A. Goswami, V. Mishra, and T. Badal, "Deep learning-based important weights-only transfer learning approach for COVID-19 CT-scan classification," *Appl. Intell.*, vol. 53, no. 6, pp. 7201-7215, 2023, doi: 10.1007/s10489-022-03893-7.
- [17] S.V. Kogilavani, et al., "COVID-19 detection based on lung CT scan using deep learning techniques," *Computat. Math. Methods Med.*, vol. 2022, p. 7672196, 2022, doi: 10.1155/2022/7672196.
- [18] V.K. Singh and M.H. Kolekar, "Deep learning empowered COVID-19 diagnosis using chest CT scan images for collaborative edge-cloud computing platform," *Multimed. Tools Appl.*, vol. 81, no. 1, pp. 3-30, 2022, doi: 10.1007/s11042-021-11158-7.
- [19] S. Serte and H. Demirel, "Deep learning for diagnosis of COVID-19 using 3D CT scans," *Comput. Biol. Med.*, vol. 132, p. 104306, 2021, doi: 10.1016/j.combiomed.2021.104306.
- [20] A. Akrami and M. Parsamanesh, "Investigation of a mathematical fuzzy epidemic model for the spread of coronavirus in a population," *Soft Comput. J.*, vol. 11, no. 1, pp. 2-9, 2022, doi: 10.22052/scj.2022.246053.1045 [In Persian].
- [21] A. Yadollahi and H. Sabaghian-Bidgoli, "A simulation model for the propagation of Covid-19 virus based on the discrete-time Markov chain," *Soft Comput. J.*, vol. 11, no. 2, pp. 88-103, 2023, doi: 10.22052/scj.2023.246527.1076 [In Persian].
- [22] M. Mousavi, S. Hosseini, and M.R. Omid, "Improved deep neural network algorithm for COVID-19 detection in the Internet of Things," *Soft Comput. J.*, vol. 12, no. 2, pp. 54-71, 2024, doi: 10.22052/scj.2023.248686.1117 [In Persian].
- [23] K.F. Haque and A. Abdelgawad, "A deep learning approach to detect COVID-19 patients from chest X-ray images," *AI*, vol. 1, no. 3, p. 27, 2020, doi: 10.3390/ai1030027.
- [24] J. Zhao, Y. Zhang, X. He, and P. Xie, "Covid-ct-dataset: a ct scan dataset about covid-19," *CoRR abs/2003.13865*, 2020.
- [25] A. Demir, F. Yilmaz, and O. Kose, "Early detection of skin cancer using deep learning architectures:

- resnet-101 and inception-v3,” in Med. Technol. Cong. (TIPTEKNO), Izmir, Turkey, 2019, pp. 1-4, doi: 10.1109/TIPTEKNO47231.2019.8972045.
- [26] I.Z. Mukti and D. Biswas, “Transfer Learning Based Plant Diseases Detection Using ResNet50,” in 4th Int. Conf. Electr. Inform. Commun. Technol. (EICT), Khulna, Bangladesh, 2019, pp. 1-6, doi: 10.1109/EICT48899.2019.9068805.
- [27] A. Vulli, et al., “Fine-tuned DenseNet169 for breast cancer metastasis prediction using FastAI and 1-cycle policy,” *Sensors*, vol. 22, no. 8, p. 2988, 2022, doi: 10.3390/s22082988.
- [28] A.M. Javid, S. Das, M. Skoglund, and S. Chatterjee, “A ReLU Dense Layer to Improve the Performance of Neural Networks,” in *IEEE Int. Conf. Acoust. Speech Signal Process. (ICASSP)*, Toronto, ON, Canada, 2021, pp. 2810-2814, doi: 10.1109/ICASSP39728.2021.9414269.