



آشکار سازی کووید ۱۹ از روی تصاویر سی تی اسکن ریه مبتنی بر ادغام هرم و ویژگی و شبکه‌های کانولوشنی عمیق

زهرا یوسف‌نیادری^۱، مهدی ازوجی^۲

^۱دانشگاه صنعتی نوشیروانی بابل،

zahrayosefnia@gmail.com

^۲دانشگاه صنعتی نوشیروانی بابل،

m.ezoji@nit.ac.ir

با توجه به شیوع نسبتاً بالای کووید ۱۹، تشخیص دقیق و زود هنگام آن بسیار حائز اهمیت است. روش‌های مختلفی برای تشخیص این بیماری پیشنهاد شده است. بنا به گفته سازمان بهداشت جهانی، تشخیص بیماری کووید ۱۹ باید توسط آزمایش‌های RT-PCR تایید شود [۴]. این آزمون پایه ساخت و توزیع کیت آزمایشگاهی است که سازمان بهداشت جهانی در جهان پخش می‌کند. با این وجود، این روش اندازه‌گیری آزمایشگاهی بسیار گران‌قیمت بوده و فرآیندی زمان‌بر است [۵].

با توجه به نرخ بالای نتایج منفی کاذب و تعداد محدود کیت‌های آزمایش اسید نوکلئیک، مانند آزمایش RT-PCR، تصویربرداری سی تی اسکن از قفسه سینه یک روش آسان بوده و ابزاری مفید برای تشخیص زود هنگام موارد مشکوک کووید ۱۹ است [۶].

از آنجا که استفاده از روش‌های هوش مصنوعی با رویکرد یادگیری عمیق در حوزه پردازش تصاویر پزشکی توسعه یافته است، پژوهش‌های بسیاری برای قطع‌بندی [۹-۸-۷] و طبقه‌بندی [۱۱-۱۰] کووید ۱۹ از روی تصاویر اشعه ایکس و سی تی اسکن انجام شده است.

به دلیل متفاوت بودن پایگاه داده‌های مورد استفاده در مطالعات صورت گرفته، هر کدام با چالش‌های متفاوتی در زمینه دسته‌بندی و قطع‌بندی نواحی درگیر مواجه بودند که از جمله این مشکلات می‌توان به کمبود داده‌های برجسب دار، تعداد کم تصاویر پایگاه داده برای آموزش شبکه عمیق، نیاز به حاشیه نویسی ضایعات و توزیع نامتقارن در اندازه نواحی عفونت بین دو دسته اشاره کرد.

یکی از الگوریتم‌های کارآمد یادگیری عمیق، استفاده از شبکه‌های عصبی کانولوشنی از پیش آموزش دیده است. در پژوهش [۱۲] از پنج مدل از پیش آموزش دیده InceptionV3،

چکیده- گسترش بیماری کووید ۱۹ در سراسر جهان تاثیر گسترده ای بر زندگی و نیز اقتصاد کشورها گذاشته است. تشخیص زود هنگام این بیماری می‌تواند در تسریع فرآیند درمان و جلوگیری از مرگ بیماران نقش بسزایی داشته باشد. یک روش مهم تشخیص سریع و دقیق این بیماری، دسته‌بندی تصاویر رادیوگرافی قفسه سینه بر اساس روش‌های یادگیری عمیق است. هدف این پژوهش، ارائه روشی با دقت و سرعت بالا جهت آشکار سازی تصاویر کووید ۱۹ است. در این پژوهش مدلی مبتنی بر ترکیب دو شبکه InceptionV3 و ResNet50V2 برای استخراج سلسله مراتبی ویژگی ارائه شده است. شبکه‌های هرمی با ایجاد ساختار سلسله مراتبی ویژگی از بالا به پایین و پایین به بالا منجر به تولید ویژگی‌های معنادارتر و در نتیجه دقت بالاتری می‌شوند. مدل پیشنهادی بر روی پایگاه داده SARS-COV-2 که از ۲۴۸۲ تصویر سی تی اسکن در دو دسته تشکیل شده، ارزیابی شده است. میانگین دقت، صحت، حساسیت و امتیاز F1 بدست آمده در ارزیابی مدل پیشنهادی به ترتیب برابر ۹۷/۸۹٪، ۹۷٪، ۹۹٪ و ۹۸٪ است.

کلمات کلیدی- کووید ۱۹، یادگیری عمیق، شبکه هرمی ویژگی، شبکه‌های عصبی کانولوشن.

۱. مقدمه

کرونا ویروس جدید با نام علمی SARS-COV-2 یک بیماری همه‌گیر است که در دسامبر ۲۰۱۹ در شهر ووهان، استان هوبئی، چین پیدا شده و از آنجا به سایر نقاط جهان گسترش یافت [۱]. کووید ۱۹ سومین کروناویروس پس از دو ویروس SARS و MERS در دو دهه اخیر است که با عبور از گونه‌های حیوانی انسان‌ها را نیز آلوده کرد [۲]. به گزارش سازمان بهداشت جهانی، تعداد کل مبتلایان جهانی به کووید ۱۹ تا تاریخ ۱۹ دسامبر ۲۰۲۲ به ۶۴۹,۰۳۸,۴۳۷ مورد و کل فوتی‌های ناشی از این بیماری به ۶,۶۴۵,۸۱۲ نفر در جهان رسید [۳].



Resnet50V2: در یک شبکه باقی‌مانده، چندین بلوک باقی‌مانده یکی پس از دیگری روی هم چیده می‌شوند. هر بلوک باقی‌مانده از اتصالات میانبر تشکیل شده است که از یک یا چند لایه عبور می‌کند. این شبکه از معماری VGG با ۳۴ لایه الهام گرفته و سپس ساختار شبکه به نسخه‌های ۵۰، ۱۱۰ و ۱۵۲ لایه افزایش پیدا کرده است. شبکه‌های باقی‌مانده نسبت به سایر شبکه‌های کانولوشنی دقت بیشتری دارند و سریع‌تر همگرا می‌شوند. این شبکه از فیلترهای کانولوشنی با ابعاد 1×1 و 3×3 تشکیل شده است و ۲۵٫۶ میلیون پارامتر دارد [۱۶].

۲-۲ شبکه هرم و ویژگی

شبکه‌های هرمی یک جز اساسی در سیستم‌های تشخیص اشیا در اندازه‌های مختلف هستند. شبکه‌های هرمی مقیاس ناپذیر هستند، به این معنا که تغییر اندازه یک شی با تغییر سطح آن در هرم جبران می‌شود.

معماری FPN از شبکه به عنوان هرم استفاده می‌کند که در آن پیش‌بینی‌ها به‌طور مستقل در هر سطح انجام می‌شود. هدف اصلی در معماری FPN استفاده از شکل هرمی سلسه مراتب و ویژگی‌های تولید شده توسط شبکه‌های کانولوشنی عمیق است [۱۷].

شبکه هرمی از طریق یک رویکرد با اتصالات جانبی از بالا به پایین و از ترکیب نقشه‌های ویژگی با وضوح نسبتاً پایین و نقشه‌های ویژگی با وضوح بالا که بیانگر ویژگی‌های سطح پایین هستند، توانست بار محاسباتی را کاهش دهد و به دقت بالا برسد [۱۸].

۳. روش پیشنهادی

اگرچه FPN برای شبکه‌های تشخیص اشیا توسعه داده شده است، به دلیل وجود عفونت‌هایی با اندازه‌های متفاوت در تصاویر سی‌تی اسکن کووید، در پژوهش [۱۴] مدل جدیدی برای تشخیص و طبقه‌بندی تصاویر سی‌تی اسکن کووید ارائه شد. با الهام از این پژوهش، در این مطالعه از ترکیب دو شبکه InceptionV3 و ResNet50v2 برای استخراج سلسه مراتبی ویژگی استفاده شد. مشابه مقاله مرجع [۱۴] از شبکه هرمی ویژگی برای تشخیص بهتر ضایعات با اندازه‌های مختلف استفاده شد. مدل پیشنهادی در این پژوهش در شکل ۱ نشان داده شده است.

در ابتدا تصویر سی‌تی اسکن ریه به عنوان ورودی شبکه با اندازه (۳، ۳۰۰، ۳۰۰) به‌طور موازی به دو شبکه عمیق InceptionV3 و Resnet50V2 داده شد. به‌منظور تشخیص ضایعات با اندازه‌های مختلف، نقشه‌های ویژگی تولید شده توسط این دو شبکه عمیق،

ResNet152 و InceptionResNetV2، Resnet50 و Resnet101 با استفاده از یادگیری انتقالی، برای طبقه‌بندی دو کلاس تصاویر اشعه ایکس استفاده شد. با توجه به نتایج بدست آمده، شبکه Resnet50 بهترین کارایی را در طبقه‌بندی چهار کلاس تصاویر کووید ۱۹ با دقت ۹۶/۱٪ داشت. در پژوهش دیگر [۱۳]، از ترکیب دو شبکه کانولوشنی از پیش آموزش دیده Xception و Resnet50V2 به منظور افزایش دقت طبقه‌بندی سه کلاس تصاویر اشعه ایکس بهره بردند. همچنین، در [۱۴] با به کارگیری شبکه ResNet50V2 و تغییر شبکه هرم ویژگی^۱، به تشخیص کووید ۱۹ از تصاویر سی‌تی اسکن پرداخته شد. به دلیل استفاده از پایگاه داده نامتوازن، مدل پیشنهاد شده حساسیت پایینی را ارائه کرد.

از آنجا که مساله دقت تشخیص به دلیل کشنده بودن بیماری کووید ۱۹ یک مساله مهم است، در این مطالعه از ترکیب دو شبکه کانولوشنی Inceptionv3 و Resnet50v2 برای بهبود دقت دسته‌بندی استفاده شد. از طرفی به دلیل این که اندازه‌های متفاوت ضایعات کووید ۱۹ برای تشخیص این بیماری یک چالش محسوب می‌شود، استفاده از شبکه هرم ویژگی علاوه بر افزایش دقت، باعث کاهش بار محاسباتی و افزایش سرعت نیز شده است. به علاوه، استفاده از پایگاه داده متوازن موجب افزایش حساسیت در طبقه‌بندی تصاویر شد.

۲. مواد و روش‌ها

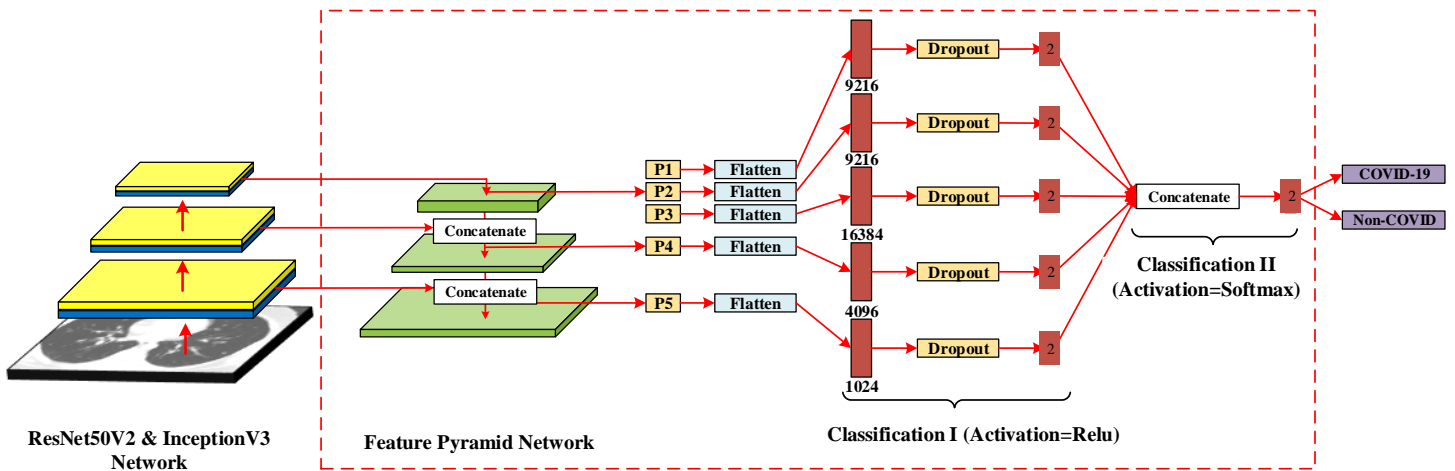
از آنجایی که در این مقاله، برای دسته‌بندی بیماری کووید ۱۹ از روی تصاویر سی‌تی اسکن ریه، از ترکیب شبکه‌های عصبی کانولوشنی InceptionV3 و Resnet50V2 طی ساختار سلسه مراتبی به همراه شبکه FPN استفاده شده است، در ادامه به مرور کوتاهی از این شبکه‌ها پرداخته می‌شود.

۲-۱ شبکه‌های عصبی کانولوشنی

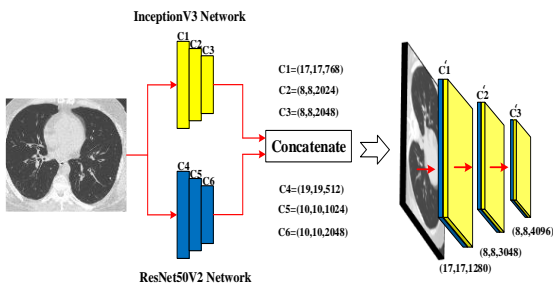
InceptionV3: این مدل ۴۸ لایه عمیق دارد که با استفاده از مجموعه داده Imagenet آموزش داده شده است. معماری این شبکه به گونه‌ای طراحی شده است که با وجود ساختار عمیق آن، تعداد پارامترهای آموزشی به میزان چشم‌گیری در مقایسه با سایر شبکه‌های عصبی کمتر است. آموزش این شبکه با به کارگیری هسته‌های کانولوشنی کوچک‌تر و جایگزینی هسته‌های 5×5 با هسته‌های 3×3 سرعت گرفته است [۱۵].

¹ Feature Pyramid Network

برگرفته از ساختار پیشنهادی در [۱۴]



شکل ۱: معماری پیشنهادی در این پژوهش با الهام از مقاله [۱۴]



شکل ۲: ساختار پیشنهادی ادغام نقشه‌های ویژگی دو شبکه Resnet50V2 & InceptionV3

۴. آزمایش‌ها و ارزیابی

در این بخش نتایج مربوط به روش پیشنهادی ارائه شده‌اند. کلیه آزمایش‌های مربوطه روی سیستم Google Colab با مشخصات Tesla T4 GPU- 12G RAM در محیط تنسورفلو انجام شده است.

به‌طور کلی مجموعه داده‌های موجود در مساله کووید ۱۹ به دو دسته تصاویر اشعه ایکس و تصاویر سی تی اسکن تقسیم‌بندی می‌شود. تصاویر اشعه ایکس در دسترس‌تر و ارزان‌تر هستند ولی تشخیص بیماری از تصاویر سی تی اسکن دقیق‌تر است. در این مقاله، از مجموعه داده سی تی اسکن SARS-COV-2 استفاده شده است که در دسترس عموم قرار دارد [۱۹]. این پایگاه داده از ۲۴۸۲ تصویر در دو کلاس تشکیل شده که ۱۲۵۲ تصویر از آن مربوط به

در سه سطح متفاوت استخراج شد. پس از یکسان‌سازی ابعاد نقشه‌های ویژگی استخراج شده توسط مدل InceptionV3 با شبکه ResnetV2، نقشه‌های ویژگی متناظر در هر سطح با هم ادغام شدند. جزئیات نقشه‌های ویژگی استخراج شده با اندازه‌های مختلف و ادغام آن‌ها در شکل ۲ آورده شده است. این سه سطح ویژگی ادغامی، به عنوان ورودی به شبکه هرمی ویژگی (FPN) داده می‌شود. با اتصالات از بالا به پایین شبکه هرمی، ویژگی استخراج شده توسط شبکه‌های عمیق پس از اعمال یک لایه کانولوشنی، با ویژگی استخراج شده در سطح بعدی ادغام می‌شود. برخلاف شبکه هرمی ویژگی در [۱۷]، در مدل پیشنهادی همانند مدل ارائه شده در [۱۴] برای ادغام اتصالات از بالا به پایین، از الحاق ویژگی‌ها به جای جمع کردن آن‌ها استفاده شده است. در نهایت پنج ویژگی از شبکه هرمی ویژگی استخراج می‌شود که هر کدام بیانگر ویژگی تصویر در اندازه‌های مختلف است. پس از آن برای جلوگیری از بیش‌برازش، از لایه Dropout (۰/۵) استفاده شد. در انتهای مدل پیشنهادی، پنج لایه دسته‌بندی شده که خود بیانگر نقشه ویژگی در اندازه‌های متفاوت است، با هم ترکیب می‌شود. پس از اعمال فعال‌ساز Softmax، طبقه‌بندی دو کلاسه تصاویر ریه انجام شد.

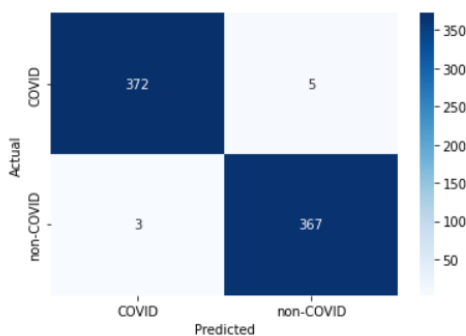


در جدول ۳ عملکرد روش پیشنهادی با پژوهش [۱۴] مقایسه شده است. به منظور امکان مقایسه مدل ارائه شده با پژوهش [۱۴]، هر دو مدل با یک شرایط آزمایش، روی پایگاه داده SARS-COV-2 آموزش دیده اند. به دلیل استفاده از پایگاه داده متوازن و ترکیب دو شبکه کانولوشنی برای استخراج تصاویر، دقت و حساسیت طبقه‌بندی روش پیشنهادی در مقایسه با شبکه دست آمده، نشان دهنده عملکرد دقیق مدل پیشنهادی در تشخیص کووید ۱۹ است.

جدول ۳: مقایسه کارایی مدل‌ها بر پایگاه داده SARS-COV-2

مدل / پارامتر	برچسب	صحت	حساسیت	F1	دقت
ResNet50v2 + FPN [14]	کووید ۱۹	۰/۹۴	۰/۹۹	۰/۹۷	۹۶/۵۱
	سالم	۰/۹۹	۰/۹۴	۰/۹۶	-
InceptionV3 + ResNet50 V2 + FPN	کووید ۱۹	۰/۹۷	۰/۹۹	۰/۹۹	۹۸/۹۲
	سالم	۰/۹۷	۰/۹۹	۰/۹۹	-

در شکل ۳، ماتریس سردرگمی مدل پیشنهادی نشان داده شده است. نرخ منفی کاذب نمونه‌ها کم است که نشان‌دهنده کارایی مدل پیشنهادی است. نمونه ای از تصاویر منفی کاذب و مثبت کاذب در شکل ۴ آورده شده است.



شکل ۳: ماتریس سردرگمی مدل پیشنهادی

بیماران مبتلا به کووید ۱۹ و ۱۲۳۰ تصویر از آن مربوط به افراد سالم است.

به منظور جلوگیری از بیش‌برازش شبکه، از داده‌افزایی برای افزایش تعداد تصاویر پایگاه داده بهره گرفته شد، که جزئیات آن در جدول ۱ آورده شده است.

جدول ۱: جزئیات داده‌افزایی بر پایگاه داده SARS-COV-2

روش‌های داده‌افزایی	مقدار
برگرداندن افقی	بله
بزرگ نمایی	۰/۲
چرخش	۴۵ درجه
بریدن	۰/۲
تغییر مقیاس	۱/۲۵۵

برای ارزیابی کارایی مدل پیشنهادی از معیارهای صحت، دقت، حساسیت و امتیاز F1 به منظور ارزیابی مدل پیشنهادی استفاده شده که طبق روابط (۱-۴) محاسبه می‌شود که TP، TN، FP و FN به ترتیب مثبت کاذب، منفی حقیقی، مثبت کاذب و منفی کاذب نمونه‌ها در دسته‌های طبقه‌بندی است [۱۴].

$$\text{Accuracy} = (TP + TN) / (P + N) \quad (1)$$

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

$$\text{Sensitivity} = TP / (TP + FN) \quad (3)$$

$$F1 = 2 \times \text{Precision} \times \text{Sensitivity} / (\text{Precision} + \text{Sensitivity}) \quad (4)$$

آزمایش ۱: تصاویر پایگاه داده به سه دسته آموزش، اعتبارسنجی و آزمون، به ترتیب با نسبت‌های ۵۰٪، ۲۰٪ و ۳۰٪ گروه‌بندی شد. جزئیات تعداد تصاویر هر دسته در داده‌های آموزش، ارزیابی و آزمون در جدول ۲ قرار داده شده است.

جدول ۲: گروه‌بندی تصاویر مربوط به هر دسته در پایگاه داده

SARS-COV-2 [۱۹].

پایگاه داده	کووید ۱۹	سالم	مجموع
داده‌های آموزش	۶۲۶	۶۱۴	۱۲۴۰
داده‌های ارزیابی	۲۵۰	۲۴۵	۴۹۵
داده‌های آزمون	۳۷۶	۳۷۰	۷۴۷

۹۵/۵۷، دقت بالاتر و انحراف معیار کمتر را ارائه کرده است. در نتیجه، روش پیشنهادی کارایی مطلوب و قابلیت تعمیم بر سایر مجموعه داده‌ها را دارد.


۵. نتیجه‌گیری

انتشار بیماری کووید ۱۹ در سراسر جهان همچنان ادامه دارد. با توجه به اهمیت بالای تصاویر سی تی اسکن ریه در شناسایی بیماران مبتلا به کووید ۱۹، ایجاد مدلی مبتنی بر یادگیری عمیق از اهداف این مقاله بود.

به دلیل وجود ضایعه‌هایی با اندازه‌های مختلف در تصاویر سی تی اسکن ریه، تشخیص این بیماری با چالش روبرو است. مدل پیشنهادی در این مقاله با ترکیب ویژگی‌های عمیق حاصل از دو شبکه InceptionV3 و Resnet50V2 و همچنین بهره‌گیری از شبکه هرمی ویژگی، دقت تشخیص بیماری کووید ۱۹ را بهبود داده است. برای ارزیابی و مقایسه کارایی مدل پیشنهادی و مدل ارائه شده در پژوهش [۱۴]، از پایگاه داده متوازن SARS-COV-2 که شامل ۲۴۸۴ تصویر سی تی اسکن است، استفاده شد. به دلیل متوازن بودن تعداد تصاویر دو دسته در این پایگاه داده، ترکیب نقشه‌های ویژگی استخراج شده از دو شبکه کانولوشنی عمیق و بهره‌گیری از شبکه هرمی ویژگی، مدل پیشنهادی به دقت ۹۷/۸۹٪ رسید که در مقایسه با الگوریتم ارائه شده در [۱۴] بهبود داشته است.

مراجع

- [1] A. S. Fauci, H. C. Lane, and R. R. Redfield, "Covid-19—navigating the uncharted," vol. 382, ed: Mass Medical Soc, 2020, pp. 1268-1269.
- [2] T. P. Velavan and C. G. Meyer, "The COVID - 19 epidemic," *Tropical medicine & international health*, vol. 25, no. 3, p. 278, 2020.
- [3] WHO Coronavirus Disease (WHO) [https://www.who.int/redirect-pages/page/novel-coronavirus-\(covid-19\)-situation-dash-board](https://www.who.int/redirect-pages/page/novel-coronavirus-(covid-19)-situation-dash-board), accessed 19 December 2022.
- [4] L. Lan *et al.*, "Positive RT-PCR test results in patients recovered from COVID-19," *Jama*, vol. 323, no. 15, pp. 1502-1503, 2020.
- [5] P. Dashraath *et al.*, "Coronavirus disease 2019 (COVID-19) pandemic and pregnancy," *American journal of obstetrics and gynecology*, vol. 222, no. 6, pp. 521-531, 2020.
- [6] H. S. Maghdid, A. T. Asaad, K. Z. Ghafoor, A. S. Sadiq, S. Mirjalili, and M. K. Khan, "Diagnosing COVID-19 pneumonia from X-ray and CT images using deep learning and transfer learning algorithms," in *Multimodal image exploitation and learning 2021*, 2021, vol. 11734: SPIE, pp. 99-110.
- [7] G. Wang *et al.*, "A noise-robust framework for automatic segmentation of COVID-19 pneumonia lesions from CT images," *IEEE Transactions on Medical Imaging*, vol. 39, no. 8, pp. 2653-2663, 2020.
- [8] D.-P. Fan *et al.*, "Inf-net: Automatic covid-19 lung infection segmentation from ct images," *IEEE Transactions on Medical Imaging*, vol. 39, no. 8, pp. 2626-2637, 2020.
- [9] A. Amyar, R. Modzelewski, H. Li, and S. Ruan, "Multi-task deep learning based CT imaging analysis for COVID-19 pneumonia: Classification and segmentation," *Computers in Biology and Medicine*, vol. 126, p. 104037, 2020.



شکل ۴: نمونه ای از تصاویر منفی کاذب (تصویر سمت راست) و مثبت کاذب (تصویر سمت چپ)

آزمایش ۲: برای ارزیابی بهتر نتایج مدل پیشنهادی در این مقاله، کارایی الگوریتم پیشنهادی طی اعتبارسنجی سه پوشه‌ای با الگوریتم ارائه شده در [۱۴] مقایسه شده و نتیجه در جدول ۴ نشان داده شده است.

اعتبارسنجی متقابل روشی برای ارزیابی کارایی یک مدل یادگیری عمیق است و تعیین می‌کند که نتایج مدل پیشنهادی بر روی مجموعه داده تا چه اندازه می‌تواند قابل تعمیم و مستقل از داده‌های آموزشی باشد. برای جلوگیری از بیش‌برازش و بهتر آموزش دیدن مدل، دو سوم داده‌ها برای آموزش و یک سوم آن برای آزمون در نظر گرفته شد. آموزش شبکه سه بار انجام می‌شود و هر بار شبکه بخش جدیدی از داده‌ها را می‌بیند. دقت نهایی که میانگینی از دقت این سه مرتبه آموزش است، در جدول ۴ نشان داده شده است.

جدول ۴: مقایسه کارایی مدل‌ها بر پایگاه داده SARS-COV-2 طی

اعتبارسنجی سه پوشه‌ای

مدل / پارامتر	برچسب	صحت	حساسیت	F1	دقت
ResNet50v2 + FPN [14]	کووید ۱۹	۰/۹۷	۰/۹۸	۰/۹۵	۹۵/۵۷
	سالم	۰/۹۴	۰/۹۵	۰/۹۵	
InceptionV3 + ResNet50 V2 + FPN	کووید ۱۹	۰/۹۷	۰/۹۹	۰/۹۸	۹۷/۸۹
	سالم	۰/۹۹	۰/۹۶	۰/۹۸	

همان‌طور که در جدول ۴ پیدا است، دقت، صحت و حساسیت روش پیشنهادی با اعتبارسنجی سه پوشه‌ای نیز، در مقایسه با روش ارائه شده در [۱۴]، بالاتر است. میانگین دقت مدل پیشنهادی در این آزمایش بر روی سه پوشه $0.97/0.89 \pm 0.49$ است که در مقایسه با دقت پژوهش [۱۴] با میانگین دقت $0.86/0.82 \pm$



- [10] E. Hussain, M. Hasan, M. A. Rahman, I. Lee, T. Tamanna, and M. Z. Parvez, "CoroDet: A deep learning based classification for COVID-19 detection using chest X-ray images," *Chaos, Solitons & Fractals*, vol. 142, p. 110495, 2021.
- [11] M. Barstugan, U. Ozkaya, and S. Ozturk, "Coronavirus (covid-19) classification using ct images by machine learning methods," arXiv preprint arXiv:2003.09424, 2020.
- [12] A. Narin, C. Kaya, and Z. Pamuk, "Automatic detection of coronavirus disease (covid-19) using x-ray images and deep convolutional neural networks," *Pattern Analysis and Applications*, vol. 24, no. 3, pp. 1207-1220, 2021.
- [13] M. Rahimzadeh and A. Attar, "A modified deep convolutional neural network for detecting COVID-19 and pneumonia from chest X-ray images based on the concatenation of Xception and ResNet50V2," *Informatics in medicine unlocked*, vol. 19, p. 100360, 2020.
- [14] M. Rahimzadeh, A. Attar, and S. M. Sakhaei, "A fully automated deep learning-based network for detecting covid-19 from a new and large lung ct scan dataset," *Biomedical Signal Processing and Control*, vol. 68, p. 102588, 2021.
- [15] C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens, and Z. Wojna, "Rethinking the inception architecture for computer vision," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2016, pp. 2818-2826.
- [16] A. N. Gomez, M. Ren, R. Urtasun, and R. B. Grosse, "The reversible residual network: Backpropagation without storing activations," *Advances in neural information processing systems*, vol. 30, 2017.
- [17] T.-Y. Lin, P. Dollár, R. Girshick, K. He, B. Hariharan, and S. Belongie, "Feature pyramid networks for object detection," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2017, pp. 2117-2125.
- [18] S. Notghimoghdam, H. Farsi, and S. Mohamadzadeh, "Object Detection by a Hybrid of Feature Pyramid and Deep Neural Networks," *Journal of Electrical and Computer Engineering Innovations (JECIEI)*, vol. 11, no. 1, pp. 173-182, 2023.
- [19] 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*, p. 2020.04. 24.20078584, 2020.