

## تشخیص بیماری کووید-۱۹ با ترکیب روش‌های دستی و یادگیری عمیق از روی تصاویر اولتراسوند

ویدا اسماعیلی<sup>۱</sup>، محمود محصل‌فقهی<sup>۲</sup>

### چکیده

بیماری کروناویروس ۲۰۱۹ یا کووید-۱۹، یک بیماری حاد تنفسی با قدرت انتقال ویروس بالا است که موجب نرخ بالای مرگ و میر در سراسر جهان شده است. اگرچه تشخیص سریع این بیماری می‌تواند نقش حیاتی در بهبود بیمار داشته باشد، اما انجام آزمایش‌های رادیوگرافی توسط کادر درمان فرآیند زمان‌بری است. بنابراین، استفاده از تصاویر اولتراسوند و روش‌های یادگیری عمیق توصیه می‌شود. تکنیک اولتراسوند بدون اشعه است و می‌تواند در بخش‌های اطفال و مراقبت‌های ویژه برای بیماران خاص مورد استفاده قرار گیرد. با این حال، تصاویر آن دارای نویز است که عملکرد روش‌های یادگیری عمیق را تحت تأثیر قرار می‌دهد. به همین منظور، در این مقاله، ما روش الگوی باینری محلی یکنواخت را که در مقابل نویز مقاوم است با روش یادگیری عمیق ترکیب می‌کنیم. ابتدا الگوی باینری محلی یکنواخت بر روی دو صفحه‌ی زمانی محاسبه می‌شود تا ویژگی‌های مربوط به تظاهرات کووید-۱۹ در تصاویر متوالی اولتراسوند استخراج شود و سپس، ماتریس به دست آمده به عنوان ورودی شبکه‌ی کانولوشنی داده می‌شود. با توجه به آزمایش‌های انجام شده، روش پیشنهادی عملکرد بهتری در مقایسه با سایر روش‌های پیشرفته دارد. نتایج نشان می‌دهد که دقت شناسایی کووید-۱۹ از روی داده‌های اولتراسوند با استفاده از روش پیشنهادی ۹۸٫۵ درصد است.

### کلیدواژه‌ها

تشخیص کووید-۱۹، تصاویر اولتراسوند، یادگیری عمیق

### ۱ مقدمه

شده است<sup>۱</sup>. این نرخ بالای مرگ و میر باعث ایجاد وحشت عمومی در میان انسان‌ها شده است. بطوریکه ترس از سرایت این ویروس از فردی به فرد دیگر، اقتصاد، آموزش، حمل و نقل، تعاملات اجتماعی و ... را مختل کرده است.

بیماری کووید-۱۹ برای اولین بار در سال ۲۰۱۹ میلادی در ووهان چین شیوع پیدا کرد و به دلیل قدرت انتقال بالا، به سرعت در کل جهان انتشار یافت [1]. سازمان بهداشت جهانی در سال ۲۰۲۰ میلادی آن را یک بیماری مسری و جهانی اعلام کرد [2]. علائم این بیماری عبارتند از: تب بالای ۳۷٫۵ درجه سانتی‌گراد،

تا امروز ۲۴ آبان ۱۴۰۰، در مجموع ۵,۰۹۴,۸۲۶ مورد مرگ ناشی از بیماری کروناویروس یا کووید-۱۹ در سراسر جهان گزارش

این مقاله در آذرماه ۱۴۰۰ دریافت، در بهمن‌ماه بازنگری و سپس پذیرفته شد.

<sup>۱</sup> دانشجوی دکتری مهندسی برق-مخابرات سیستم، دانشکده مهندسی برق و کامپیوتر، دانشگاه تبریز، بلوار ۲۹ بهمن، تبریز، ایران.

رایانامه: [v.esmaeili@tabrizu.ac.ir](mailto:v.esmaeili@tabrizu.ac.ir)

<sup>۲</sup> استادیار، دانشکده مهندسی برق و کامپیوتر، دانشگاه تبریز، بلوار ۲۹ بهمن، تبریز، ایران.

رایانامه: [mohasselfeghi@tabrizu.ac.ir](mailto:mohasselfeghi@tabrizu.ac.ir)

<sup>1</sup> [https://covid19.who.int/?gclid=EAIaIQobChMIsoPM16fw8wIVSqmWCh2swADqEAAYASABEGLsx\\_D\\_BwE](https://covid19.who.int/?gclid=EAIaIQobChMIsoPM16fw8wIVSqmWCh2swADqEAAYASABEGLsx_D_BwE)

نویسنده مسئول: محمود محصل‌فقهی

تصاویر می‌تواند با روش‌های مختلف پردازش تصویر کاهش یابد و یا حتی حذف شود [11-12].

امروزه، تفسیر تصاویر پزشکی با استفاده از روش‌های یادگیری عمیق مورد توجه است تا تشخیص، بسیار سریع و بدون خطای انسانی انجام شود [5, 6, 11, 13, 14]. ترکیب روش‌های یادگیری ماشین آموزش‌دیده با ویژگی‌های دستی<sup>۵</sup> (روش‌های دستی) و روش‌های یادگیری عمیق می‌تواند عملکرد را بهبود بخشد. به‌عنوان مثال، روش الگوی باینری محلی یکنواخت مقاوم در برابر چرخش<sup>۶</sup> و نویز تصویر [15] به‌عنوان یک روش دستی می‌تواند با یکی از مدل‌های شبکه‌ی عصبی کانولوشنی<sup>۷</sup> ترکیب شود تا نویز تصاویر اولتراسوند بر عملکرد شبکه تأثیر نگذارد.

استفاده از هر یک از مدل‌های شبکه‌ی عصبی کانولوشنی نیز مزایا و معایبی دارد. مثلاً، AlexNet [16] خطای کمتری در طبقه‌بندی تصاویر دارد اما با توجه به دارا بودن عمق کم، نیاز به زمان بیشتری برای دستیابی به دقت بالا دارد. VGG [17] عمق بیشتری نسبت به AlexNet دارد اما افزایش بیشتر عمق آن منجر به ناپدید شدن گرادیان‌ها<sup>۸</sup> می‌شود. آموزش GoogLeNet [18] سریع‌تر از VGG است اما پیچیدگی محاسباتی بالایی دارد. MobileNet [19] محاسبات و تعداد پارامترهای کمتری نسبت به GoogLeNet دارد و زمان تأخیر آن کم است. با این حال، دقت آن کمی پایین است. ResNet [20] مشکل ناپدید شدن گرادیان را حل کرده است. همچنین، نیاز به زمان آموزش کمتری دارد. اما معماری آن کمی پیچیده است.

قرار دادن ویژگی‌های مفید مربوط به کووید-۱۹ در اختیار شبکه می‌تواند دقت و سرعت را ارتقاء بخشد. مشخص شده است که نمایان شدن کووید-۱۹ در تصاویر اولتراسوند به‌صورت خطوط عمودی دنباله‌دار و خط پلور<sup>۹</sup> ناپیوسته، ضخیم و ناصاف است [3, 21-22]. اگر ویدئوی اولتراسوند به‌صورت تصاویر متوالی باشد، صفحات زمانی می‌توانند وجود خطوط عمودی و خط پلور ناپیوسته و ضخیم افقی را نمایان کنند. این صفحات که در راستای محور زمان در نظر گرفته می‌شوند، نقش بسزایی در دریافت ویژگی‌های با اهمیت و معنادار دارند [23-27].

بدین ترتیب در این مقاله، ما دو صفحه‌ی زمانی را که یکی در راستای خطوط عمودی و دیگری در راستای خط پلور می‌تواند ویژگی‌های مربوط به کووید-۱۹ را از تصاویر متوالی اولتراسوند دریافت کند، معرفی می‌کنیم. روش الگوی باینری محلی یکنواخت مقاوم در برابر چرخش و نویز تصویر بر روی این دو صفحه اعمال می‌شود. سپس، بردار ویژگی استخراج شده را به‌عنوان ورودی به شبکه عصبی کانولوشنی می‌دهیم. این کار سبب بهبود عملکرد شناسایی کووید-۱۹ در تصاویر اولتراسوند خواهد شد. شکل ۱

سرفه خشک، تنگی نفس، درد عضلانی، از دست دادن حس چشایی یا بویایی، خستگی، علائم گوارشی، سردرد و گلو درد [3-4]. از نظر علائم ظاهری شبیه آنفلوآنزا است اما ضایعات ریوی بیشتری دارد [5]. علت مرگ ناشی از این بیماری نیز التهاب ریه و پر شدن کیسه‌های هوایی با ترشحات است که مانع از دریافت اکسیژن کافی می‌شود [6].

تشخیص دقیق و سریع بیماری کووید-۱۹ در مراحل اولیه‌ی بروز آن نقش حیاتی در بهبود بیمار دارد [3]. همچنین، شناسایی سریع بیمار مبتلا به کووید-۱۹ می‌تواند تصمیم‌گیری فوری برای بستری یا قرنطینه کردن بیمار را به‌دنبال داشته باشد که خود منجر به کاهش انتقال ویروس به سایر افراد خواهد شد. علاوه بر این، مشکل محدود بودن منابع مراقبت‌های بهداشتی از جمله تخت‌های بیمارستان با تصمیم فوری و دقیق برای پذیرش یا ترخیص مراجعه‌کنندگان برطرف خواهد شد.

برای تشخیص این بیماری از واکنش زنجیره‌ای پلیمراز رونویسی معکوس<sup>۱</sup> استفاده می‌شود که پر زحمت و زمان‌بر است. گاهی نتیجه‌ی آن پس از گذشت ۲۴ ساعت در دسترس است [2]. ۳۰ درصد منفی کاذب<sup>۲</sup> برای نتیجه‌ی این آزمایش گزارش شده است [7-8]. بنابراین، دقت آن مشخص نیست [7]. زیرا در مواردی فرد ممکن است مبتلا به کووید-۱۹ باشد اما آزمایش، عدم وجود بیماری را نشان دهد. اگر نتیجه‌ی این آزمایش برای فردی منفی باشد، آنگاه توموگرافی کامپیوتری<sup>۳</sup> یا سی تی اسکن ریه می‌تواند صحت آن را تأیید و یا تکذیب کند.

این تصویربرداری از ریه، ارزیابی سریع بیماران را در مدت کمتر از ۲۰ دقیقه امکان‌پذیر می‌سازد [3]. با این حال، دارای معایبی از جمله: قرار گرفتن در معرض اشعه‌ی بیشتر است [9]. در واقع، اشعه‌ی ایکس ساطع می‌کند که انرژی بسیار بالایی دارد. بنابراین، برای کودکان توصیه نمی‌شود [3].

روش تصویربرداری رادیوگرافی (رادیولوژی) قفسه سینه در دسترس است. هزینه و زمان تصویربرداری آن کمتر از سی تی اسکن است. در این روش از اشعه‌ی ایکس به مقدار بسیار کم استفاده می‌شود. با وجود مزایای ذکر شده، حساسیت<sup>۴</sup> کمتری نسبت به سی تی اسکن دارد [3].

در نتیجه، استفاده از یک روش تشخیص تکمیلی که دقیق، ایمن و قابل حمل باشد، ضروری است. جالب است که روش سونوگرافی (اولتراسوند) این الزامات را برآورده می‌کند [9]. این روش بدون اشعه است و می‌تواند در بخش‌های اطفال و مراقبت‌های ویژه مورد استفاده قرار گیرد [10]. همچنین، دقت و حساسیت آن نسبت به روش‌های قبلی بالاتر است [3, 10]. مشکل این روش، تولید تصاویر نویزی است. البته نویز موجود در این

<sup>5</sup> Handcrafted features

<sup>6</sup> Rotation Invariant Uniform Local Binary Pattern (LBP<sup>riu2</sup>)

<sup>7</sup> Convolutional Neural Network (CNN) models

<sup>8</sup> vanishing gradients

<sup>9</sup> pleural line

<sup>1</sup> Reverse Transcription Polymerase Chain Reaction (RT-PCR)

<sup>2</sup> false-negative

<sup>3</sup> Computed Tomography (CT)

<sup>4</sup> sensitivity

[28]. حساسیت<sup>۲</sup>، ویژگی<sup>۳</sup>، و امتیاز F1 به ترتیب ۰,۷۹، ۰,۹۶ و ۰,۹۲، با اعتبارسنجی متقابل پنج برابر<sup>۴</sup> به دست آمد [13]. در [29] مدل GoogLeNet/InceptionV3 از قبل آموزش-دیده، با تصاویر اولتراسوند پایگاه داده‌ی POCUS [13] آموزش داده شد. بهترین میانگین دقت به دست آمده ۸۹,۱٪ برای شناسایی کووید-۱۹ بود. علاوه بر این، روش LUS-Net در [30] برای طبقه بندی تصاویر اولتراسوند ریه پیشنهاد شد. این روش از U-Net [31] استفاده می‌کند. میانگین دقت آن ۹۷ درصد بود.

برای طبقه بندی نشانه‌های بیماری کووید-۱۹، یک شبکه سبک وزن در [32] ارائه شد. در واقع، از MobileNet در این پژوهش استفاده شد [32]. داده‌های اولتراسوند از منابع مختلف اینترنتی جمع‌آوری شدند و سپس، توسط دو متخصص رادیولوژی (رادیولوژیست) حاشیه‌نویسی شدند. دقت به دست آمده با استفاده از MobileNet بیش از ۹۵٪ بود.

### ۳ روش پیشنهادی

ما ترکیب روش دستی بر روی دو صفحه‌ی زمانی و روش یادگیری عمیق را برای تشخیص بیماری کووید-۱۹ از داده‌های اولتراسوند پیشنهاد می‌کنیم. این دو صفحه‌ی مفید و پر اهمیت می‌توانند بافت تصاویر و نشانه‌های کووید-۱۹ را به طرز ماهرانه‌ای توصیف کنند. فریم‌های ویدئوی اولتراسوند پشت سر هم ردیف می‌شوند تا دو صفحه‌ی پیشنهادی، پیکسل‌های آن‌ها را دربرگیرند. اگر  $\rho$  پیکسلی در مرکز دایره‌ای به شعاع  $\gamma$  باشد که تعداد  $\beta$  پیکسل بر روی این دایره قرار گرفته‌اند و هر یک از این پیکسل‌ها را با  $\zeta_{f=1, \dots, \beta}$  نشان دهیم؛ آنگاه، الگوی باینری محلی یکنواخت مقاوم در برابر چرخش و نویز تصویر [15] و هیسوگرام آن به ترتیب از رابطه‌ی ۱ و رابطه‌ی ۲ در هر یک از دو صفحه‌ی پیشنهادی قابل محاسبه است:

$$U(LBP_{\beta, \gamma}) = \left| \operatorname{sgn}(\zeta_{\beta-1} - \rho) - \operatorname{sgn}(\zeta_0 - \rho) \right| + \sum_{f=1}^{\beta-1} \left| \operatorname{sgn}(\zeta_f - \rho) - \operatorname{sgn}(\zeta_{\beta-1} - \rho) \right| \quad (1)$$

$$LBP_{\beta, \gamma}^{rtw2} = \begin{cases} \sum_{f=0}^{\beta-1} \operatorname{sgn}(\zeta_f - \rho) & \text{if } U(LBP_{\beta, \gamma}) \leq 2 \\ \beta + 1 & \text{otherwise} \end{cases} \quad (2)$$

روش الگوی باینری محلی یکنواخت مقاوم در برابر چرخش و نویز، مقدار سطح خاکستری  $\rho$  را با مقدار هر یک از همسایگان  $\zeta$  (ها) سمت چپ، پایین، راست، و بالا (اطراف) مقایسه می‌کند.

چارچوب کلی اعمال روش شناسایی کووید-۱۹ پیشنهادی بر روی تصاویر اولتراسوند را نشان می‌دهد. نوآوری این مقاله، ترکیب روش الگوی باینری محلی یکنواخت مقاوم در برابر چرخش و نویز در دو صفحه‌ی زمانی با شبکه عصبی کانولوشنی است. تا جائیکه ما اطلاع داریم تاکنون اعمال دو صفحه‌ی زمانی بر روی تصاویر اولتراسوند و ترکیب ویژگی‌های دستی مستخرج از آن با روش‌های یادگیری عمیق انجام نشده است. همچنین، ما از فریم‌های متوالی ویدئوی اولتراسوند استفاده می‌کنیم.

در ادامه، هر یک از بخش‌های مرور پژوهش‌های پیشین، روش پیشنهادی، آزمایش‌ها و نتایج و بحث بر روی آن‌ها، و نتیجه‌گیری به ترتیب بیان خواهد شد.

### ۲ مروری بر پژوهش‌های پیشین

از آنجائیکه روش‌های یادگیری عمیق می‌توانند درک سریعی از وضعیت بیماران بدحال از روی تصاویر پزشکی ارائه دهند، یک شبکه‌ی طبقه بندی کننده بر اساس نشانگرهای زیستی بیماری کووید-۱۹ در داده‌های اولتراسوند در سال ۲۰۲۰ پیشنهاد شد [14]. این شبکه از شبکه‌های ترانسفورماتور فضایی به دست آمده بود. دوپست و هفتاد و هفت داده‌ی سونوگرافی ریه به این شبکه داده شد. این اولین پژوهش بر روی داده‌های اولتراسوند کووید-۱۹ بود. داده‌ها توسط نویسندگان جمع‌آوری و سازماندهی شدند. میانگین امتیاز F1، ۷۱/۴ درصد به دست آمد.

سپس، مدل VGG-19 توسط هوری<sup>۱</sup> و همکاران انتخاب شد [11]. آن‌ها نشان دادند که مدل بهینه‌شده را می‌توان برای مجموعه داده‌ی بسیار کم استفاده کرد. مشخص شد که یک شبکه‌ی از پیش آموزش دیده می‌تواند با تصاویر کم اولتراسوند مربوط به کووید-۱۹ آموزش ببیند و آن‌ها را تفسیر و طبقه بندی کند. طبق نتایج آزمایش‌های آن‌ها، عملکرد برای ۳ دسته (کووید-۱۹، سالم (ریه طبیعی) و ذات الریه) با اندازه گیری F1، ۰/۹۸ بود. همچنین، آن‌ها دریافته‌اند که استفاده از داده‌های اولتراسوند بهترین نتایج را در مقایسه با اشعه ایکس قفسه‌ی سینه (تصاویر رادیوگرافی) و سی تی اسکن ریه تولید می‌کند.

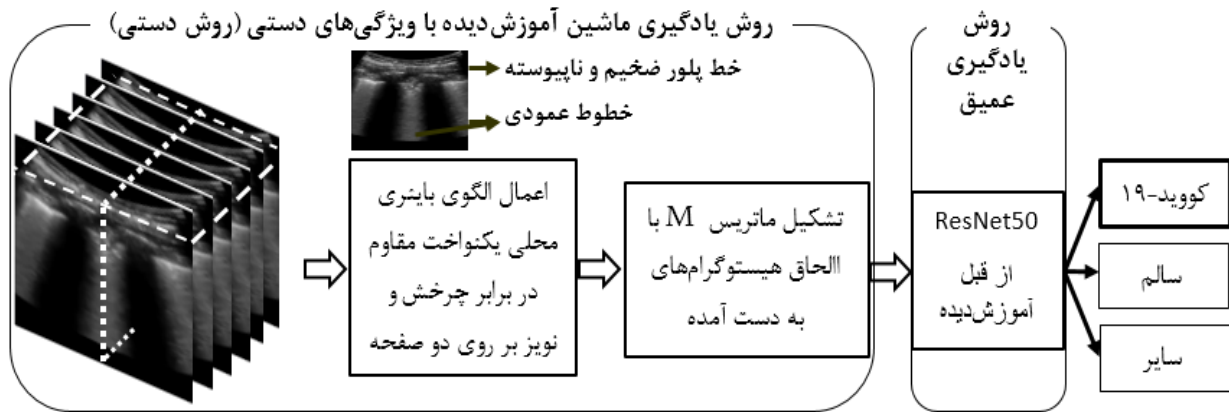
در [13] یک شبکه‌ی عصبی کانولوشنی عمیق به نام POCOVID-Net برای تشخیص کووید-۱۹ پیشنهاد شد. POCOVID-Net شامل VGG-16، یک لایه با فعال‌ساز ReLU، و یک لایه خروجی softmax است. این شبکه با داده‌های تصویر اولتراسوند POCUS [13] شامل سه دسته (کووید-۱۹، بیماری‌های ریوی دیگر، و سالم) آموزش دید. دقت با استفاده از این روش برای تشخیص کووید-۱۹، ۸۹ درصد گزارش شده است؛ در حالی که در کار توسعه یافته، دقت ۸۷ درصد است

<sup>2</sup> sensitivity

<sup>3</sup> specificity

<sup>4</sup> 5-fold cross-validation

<sup>1</sup> Horry



شکل ۱ چارچوب کلی اعمال روش پیشنهادی بر روی تصاویر متوالی اولتراسوند برای شناسایی بیماری کووید-۱۹. در این شکل، دو صفحه‌ی زمانی معرفی شده به صورت خط چین و نقطه چین بر روی تصاویر متوالی نشان داده شده‌اند.

ویژگی که ماتریس  $M$  است به صورت رابطه ۵ به دست می‌آید. سطر اول آن هیستوگرام نهایی به دست آمده از صفحه‌ی افقی است و سطر دوم متعلق به هیستوگرام صفحه‌ی عمودی است. شکل ۳، روند کلی تشکیل ماتریس  $M$  را نشان می‌دهد. ما از ماتریس  $M$  که ویژگی‌های سودمند و مؤثری را در بر دارد، به عنوان ورودی شبکه‌ی عصبی کانولوشنی استفاده می‌کنیم.

$$M = \begin{bmatrix} LBP_{\beta, \gamma}^{riu2} & \text{for first plane} \\ LBP_{\beta, \gamma}^{riu2} & \text{for second plane} \end{bmatrix} \quad (5)$$

با توجه به مزایای ResNet نسبت به سایر مدل‌های شبکه‌ی عصبی کانولوشنی و طبق نتایج آزمایش‌های اولیه انجام شده، ما از مدل ResNet50 از قبل آموزش دیده استفاده می‌کنیم که شامل ۵۰ لایه است. آموزش اولیه آن با استفاده از مجموعه داده‌ی ImageNet انجام شده است. در واقع، در ابتدا با بیش از چهارده میلیون تصویر متعلق به بیش از ۲۰۰۰۰ دسته آموزش داده شده است [33]. از مزایای استفاده از این مدل می‌توان به آموزش سریع و جلوگیری از اغواچ<sup>۲</sup> اشاره کرد [34]. همچنین، بهینه‌سازی آن آسان است و اتصالات میانبر<sup>۳</sup> در آن می‌توانند مشکل محو شدن گرادیان را حل کنند. معماری مدل ResNet50 در شکل ۴ نشان داده شده است.

همانطور که قبلاً نیز اشاره شد؛ ورودی ResNet50 از قبل آموزش دیده، ماتریس  $M$  است که ابعاد آن را به  $224 \times 224$  تغییر داده‌ایم. در واقع، استفاده از این ماتریس به جای تصویر اصلی برای رسیدن به عملکرد کارآمدتر است. بنابراین، شبکه می‌تواند ویژگی‌های عمیق، ضروری و مقاوم را استخراج کند. ما آخرین لایه‌ی ResNet50 از قبل آموزش دیده را با توجه به داده‌های خود تغییر می‌دهیم. در واقع، ما آن را با کار دسته‌بندی خود تطبیق می‌دهیم. این لایه شامل softmax و کاملاً متصل (FC) است. به


هرگاه مقدار  $\rho$  کمتر از مقدار همسایه  $\gamma$  باشد، کد "۰" را وارد می‌کند. در غیر این صورت، کد "۱". کدها را در خلاف جهت عقربه‌های ساعت دنبال کنید و پشت سر هم بنویسید. در این صورت، الگویی از اعداد ۰ و ۱ به دست می‌آید. این الگو هنگامی یکنواخت است که حداکثر دو انتقال ۰ به ۱ یا ۱ به ۰ وجود داشته باشد. به عنوان مثال،  $01000000$  دارای ۲ انتقال است. بنابراین، یکنواخت است.

مختصات هر یک از پیکسل‌های  $\gamma$  در صفحه‌ی افقی و عمودی به ترتیب از روابط ۳ و ۴ محاسبه می‌شود. که در آن‌ها طول تصاویر را با 1، عرض تصاویر را با  $w$  و محور زمان را با  $t$  نشان داده‌ایم. دو نمونه از مختصات پیکسل‌های  $\gamma$  (نقاط روی دایره) در صفحه‌ی عمودی محاسبه شده مطابق رابطه‌ی ۴ در شکل ۲ نشان داده شده است.

$$(wp + \gamma \cos(2\pi f / \beta), lp, tp + \gamma \sin(2\pi f / \beta)) \quad (3)$$

$$(wp, lp + \gamma \sin(2\pi f / \beta), tp + \gamma \cos(2\pi f / \beta)) \quad (4)$$

مختصات این نقطه:  $(wp, lp - 1, tp)$



شکل ۲ مختصات دو نمونه پیکسل  $\gamma$  در صفحه‌ی عمودی.

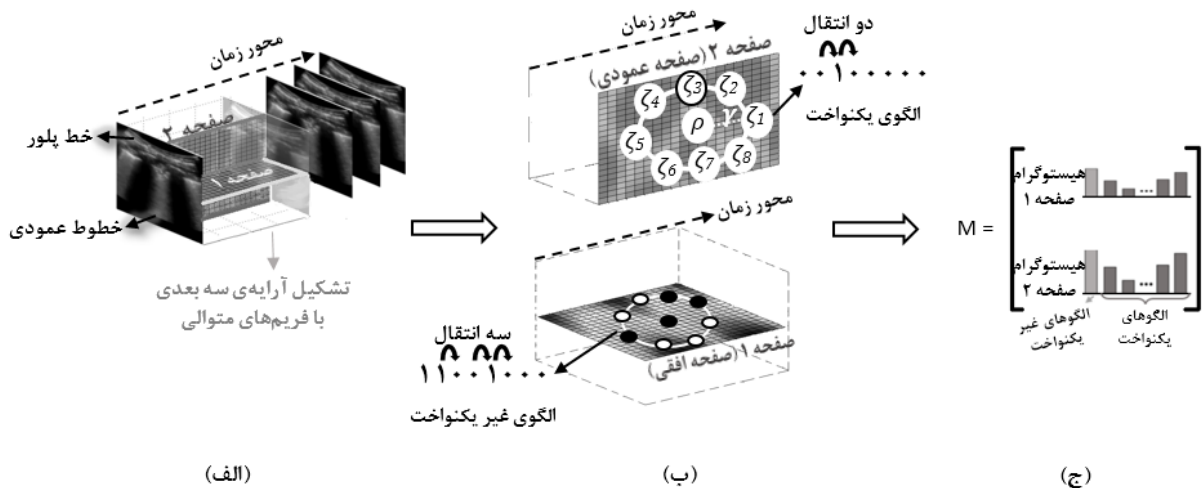
در محاسبه‌ی هیستوگرام الگوی باینری محلی یکنواخت مقاوم در برابر چرخش و نوپز، تنها یک بین<sup>۱</sup> یا سطل به همه‌ی الگوهای غیر یکنواخت اختصاص داده می‌شود و هر الگوی یکنواخت در یک بین<sup>۱</sup> جداگانه قرار می‌گیرد. با بهم پیوستن هیستوگرام‌ها، بردار

<sup>2</sup> distortion

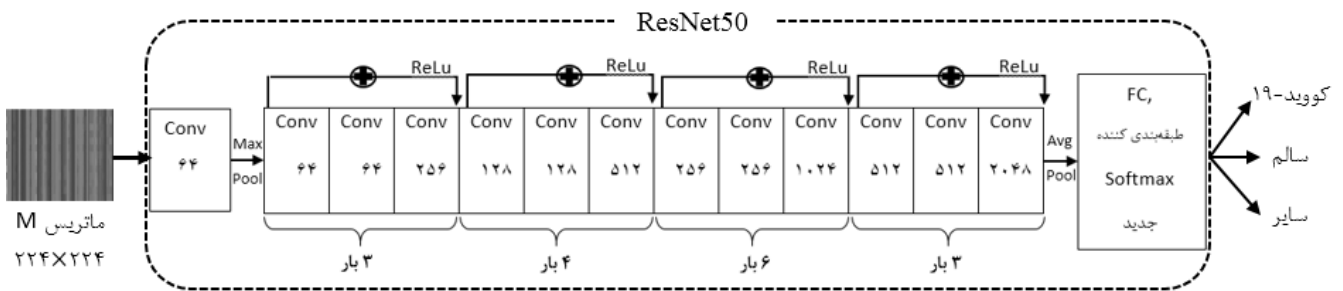
<sup>3</sup> skip connections

<sup>4</sup> Fully Connected (FC)

<sup>1</sup> bin






شکل ۳ روند کلی تشکیل ماتریس  $M$ . (الف) تصاویر اولتراسوند پشت سر هم قرار می‌گیرند تا آرایه‌های ۳ بعدی با استفاده از تصاویر متوالی تشکیل شود. سپس، دو صفحه‌ی پیشنهادی برای دریافت پیکسل‌ها در راستای محور زمان بر روی تصاویر اعمال می‌شوند. (ب) با مقایسه‌ی مقدار  $\rho$  و  $\zeta$ ‌های اطراف آن، الگوی باینری محلی یکنواخت مقاوم در برابر چرخش و نویز تصویر و هیستوگرام آن محاسبه می‌شود. (ج) ماتریس  $M$  با الحاق هیستوگرام‌های به دست آمده از صفحات افقی و هیستوگرام‌های به دست آمده از صفحات عمودی تشکیل می‌شود.



شکل ۴ معماری مدل ResNet50.

دسترس قرار دارد. نمونه‌ای از تصاویر متوالی مجموعه داده POCUS در شکل ۵ نشان داده شده است. تفاوت در تصاویر متوالی یک نمونه به دلیل جابجایی مبدل می‌باشد.



شکل ۵ نمونه‌ای از تصاویر متوالی مجموعه داده POCUS. (الف) کووید-۱۹ (ب) سایر بیماری‌ها (ج) سالم.

عبارت دیگر، ما این لایه‌ی آخر را با یک softmax و کاملاً متصل (FC) جدید جایگزین می‌کنیم. خروجی نشان‌دهنده‌ی یکی از سه دسته‌ی کووید-۱۹، سالم و بیماری‌های ریوی دیگر است.

#### ۴ آزمایش‌ها، نتایج و بحث

در این بخش، پیاده‌سازی روش پیشنهادی ترکیب الگوی باینری محلی یکنواخت مقاوم در برابر چرخش و نویز را با مدل از پیش آموزش دیده ResNet50 به تفصیل ارائه می‌کنیم. تمام آزمایش‌ها با استفاده از MATLAB 2020b در سیستمی با پردازنده Core i7 اینتل و حافظه ۸ گیگابایتی انجام شده است.

#### ۴-۱ مجموعه داده‌ی مورد استفاده

ما از ویدئوهای موجود در مجموعه داده POCUS [13] برای اعمال روش پیشنهادی استفاده می‌کنیم. زیرا برای اعمال دو صفحه‌ی زمانی نیاز به فریم‌های متوالی است. POCUS شامل ۲۴۷ ویدئوی اولتراسوند از ریه (۱۱۵ ویدئو از کووید-۱۹، ۷۵ ویدئو از ریه‌ی سالم، و ۵۷ ویدئوی دیگر از سایر بیماری‌های ریوی) است [13, 28]. این مجموعه داده به صورت عمومی در


<sup>1</sup>[https://github.com/janniborn/covid19\\_ultrasound/tree/master/data](https://github.com/janniborn/covid19_ultrasound/tree/master/data)



## ۴-۲ پیاده‌سازی روش پیشنهادی


در مرحله‌ی اول، آرایه‌های ۳ بُعدی شامل پیکسل‌های تصاویر پیاپی از فریم‌های<sup>۱</sup> ویدئوی اولتراسوند تشکیل می‌شود. به عبارت ساده‌تر، هر ویدئوی اولتراسوند ریه به تصاویر پشت سر هم تبدیل می‌شود که به صورت آرایه‌های ۳ بُعدی مرتب می‌شوند. یک صفحه‌ی معرفی شده، پیکسل‌های افقی و دیگری، پیکسل‌های عمودی هر آرایه را در راستای محور زمان احاطه می‌کند تا الگوی باینری محلی یکنواخت مقاوم در برابر چرخش و نویز محاسبه شود و ماتریس  $M$  تشکیل گردد.

به همین منظور، لازم است پارامترها تعریف شوند.  $\beta$  (تعداد پیکسل‌های روی دایره) با توجه به تنظیم شعاع  $\gamma$  تعیین می‌شود (با استفاده از رابطه  $\beta = 8\gamma$ ). به عنوان مثال، اگر شعاع را یک انتخاب کنیم، آنگاه  $\beta = 8\gamma = 8$  پیکسل در اطراف  $p$  (پیکسل واقع در مرکز دایره) برای محاسبه‌ی الگوی باینری محلی یکنواخت مقاوم در برابر چرخش و نویز در نظر گرفته می‌شود. طبق آزمایش‌های انجام شده، مشخص شد که انتخاب مقادیر مختلف  $\gamma$  بر روی دقت شناسایی کووید-۱۹ تأثیرگذار است. شکل ۶ تفاوت در عملکرد روش پیشنهادی را با تنظیم چند مقدار مختلف  $\gamma$  نشان می‌دهد. همانطور که مشاهده می‌شود، بهترین عملکرد با  $\gamma = 1$  به دست آمده است.



شکل ۶ تأثیر مقادیر مختلف  $\gamma$  بر دقت شناسایی کووید-۱۹

بنابراین، فاصله‌ی بین فریم‌های اولتراسوند یک است و الگوی باینری محلی یکنواخت مقاوم در برابر چرخش و نویز با استفاده از پیکسل‌های سه فریم ابتدایی اولتراسوند تا سه فریم انتهایی آن در یک ویدئو محاسبه می‌شود. قابل ذکر است از هر سه فریم، پیکسل‌هایی که در صفحه‌ی عمودی و صفحه‌ی افقی پیشنهادی واقع هستند، مورد استفاده قرار می‌گیرند و صفحات عمودی و افقی بر روی فریم‌های اولتراسوند حرکت داده می‌شوند تا تمام پیکسل‌ها را دریافت کنند. برای درک بهتر می‌توانید پشته‌ای از آن‌ها را بر روی فریم‌های اولتراسوند فرض کنید که در راستای محور زمان نیز حرکت داده می‌شوند (شکل ۷).




شکل ۷ الف) اعمال پشته‌ای از صفحات افقی و عمودی بر روی تصاویر متوالی اولتراسوند ب) پیکسل‌های دریافت شده از تصاویر متوالی اولتراسوند توسط پشته‌ای از صفحات افقی و عمودی.

به دلیل اینکه این صفحات هم‌راستا با خطوط ظاهر شده در تصاویر اولتراسوند (خطوط ایجاد شده به سبب بیماری کووید-۱۹ و کمبود میزان هوای ریه) هستند، می‌توانند نشانه‌های مربوط به بیماری را به خوبی دریافت کنند تا پردازش بر روی آن‌ها انجام شود. هیستوگرام یا به عبارت بهتر، بردار ویژگی نهایی به دست آمده از صفحه‌ی افقی و صفحه‌ی عمودی در یک ماتریس به نام  $M$  قرار می‌گیرد. این ماتریس به  $224 \times 224$  تغییر اندازه می‌یابد تا به عنوان ورودی شبکه‌ی عصبی کانولوشنی مورد استفاده قرار گیرد. با توجه به تعداد داده‌های نسبتاً کم، از مدل‌های از پیش آموزش دیده‌ی شبکه استفاده می‌شود. با توجه به آزمایش‌های اولیه-ی انجام شده مشخص شد که مدل از پیش آموزش دیده ResNet50 نسبت به سایر مدل‌ها عملکرد بهتری در تفکیک و طبقه‌بندی ماتریس‌های  $M$  ورودی دارد. در واقع، ResNet50 می‌تواند بهتر ویژگی‌های مربوطه را یاد بگیرد و آن‌ها را در سه دسته‌ی کووید-۱۹، سالم و بیماری‌های دیگر طبقه‌بندی کند.


ما ماتریس‌های  $M$  به دست آمده از فریم‌های ویدئوی کووید-۱۹ را در یک پوشه‌ی جداگانه ذخیره کردیم و نام پوشه را کووید-۱۹ گذاشتیم. به همین ترتیب، ماتریس‌های به دست آمده از داده‌های سالم و سایر بیماری‌های ریوی را در پوشه‌های جداگانه که نام هر پوشه همان نام دسته‌ی مربوطه می‌باشد، ذخیره کردیم. اندازه‌ی تمام ماتریس‌ها  $224 \times 224$  است. در واقع، پس از استفاده از دستور `mat2gray`، تغییر اندازه و ذخیره‌سازی را انجام دادیم. هنگام ذخیره، آن‌ها را با نام برجسب مربوطه و شماره (به عنوان مثال، کووید ۱ (COVID 1)، کووید ۲ (COVID 2) و ...) نام

<sup>1</sup> frames

ساختیم. شکل ۱۰ ویژگی‌های استخراج شده از اولین لایه‌ی کانولوشن (Conv) در ResNet50 را نشان می‌دهد.



شکل ۹ فعالسازی ویژگی‌ها با استفاده از فعالساز ReLU



شکل ۱۰ ویژگی‌های استخراج شده از اولین لایه‌ی کانولوشن

### ۳-۴ نتایج آزمایش‌ها و بحث


شکل ۱۱، نمودارهای مقدار دقت و تلفات اندازه‌گیری شده در هر مرحله از آموزش و ارزیابی را نشان می‌دهد. همانطور که مشاهده می‌شود، نمودارها نزدیک به ایده‌آل هستند.

ذخیره کردیم. این داده‌ها را به طور تصادفی به ۸۰٪ داده‌های آموزش و ۲۰٪ داده‌های آزمایش تقسیم کردیم.

لایه کاملاً متصل (FC) جدید (برای یادگیری تابع طبقه‌بندی کننده) و softmax جدید را با لایه‌ی آخر ResNet50 از پیش آموزش دیده جایگزین کردیم و بدین ترتیب، ResNet50 از پیش آموزش دیده با توجه داده‌های جدید تغییر کرد. این کار به منظور تطبیق ResNet50 برای طبقه‌بندی ورودی‌های مورد نظر به سه دسته‌ی کووید-۱۹، سالم و سایر بیماری‌ها انجام شد.

پارامترهای آموزش شبکه مانند اندازه‌ی دسته<sup>۱</sup>، تعداد دوره‌ها<sup>۲</sup>، نرخ یادگیری اولیه<sup>۳</sup> را تعریف کردیم. ما از بهینه‌ساز برآورد لحظه تطبیقی (Adam) استفاده می‌کنیم. زیرا باعث کاهش نوسان در طول فرآیند آموزش شبکه می‌شود. اندازه‌ی دسته را ۲۰ انتخاب می‌کنیم. نرخ یادگیری اولیه روی ۰,۰۰۰۱ تنظیم می‌شود. حداکثر دوره ۵ است. توجه می‌کنیم که مقادیر مختلف اندازه‌ی دسته و نرخ یادگیری اولیه نیز بر نتایج تأثیر می‌گذارند. تأثیر انتخاب مناسب اندازه‌ی دسته و نرخ یادگیری بر دقت تشخیص بیماری کووید-۱۹ در شکل ۸ نشان داده شده است.

ما با استفاده از چرخش<sup>۴</sup>، تعداد داده‌ها را افزایش دادیم و شبکه با داده‌های مربوط به سه دسته‌ی کووید-۱۹، سالم و سایر بیماری‌ها آموزش داده شد. ما از تابع آموزش شبکه<sup>۵</sup> استفاده کردیم. زمان آموزش، ۴۶ دقیقه و ۲۷ ثانیه طول کشید. پس از آموزش، داده‌های آزمایش برای بررسی دقت و صحت استفاده می‌شوند.



شکل ۸ تأثیر اندازه‌ی دسته و نرخ یادگیری بر دقت تشخیص بیماری کووید-۱۹

همچنین، فعالسازی ویژگی‌ها را با استفاده از فعالساز ReLU بررسی کردیم. نتیجه در شکل ۹ قابل مشاهده است. در این شکل، رنگ تیره ویژگی‌های کمتر فعال را نشان می‌دهد و رنگ روشن ویژگی‌های بسیار فعال را نمایان می‌کند. علاوه بر این، ویژگی‌های استخراج شده از لایه‌های شبکه‌ی عصبی کانولوشنی را متصور

<sup>1</sup> batch size

<sup>2</sup> epoch

<sup>3</sup> initial learning rate

<sup>4</sup> rotation

<sup>5</sup> trainNetwork

[35]. محاسبه‌ی پیش‌بینی‌های صحیح روش پیشنهادی در همه پیش‌بینی‌ها، صحت نام دارد. حساسیت نشان می‌دهد چه مقدار از پیش‌بینی‌های مثبت، صحیح تشخیص داده شده‌اند. اندازه‌گیری کلی دقت روش با امتیاز F1 نیز نشان داده می‌شود.

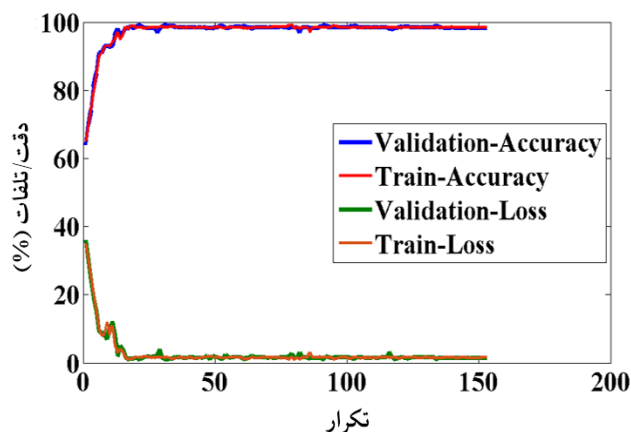
$$\text{صحت} = \frac{\text{مثبت صحیح}}{\text{مثبت صحیح} + \text{مثبت کاذب}} \quad (۶)$$

$$\text{حساسیت} = \frac{\text{مثبت صحیح}}{\text{مثبت صحیح} + \text{منفی کاذب}} \quad (۷)$$

$$F1 = 2 \times \left( \frac{\text{صحت} \times \text{حساسیت}}{\text{صحت} + \text{حساسیت}} \right) \quad (۸)$$

بیماری شناسایی شده با تشخیص صحیح، مثبت صحیح<sup>۴</sup> (TP) است. پیش‌بینی صحیح فقدان بیماری، منفی صحیح<sup>۵</sup> (TN) است. نمونه‌ی سالم طبقه‌بندی شده به‌عنوان بیماری، مثبت کاذب<sup>۶</sup> (FP) است. بیماری طبقه‌بندی شده به‌عنوان سالم، منفی کاذب<sup>۷</sup> (FN) است. جدول ۲، ارزیابی روش‌های مختلف را با استفاده از معیارهای صحت، حساسیت و امتیاز F1 برای طبقه‌بندی کووید-۱۹ نشان می‌دهد. طبق نتایج به دست آمده، روش پیشنهادی ما (ترکیب روش الگوی باینری محلی یکنواخت مقاوم در برابر چرخش و نویز در دو صفحه‌ی زمانی با ResNet50 قبل آموزش دیده) نسبت به سایر روش‌ها در اکثر معیارها برتری دارد. اگرچه صحت برای VGG-19 نیز همانند روش پیشنهادی ما ۱ است، اما مقدار F1 و حساسیت آن کمتر است.

جدول ۳، میزان تشخیص کووید-۱۹ را با استفاده از مدل‌های مختلف از پیش آموزش دیده بر اساس معیار F1 بر روی مجموعه داده مورد استفاده نشان می‌دهد. طبق نتایج به دست آمده مدل ResNet نسبت به سایر مدل‌ها عملکرد بهتری دارد. ResNet50 علاوه بر برتری در میزان دقت شناسایی کووید-۱۹، با توجه به عمق کم (۵۰ لایه) نسبت به ResNet101 (۱۰۱ لایه) نیاز به صرف زمان کمتری دارد. شکل ۱۲، زمان آموزش را با استفاده از چند مدل شبکه‌ی عصبی کانولوشنی مختلف بر روی داده‌های اولتراسوند نشان می‌دهد.



شکل ۱۱ نمودار دقت و تلفات در هر مرحله از آموزش و ارزیابی مدل از پیش آموزش دیده ResNet50.

همچنین، از اعتبارسنجی ۱۰ برابر<sup>۱</sup> استفاده شد و میانگین نتایج محاسبه شد. دقت به دست آمده برای تشخیص کووید-۱۹ با استفاده از روش پیشنهادی ما (ترکیب روش الگوی باینری محلی یکنواخت مقاوم در برابر چرخش و نویز در دو صفحه‌ی زمانی با ResNet50 از قبل آموزش دیده) ۹۸٫۵ درصد است. در جدول ۱ اثربخشی روش پیشنهادی در مقایسه با سایر روش‌های پیشرفته‌ی ارائه شده در پژوهش‌های پیشین بر اساس دقت شناسایی کووید-۱۹ مشهود است. مطابق این جدول، روش پیشنهادی ما برای دسته‌بندی تصاویر کووید-۱۹ عملکرد بهتری دارد. علت آن می‌تواند مقاوم بودن روش پیشنهادی در برابر چرخش و نویز باشد. زیرا نویز موجود در تصاویر بر عملکرد شبکه‌ی عصبی کانولوشنی تأثیر می‌گذارد. همچنین، دو صفحه‌ی زمانی استفاده شده می‌تواند ویژگی‌های خطوط عمودی موجود در تصاویر و ناپیوستگی خط پلور را به‌وضوح نمایان سازند.

جدول ۱ دقت شناسایی کووید-۱۹ از روی داده‌های اولتراسوند با استفاده از روش پیشنهادی در مقایسه با سایر روش‌ها.

نام روش	دقت به دست آمده
VGG-19 [11]	۸۶%
POCOVID-Net [13]	۸۹%
GoogLeNet [29]	۸۹٫۱%
U-Net [14]	۹۴%
MobileNet [32]	۹۵%
LUS-Net [30]	۹۷%
روش پیشنهادی ما	۹۸٫۵%

برای تأیید سودمندی روش پیشنهادی، معیارهای صحت<sup>۲</sup>، حساسیت<sup>۳</sup> و امتیاز F1 با استفاده از روابط ۶ تا ۸ محاسبه شده‌اند

<sup>3</sup> sensitivity

<sup>4</sup> True Positive

<sup>5</sup> True Negative

<sup>6</sup> False Positive

<sup>7</sup> false-negative

<sup>1</sup> 10-fold cross-validation

<sup>2</sup> precision



جدول ۲ دقت شناسایی کووید-۱۹ با استفاده از روش پیشنهادی در مقایسه با سایر روش‌ها.

نام روش	صحت	حساسیت	معیار F1
VGG-19 [11]	۱,۰۰	۰,۹۷	۰,۹۸
POCOVID-Net [13]	۰,۸۸	۰,۹۶	۰,۹۲
GoogLeNet [29]	۰,۹۰	۰,۸۶	۰,۸۸
روش پیشنهادی ما	۱,۰۰	۰,۹۹	۰,۹۹۵

روش پیشنهادی به خوبی نشانه‌های کووید-۱۹ را آشکار می‌سازند. همچنین، نتایج نشان می‌دهد که با اعمال روش پیشنهادی بر روی تصاویر متوالی اولتراسوند، هیچ درهم‌ریختگی بین دسته‌ی سالم و بیماران کووید-۱۹ ایجاد نمی‌شود.

		Precision		
		کووید-۱۹	سالم	سایر بیماری‌ها
دسته‌های واقعی	کووید-۱۹	100%	0%	0%
	سالم	0%	98%	2%
	سایر بیماری‌ها	1%	0%	99%
		کووید-۱۹	سالم	سایر بیماری‌ها

دسته‌های پیش‌بینی شده

شکل ۱۳ ماتریس درهم‌ریختگی اعمال روش پیشنهادی بر روی داده‌های اولتراسوند بر اساس صحت پیش‌بینی شده در هر دسته.

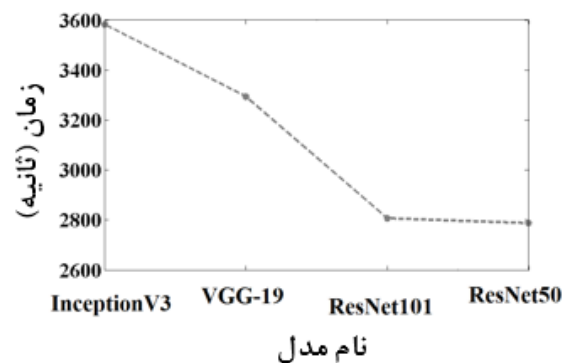
## ۵ نتیجه‌گیری

بیماری کووید-۱۹ به دلیل قدرت سرایت بالا و نرخ بالای مرگ ناشی از آن، خسارات زیادی را در حوزه‌های مختلف وارد کرده است. ثابت شده است که با تشخیص زودهنگام این بیماری همه‌گیر، روند درمان بسیار سریع‌تر و راحت‌تر پیش می‌رود. بنابراین، ما در این مقاله، یک روش جدید به نام ترکیب الگوی باینری محلی یکنواخت مقاوم در برابر چرخش و نویز از دو صفحه‌ی زمانی و ResNet50 را پیشنهاد کردیم که بر روی تصاویر متوالی اولتراسوند ریه اعمال شد. از مزایای این روش می‌توان به مقاوم بودن در برابر نویز داده‌های اولتراسوند و صرف زمان کم‌تر برای تشخیص اشاره کرد.

دو صفحه‌ی معرفی شده در روش پیشنهادی می‌توانند به خوبی نشانه‌های بیماری کووید-۱۹ را از تصاویر دریافت کنند تا این ویژگی‌ها به صورت باینری (الگویی از اعداد ۰ و ۱) رمزگذاری و توسط مدل سریع ResNet50 طبقه‌بندی شوند. طبق نتایج آزمایش‌ها و مقایسه آن‌ها با سایر روش‌هایی که در پژوهش‌های پیشین مورد استفاده قرار گرفته‌اند، مشخص شد که روش پیشنهادی عملکرد مناسبی در شناسایی کووید-۱۹ از روی داده‌های اولتراسوند دارد. این روش می‌تواند در آینده برای سایر مشکلات تشخیصی مرتبط مانند آنفلوآنزا، تومورها و غیره بر روی داده‌های اولتراسوند اعمال شود.

جدول ۳ میزان تشخیص کووید-۱۹ از داده‌های اولتراسوند با استفاده از مدل‌های مختلف از پیش آموزش دیده بر اساس معیار F1.

نام مدل	معیار F1
ResNet50	۹۸%
ResNet101	۹۷%
VGG-19	۹۶%
MobileNet	۹۴%
InceptionV3	۸۹%



شکل ۱۲ زمان آموزش مدل‌های مختلف شبکه‌ی عصبی کانولوشنی با داده‌های اولتراسوند.

شکل ۱۳، ماتریس درهم‌ریختگی<sup>۱</sup> روش پیشنهادی را با داده‌های مورد استفاده بر اساس درصد صحت اندازه‌گیری شده برای هر دسته نشان می‌دهد. طبق نتایج، همه دسته‌ها (کووید-۱۹، سالم و سایر بیماری‌ها) با درصد مثبت صحیح<sup>۲</sup> (TP) بالا شناسایی شده‌اند. توجه داشته باشید که موارد کووید-۱۹ در ۱۰۰% داده‌ها به درستی توسط مدل ResNet50 طبقه‌بندی شده‌اند. به عبارت دیگر، صحت به دست آمده برای شناسایی کووید-۱۹ با استفاده از روش پیشنهادی بیشینه است.

صحت برای دسته‌ی سالم ۹۸% و برای دسته‌ی سایر بیماری‌ها ۹۹% است. تنها در ۱ درصد از موارد سایر بیماری‌ها به اشتباه به عنوان کووید-۱۹ طبقه‌بندی شده است. یک دلیل محتمل این است که در برخی از بیماری‌های ریوی نیز حجم هوای کم در ریه موجب ایجاد خطوط عمودی در تصاویر اولتراسوند خواهد شد. این نتایج نشان می‌دهند که دو صفحه‌ی زمانی معرفی شده در

<sup>۱</sup> confusion matrix

<sup>۲</sup> True Positive

## مراجع

- ultrasound*", IEEE transactions on medical imaging, vol. 39, no. 8, pp. 2676–2687, 2020.
- [15] Ojala, T., Pietikainen, M., Maenpaa, T., "Multiresolution gray-scale and rotation invariant texture classification with local binary patterns", IEEE Transactions on pattern analysis and machine intelligence, vol. 24, no. 7, pp. 971–987, 2002.
- [16] Krizhevsky, A., Sutskever, I., Hinton, G. E., "Imagenet classification with deep convolutional neural networks", Advances in neural information processing systems, vol. 25, pp. 1097–1105, 2012.
- [17] Simonyan, K., Zisserman, A., "Very deep convolutional networks for large-scale image recognition", arXiv preprint arXiv:1409.1556, 2014.
- [18] Szegedy, C., et al., "Going deeper with convolutions", in Proceedings of the IEEE conference on computer vision and pattern recognition, 2015, pp. 1–9.
- [19] Howard, A. G., et al., "Mobilenets: Efficient convolutional neural networks for mobile vision applications", arXiv preprint arXiv:1704.04861, 2017.
- [20] He, K., Zhang, X., Ren, S., Sun, J., "Deep residual learning for image recognition," in Proceedings of the IEEE conference on computer vision and pattern recognition, 2016, pp. 770–778.
- [21] McDermott, C., et al., "Sonographic diagnosis of COVID-19: A review of image processing for lung ultrasound", Frontiers in big Data, vol. 4, 2021.
- [22] Karakuş, O., et al., "Line artefact quantification in lung ultrasound images of covid-19 patients via non-convex regularization", 2020.
- [23] Esmaeili, V., Feghhi, M. M., Shahdi, S. O., "Autonomous Apex Detection and Micro-Expression Recognition using Proposed Diagonal Planes", International Journal of Nonlinear Analysis and Applications, vol. 11, pp. 483–497, 2020.
- [24] Esmaeili, V., Feghhi, M. M., Shahdi, S. O., "Automatic Micro-Expression Apex Frame Spotting using Local Binary Pattern from Six Intersection Planes", arXiv preprint arXiv: 2104.02149, 2021.
- [25] Zhao, G., Pietikainen, M., "Dynamic texture recognition using local binary patterns with an application to facial expressions", IEEE transactions on pattern analysis and machine intelligence, vol. 29, no. 6, pp. 915–928, 2007.
- [26] Esmaeili, V., Shahdi, S. O., "Automatic micro-expression apex spotting using Cubic-LBP", Multimedia Tools and Applications, vol. 79, no. 27, pp. 20221–20239, 2020.
- [27] Esmaeili, V., Feghhi, M. M., Shahdi, S. O., "Micro-Expression Recognition Using Histogram of Image Gradient Orientation on Diagonal Planes", In: 2021 5th International Conference on Pattern Recognition and Image Analysis (IPRIA). IEEE, p. 1–5, 2021.
- [28] Born, J., et al., "Accelerating detection of lung pathologies with explainable ultrasound image analysis", Applied Sciences, vol. 11, no. 2, p. 672, 2021.
- [1] Secco, G., et al., "Lung ultrasound presentation of COVID-19 patients: phenotypes and correlations", Internal and Emergency Medicine, pp. 1–11, 2021.
- [2] Buda, N., Segura-Grau, E., Cylwik, J., Wehnicki, M., "Lung ultrasound in the diagnosis of COVID-19 infection—A case series and review of the literature", Advances in medical sciences, vol. 65, no. 2, pp. 378–385, 2020.
- [3] Sultan, L. R., Sehgal, C. M., "A review of early experience in lung ultrasound in the diagnosis and management of COVID-19", Ultrasound in Medicine & Biology, vol. 46, no. 9, pp. 2530–2545, 2020.
- [4] Volpicelli, G., et al., "Lung ultrasound for the early diagnosis of COVID-19 pneumonia: an international multicenter study", Intensive care medicine, vol. 47, no. 4, pp. 444–454, 2021.
- [5] Rajpal, S., Lakhyani, N., Singh, A. K., Kohli, R., Kumar, N., "Using handpicked features in conjunction with ResNet-50 for improved detection of COVID-19 from chest X-ray images", Chaos, Solitons & Fractals, vol. 145, p. 110749, 2021.
- [6] Ahsan, M., Based, M., Haider, J., Kowalski, M., "COVID-19 detection from chest X-ray images using feature fusion and deep learning", Sensors, vol. 21, no. 4, p. 1480, 2021.
- [7] Sorlini, C., et al., "The role of lung ultrasound as a frontline diagnostic tool in the era of COVID-19 outbreak", Internal and emergency medicine, vol. 16, no. 3, pp. 749–756, 2021.
- [8] Ai, T., et al., "Correlation of chest CT and RT-PCR testing for coronavirus disease 2019 (COVID-19) in China: a report of 1014 cases", Radiology, vol. 296, no. 2, pp. E32–E40, 2020.
- [9] Colombi, D., et al., "Comparison of admission chest computed tomography and lung ultrasound performance for diagnosis of COVID-19 pneumonia in populations with different disease prevalence", European journal of radiology, vol. 133, p. 109344, 2020.
- [10] Denina, M., et al., "Lung ultrasound in children with COVID-19", Pediatrics, vol. 146, no. 1, 2020.
- [11] Horry, M. J., et al., "COVID-19 detection through transfer learning using multimodal imaging data", IEEE Access, vol. 8, pp. 149808–149824, 2020.
- [12] Singh, P., Mukundan, R., De Ryke, R., "Feature enhancement in medical ultrasound videos using contrast-limited adaptive histogram equalization", Journal of digital imaging, vol. 33, no. 1, pp. 273–285, 2020.
- [13] Born, J., et al., "POCOVID-Net: automatic detection of COVID-19 from a new lung ultrasound imaging dataset (POCUS)", arXiv preprint arXiv:2004.12084, 2020.
- [14] Roy, S., et al., "Deep learning for classification and localization of COVID-19 markers in point-of-care lung



ویدا اسماعیلی در سال ۱۳۹۳ مدرک کارشناسی خود را در رشته مهندسی برق گرایش الکترونیک از دانشگاه آزاد اسلامی واحد ابهر دریافت کرد. سپس، در سال ۱۳۹۷ مدرک کارشناسی ارشد خود را در رشته مهندسی برق گرایش الکترونیک از دانشگاه آزاد اسلامی واحد قزوین اخذ نمود.

ایشان هم‌اکنون دانشجوی دکتری رشته مهندسی برق گرایش مخابرات سیستم در دانشگاه تبریز است. حوزه پژوهشی و مورد علاقه ایشان پردازش تصویر، پردازش سیگنال، الگوریتم‌های هوش مصنوعی و بینایی ماشین می‌باشد.



محمود محصل فقهی تحصیلات خود را در مقاطع کارشناسی و کارشناسی ارشد مهندسی برق (به ترتیب در سال‌های ۱۳۸۵ و ۱۳۸۸ در دانشگاه علم و صنعت ایران و مقطع دکتری تخصصی مهندسی برق در سال ۱۳۹۴ در دانشگاه تهران به پایان رساند. نامبرده از سال

۱۳۸۷ به عنوان پژوهشگر و مجری پروژه‌های مختلف تحقیقاتی و صنعتی در صنایع مخابرات کشور فعالیت داشته است. ایشان مولف بیش از ۴۰ مقاله ژورنال و کنفرانس در زمینه‌های مختلف مخابرات و هم‌اکنون استادیار گروه مخابرات دانشکده مهندسی برق و کامپیوتر دانشگاه تبریز می‌باشند. زمینه‌های علمی و تحقیقاتی مورد علاقه ایشان متنوع بوده و شامل نظریه اطلاعات شبکه‌ای، پردازش سیگنال، نظریه مخابرات، سامانه‌های ارتباطی بی‌سیم و بهینه‌سازی و تخصیص منابع در شبکه‌های مخابراتی می‌باشند.

- [29] Diaz-Escobar, J., et al., "Deep-learning based detection of COVID-19 using lung ultrasound imagery", Plos one, vol. 16, no. 8, p. e0255886, 2021.
- [30] Panicker, M. R., Chen, Y. T., Narayan, K. V., Kesavadas, C., Vinod, A., "An Approach Towards Physics Informed Lung Ultrasound Image Scoring Neural Network for Diagnostic Assistance in COVID-19", arXiv preprint arXiv:2106.06980, 2021.
- [31] Ronneberger, O., Fischer, P., Brox, T., "U-net: Convolutional networks for biomedical image segmentation", in International Conference on Medical image computing and computer-assisted intervention, pp. 234-241: Springer, 2015.
- [32] Almeida, A., et al., "Lung ultrasound for point-of-care COVID-19 pneumonia stratification: computer-aided diagnostics in a smartphone. First experiences classifying semiology from public datasets", in 2020 IEEE International Ultrasonics Symposium (IUS), pp. 1-4: IEEE, 2020.
- [33] Wu, Z., Shen, C., Van Den Hengel, A., "Wider or deeper: Revisiting the resnet model for visual recognition", Pattern Recognition, vol. 90, pp. 119-133, 2019.
- [34] Narin, A., Kaya, C., Pamuk, Z., "Automatic detection of coronavirus disease (covid-19) using x-ray images and deep convolutional neural networks", Pattern Analysis and Applications, pp. 1-14, 2021.
- [35] Nicholson, C., "Evaluation metrics for machine learning—accuracy, precision, recall, and F1 defined", ed: Pathmind. <http://pathmind.com/wiki/accuracy-precision-recall-f1>, 2019.