



Computational Intelligence in Electrical Engineering  
Vol. 14, No. 1, 2023  
Research Paper

## Recognition Covid-19 cases using deep type-2 fuzzy neural networks based on chest X-ray image

Kamel Sabahi<sup>1\*</sup>, S. Sheykhivand<sup>2</sup>, Z. Mousavi<sup>3</sup>, and Mehdi Rajabioun<sup>4</sup>

<sup>1</sup>Department of Engineering Sciences, Faculty of Advanced Technologies, University of Mohaghegh Ardabili, Namin, Iran

<sup>2</sup>Faculty of Electrical and Computer Engineering, University of Tabriz, Tabriz, Iran

<sup>3</sup>Department of Mechanical Engineering, University of Tabriz, Tabriz, Iran, Iran

<sup>4</sup>Department of Biomedical Engineering, Mamaghan Branch, Islamic Azad University, Mamaghan, Iran

### Abstract:

Today, the new coronavirus (Covid-19) has become a major global epidemic. Every day, a large proportion of the world's population is infected with the Covid-19 virus, and a significant proportion of those infected dies as a result of this virus. Because of the virus's infectious nature, prompt diagnosis, treatment, and quarantine are considered critical. In this paper, an automated method for detecting Covid-19 from chest X-ray images based on deep learning networks is presented. For the proposed deep learning network, a combination of convolutional neural networks with type-2 fuzzy activation function is used to deal with noise and uncertainty. In this study, Generative Adversarial Networks (GANs) were also used for data augmentation. Furthermore, the proposed network is resistant to Gaussian noise up to 10 dB. The final accuracy for the classification of the first scenario (healthy and Covid-19) and the second scenario (healthy, Pneumonia and Covid-19) is about 99% and 95%, respectively. In addition, the results of the proposed method in terms of accuracy, precision, sensitivity, and specificity in comparison with recent research are promising. For example, the proposed method for classifying the first scenario has 100% and 99% sensitivity and specificity, respectively. In the field of medical application, the proposed method can be used as a physician's assistant during patient treatment.

**Keywords:** Covid-19, Type 2 fuzzy sets, Convolutional neural network, Chest X-ray images.



This is an open access article under the CC BY-NC-ND/4.0/ License (<https://creativecommons.org/licenses/by-nc-nd/4.0/>).



<https://doi.org/10.22108/isee.2021.128829.1475>

## مقاله پژوهشی

# شناسایی موارد ابتلا به کووید-۱۹ با استفاده از شبکه عصبی فازی نوع ۲ عمیق براساس

## تصاویر X-Ray قفسه سینه

کامل صباحی<sup>۱\*</sup>، سبحان شیخی‌وند<sup>۲</sup>، زهره موسوی<sup>۳</sup> و مهدی رجیبون<sup>۴</sup>

۱- استادیار، گروه علوم مهندسی، دانشکده فناوری‌های نوین - دانشگاه محقق اردبیلی - نمین - ایران

k.sabahi@uma.ac.ir

۲- دانشجوی دکتری، دانشکده مهندسی برق و کامپیوتر - دانشگاه تبریز - تبریز - ایران

s.sheikhivand@tabrizu.ac.ir

۳- محقق فرادکتری، دانشکده مهندسی مکانیک - دانشگاه تبریز - تبریز - ایران

zohreh\_mousavi@tabrizu.ac.ir

۴- استادیار، گروه مهندسی پزشکی، واحد ممقان - دانشگاه آزاد اسلامی - ممقان - ایران

mrajabioun@gmail.com

**چکیده:** امروزه ویروس کروناي جديد به يك اپیدمی بزرگ جهانی تبدیل شده است. روزانه درصد بالایی از جمعیت کل جهان به این ویروس مبتلا می‌شوند و درصد چشمگیری در اثر ابتلا جان خود را از دست می‌دهند. با توجه به ماهیت واگیرداری شدید این ویروس، تشخیص، درمان و قرنطینه به موقع امری ضروری تلقی می‌شود. در این مقاله یک روش خودکار برای تشخیص کووید-۱۹ از تصاویر اشعه ایکس قفسه سینه براساس شبکه‌های یادگیری عمیق ارائه شده است. برای شبکه یادگیری عمیق پیشنهادی در این کار از ترکیب شبکه‌های کانولوشنال با توابع فعال‌سازی فازی نوع ۲ به منظور مواجهه بهتر با نویز استفاده شده است. همچنین برای افزایش دادگان، شبکه‌های مولد تخصصی در این پژوهش به کار گرفته شده‌اند. صحت نهایی حاصل شده برای طبقه‌بندی سناریوی اول (سالم و کووید-۱۹) و سناریوی دوم (سالم، پنومونیا و کووید-۱۹) به ترتیب حدود ۹۹ و ۹۵ درصد است. علاوه بر این، نتایج روش پیشنهادی از نظر معیارهای صحت، حساسیت و اختصاصیت در مقایسه با پژوهش‌های اخیر امیدوارکننده‌اند؛ به طوری که برای طبقه‌بندی سناریوی اول به ترتیب دارای حساسیت و اختصاصیت ۱۰۰ و ۹۹ درصد است. روش پیشنهادی با راه‌یابی به حوزه کاربردی می‌تواند به عنوان دستیار پزشک در طول درمان بیماران استفاده شود.

**واژه‌های کلیدی:** Covid-19، مجموعه‌های فازی نوع ۲، CNN، تصاویر X-Ray قفسه سینه

## ۱- مقدمه

در سراسر جهان با مشکل مواجه کرده است [۲]. ویروس کروناي جديد با نام SARS-COV-2 نیز شناخته می‌شود. شواهدی وجود دارد که براساس آن محققان معتقدند این ویروس از خفاش‌ها و مورچه‌خوارها به انسان منتقل شده است [۳]. تاکنون (بهمن ۹۹) بیش از ۱۰۰ میلیون نفر از جمعیت جهان به این ویروس مبتلا شده‌اند که از این تعداد، متأسفانه بیش از ۲ میلیون نفر جان خود را بر اثر ابتلا به این بیماری از دست داده‌اند [۴]. طبق یافته‌های محققان، این ویروس برخلاف مرگ‌ومیر کم، می‌تواند بسیار واگیردار

ویروس کروناي جديد<sup>۱</sup> در وهان چین در دسامبر سال ۲۰۱۹ آغاز شد [۱]. این ویروس امروزه بهداشت عمومی را

<sup>۱</sup> تاریخ ارسال مقاله: ۱۴۰۰/۰۳/۰۲

تاریخ پذیرش مقاله: ۱۴۰۰/۰۹/۲۷

نام نویسنده مسئول: کامل صباحی

نشانی نویسنده مسئول: ایران - نمین - دانشگاه محقق اردبیلی - دانشکده فناوری‌های نوین - گروه علوم مهندسی

مراکز درمانی موجود نیست و یک دستگاه تصویربرداری پرهزینه محسوب می‌شود [۱۱]؛ در مقابل، RD تقریباً در تمامی مراکز درمانی موجود بوده و مقرون‌به‌صرفه‌تر است.

در تشخیص مبتنی بر RD، پزشک باید به صورت بصری براساس دانش و تجربه خود از روی تصاویر اشعه ایکس<sup>۴</sup> قفسه سینه، پنومونیای<sup>۱۱</sup> ویروسی، باکتریایی، کووید-۱۹ و غیره را تشخیص دهد [۱۳]. همان‌طور که ثابت شده است، تشخیص براساس دانش و تخصص پزشک به صورت بصری وقت‌گیر و مستعد خطا است و سبب دقت پایین در تشخیص نیز خواهد شد [۱۴]؛ درنهایت، به سیستمی نیاز است تا بتواند به صورت خودکار پنومونیای باکتریایی، ویروسی، کووید-۱۹ و غیره را از تصاویر ایکس بدون نیاز به تشخیص بصری تشخیص دهد. تشخیص خودکار کووید-۱۹ از تصاویر ایکس علاوه بر تشخیص سریع، کاهش حجم کار پزشکان را سبب می‌شود و برای درمان به‌موقع و کاهش مرگ‌ومیر بیماران امری ضروری تلقی می‌شود. به‌تازگی تحقیقات بسیاری در زمینه تشخیص خودکار کووید-۱۹ با استفاده از تصاویر X-Ray قفسه سینه ارائه شده است که در ادامه هریک از این پژوهش‌ها را بررسی خواهیم کرد.

نارین و همکاران [۱۵] از تصاویر اشعه ایکس قفسه سینه برای تشخیص خودکار پنومونیا براساس سه شبکه یادگیری عمیق از پیش آموزش دیده<sup>۱۱</sup> شامل Inception V3، ResNet 50 و Inception-ResNet V2 استفاده کردند. مدل ResNet 50 در میان سایر شبکه‌های ارائه‌شده توسط این پژوهشگران، بهترین عملکرد را داشته است. صحت گزارش شده برای طبقه‌بندی ۲ کلاس (سالم و کووید-۱۹) براساس الگوریتم پیشنهادی آنها، حدود ۹۸ درصد بوده است. پایبرا و همکاران [۱۶] از شبکه‌های یادگیری عمیق برای تشخیص خودکار بیماری‌های MERS، SARS و کووید-۱۹ با استفاده از تصاویر اشعه ایکس قفسه سینه استفاده کردند. آنها از ResNet 50 به همراه ماشین بردار پشتیبان<sup>۱۲</sup> (SVM) در مدل پیشنهادی خود استفاده کردند و به صحت ۹۵ درصد در طبقه‌بندی این بیماری‌ها از یکدیگر دست یافتند. چوچان و همکاران [۱۷] از تصاویر اشعه ایکس قفسه سینه برای تشخیص خودکار

باشد. تخمین زده شده است که هر فرد در صورت ابتلا به این ویروس، به‌طور متوسط می‌تواند ۷ فرد دیگر را آلوده کند [۵]. طبق تحقیقات اخیر، ابتلا به این ویروس در کودکان به دلیل داشتن سیستم ایمنی قوی بسیار خفیف است؛ در مقابل، این ویروس در افراد مسن و سیگاری بسیار پرخطر ظاهر می‌شود [۵]. همچنین، شواهد دیگری وجود دارد که نشان می‌دهد شناس مبتلای افراد مذکور به این ویروس نسبت به افراد مؤنث بسیار بیشتر است [۵]. از علائم ابتلا به ویروس کرونای جدید، سرفه، تب شدید، خستگی، سندروم حاد تنفسی<sup>۲</sup>، شوک سپتیک<sup>۳</sup> و غیره است. این ویروس با هدف قراردادن سیستم تنفسی فرد، سبب ذات‌الریه می‌شود. عفونت ذات‌الریه در ریه، نفس‌کشیدن را برای بیمار دشوار می‌کند [۶].

طبق آخرین توصیه‌های سازمان بهداشت جهانی<sup>۴</sup>، از آزمون واکنش زنجیره‌ای پلیمرز ترانس‌کریپتاز معکوس (RT-PCR)<sup>۵</sup> برای تشخیص قطعی آلودگی فرد به ویروس کرونای جدید استفاده می‌شود [۶-۷]. این آزمون از نمونه‌گیری بزاق دهان و بینی به دست می‌آید؛ با این حال، کیت‌های مربوط به تشخیص ویروس مبتنی بر این آزمون محدودند [۸]. علاوه بر این، این کیت‌ها زمان زیادی برای تشخیص نیاز دارند و نسبت به تشخیص ویروس حساسیت کمی دارند. همچنین این کیت‌ها با توجه به ماهیت تهاجمی که دارند، پزشکان و پرستاران را در معرض آلودگی به ویروس قرار می‌دهند [۹]؛ درنهایت، گفتنی است تشخیص مبتنی بر این آزمون مقرون‌به‌صرفه نیست.

تصویربرداری قفسه سینه<sup>۶</sup> روش دیگری است که برای تشخیص این ویروس در طول مدت درمان بیمار استفاده می‌شود [۱۰]. اسکن توموگرافی کامپیوتری<sup>۷</sup> (CT) و رادیوگرافی دیجیتالی<sup>۸</sup> (DR) از جمله روش‌های تصویربرداری قفسه سینه هستند [۱۱، ۱۲]. هرکدام از این روش‌ها برای تصویربرداری مزایا و معایبی دارند که در ادامه هریک را بررسی خواهیم کرد. از DR به‌منظور تشخیص شکستگی استخوان‌ها، ذات‌الریه، تومورها و بیماری‌های ریوی استفاده می‌شود [۱۲]. در مقابل، CT یک رادیوگرافی پیشرفته است که تصاویر واضح‌تری از بافت‌ها، اندام‌ها و استخوان‌ها فراهم می‌کند [۱۱]؛ با این حال، CT در تمامی

ایکس، سونوگرافی<sup>۱۸</sup> و CT) برای تشخیص خودکار کلاس‌های کووید-۱۹ و سالم از یکدیگر استفاده کردند. این پژوهشگران در تحقیقات خود از شبکه‌ای از پیش آموزش دیده VGG با تغییراتی در معماری این شبکه استفاده کردند. صحت طبقه‌بندی روش پیشنهادی آنها برای سه حالت تصویربرداری مختلف (اشعه ایکس، CT و سونوگرافی) به ترتیب ۸۶، ۸۴ و ۱۰۰ درصد گزارش شده است. اردکانی و همکاران [۲۳] از شبکه‌های یادگیری عمیق با استفاده از تصاویر CT برای تشخیص دو کلاس کووید-۱۹ و سالم استفاده کردند. آنها از ۱۰ شبکه‌ای از پیش آموزش دیده عمیق از جمله SqueezeNet، VGG-16، ResNet-50، AlexNet، MobileNet-V2، VGG-19، ResNet-101، Xception و ResNet-18 استفاده کردند و براساس شبکه Xception به نتایج امیدوارکننده‌ای دست یافتند. صحت نهایی گزارش شده این محققان براساس شبکه Xception حدود ۹۹ درصد است.

همان‌طور که مشهود است بیشتر مطالعات قبلی در روش پیشنهادی خود از شبکه‌های از پیش آموزش دیده عمیق استفاده کرده‌اند و به نتایج درخور توجهی دست یافته‌اند؛ با این حال، این شبکه‌ها بیشتر برای استفاده در داده‌هایی با مقیاس کوچک مناسب‌اند. همچنین، بعضی از مطالعات پیشین صرفاً به ارزیابی الگوریتم خود در طبقه‌بندی دو کلاس بسنده کرده‌اند و کلاس‌های چالش‌برانگیز را در روش پیشنهادی خود به کار نگرفتند. برای ورود پژوهش حاضر به حوزه کاربردی و عملی لازم است معماری شبکه پیشنهادی به گونه‌ای طراحی شود که نخست بتواند برای داده‌های با مقیاس بزرگ‌تر استفاده شود؛ دوم، انواع کلاس‌ها و سناریوهای مهم و کاربردی در آن در نظر گرفته شود. در این مطالعه از ترکیب شبکه‌های یادگیری عمیق با توابع فعال‌سازی نوع دو<sup>۱۹</sup> به همراه شبکه‌های GAN برای تشخیص انواع پنومونیا در ۳ کلاس (سالم، پنومونیا و کووید-۱۹) و ۲ سناریوی مهم کاربردی استفاده شده است. همچنین، شبکه پیشنهادی را می‌توان یک طبقه‌بندی‌کننده پایان به پایان در نظر گرفت که در آن نیازی به فرایند انتخاب / استخراج ویژگی‌های مطلوب نیست و ویژگی‌های لازم و مورد نیاز هر کلاس به‌طور خودکار

پنومونیا استفاده کردند. محققان در مدل پیشنهادی خود از پنج شبکه‌ای از پیش آموزش دیده عمیق شامل AlexNet، DenseNet، Inception V3، ResNet 18 و GoogLeNet استفاده کردند. صحت نهایی گزارش شده توسط این محققان برای طبقه‌بندی پنومونیا ۲ کلاس ۹۶ درصد بود. خلیفه و همکاران [۱۸] از ترکیب شبکه‌های مولد تخصصی<sup>۱۳</sup> (GANs) با شبکه‌های از پیش آموزش دیده عمیق برای تشخیص خودکار پنومونیا از تصاویر اشعه ایکس قفسه سینه استفاده کردند؛ از جمله شبکه‌های استفاده شده در مدل پیشنهادی این پژوهشگران، AlexNet، GoogLeNet، SqueezeNet و ResNet18 بود. صحت گزارش شده توسط این محققان برای طبقه‌بندی پنومونیا در ۲ کلاس مختلف تقریباً ۹۹ درصد گزارش شده است. استفان و همکاران [۱۹] یک مدل کارآمد یادگیری عمیق را برای طبقه‌بندی پنومونیا از تصاویر اشعه ایکس قفسه سینه ارائه داده‌اند. معماری شبکه آنها از ۴ لایه کانولوشن<sup>۱۴</sup> و ۲ لایه تماماً متصل<sup>۱۵</sup> تشکیل شده بود. محققان در طبقه‌بندی دو کلاس سالم و پنومونیا به صحت ۹۳/۷ درصد دست یافتند. لونیس و همکاران [۲۰] از ۱۴۲۷ تصویر اشعه ایکس قفسه سینه برای طبقه‌بندی خودکار سه نوع پنومونیا (ویروسی، باکتریایی و کووید-۱۹) استفاده کرده‌اند. آنها پنج شبکه‌ای از پیش آموزش دیده عمیق شامل VGG، MobileNet V2، Xception، Inception و ResNet V2 را در الگوریتم پیشنهادی خود به کار گرفتند. تحقیقات آنها نشان می‌دهد شبکه VGG عملکرد بهتری نسبت به سایر شبکه‌ها داشته است. صحت نهایی برای طبقه‌بندی ۲ کلاس (سالم و کووید-۱۹) و ۳ کلاس (ویروسی، باکتریایی و کووید-۱۹) به ترتیب ۹۸/۷۵ درصد و ۹۳/۴۸ درصد گزارش شده است. هوآیانگ و همکاران [۲۱] از شبکه‌های عصبی عمیق<sup>۱۶</sup> در ترکیب با جنگل تصادفی<sup>۱۷</sup> برای طبقه‌بندی خودکار پنومونیا ۲ کلاس استفاده کردند. همچنین، این پژوهشگران از یک فیلتر میانی برای از بین بردن نویز تصاویر اشعه ایکس قفسه سینه استفاده کردند. دقت نهایی گزارش شده توسط این محققان برای طبقه‌بندی پنومونیا در ۲ کلاس مختلف، ۹۷ درصد گزارش شده است. هیتون و همکاران [۲۲] از ۳ نوع روش تصویربرداری پزشکی (اشعه

## ۲-۲- شبکه‌های مولد تخصصی (GAN)

گودفلو و همکاران در سال ۲۰۱۴ برای نخستین بار شبکه‌های GAN را معرفی کردند [۲۵]. در سال‌های اخیر، این شبکه‌ها شایان توجه بسیاری از محققان در حوزه یادگیری عمیق قرار گرفته‌اند. GANها با استفاده از معماری شبکه عصبی کانولوشن می‌توانند مجموعه داده‌های (مانند تصاویر اشعه ایکس قفسه سینه) استفاده‌شده در آزمایش‌ها را یاد بگیرند و یک مجموعه داده جدید و واقعی ایجاد کنند که در مجموعه داده قبلی موجود نیست. از جمله کاربردهای این شبکه در حوزه بینایی ماشین، می‌توان به تولید محتوای ویدئویی، استخراج ویژگی به صورت یادگیری بدون نظارت، کدگذاری تصویر و تصویربرداری با وضوح فوق‌العاده، تجزیه و تحلیل و سنتز گفتار اشاره کرد [۲۵].

این شبکه‌ها براساس رویکرد تئوری بازی‌ها بناگذاری شده‌اند که در آن یک شبکه یادگیری عمیق که مولد  $G$  نامیده می‌شود، با یک روند تخصصی رقابت می‌کند. شبکه عمیق دیگری که متمایزکننده  $D$  نامیده می‌شود، سعی می‌کند نمونه‌های تولیدشده از شبکه مولد را از داده‌های اصلی متمایز کند. رقابت بین این دو شبکه در نهایت باعث یادگیری بهتر و بهبود عملکرد هر دو می‌شود. شبکه  $G$  وظیفه دارد تصاویر را تا حد ممکن طبیعی و واقعی تولید کند. برای یادگیری توزیع شبکه  $G$  روی داده‌های ورودی، ابتدا از یک توزیع نویز به‌عنوان ورودی استفاده می‌شود. شبکه  $D$  وظیفه تشخیص تصاویر از تصاویر مصنوعی را بر عهده دارد؛ برای مثال، در مطالعه حاضر شبکه  $D$  باید به تصاویر اشعه ایکس قفسه سینه تولیدشده توسط شبکه  $G$  نگاه کند تا تعیین کند آیا این تصاویر به اندازه کافی طبیعی هستند یا خیر. شبکه  $D$  به‌منظور به حداکثر رساندن دقت تشخیص داده‌های اصلی از داده‌های تولیدشده آموزش داده می‌شود. همچنین، شبکه  $G$  به‌طور هم‌زمان آموزش داده شده است تا شبکه  $D$  را گمراه کند که تابع زیر را به حداقل برساند:

$$\log(1 - D(G(z))) \quad (1)$$

در نهایت، تابع زیر به حداقل می‌رسد:

توسط شبکه عمیق پیشنهادی فراآموخته می‌شود.

ادامه مقاله به صورت زیر تدوین شده است: بخش ۲ پایگاه داده استفاده‌شده را توصیف می‌کند؛ همچنین، شبکه‌های عصبی کانولوشنال به همراه شبکه‌های فازی نوع ۲ در این بخش توضیح داده می‌شوند. در بخش ۳، معماری شبکه پیشنهادی براساس ترکیب با تابع فازی نوع ۲ ارائه می‌شود. در بخش ۴، نتایج شبیه‌سازی بررسی می‌شوند. در نهایت، بخش ۵ مربوط به نتیجه‌گیری است.

## ۲- مواد و روش‌ها

در این بخش ابتدا مجموعه داده‌های استفاده‌شده در این پژوهش توضیح داده می‌شود. سپس شبکه‌های GAN شرح داده خواهد شد. همچنین، شبکه‌های عصبی عمیق به همراه شبکه‌های فازی نوع ۲ در این بخش بررسی خواهند شد.

### ۲-۱- پایگاه داده

در این پژوهش محققان برای ارزیابی روش پیشنهادی خود از پایگاه داده رادیوگرافی کووید-۱۹ [۲۴] استفاده کرده‌اند. این پایگاه داده به‌تازگی به‌صورت گسترده در مطالعات پیشین استفاده شده است. محققان کشورهای قطر، دوحه، پاکستان و مالزی، پایگاه داده استفاده‌شده را ایجاد کرده‌اند که شامل تصاویر رادیوگرافی قفسه سینه در ۳ کلاس مختلف سالم، پنومونیا (ویروسی و باکتریایی) و کووید-۱۹ است. تعداد تصاویر رادیوگرافی قفسه سینه برای هر یک از کلاس‌های سالم، پنومونیا و کووید-۱۹ به ترتیب ۱۳۴۱، ۱۳۴۵ و ۲۰۲ است. شکل ۱ نمونه‌ای از تصاویر رادیوگرافی قفسه سینه برای ۳ کلاس سالم، پنومونیا و کووید-۱۹ را نشان می‌دهد. همان‌طور که در شکل ۱ مشخص است، هیچ تفاوت محسوس بین کلاس‌های کووید-۱۹ و پنومونیا مشاهده نمی‌شود.



شکل (۱): تصاویر رادیوگرافی قفسه سینه مربوط به کلاس‌های

سالم، پنومونیا و کووید-۱۹ (از چپ به راست).

میزان خطای شبکه استفاده می‌شود. برای این کار، خروجی شبکه با استفاده از یک تابع خطا<sup>۲۴</sup> با پاسخ صحیح، مقایسه و به این ترتیب، میزان خطا محاسبه می‌شود. در مرحله بعد، براساس میزان خطای محاسبه‌شده، مرحله پس‌انتشار آغاز می‌شود. در این مرحله، گرادیان هر پارامتر با توجه به قاعده زنجیره‌ای محاسبه شده و تمامی پارامترها با توجه به تأثیرشان بر خطای ایجادشده در شبکه، به‌روزرسانی می‌شوند. بعد از به‌روزرسانی پارامترها، مرحله بعدی انتشار پیشرو آغاز خواهد شد. بعد از تکرار تعداد مناسبی از این مراحل، آموزش شبکه به پایان می‌رسد. در این شبکه، خروجی هر لایه همان ویژگی‌ها هستند که بعد کمتری نسبت به داده اصلی دارند [۲۷، ۲۸].

به‌طور کلی، یک شبکه کانولوشنال از سه لایه اصلی تشکیل می‌شود که عبارت‌اند از لایه کانولوشن، لایه ادغام<sup>۲۵</sup> و لایه تمام متصل<sup>۲۶</sup> (FC) [۲۹]. برای جلوگیری از فرایند بیش‌برازش<sup>۲۷</sup> و بهبود عملکرد شبکه می‌توان از لایه‌های حذف تصادفی<sup>۲۸</sup> و نرمال‌سازی دسته‌ای<sup>۲۹</sup> نیز استفاده کرد. همچنین در شبکه‌های عصبی نیاز است پس از هر لایه از تابع فعال‌سازی استفاده شود که در ادامه، این لایه‌ها و توابع به‌طور خلاصه معرفی می‌شوند.

لایه کانولوشن: شامل فیلترهایی (کرنل‌هایی) است که روی سیگنال EEG می‌لغزند. یک کرنل، یک ماتریس است که با سیگنال ورودی EEG کانوالو می‌شود. این لایه عمل کانولوشن را روی سیگنال EEG ورودی با استفاده از کرنل انجام می‌دهد. خروجی کانولوشن را نگاشت ویژگی می‌نامند. عملگر کانولوشن به شرح زیر است:

$$y_k = \sum_{n=0}^{N-1} x_n h_{k-n} \quad (3)$$

که  $x$  سیگنال،  $h$  فیلتر،  $N$  تعداد عناصر در  $x$  و  $y$  بردار خروجی است.

لایه ادغام: این لایه که به کاهش نمونه<sup>۳۰</sup> نیز معروف است، ابعاد نوروهای خروجی از لایه کانولوشن را کاهش می‌دهد و باعث کاهش محاسبات و همچنین جلوگیری از پدیده بیش‌برازش می‌شود. در این پژوهش از لایه ادغام بیشینه<sup>۳۱</sup> استفاده شده است که فقط مقادیر بیشینه در هر نگاشت ویژگی را انتخاب می‌کند و باعث کاهش تعداد

$$\min_{GD} \max V(G, D) = E_x - P_{data} [\log D(x)] + E_{Z_{P(Z)}} [\log(1 - D(G(Z)))] \quad (2)$$

با توجه به معادله بالا،  $D$  به گونه‌ای استخراج می‌شود که بتواند داده‌های واقعی و مصنوعی را به‌درستی تشخیص دهد [۲۶]. رابطه (۲) به‌صورت فرم بسته قابل حل نیست و بنابراین از روش‌های تکراری و عددی به‌منظور حل آن استفاده می‌شود. بهینه‌سازی  $D$  در حلقه داخلی آموزش، پیچیدگی محاسباتی بالایی دارد و برای داده‌های با تعداد نمونه کم، باعث پدیده بیش‌برازش خواهد شد؛ بنابراین، به‌ازای هر  $k$  بار بهینه‌سازی تابع  $D$ ، یک بار تابع  $G$  بهینه می‌شود. به‌ازای هر تکرار  $k$ ، به تعداد  $m$  از فضای نوین اولیه

$$P_g(z) \text{ نمونه‌برداری شده است } z = \{z^{(1)}, \dots, z^{(m)}\} \text{ و به تعداد } m \text{ از توزیع اولیه داده‌ها } P_{data} \text{ نمونه‌برداری می‌شود}$$

$$x = \{z^{(1)}, \dots, z^{(m)}\}$$

## ۲-۳- شبکه‌های عصبی کانولوشن

شبکه عصبی کانولوشنال، در واقع یک شبکه عصبی بهبودیافته است. در این شبکه، چندین لایه با روشی قدرتمند در کنار هم آموزش می‌بینند [۲۷]. این روش، بسیار کارآمد بوده و یکی از رایج‌ترین روش‌ها در کاربردهای مختلف بینایی ماشین است. همانند ANN، تصمیم خروجی نهایی مدل CNN براساس وزن و بایاس لایه‌های قبلی در ساختار شبکه است.

در هر شبکه عصبی کانولوشنال، دو مرحله برای آموزش وجود دارد؛ مرحله انتشار پیشرو<sup>۳۲</sup> و مرحله پس‌انتشار<sup>۳۳</sup>

(BP) [۲۷]. BP روشی برای محاسبه گرادیان تابع اتلاف نسبت به وزن‌ها است. BP سیگنال‌های خطا را در شبکه حین آموزش به عقب انتشار می‌دهد و باعث به‌روزرسانی وزن‌ها می‌شود. در مرحله اول، داده‌های ورودی به شبکه اعمال می‌شوند و این عمل چیزی بجز ضرب نقطه‌ای بین ورودی و پارامترهای هر نورو و سپس اعمال عملیات کانولوشن در هر لایه نیست و در نهایت، خروجی شبکه محاسبه می‌شود. به‌منظور تنظیم پارامترهای شبکه یا به عبارت دیگر آموزش شبکه، از نتیجه خروجی برای محاسبه

$$\text{Relu} > f(x) = \begin{cases} x & x \geq 0 \\ 0 & x < 0 \end{cases} \quad (6)$$

تابع سافت مکس<sup>۳۳</sup>: این تابع توزیع احتمالی کلاس‌های خروجی را محاسبه می‌کند؛ بنابراین، در لایه تمام متصل آخر از تابع سافت مکس برای پیش‌بینی اینکه کدام سیگنال ورودی به هیجان مثبت، منفی و خنثی مربوط است، استفاده می‌شود و رابطه آن به فرم زیر است:

$$p_j = \frac{e^{x_j}}{\sum_k e^{x_k}} \quad \text{for } j = 1, \dots, k \quad (7)$$

که در آن،  $x$  ورودی شبکه است و مقادیر خروجی  $p$  بین صفر و یک بوده که مجموع آنها برابر با یک است.

## ۲-۴- مجموعه‌های فازی نوع ۲ (T2F sets)

پروفسورزاده در سال ۱۹۷۵ مجموعه‌های فازی نوع ۲ را به‌عنوان توسعه‌ای از مجموعه‌های فازی نوع ۱ معرفی کرد [۳۰]. برخلاف سیستم‌های فازی نوع ۱، توابع تعلق در سیستم‌های فازی نوع ۲ دارای درجه عضویت‌های فازی‌اند. استفاده از توابع تعلق فازی نوع ۲ توانایی سیستم‌های فازی را در مواجهه با عدم قطعیت‌ها (ساختاری و نویز اندازه‌گیری) و در مقایسه با سیستم‌های فازی معمولی (توابع فازی نوع ۱) تا حد چشمگیری افزایش داده است.

در پژوهش‌های انجام‌شده، از این توانایی سیستم‌های فازی نوع ۲ در طراحی سیستم‌های کنترل، پیش‌بینی سری‌های زمانی و محاسبه با کلمات استفاده شده است که عدم قطعیت و پیچیدگی زیاد دارند و کارایی آنها در کاربردهای تئوری و عملی نشان داده شده است. در این میان، یکی از مهم‌ترین اجزای DNN عملکرد توابع فعال‌سازی‌ها است؛ زیرا توابع فعال‌سازی در فرایند یادگیری نقش مهمی دارند. پس از کشف تابع Relu که امروزه به‌عنوان پرکاربردترین واحد فعال‌سازی به‌شمار می‌رود، DNN‌ها پیشرفت زیادی کرده‌اند؛ زیرا Relu علاوه بر کاهش مشکل حذف گرادیان، عملکرد یادگیری را نیز بهبود می‌بخشد. توابع مختلف فعال‌سازی مشابه Relu و Leaky-Relu برای بهبود بیشتر عملکرد یادگیری در شبکه‌های DNN ارائه شده است. با این حال، حتی اگر این توابع فعال‌سازی عملکرد

نورون‌های خروجی می‌شود.

لایه FC: دارای اتصال کامل به تمام فعال‌سازی‌ها در لایه قبلی است.

لایه حذف تصادفی: از این لایه به‌منظور جلوگیری از پدیده بیش‌برازش استفاده می‌شود. نحوه کار آن به این صورت است که در هر مرحله از آموزش، هر نورون با احتمالی از شبکه بیرون انداخته شده است؛ به طوری که در نهایت یک شبکه کاهش داده شده باقی می‌ماند.

لایه نرمال‌سازی دسته‌ای: این لایه به‌منظور نرمال‌سازی داده‌ها در داخل شبکه انجام می‌شود [۲۹]. زمانی که محاسبات مختلف روی داده ورودی اعمال شود، توزیع داده‌ها تغییر خواهد کرد. این لایه با هدف کاهش تغییر کوواریانس داخلی، سرعت آموزش شبکه را افزایش می‌دهد و باعث تسریع در همگرایی می‌شود. تبدیل لایه نرمال‌سازی دسته‌ای به شرح زیر است:

$$\begin{aligned} \mu_B &= \frac{1}{n} \sum_{i=1}^n y_i^{(l-1)} \\ \sigma_B^2 &= \frac{1}{n} \sum_{i=1}^n (y_i^{(l-1)} - \mu_B)^2 \\ \hat{y}^{(l-1)} &= \frac{y^{(l-1)} - \mu_B}{\sqrt{(\sigma_B^2 + \varepsilon)}} \\ z^{(l)} &= \gamma^{(l)} \hat{y}^{(l-1)} + \beta^{(l)} \end{aligned} \quad (8)$$

که  $\mu_B$  و  $\sigma_B^2$  به ترتیب میانگین و واریانس دسته‌اند.  $\varepsilon$  یک ثابت کوچک برای ثبات عددی،  $l$  شماره لایه، بردار ورودی به لایه نرمال‌سازی،  $z^{(l)}$  بردار خروجی نرمال مربوط به یک نورون است،  $\gamma^{(l)}$  و  $\beta^{(l)}$  به ترتیب پارامترهای مربوط به مقیاس و تغییر نرخ یادگیری‌اند.

تابع فعال‌سازی: پس از هر لایه کانولوشن، یک تابع فعال‌سازی اعمال می‌شود. تابع فعال‌سازی یک عملگر است که خروجی را به مجموعه‌ای از ورودی‌ها نگاشت می‌کند و برای غیرخطی کردن ساختار شبکه استفاده می‌شود. رابطه‌های ۵ و ۶ توابع فعال‌سازی LeakyRelu و Relu را نشان می‌دهند. مطابق با رابطه ۵، در حالت نرمال  $\alpha = 0.01$  است.

$$\text{Leaky Relu} > f(x) = \begin{cases} x & x > 0 \\ \alpha x & x \leq 0 \end{cases} \quad (5)$$

که در معادله بالا،  $k_c(\cdot)$  از قانون به روزرسانی پارامترها به فرم زیر حاصل می شود:

$$\Delta \gamma = \rho \Delta \gamma + \xi \frac{\partial L}{\partial \gamma} \quad (13)$$

که در آن، پارامترهای  $\rho$  و  $\xi$  به ترتیب نشان دهنده مقدار حرکت و نرخ آموزش اند [۳۰-۳۲].

با توجه به اینکه تعداد کل پارامترهای قابل یادگیری / تنظیم در استفاده از تابع فعال ساز فازی نوع ۲ فقط  $3C$  است (C تعداد واحدهای پنهان)، در مقایسه با تعداد کل وزن های DNN معمولی، عدد نسبتاً کمی است؛ بنابراین، با توجه به مزایای مطرح شده در استفاده از تابع فعال ساز فازی نوع ۲، در این پژوهش و در روش پیشنهادی از ترکیب شبکه های CNN و این توابع، به منظور مقابله با عدم قطعیت ها و نویز اندازه گیری استفاده شده است.

### ۳- روش پیشنهادی

در این بخش، روش پیشنهادی در این مقاله ارائه می شود. شکل ۲ ساختار کلی روش پیشنهادی را نشان می دهد. مطابق با شکل ۲ همان طور که مشخص است در ابتدا عملیات پیش پردازش داده ها شامل عملیات نرمال سازی، سگمنت بندی و افزایش دادگان روی تصاویر انجام می گیرد. سپس عملیات انتخاب و استخراج ویژگی به منظور طبقه بندی کلاس ها روی دادگان انجام خواهد شد. در ادامه هر یک از این مراحل به صورت کامل شرح داده می شوند.

#### ۳-۱- پیش پردازش داده ها

در این بخش، پیش پردازش های انجام شده روی دادگان بررسی می شوند. مطابق با الگوریتم پیشنهادی، عملیات پیش پردازش روی داده ها شامل چهار مرحله زیر است: ابتدا تمامی تصاویر بین (۰ و ۱) نرمالیزه می شوند. سپس در مرحله دوم اندازه تصاویر به  $224 \times 224$  تغییر داده می شود. تغییر اندازه تصاویر به منظور تسهیل در روند آموزش و کاهش زمان محاسباتی انجام می پذیرد. در مرحله سوم با توجه به یکسان نبودن تعداد نمونه های مربوط به هر کلاس

خوبی در DNN ها داشته باشند، روابط ورودی و خروجی بین آنها غیرخطی است که یک نقطه ضعف مشترک در همه این توابع فعال سازی ها محسوب می شود [۳۱].

با توجه به توانایی یاد شده مجموعه های فازی نوع ۲، در این پژوهش از توابع تعلق فعال ساز فازی نوع ۲ به جای توابع فعال سازی Relu و Leaky-Relu در لایه های میانی معماری FCNN پیشنهادی استفاده شده است. بر همین اساس، نسبت توابع آن در شبکه FCNN پیشنهادی به صورت زیر تعریف می شود:

$$f(\sigma; \gamma) = \begin{cases} P \sigma k(\sigma), & \text{if } \sigma > 0 \\ N \sigma(-\sigma), & \text{if } \sigma \leq 0 \end{cases} \quad (8)$$

که در آن تابع  $k$  به صورت زیر بیان می شود [۳۱]:

$$k(\sigma) = \frac{1}{2} \left( \frac{1}{\alpha + \sigma - \alpha \sigma} + \frac{-1 + \alpha}{-1 + \alpha \sigma} \right) \quad (9)$$

اگر مشتقات ریاضی مورد نیاز را درباره پارامترهای معرفی شده در بالا ارائه دهیم، این پارامترها می توانند به عنوان پارامترهای یادگیری استفاده شوند. به بیان دیگر، پارامترهای  $\gamma = [\alpha, P, N]$  باید در هر تکرار به روزرسانی شوند که الگوریتم به روزرسانی آنها به شکل معادلات زیر است:

$$\frac{\partial L}{\partial \gamma_c} = \sum_j \frac{\partial L}{\partial f_c(\sigma_{c_j})} \frac{\partial f_c(\sigma_{c_j})}{\partial \gamma_c} \quad (10)$$

که  $c$  نشان دهنده لایه ها،  $j$  مربوط به المان مشاهدات و  $L$  نشان دهنده تابع هدف DNN است. همچنین، نشان دهنده شیب انتشار یافته از لایه های عمیق تر پس از لایه فعال ساز فازی نوع ۲ است و شیب کلی آن برابر است با:

$$\frac{\partial f_c(\sigma_c)}{\partial a_c} = \begin{cases} \frac{P_c \sigma_c}{2} \left( \frac{1}{\alpha_c \sigma_c - 1} + \frac{\sigma_c - 1}{(a_c + \sigma_c - \alpha_c \sigma_c)^2} + \frac{\sigma_c (1 - a_c)}{(a_c \sigma_c - 1)^2} \right) & \text{if } \sigma_c > 0 \\ -\frac{N_c \sigma_c}{2} \left( \frac{1}{\alpha_c \sigma_c + 1} + \frac{\sigma_c + 1}{(a_c - \sigma_c + \alpha_c \sigma_c)^2} + \frac{\sigma_c (1 - a_c)}{(a_c \sigma_c + 1)^2} \right) & \text{if } \sigma_c \leq 0 \end{cases} \quad (11)$$

و همچنین:

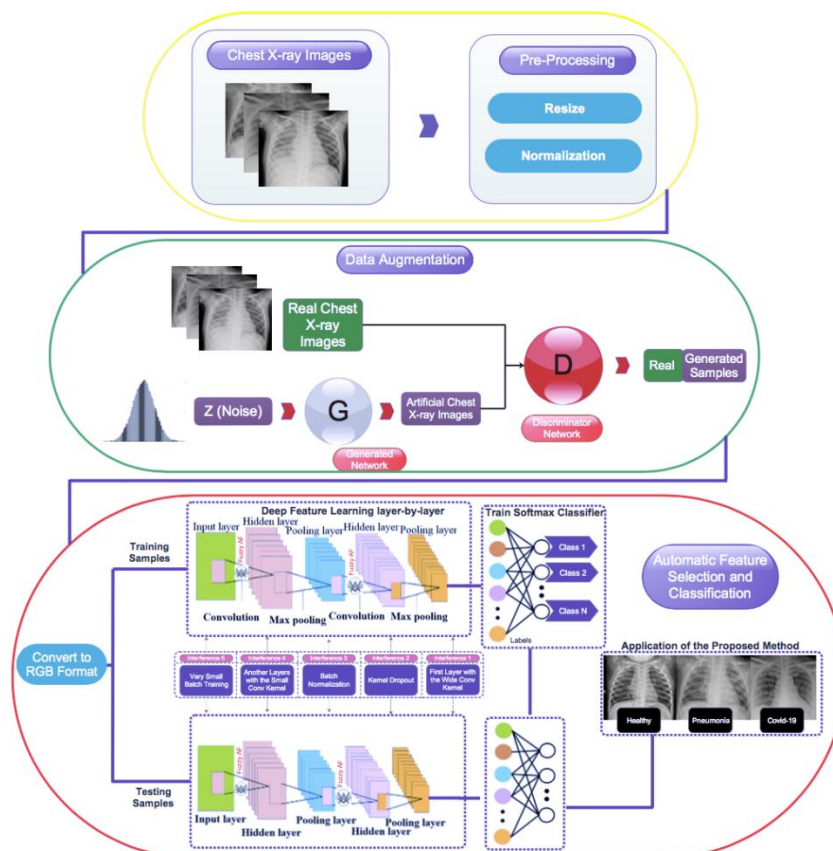
$$\frac{\partial f_c(\sigma_c)}{\partial P_c} = \begin{cases} \sigma_c k_c(\sigma_c), & \text{if } \sigma_c > 0 \\ 0, & \text{if } \sigma_c \leq 0 \end{cases} \quad (12)$$

$$\frac{\partial f_c(\sigma_c)}{\partial N_c} = \begin{cases} 0, & \text{if } \sigma_c > 0 \\ \sigma_c k_c(-\sigma_c), & \text{if } \sigma_c \leq 0 \end{cases}$$




متصل (۱۰۲۴، ۵۱۲، ۲۵۶ و ۱) به همراه یک لایه حذف تصادفی در هر لایه تشکیل شده است. در این شبکه از تابع **Leaky-Relu** به عنوان تابع فعال‌سازی در لایه‌های مخفی و از تابع سیگموئید در انتهای شبکه استفاده شده است. فرایند آموزش شبکه توسط تابع هزینه خطای میانگین مربعات<sup>۳۳</sup> (MSE) و بهینه‌ساز آنتروپی باینری<sup>۳۴</sup> با نرخ یادگیری ۰/۰۰۰۲ و اندازه دسته ۱۰ برای ۱۰۰۰ تکرار انجام شده است. شکل ۳ تصاویر مصنوعی تولیدشده توسط شبکه‌های **GAN** برای کلاس کووید-۱۹ را نشان می‌دهد. همچنین، جدول ۱ تعداد نمونه‌های مربوط به هر کلاس را قبل و بعد از داده‌افزایی با استفاده از شبکه‌های **GAN** نمایش می‌دهد. در مرحله چهارم تمامی تصاویر به فرمت **RGB** تبدیل می‌شوند که پس از تبدیل، اندازه تصاویر به  $3 \times 224 \times 224$  تغییر می‌کند.

سالم، پنومونیا و کووید-۱۹، از شبکه‌های **GAN** برای افزایش تعداد نمونه‌های کووید-۱۹ به منظور برقراری توازن بین کلاس‌ها استفاده می‌شود. استفاده از این شبکه‌ها سبب عدم بروز مشکل بیش‌برازش در طول آموزش روش پیشنهادی نیز خواهد شد. شبکه **GAN** بردار تصادفی صدتایی با توزیع یکنواخت را به عنوان ورودی می‌گیرد و سیگنالی به اندازه  $224 \times 224 = 50176$  را به عنوان خروجی تولید می‌کند. معماری این شبکه از چهار لایه متراکم کاملاً متصل (۲۵۶، ۵۱۲، ۱۰۲۴ و ۵۰۱۷۶) تشکیل شده است که هر لایه با یک تابع نرمال‌ساز دسته‌ای به یکدیگر متصل است. برای شبکه‌های **GAN**، ما از تابع فعال‌سازی **Leaky-Relu** و تابع فعال‌سازی **tanh** به ترتیب در لایه‌های مخفی و انتهای شبکه استفاده کرده‌ایم. شبکه **D** ورودی  $50176$  را دریافت می‌کند و یک تصمیم (واقعی یا جعلی بودن تصاویر) را صادر می‌کند. شبکه **D** از چهار لایه متراکم کاملاً



شکل (۲): بلوک دیاگرام کلی روش پیشنهادی شامل بخش‌های پیش‌پردازش، افزایش دادگان و شبکه عمیق پیشنهادی (بخش پیش‌پردازش دادگان شامل تغییر اندازه و نرمال‌سازی تصاویر، بخش افزایش دادگان براساس شبکه‌های مولد تخصصی و بخش شبکه عمیق پیشنهادی براساس شبکه‌های تمام کانونلوشنی با تابع فعال‌سازی نوع ۲).

سه عامل اصلی بر شبکه پیشنهادی تأثیر می‌گذارد: (۱) استفاده از توابع فعال‌سازی فازی به جای توابع فعال‌سازی Relu و Leaky-Relu (۲) استفاده از فیلتر بزرگ در لایه اول که سبب حذف نویزهای در محدوده فرکانس بالا می‌شود. (۳) استفاده از فیلترهای کوچک در لایه‌های میانی که روند آموزش شبکه را تسهیل می‌کنند.



شکل (۳): تصاویر مصنوعی تولیدشده برای کلاس کووید-۱۹.

### ۳-۳- مجموعه آموزش، ارزیابی و آزمون

در این تحقیق تمامی ابرپارامترها مربوط به شبکه پیشنهادی به دقت تنظیم شده است تا بهترین میزان همگرایی حاصل شود. همچنین، از روش آزمون و خطا برای تعیین این ابرپارامترها در این پژوهش استفاده شده است؛ در نهایت، فرایند آموزش شبکه براساس تابع هزینه MSE و بهینه‌ساز Rmsprop با میزان یادگیری و اندازه دسته ۱۰ انجام شده است. تعداد کل پارامترها و نمونه‌ها برای هر سناریو به ترتیب ۹۲۳۳۲۷ و ۴۰۳۱ است. از کل نمونه‌های موجود (۴۰۳۱ نمونه)، ۲۰۱۵ نمونه برای مجموعه آموزشی (۵۰ درصد)، ۴۰۳ نمونه به منظور مجموعه اعتبارسنجی (۱۰ درصد) و ۱۶۱۳ نمونه برای مجموعه آزمون (۴۰ درصد) استفاده شده است. گفتنی است تمام نمونه‌های اختصاص داده شده به مجموعه‌های آموزش، ارزیابی و آزمون به طور تصادفی انتخاب شده‌اند.

در این پژوهش، به منظور طراحی مطلوب معماری پیشنهادی، از انواع مختلف بهینه‌سازها، تعداد مختلف لایه‌ها، تعداد و اندازه مختلف فیلترها و غیره استفاده شده است و پس از آزمون و خطا، معماری نهایی شبکه به دست آمده است. جدول ۳ فیلترها و ابرپارامترهای بهینه انتخاب شده را نشان می‌دهد.

جدول (۱): تعداد نمونه‌های مربوط به هر کلاس

گروه‌ها	سالم	پنومونیا	کووید-۱۹
قبل از استفاده از GAN	۱۳۴۱	۱۳۴۵	۲۰۲
بعد از استفاده از GAN	-	-	۱۲۰۰
مجموع	۱۳۴۱	۱۳۴۵	۱۴۰۲

### ۳-۲- معماری شبکه عمیق پیشنهادی

در معماری شبکه پیشنهادی از ترکیب ۷ لایه کانولوشن دوبعدی استفاده شده است. برای پیاده‌سازی شبکه پیشنهادی FCNN از کتابخانه کراس در زبان برنامه‌نویسی پایتون استفاده شده است. معماری شبکه عصبی عمیق پیشنهادی به صورت زیر انتخاب شده است: (۱) یک لایه حذف تصادفی؛ (۲) یک لایه کانولوشن با تابع فعال‌سازی فازی نوع ۲ و یک لایه ادغام پیشینه همراه با نرمال‌ساز دسته‌ای اضافه می‌شود؛ (۳) معماری مرحله قبل، ۶ بار دیگر تکرار می‌شود؛ (۴) خروجی معماری قبلی به یک ماتریس دوبعدی Flatten متصل می‌شود؛ (۵) برای دسترسی به لایه خروجی از یک لایه سافت‌مکس استفاده می‌شود. شکل ۴ جزئیات معماری شبکه عمیق پیشنهادی را نشان می‌دهد. جدول ۲ جزئیات معماری شبکه پیشنهادی استفاده شده را نشان می‌دهد. طبق جدول ۲ کاهش بعد در لایه‌های پنهان از  $۲۲۴ \times ۲۲۴ \times ۳$  به ۳ ادامه یافته است.

جدول (۲): جزئیات معماری مربوط به شبکه عمیق پیشنهادی.

L	Layer type	Activation function	Output Shape	Size of filter and Pooling	Strides	Number of filters	padding
0-1	Convolution2-D	Fuzzy	(None, 16, 224,224)	128×128	1	16	yes
1-2	Max-Pooling2-D	-	(None, 16, 112,112)	2×2	2	-	no
2-3	Convolution2-D	Fuzzy	(None, 32,112,112)	3×3	1	32	yes
3-4	Max-Pooling2-D	-	(None, 32, 56, 56)	2×2	2	-	no
4-5	Convolution2-D	Fuzzy	(None, 64, 56, 56)	3×3	1	64	yes
5-6	Max-Pooling2-D	-	(None, 64, 28, 28)	2×2	2	-	no
6-7	Convolution2-D	Fuzzy	(None, 64, 28, 28)	3×3	1	64	yes
7-8	Max-Pooling2-D	-	(None, 64, 14, 14)	2×2	2	-	no
8-9	Convolution2-D	Fuzzy	(None, 64, 14, 14)	3×3	1	64	yes
9-10	Max-Pooling2-D	-	(None, 64, 7, 7)	2×2	2	-	no
10-11	Convolution2-D	Fuzzy	(None, 64, 7, 7)	3×3	1	64	yes
11-12	Max-Pooling2-D	-	(None, 64, 3, 3)	2×2	2	-	no
10-11	Convolution2-D	Fuzzy	(None, 3, 3, 3)	3×3	1	3	yes
11-12	Max-Pooling2-D	-	(None, 3, 1, 1)	2×2	2	-	no
13-14	Flatten	-	(None, 3)	-	-	-	-
14-15	Softmax	-	(None, 3)	-	-	-	-

جدول (۳): پارامترهای بهینه انتخاب شده در شبکه پیشنهادی

Parameter	Search space	Optimal value
Optimizer	RMSProp, Adam, Sgd, Adamax, Adadelata	RMSProp
Cost function	MSE, MAE, Cross-entropy	MSE
Number of Convolution layers	3, 5, 7, 10,15	7
Number of Filters in the first convolution layer	16, 32, 64, 128	16
Number of Filters in the second convolution layer	16, 32, 64, 128	32
Number of Filters in the third convolution layer	16, 32, 64, 128	64
Number of Filters in the fourth convolution layer	16, 32, 64, 128	64
Number of Filters in the fifth convolution layer	16, 32, 64, 128	64
Number of Filters in the SIXTH convolution layer	16, 32, 64, 128	64
Size of filter in the first convolution layer	(3,3), (16,16), (32,32), (64,64), (128,128)	(128,128)
Size of filter in another convolution layers	(3,3), (16,16), (32,32), (64,64), (128,128)	(3, 3)
Dropout rate	0, 0.2, 0.3, 0.4, 0.5	0.3
Batch size	4, 8, 10, 16, 32, 64	10
learning rate	0.01, 0.001,0.0001	0.0001

#### ۴- نتایج و بحث

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (14)$$

$$Precision = \frac{TP}{TP + FP} \quad (15)$$

$$Sensitivity = \frac{TP}{TP + FN} \quad (16)$$

$$Sensitivity = \frac{TN}{TN + FP} \quad (17)$$

مطابق با روابط بالا، TP مثبت حقیقی، TN منفی حقیقی، FP مثبت کاذب و FN منفی کاذب نمونه‌ها در کلاس‌های طبقه‌بندی است.

شکل ۵ صحت و خطای طبقه‌بندی را برای جداسازی

در این بخش نتایج مربوط به روش پیشنهادی ارائه شده‌اند. کلیه آزمایش‌های مربوطه روی سیستم کلاب<sup>۳۰</sup> گوگل انجام شده است که مشخصات آن به شرح زیر است: رم ۲۵ گیگابایت و Tesla k90 GPU. در این پژوهش از معیارهای صحت، دقت، حساسیت و اختصاصیت به‌منظور ارزیابی مدل پیشنهادی استفاده شده است. فرمول محاسبه مربوط به این معیارها در روابط (۱۴-۱۷) ارائه شده است.

کمتری در مقایسه با ترکیب شبکه با سایر فعال‌سازی‌ها است که نشان‌دهنده مطلوبیت طراحی معماری پیشنهادی است. با توجه به این موضوع که بیشتر سیستم‌های رادیولوژی موجود در بیمارستان‌های دولتی قدیمی‌اند، تصاویر تولیدی از این سیستم‌ها بیشتر همراه با نویز هستند؛ به همین دلیل، لازم است معماری شبکه پیشنهادی به گونه‌ای طراحی شود تا در مقابل نویز مقاومت قابل‌انتظاری داشته باشد. بدین منظور، برای ارزیابی شبکه پیشنهادی، نویز سفید گاوسی را به تصاویر اشعه ایکس قفسه سینه در SNRهای مختلف (۴- تا ۲۰ دسی‌بل) اضافه کردیم.

نویز اضافه‌شده به تصاویر در شکل ۱۰ نشان داده شده است. همچنین، صحت حاصل‌شده در هر SNR در شکل ۱۱ گزارش شده است. براساس این شکل، شبکه پیشنهادی می‌تواند در طیف وسیعی از SNRهای مختلف، مقاومت خوبی داشته باشد؛ به طوری که صحت طبقه‌بندی در  $SNR = -4dB$  هنوز هم بالای ۸۰ درصد است. دلیل مقاومت شبکه پیشنهادی را می‌توان در ۳ عامل زیر یافت:

(۱) استفاده از توابع فعال‌سازی فازی تاپ ۲ در لایه‌های کانولوشنال به‌جای توابع  $Relu$  و  $Leaky Relu$  (۲) استفاده از فیلتر گسترده در لایه اول کانولوشن (۳) استفاده از فیلترهای با اندازه کوچک در لایه‌های میانی. براساس شواهد موجود، از شبکه پیشنهادی می‌توان برای تصاویر نویزی با پیش‌شرط صحت بالا نیز استفاده کرد.

عملکرد روش پیشنهادی با پژوهش‌های اخیر در جدول ۴ مقایسه شده است. همان‌طور که از جدول ۴ مشاهده می‌شود، صحت طبقه‌بندی برای روش پیشنهادی در مقایسه با پژوهش‌های پیشین امیدوارکننده است. توزیع داده‌ها برای مجموعه‌های آموزش و آزمون در کلیه پژوهش‌های پیشین یکسان بوده است؛ با این حال، به دلیل شرایط شبیه‌سازی مختلف، تغییر در پایگاه داده‌ها و عوامل دیگر، مقایسه یک‌به‌یک با دیگر مطالعات، امری نامطلوب تلقی می‌شود.

با وجود عملکرد مطلوب روش پیشنهادی، این کار نیز مانند سایر پژوهش‌ها دارای معایبی است. یک مطالعه واقع‌بینانه دیگر لازم است تا روش پیشنهادی با سناریوهای بیشتری از جمله بیماری‌های سارس و مرس

۲ کلاس سالم و کووید-۱۹ (سناریوی اول) و ۳ کلاس سالم، پنومونیا و کووید-۱۹ (سناریوی دوم) برای داده‌های آموزشی و ارزیابی در ۱۰۰ تکرار نشان می‌دهد. همان‌طور که از شکل ۵ مشخص است، درصد صحت طبقه‌بندی برای سناریوهای اول و دوم به ترتیب در تکرارهای ۵۰ و ۸۰ به حالت پایدار خود رسیده است. مطابق با شکل ۵، همان‌طور که مشخص است، صحت نهایی طبقه‌بندی برای سناریوهای اول و دوم به ترتیب حدود ۹۹ و ۹۵ درصد است. همچنین، همان‌طور که از شکل ۵ مشخص است، خطای نهایی طبقه‌بندی برای سناریوهای اول و دوم در نهایت به مقدار ۰/۰۰۱ و ۰/۰۰۱ کاهش یافته است.

شکل ۶ مقادیر صحت، دقت، حساسیت و اختصاصیت الگوریتم پیشنهادی را به تفکیک هر سناریو، در نمودار بار نشان می‌دهد. مطابق با شکل ۶ همان‌طور که مشخص است، کلیه مقادیر مربوط به صحت، دقت، حساسیت و اختصاصیت حاصل‌شده براساس شبکه پیشنهادی برای طبقه‌بندی هر دو سناریو بالای ۹۰ درصد هستند. شکل ۷ نمودار  $ROC^{33}$  را برای سناریوهای اول و دوم نشان می‌دهد. مطابق با شکل ۷، نمودار ROC برای هر دو سناریو در محدوده ۰/۹ تا ۱ است و در نیمساق سمت چپ قرار دارد.

شکل ۸ ماتریس درهم‌ریختگی و نمودار T-Sen را برای سناریوی دوم نشان می‌دهد.

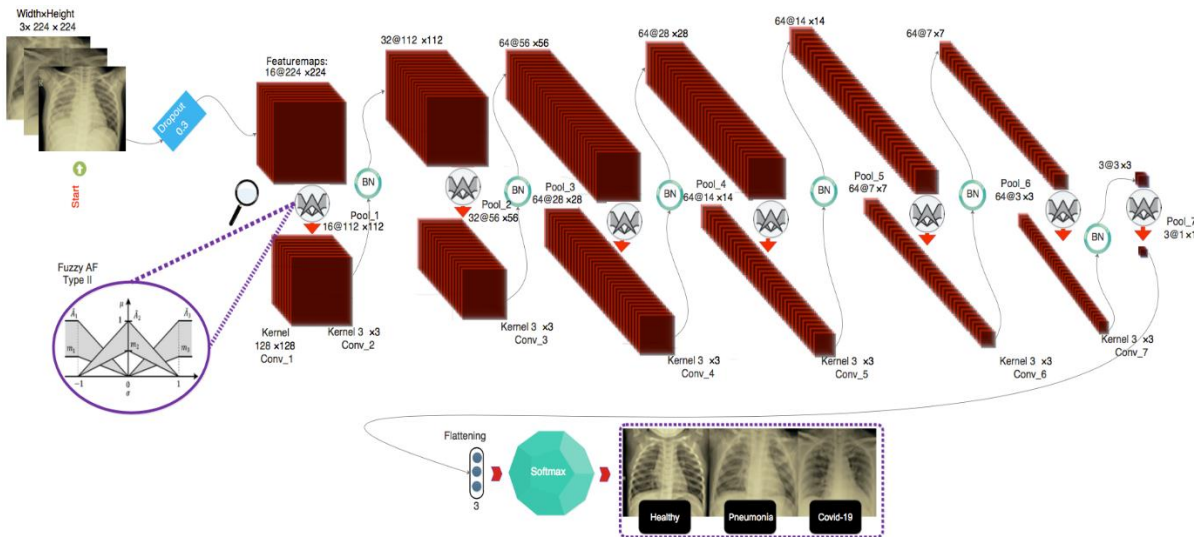
همان‌طور که از شکل ۸ مشخص است، تقریباً کلیه نمونه‌ها مربوط به هر کلاس در نمودار T-Sen در لایه Flatten از یکدیگر تفکیک شده‌اند که نشان‌دهنده عملکرد مطلوب روش پیشنهادی است.

به منظور نشان دادن کارایی مطلوب روش پیشنهادی بر پایه شبکه‌های تمام کانولوشنی با تابع فعال‌سازی فازی نوع ۲، این روش با روش‌های مشابه مقایسه شده است. بدین منظور، از توابع فعال‌سازی  $Relu$  و  $Leaky-Relu$  به‌جای استفاده از تابع فعال‌سازی فازی نوع ۲ در شبکه FCNN استفاده کرده‌ایم. شکل ۹ عملکرد معماری پیشنهادی را در مقایسه با دو حالت یادشده نشان می‌دهد. مطابق با شکل ۹ همان‌طور که مشاهده می‌شود، شبکه پیشنهادی در ترکیب با تابع فعال‌سازی فازی نوع ۲ دارای صحت بیشتر و خطای

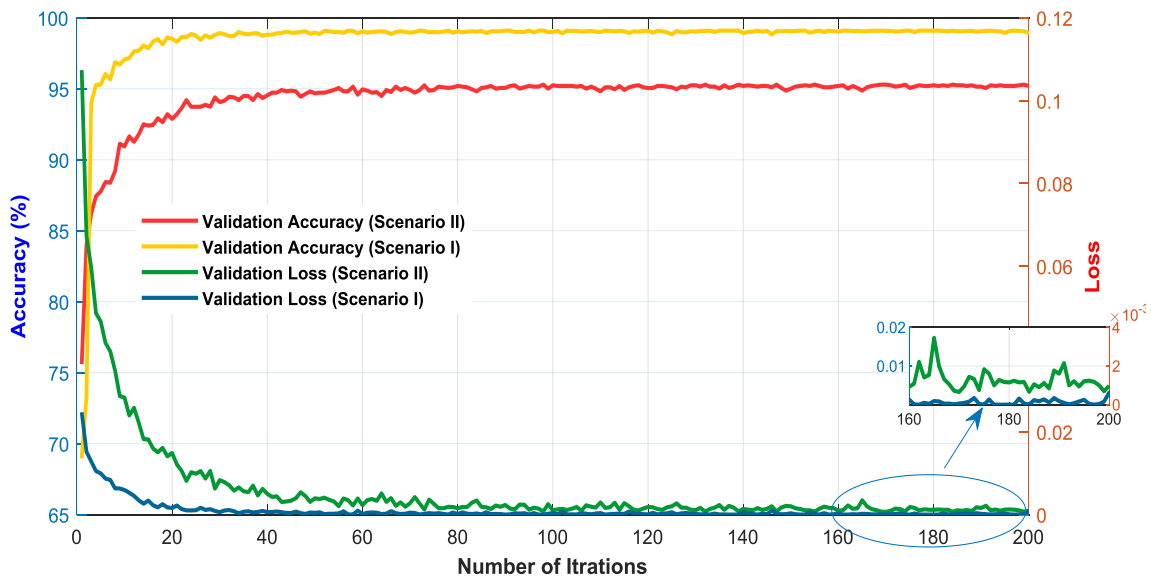
شناسایی موارد ابتلا به کووید-۱۹ با استفاده از شبکه عصبی فازی نوع ۲ عمیق براساس تصاویر X-Ray قفسه سینه

به‌عنوان دستیار پزشکان در طول درمان بیماران، استفاده و سبب کاهش خطای تشخیص بصری و در نتیجه، کاهش مرگ‌ومیر افراد شود.

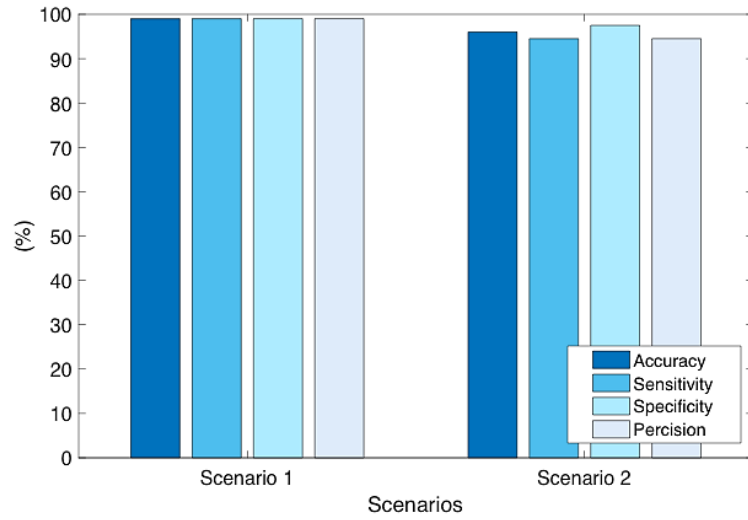
ارزیابی شود. متأسفانه به‌دلیل عدم دسترسی به این داده‌ها، این سناریوها در این مطالعه بررسی نشده‌اند. با این حال، با گسترش روش پیشنهادی و راه‌یابی آن به حوزه عملی و کاربردی، روش پیشنهادی می‌تواند در آینده‌ای نزدیک



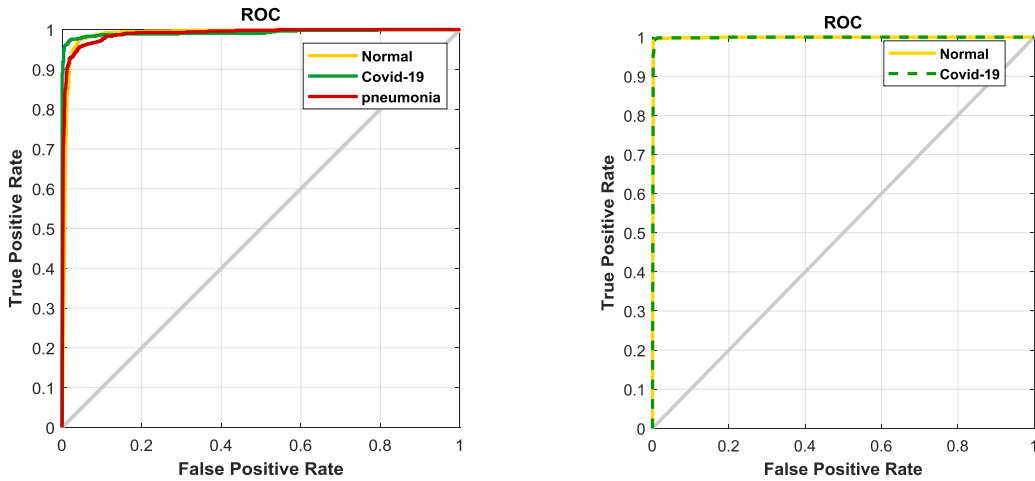
شکل (۴): نمایش گرافیکی از طراحی معماری پیشنهادی در این پژوهش.



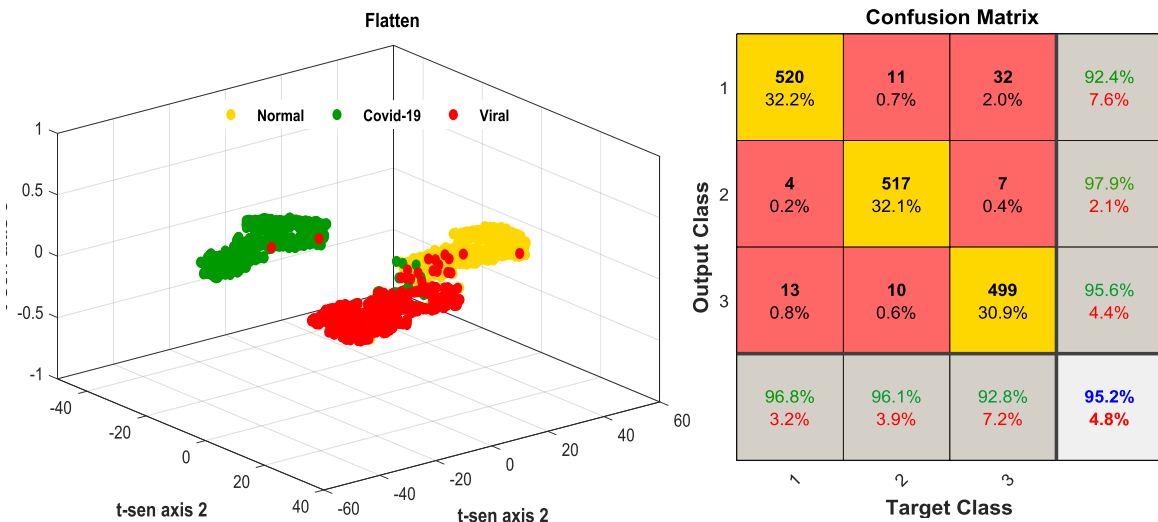
شکل (۵): صحت طبقه‌بندی سناریوهای اول و دوم در ۲۰۰ تکرار برای داده‌های آموزش و ارزیابی.



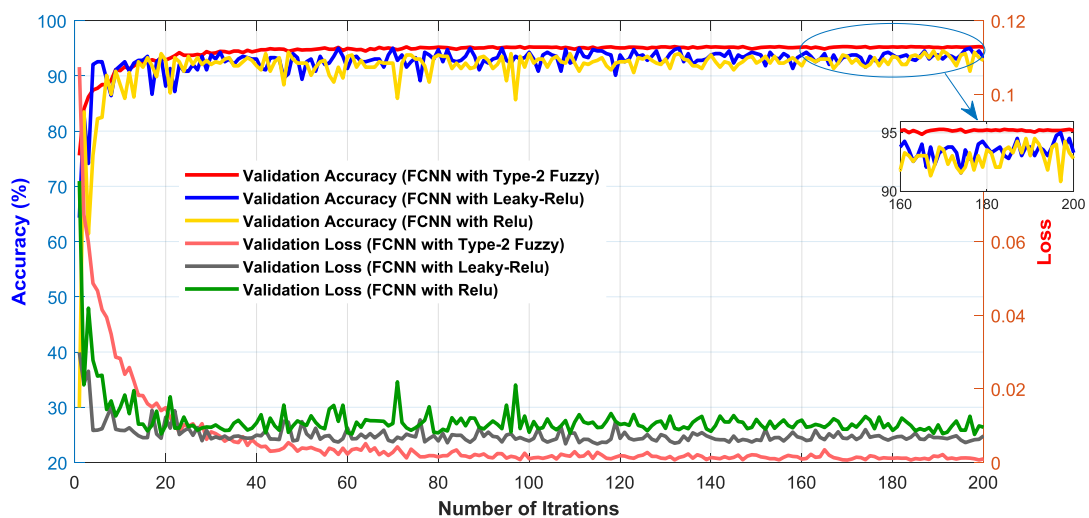
شکل (۶): مقادیر صحت، دقت، حساسیت و اختصاصیت حاصل شده براساس شبکه پیشنهادی برای سناریوی اول و دوم.




شکل (۷): نمودار ROC برای سناریوی اول و دوم.



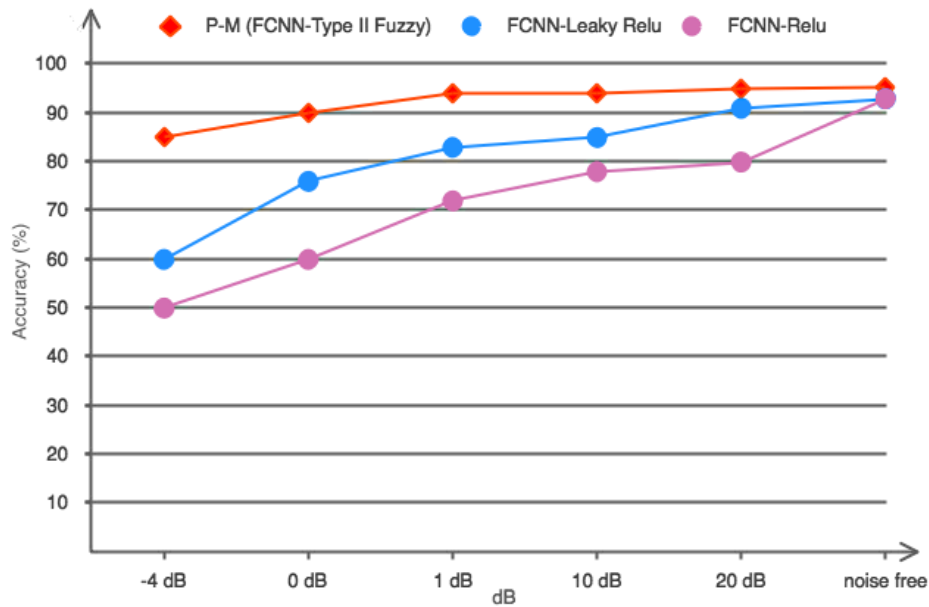
شکل (۸): ماتریس درهم‌ریختگی و نمودار T-SEN حاصل شده از شبکه پیشنهادی برای سناریوی دوم.



شکل (۹): مقایسه شبکه پیشنهادی با روش‌های مشابه برای سناریوی دوم در ۲۰۰ تکرار.



شکل (۱۰): نویز اضافه شده به تصاویر در SNRهای مختلف.



شکل (۱۱): مقایسه روش پیشنهادی با روش‌های مشابه در محیط نویزی.

جدول (۴): مقایسه روش پیشنهادی با مطالعات اخیر.

Methods	Dataset	# of classes	Acc (%)	Se (%)	Sp (%)
Khalifa et al. [18]	Private	2	99	-	-
Chuchan et al. [17]	Public	3	96.39	-	-
Stephen et al. [19]	Public	2	95	-	-
Liang et al. [20]	Public	2	90	-	-
Chang et al. [13]	Public	3	98.97	89.39	99.75
Borghesi et al. [14]	Public	2	96	96	98
Ardakani et al. [23]	Private	2	99.02	98.04	100
Narin et al. [15]	Public	2	98	-	-
P-M (FCNN with Type-2 Fuzzy Activation Function)	Public	3	99	100	99.02

## ۵- نتیجه‌گیری

در این مطالعه یک روش جدید براساس شبکه‌های یادگیری عمیق برای تشخیص خودکار کووید-۱۹ در دو سناریوی مختلف با استفاده از تصاویر اشعه ایکس قفسه سینه ارائه شده است. برای معماری شبکه پیشنهادی، از ۷ لایه کانولوشنال به همراه توابع فعال‌سازی فازی نوع ۲ به منظور انتخاب و استخراج ویژگی‌های خودکار و یک لایه سافت‌مکس به منظور طبقه‌بندی کلاس‌ها استفاده شده است. صحت نهایی روش پیشنهادی برای طبقه‌بندی سناریوی اول (سالم و کووید-۱۹) و سناریوی دوم (سالم، پنومونیا و کووید-۱۹) به ترتیب حدود ۹۹ و ۹۵ درصد است که در مقایسه با پژوهش‌های پیشین امیدوارکننده است. با توجه به عملکرد مطلوب روش پیشنهادی می‌توان از آن برای

تشخیص خودکار کووید-۱۹ بدون نیاز به تشخیص بصری استفاده کرد.

## مراجع

- [1] S. Fauci, H. C. Lane, and R. R. Redfield, "Covid-19—navigating the uncharted," ed: Mass Medical Soc, 2020.
- [2] T. P. Velavan and C. G. Meyer, "The COVID- 19 epidemic," Tropical medicine & international health, Vol. 25, No. 3, p. 278, 2020.
- [3] B. Pfefferbaum and C. S. North, "Mental health and the Covid-19 pandemic," New England Journal of Medicine, Vol. 383, No. 6, pp. 510-512, 2020.
- [4] J. Daniel, "Education and the COVID-19 pandemic," Prospects, Vol. 49, No. 1, pp. 91-96, 2020.
- [5] S. B. Omer, P. Malani, and C. Del Rio, "The COVID-19 pandemic in the US: a clinical update,"



- Jeong, "An efficient deep learning approach to pneumonia classification in healthcare," *Journal of healthcare engineering*, Vol. 2019, 2019.
- [20] I. D. Apostolopoulos and T. A. Mpesiana, "Covid-19: automatic detection from x-ray images utilizing transfer learning with convolutional neural networks," *Physical and Engineering Sciences in Medicine*, Vol. 43, No. 2, pp. 635-640, 2020.
- [21] H. Wu, P. Xie, H. Zhang, D. Li, and M. Cheng, "Predict pneumonia with chest X-ray images based on convolutional deep neural learning networks," *Journal of Intelligent & Fuzzy Systems*, no. Preprint, pp. 1-15, 2020.
- [22] G. E. Hinton, N. Srivastava, A. Krizhevsky, I. Sutskever, and R. R. Salakhutdinov, "Improving neural networks by preventing co-adaptation of feature detectors," *arXiv preprint arXiv:1207.0580*, 2012.
- [23] A. A. Ardakani, A. R. Kanafi, U. R. Acharya, N. Khadem, and A. Mohammadi, "Application of deep learning technique to manage COVID-19 in routine clinical practice using CT images: Results of 10 convolutional neural networks," *Computers in Biology and Medicine*, Vol. 121, p. 103795, 2020.
- [24] <https://www.kaggle.com/tawsifurrahman/covid19-radiography-database>
- [25] T. Iqbal and H. Ali, "Generative adversarial network for medical images (MI-GAN)," *Journal of medical systems*, Vol. 42, No. 11, pp. 1-11, 2018.
- [26] N. U. Din, K. Javed, S. Bae, and J. Yi, "A novel GAN-based network for unmasking of masked face," *IEEE Access*, Vol. 8, pp. 44276-44287, 2020.
- [27] W. Rawat and Z. Wang, "Deep convolutional neural networks for image classification: A comprehensive review," *Neural computation*, Vol. 29, No. 9, pp. 2352-2449, 2017.
- [28] G. Yao, T. Lei, and J. Zhong, "A review of convolutional-neural-network-based action recognition," *Pattern Recognition Letters*, vol. 118, pp. 14-22, 2019.
- [29] A. Dhillon and G. K. Verma, "Convolutional neural network: a review of models, methodologies and applications to object detection," *Progress in Artificial Intelligence*, Vol. 9, No. 2, pp. 85-112, 2020.
- [30] J. M. Mendel and R. B. John, "Type-2 fuzzy sets made simple," *IEEE Transactions on fuzzy systems*, Vol. 10, No. 2, pp. 117-127, 2002.
- [31] A. Beke and T. Kumbasar, "Learning with type-2 fuzzy activation functions to improve the performance of deep neural networks," *Engineering Applications of Artificial Intelligence*, Vol. 85, pp. 372-384, 2019.
- [32] A. Beke and T. Kumbasar, "Learning with type-2 fuzzy activation functions to improve the performance of deep neural networks," *Engineering Applications of Artificial Intelligence*, Vol. 85, pp. 372-384, 2019.
- Jama, vol. 323, no. 18, pp. 1767-1768, 2020.
- [6] 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.
- [7] L. Lan et al., "Positive RT-PCR test results in patients recovered from COVID-19," *Jama*, Vol. 323, No. 15, pp. 1502-1503, 2020.
- [8] K. Syal, "Guidelines on newly identified limitations of diagnostic tools for COVID-19 and consequences," *Journal of medical virology*, Vol. 93, No. 4, pp. 1837-1842, 2021.
- [9] C. Martin et al., "Dynamics of SARS-CoV-2 RT-PCR positivity and seroprevalence among high-risk healthcare workers and hospital staff," *Journal of Hospital Infection*, Vol. 106, No. 1, pp. 102-106, 2020.
- [10] 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: International Society for Optics and Photonics, p. 117340E.
- [11] S. Sheykhivand et al., "Developing an efficient deep neural network for automatic detection of COVID-19 using chest X-ray images," *Alexandria Engineering Journal*, Vol. 60, No. 3, pp. 2885-2903, 2021.
- [12] A. Saygılı, "A new approach for computer-aided detection of coronavirus (COVID-19) from CT and X-ray images using machine learning methods," *Applied Soft Computing*, Vol. 105, p. 107323, 2021.
- [13] M. C. Chang, Y.-K. Park, B.-O. Kim, and D. Park, "Risk factors for disease progression in COVID-19 patients," *BMC infectious diseases*, Vol. 20, No. 1, pp. 1-6, 2020.
- [14] A. Borghesi et al., "Radiographic severity index in COVID-19 pneumonia: relationship to age and sex in 783 Italian patients," *La radiologia medica*, Vol. 125, No. 5, pp. 461-464, 2020.
- [15] 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*, pp. 1-14, 2021.
- [16] P. K. Sethy, S. K. Behera, P. K. Ratha, and P. Biswas, "Detection of coronavirus disease (COVID-19) based on deep features and support vector machine," 2020.
- [17] V. Chouhan et al., "A novel transfer learning based approach for pneumonia detection in chest X-ray images," *Applied Sciences*, Vol. 10, No. 2, p. 559, 2020.
- [18] N. E. M. Khalifa, M. H. N. Taha, A. E. Hassanien, and S. Elghamrawy, "Detection of coronavirus (covid-19) associated pneumonia based on generative adversarial networks and a fine-tuned deep transfer learning model using chest x-ray dataset," *arXiv preprint arXiv:2004.01184*, 2020.
- [19] O. Stephen, M. Sain, U. J. Maduh, and D.-U.

- <sup>1</sup> Novel Coronavirus (COVID-19)
- <sup>2</sup> Severe Acute Respiratory Syndrome
- <sup>3</sup> Septic Shock
- <sup>4</sup> World Health Organization (WHO)
- <sup>5</sup> Reverse Transcription-Polymerase Chain Reaction (RT-PCR)
- <sup>6</sup> Chest Scan
- <sup>7</sup> Computerized Tomography (CT)
- <sup>8</sup> Digital Radiography (DR)
- <sup>9</sup> X-ray Images
- <sup>10</sup> Pneumonia
- <sup>11</sup> Deep Transfer Learning Networks
- <sup>12</sup> Support Vector Machine (SVM)
- <sup>13</sup> Generative Adversarial Networks (GANs)
- <sup>14</sup> Convolutional
- <sup>15</sup> Fully Connected
- <sup>16</sup> Deep Neural Networks
- <sup>17</sup> Random Forest (RF)
- <sup>18</sup> Sonography
- <sup>19</sup> Type-2 Fuzzy Sets
- <sup>20</sup> Generator
- <sup>21</sup> Discriminator
- <sup>22</sup> Feedforward
- <sup>23</sup> Back Propagation
- <sup>24</sup> Loss Function
- <sup>25</sup> Pooling Layer
- <sup>26</sup> Fully Connected
- <sup>27</sup> Over Fitting
- <sup>28</sup> Dropout
- <sup>29</sup> Batch Normalization
- <sup>30</sup> Down Sampling
- <sup>31</sup> Max-Pooling
- <sup>32</sup> Softmax
- <sup>33</sup> Mean squared error (MSE)
- <sup>34</sup> Cross- entropy
- <sup>35</sup> Google Colab

