



University of Kashan

مجله محاسبات نرم SOFT COMPUTING JOURNAL

تارنمای مجله: scj.kashanu.ac.ir



الگوریتم شبکه عصبی عمیق بهبود یافته برای شناسایی بیماری کوید-۱۹ در اینترنت اشیا*

سیدمحمد موسوی^۱، دانشجوی کارشناسی ارشد، سوده حسینی^۲ (iD)، دانشیار، محمدرضا امیدی^۱، مربی

^۱ دانشکده ریاضی و کامپیوتر، دانشگاه شهید باهنر کرمان، کرمان، ایران.

اطلاعات مقاله

چکیده

تاریخچه مقاله:

دریافت ۲۱ آذر ماه ۱۴۰۱

پذیرش ۳۱ تیر ماه ۱۴۰۲

کلمات کلیدی:

پردازش تصویر

هوش مصنوعی

اینترنت اشیا

شبکه عصبی پیچشی

یادگیری عمیق

در این مقاله یک سیستم تشخیص خودکار موارد مبتلا به کوید-۱۹ مبتنی بر اینترنت اشیا پیشنهاد می‌شود. در مدل پیشنهادی ابتدا با استفاده از فن‌آوری اینترنت اشیا تصاویر پزشکی مستقیم پس از مراجعه فرد مشکوک از طریق تجهیزات پزشکی مجهز به اینترنت اشیا به مخزن داده ارسال می‌شود. سپس به منظور کمک به متخصصین رادیولوژی برای تفسیر هرچه بهتر تصاویر پزشکی از چهار مدل شبکه عصبی پیچشی از پیش آموزش دیده به نام‌های VGG19، InceptionV3، InceptionResNetV2 و ResNet152 و دو مجموعه داده تصاویر پزشکی رادیولوژی قفسه سینه و CT Scan در یک طبقه‌بندی سه کلاسه برای پیش‌بینی دقیق موارد مبتلا به کوید-۱۹، افراد سالم و موارد مبتلا بیماری استفاده می‌شود. در نهایت بهترین نتیجه به دست آمده برای تصاویر CT Scan متعلق به معماری InceptionResNetV2 با دقت ۹۹/۳۶۶٪ و برای تصاویر رادیولوژی مربوط به معماری InceptionV3 با دقت ۹۶/۹۴۳٪ می‌باشد. نتایج نشان می‌دهد این سیستم منجر به کاهش مراجعه روزانه به مراکز درمانی و در نتیجه کاهش فشار بر سیستم مراقبت‌های درمانی می‌شود. همچنین به متخصصین رادیولوژی و کادر درمان کمک می‌کند تا هرچه سریعتر بیماری شناسایی شود.

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

۱. مقدمه

ویروس کرونا (COVID-19) اولین بار در شهر ووهان چین اواخر سال ۲۰۱۹ میلادی مشاهده شد. از می ۲۰۲۱ ویروس کرونا توسط سازمان بهداشت جهانی (WHO) یک پاندمی اعلام شد [۱]. کرونا از طریق تماس فیزیکی یا قطرات تنفسی فرد آلوده به کوید ۱۹ انتشار می‌یابد [۲]. از آنجا که ویروس کرونا

یک بیماری واگیردار است، زندگی میلیاردها نفر در سراسر جهان را تحت تاثیر قرار داده است. تشخیص زودهنگام و دقیق ویروس کرونا برای کنترل شیوع بیماری و کاهش مرگومیر آن از اهمیت زیادی برخوردار است. امروزه محققان از روش‌های مختلف ماشینی و یادگیری عمیق همراه با هوش مصنوعی برای تجزیه و تحلیل تصاویر پزشکی استفاده می‌کنند. این روش‌های توسعه‌یافته برای شناسایی بیماری‌هایی استفاده می‌شوند که ممکن است به متخصصان پزشکی در تشخیص بیماری‌ها در مراحل اولیه و ارائه نتایج دقیق، ثابت، موثر و سریع و کاهش میزان مرگومیر کمک کنند [۳]. همچنین کمبود کارکنان بهداشتی برای مراقبت از همه بیماران وجود دارد، بنابراین توسعه یک روش

* نوع مقاله: پژوهشی

* نویسنده مسئول

پست(های) الکترونیک: m.mousavi@math.uk.ac.ir (موسوی)

so_hosseini@uk.ac.ir (حسینی)

r_omidi@uk.ac.ir (امیدی)

هوشمند خودکار که نتایج فوری و با دقت بالا را ارائه می‌کند و اساساً امکان آزمایش را در هر مکان و هر زمان ممکن می‌سازد، بسیار مهم است. این کار می‌تواند توسط اینترنت اشیا ارائه شود و داده‌های بازیابی شده را می‌توان با استفاده از روش‌های هوش مصنوعی برای تشخیص، تجزیه و تحلیل استفاده کرد. حتی اگر مراکز تصویربرداری پزشکی در مناطق دور افتاده تاسیس شده باشد، در دسترس بودن رادیولوژیست‌ها همچنان مشکل است. کشورهای در حال توسعه یا توسعه‌نیافته در تلاش برای بهبود قابلیت‌های تشخیص خود هستند، زیرا روش‌های فعلی از جمله RT-PCR به کیت‌های گران قیمت برای آزمایش در محل نیاز دارند و به دست آوردن این نوع کیت‌ها همیشه آسان نیست. از این رو، یک سیستم تشخیص از راه دور که به راحتی قابل دسترس است برای غربالگری فوری و تشخیص موارد مبتلا ضروری است. علائم اولیه بیماران مبتلا به ویروس کرونا سرفه خشک، تب، سردرد، از دست دادن حس چشایی، تنگی نفس، گلودرد و در برخی موارد اسهال می‌باشد [۴]. طبق آمار منتشر شده از سازمان بهداشت جهانی تا آوریل ۲۰۲۳، تعداد کل موارد تایید شده ویروس کرونا در سراسر جهان بیش از ۷۶۲ میلیون نفر بوده است. برای مقابله با این شیوع، محققان به دنبال طیف گسترده‌ای از فناوری‌ها مانند اینترنت اشیا، هوش مصنوعی و فراداده^۱ هستند که می‌تواند به غلبه بر چالش‌های ناشی از ویروس کرونا کمک کند. اینترنت اشیا یک اکوسیستم در حال گسترش است که انواع دستگاه‌های الکترونیکی و اشیا فیزیکی که قابلیت مبادله اطلاعات دارند را برای برقراری ارتباط، جمع‌آوری و تبادل داده‌ها ادغام می‌کند. اینترنت اشیا پزشکی نقشی اساسی در بخش مراقبت‌های درمانی ایفا می‌کند و دقت، قابلیت اطمینان و بهره‌وری دستگاه‌های الکترونیکی را افزایش می‌دهد.

علاوه بر آزمایش RT-PCR، اخیراً چندین روش مبتنی بر هوش مصنوعی پیشنهاد شده است که از رادیوگرافی قفسه سینه [۵]–[۱۱] و CT Scan [۷]–[۹]، برای تشخیص شاخص‌های بصری عفونت ویروسی کرونا استفاده می‌کنند. در عین حال، برای استفاده از RT-PCR، CT Scan و رادیوگرافی برای تشخیص،

مراجعه به مراکز بالینی مجهز ضروری است. از آنجایی که پروتکل آزمایش ذکر شده نیاز به حضور کادر درمان و فاصله نزدیک آنها با بیماران دارد و به دلیل امکان ابتلای بالا، خطر شیوع عفونت تا حد بیشتری وجود دارد. برای محدود کردن رشد تصاعدی موارد ویروس کرونا، یک راه‌حل این است که مدلی طراحی شود که بتواند آزمایش‌های بیولوژیکی را بدون دخالت افراد زیادی انجام دهد.

در این مقاله یک سیستم تشخیص خودکار موارد مبتلا به ویروس کرونا با استفاده از سه شبکه عصبی پیچشی از پیش آموزش دیده به کمک روش یادگیری انتقالی بر اساس تصاویر رادیولوژی و CT Scan قفسه سینه پیشنهاد شده است. مدل پیشنهادی شامل یک بخش جمع‌آوری اطلاعات به کمک دستگاه‌های مجهز به فناوری اینترنت اشیا و ارسال به مخزن اطلاعات و سپس پردازش اطلاعات و استخراج دانش و در نهایت ارسال نتایج به پزشک مورد نظر برای ارزیابی وضعیت بیمار می‌باشد. مشارکت اصلی این تحقیق به شرح زیر است:

۱. یک چارچوب مبتنی بر اینترنت اشیا از مدل‌های یادگیری عمیق برای تشخیص خودکار بیماران ویروس کرونا پیشنهاد شده است.
۲. فرآیند استفاده از قابلیت‌های یادگیری انتقالی چهار مدل شبکه عصبی پیچشی از پیش آموزش دیده شده، در شناسایی موارد مبتلا به ویروس کرونا از افراد سالم ارائه شده است.
۳. به منظور بهبود عملکرد شبکه‌های عصبی پیچشی از روش تقویت داده و تنظیم دقیق متغیرهای اصلی استفاده شده است.
۴. از لایه GlobalAveragePooling در ابتدای هر مدل و قبل از لایه‌های طبقه‌بندی در انتهای مدل به منظور بهبود دقت تشخیص بیماری استفاده شده است. به این صورت در انتهای مرحله استخراج ویژگی برای هر کدام از feature map ها عمل ادغام میانگین کلی انجام می‌پذیرد. سپس با تغذیه مقادیر تولید شده در یک تابع فعال‌سازی مانند

¹ Big data

چهار معماری شبکه عصبی پیچشی از پیش آموزش دیده به نام های DenseNet، VGGNet، NASNet، و GoofleNet استخراج کرده و توسط لایه های کاملاً متصل، طبقه بندی کردند. آنها چارچوب پیشنهادی خود را بر روی دو مجموعه داده عمومی و یک مجموعه داده خصوصی ارزیابی کرده و نشان دادند که معماری ترکیبی چند مدل شبکه عصبی پیچشی بهتر از طبقه بندی های تک مدلی عمل می کند. همچنین در مرجع [۵]، از روش CLAHE به عنوان یک مرحله پیش پردازش برای تصاویر CT Scan^۲ استفاده شده است. پس از آن ۱۰۰ ویژگی توسط شبکه عصبی پیچشی استخراج و سپس با استفاده از الگوریتم های مختلف یادگیری ماشین طبقه بندی شدند و در انتها یک مدل ترکیبی برای طبقه بندی تصاویر CT Scan پیشنهاد شده است. ثکوری و کومار [۷]، یک شبکه عصبی پیچشی برای طبقه بندی تصاویر CXR^۳ و CT Scan پیشنهاد کردند. آنها از دو سناریو طبقه بندی دو کلاس و چند کلاس و ۱۱۰۹۵ تصویر استفاده کردند. نتایج آنها نشان داد که بهترین دقت در طبقه بندی دو کلاس ۹۹/۶٪ و در طبقه بندی چند کلاس ۹۸/۲٪ است. در مرجع [۸]، نویسندگان از تصاویر اشعه ایکس و CT scan برای پیش بینی موارد مبتلا به ویروس کرونا بر اساس مدل های ReseNet، GoogleNet، AlexNet، DenseNet، و VGG^۴، Inception V3 و Network به همراه یک مدل پیشنهادی استفاده کردند. بالاترین دقت به دست آمده با استفاده از تصاویر اشعه ایکس ۹۷/۷٪ و با استفاده از تصاویر CT Scan میزان ۹۷/۱٪ گزارش شده است.

لورنسین و همکاران [۱۰]، از تصاویر اشعه ایکس قفسه سینه برای طبقه بندی افراد آلوده به ویروس کرونا به وسیله یادگیری عمیق و با استفاده از یادگیری انتقالی^۵ استفاده کرده اند. آنها به بررسی پنج مدل مبتنی بر شبکه های عصبی پیچشی از پیش آموزش دیده AlexNet، VGG16، ReseNet50، ReseNet101 و ReseNet152 بر روی ۱۸۵ تصویر اشعه ایکس شامل چهار

softmax یافتن پاسخ بهینه توزیع احتمال چند کلاس^۱ آسان تر خواهد شد. علاوه بر آن به دلیل عدم وجود متغیر قابل آموزش در این لایه تمایل به بیش برآزش کاهش می یابد.

۵. تجزیه و تحلیل عملکرد سیستم با جزئیات انجام شده است. برای این منظور علاوه بر استفاده از معیارهای ارزیابی، ماتریس درهم ریختگی برای هر مدل نشان داده شده است. همچنین مدل پیشنهادی با شبکه های مورد استفاده در کارهای مرتبط روی مجموعه داده معرفی شده ارزیابی و نتایج آنها مقایسه شده است.

ادامه مقاله به این صورت سازماندهی شده است. در بخش بعد به بررسی برخی از کارهای مرتبط پرداخته خواهد شد. در بخش ۳ ابتدا مجموعه داده های بکار رفته، معرفی شده و سپس روش تقویت داده بررسی خواهد شد. در بخش ۴ به معرفی مدل پیشنهادی با استفاده از اینترنت اشیا پرداخته خواهد شد. در بخش بعدی نتایج به دست آمده مورد ارزیابی قرار گرفته و با نتایج حاصله از کارهای مرتبط مقایسه می شوند. قسمت آخر نیز به نتیجه گیری و کارهای آینده می پردازد.

۲. کارهای مرتبط

احمد و همکاران [۳]، یک سیستم مراقبت بهداشتی هوشمند مجهز به اینترنت اشیا را برای شناسایی و طبقه بندی تصاویر اشعه ایکس قفسه سینه به سه کلاس کرونا، ذات الریه و سالم معرفی کردند. در مرحله اول پس از پیش پردازش، عملیات تقویت داده برای افزایش تنوع مجموعه داده اعمال شده و سپس داده ها به دو مجموعه آموزش و آزمایش تقسیم می شوند و از دو معماری از پیش آموزش دیده VGG19 و InceptionV3 برای طبقه بندی استفاده می شود. آنها از مجموعاً ۴۵۰۰ تصویر اشعه ایکس قفسه سینه برای تحقیق خود استفاده کردند و در نهایت بهترین دقت به دست آمده ۹۷٪ را ثبت کردند.

نویسندگان مرجع [۴]، در یک چارچوب پیشنهادی، ویژگی های سطح پایین از تصاویر رادیوگرافی را با استفاده از مجموعه ای از

^۲ Computed Tomography Scan

^۳ Chest X-Ray

^۴ Visual Geometry Group

^۵ Transfer learning

^۱ Multiclass probability distribution

به ویروس کرونا استفاده کرده‌اند. تحقیقات نشان می‌دهد که تشخیص موارد مبتلا از طریق تصاویر CT Scan با دقت بالاتری نسبت به تصاویر اشعه ایکس صورت می‌پذیرد هرچند بیمار دوز تابشی اشعه کمتری در حین تصویر برداری اشعه ایکس نسبت به CT Scan دریافت می‌کند. این امر شاید در تعداد آزمایشات کم قابل چشم‌پوشی باشد اما برای مادران باردار و همچنین کودکان از اهمیت بالایی برخوردار است. در این مقاله، از دو مجموعه داده تصاویر پزشکی رادیوگرافی و CT Scan استفاده شده تا امکان استفاده از انواع تصاویر پزشکی برای چارچوب پیشنهادی فراهم شود.

۱.۳. پیش‌پردازش و پاکسازی داده‌ها

پیش‌پردازش داده‌ها، به آماده‌سازی داده‌های خام برای تجزیه و تحلیل اشاره دارد. این فرآیند شامل پاکسازی، استانداردسازی داده‌ها و مهندسی ویژگی می‌باشد. از جمله ویژگی‌های سطح می‌توان به رنگ، شکل، لبه و بافت در تصاویر اشاره کرد [۱۹]. یکی از مشکلات شایع در مجموعه داده‌ها پایین بودن کیفیت برخی داده‌ها و وجود نویز در داده‌ها است. پاکسازی داده منجر می‌شود تا تصاویر بی‌کیفیت، تکراری و حاوی نویز از مجموعه داده حذف شده و مجموعه داده‌ای با کیفیت جهت آموزش مدل یادگیری فراهم شود. در همین راستا، از استانداردسازی و نرمال‌سازی استفاده می‌شود که شامل تبدیل داده‌ها به یک قالب استاندارد جهت تجزیه و تحلیل است.

۲.۳. مجموعه داده CT Scan

دو مجموعه داده تصاویر CT Scan [۲۰]، [۲۱] جمع‌آوری شده از منابع برخط مختلف ترکیب شده‌اند تا مجموعه داده مورد نظر ایجاد شود. همان‌طور که در شکل (۲) نشان داده شده است، تعداد ۵۲۰۳ تصویر ویروس کرونا و ۲۴۱۸ تصویر سالم در این مجموعه داده موجود می‌باشد. همچنین به منظور عملکرد بهتر مدل پیشنهادی در دنیای واقعی تعداد ۲۶۱۸ تصویر بیماری ریوی به مجموعه داده اول اضافه شده است. در مجموع از ۱۰۲۳۹ داده تصویری CT Scan استفاده شده است.

کلاس پرداختند. در روش آنها، با توجه به تعداد کم تصاویر در مجموعه داده، از فرآیند تقویت اطلاعات^۱ از جمله چرخش ۹۰، ۱۸۰ و ۲۷۰ درجه در محورهای مختلف استفاده شد. همچنین افزایش روشنایی به منظور بهبود عملکرد طبقه‌بندی استفاده شده است. در این روش، بهترین نتایج در صورتی حاصل می‌شود که معماری از قبل آموزش دیده شده ReseNet152 با استفاده از دسته‌های بزرگ‌تر داده در تعداد متوسط دوره‌های آموزش با استفاده از تابع بهینه‌ساز Nadam آموزش داده شود.

اسماعیلی و سنگور [۱۱]، از رویکردهای مبتنی بر یادگیری عمیق، یعنی استخراج ویژگی‌های عمیق^۲ و تنظیم دقیق^۳ شبکه‌های عصبی پیچشی از پیش آموزش دیده و آموزش انتها به انتها^۴ یک مدل توسعه‌یافته شبکه عصبی پیچشی متشکل از ۲۱ لایه شامل لایه‌های کانولوشن، ادغام حداکثر، لایه‌های کاملاً متصل و لایه طبقه‌بندی نهایی به همراه نرمال‌سازی دسته‌ای و لایه‌های ReLU به منظور طبقه‌بندی تصاویر اشعه ایکس قفسه سینه ویروس کرونا و سالم را ارائه کردند. در این کار از مجموعه داده حاوی ۱۸۰ تصویر ویروس کرونا و ۲۰۰ تصویر سالم استفاده شده است و به منظور استخراج ویژگی‌های عمیق از مدل‌های شبکه عصبی پیچشی از پیش آموزش دیده VGG16، VGG19، ReseNet101، ReseNet50 و ReseNet18 بهره‌گرفته شده است. در نهایت ویژگی‌های عمیق استخراج شده از مدل ReseNet50 به کمک SVM دقت ۹۴/۷٪ را به دست آورد که بالاترین امتیاز در بین تمام نتایج به دست آمده، بود. جدول (۱) به طور خلاصه کارهای گذشته را با هم مقایسه کرده است.

۳. مجموعه داده

در این بخش، دو مجموعه داده از تصاویر پزشکی برای تجزیه و تحلیل بیماری کوید ۱۹ شرح داده می‌شود. محققان از مجموعه داده‌های عمومی مختلفی از جمله تصاویر اشعه ایکس [۶] - [۱۲] و تصاویر CT Scan [۷] - [۱۰]، برای تشخیص موارد مبتلا

¹ Data Augmentation


² Deep feature extraction

³ Fine-tuning

⁴ End-to-end

جدول (۱): کارهای مرتبط در زمینه شناسایی بیماری COVID-19				
مرجع	رویکرد	مجموعه داده	نوع داده	بهترین دقت
احمد و همکاران [۳] (۲۰۲۲)	VGG19, InceptionV3	۴۵۰۰ تصویر رادیوگرافی قفسه سینه	X-ray	۹۷٪
دب و همکاران [۴] (۲۰۲۲)	VGGNet, GoogleNet, DenseNet, NASNet, ResNet, ReseNext, Ensemble model	J.P. Cohen [۱۲], chest-xray-covid19-pneumonia dataset, private dataset from MGM medical college and hospital	X-ray	مجموعه داده خصوصی: دوکلاسه: ۹۵/۶٪ و چندکلاسه: ۹۳/۴٪ مجموعه داده عمومی: دوکلاسه: ۹۸/۵٪ و چندکلاسه: ۸۸/۹٪
اسلام و همکاران [۵] (۲۰۲۲)	CNN + gaussian naïve base + SVM + Decision tree + Random forest + Logistic regression	sarscov2-ctscan-dataset [۱۴]	CT Scan	۹۵/۴٪
کاویا و همکاران [۶] (۲۰۲۲)	VGG16, ResNet50	۱۵۱۵۳ تصویر رادیولوژی گردآوری شده توسط یک تیم تحقیقاتی چند ملیتی	X-ray	۹۱/۳٪ با استفاده از الگوریتم ResNet50
ثکور و کومار [۷] (۲۰۲۱)	یک شبکه عصبی پیچشی پیشنهادی	۱۱۰۹۵ تصویر پزشکی	X-ray and CT Scan	دوکلاسه: ۹۹/۶٪ چندکلاسه: ۹۸/۲٪
الپلتاجی و سلام [۸] (۲۰۲۱)	ReseNet50, ReseNet53, GoogleNet, AlexNet, DenseNet201, VGGNet, InceptionV3, ReseNet50+SVM, شبکه عصبی پیچشی پیشنهادی	[۱۵]	X-ray and CT Scan	۹۷/۷٪ برای داده‌های رادیوگرافی و CT ۹۷/۱٪ برای مجموعه داده CT
اویس و همکاران [۹] (۲۰۲۱)	ShuffleNet, mobile net, mobshufnet	۵۴۷۱ تصویر CT و ۷۴۳۹ تصویر X-ray	X-ray and CT Scan	۹۴/۷٪ برای مجموعه داده CT و ۹۵/۸٪ برای مجموعه داده X-ray
لورنسن [۱۰] (۲۰۲۱)	AlexNet, VGG16, ReseNet50, ReseNet101, ReseNet152	مجموعه داده جمع آوری شده توسط Kragujevac	X-Ray	۹۵٪ با استفاده از ResNet152
اسماعیل و همکاران [۱۱] (۲۰۲۱)	ReseNet18, ReseNet50, ReseNet101, VGG16, VGG19+SVM	[۱۶] - [۱۸]	X-ray	۹۴/۷٪ با استفاده از ResNet50 + SVM
اویانگ و همکاران [۱۲] (۲۰۲۱)	Faster RCNN + ResNet101	۱۱۰۰۰ تصویر رادیوگرافی	X-ray	۹۸٪

۳.۳. مجموعه داده رادیوگرافی



شکل (۱): ساختار مجموعه داده تصاویر پزشکی CT SCAN


تصاویر رادیوگرافی توسط کومار [۲۲]، از چندین منبع دیگر جمع‌آوری شده است. تصاویر به سه دسته بیماران کرونایی، بیماران غیرکرونایی و افراد عادی طبقه‌بندی شده و همه عکس‌ها به اندازه ۲۵۶×۲۵۶ تغییر داده شده‌اند. در مجموع ۵۲۲۸ تصویر اشعه ایکس قفسه سینه استفاده شده که توزیع داده‌های مجموعه اشعه ایکس در شکل (۲) ارائه شده است. این مجموعه داده شامل پوشه‌هایی با همین نام‌ها بوده و هیچ اطلاعات دیگری در آن در دسترس نیست.

حالت رنگی (سه کانال RGB) به تصاویر سیاه سفید (یک کانال رنگی gray scale) تبدیل شده‌اند. به علاوه، به منظور عملکرد بهتر شبکه مقادیر هر پیکسل از بازه ۰-۲۵۵ به بازه بین ۰-۱ تغییر یافته و سپس با استفاده از انتخاب تصادفی تصاویر به سه مجموعه آموزش، اعتبارسنجی و آزمایش تقسیم شده‌اند.

۴. مدل پیشنهادی

در این بخش، چارچوب مدل پیشنهادی هوشمند بر پایه اینترنت اشیا شرح داده می‌شود. اینترنت اشیا نظارت بر تعداد زیاد بیماران در خانه یا بیمارستان را امکان‌پذیر می‌سازد. علاوه بر داده‌های اصلی بکار رفته در این مقاله، امکان انتقال دیگر داده‌های بیومتریک بیماران به مخزن اصلی داده‌ها به منظور تجزیه و تحلیل و استخراج دانش بدون اینکه کارکنان مراقبت‌های درمانی را در معرض عفونت قرار دهند، وجود دارد. نویسندگان مرجع [۲۳]، یک سیستم اینترنت اشیا ارزان را پیشنهاد کرده‌اند که به صورت خودکار داده‌های حاصله را با استفاده از ارتباط بی‌سیم از طریق گوشی‌های هوشمند در یک شبکه جهانی بارگزاری می‌کند. از این رو نتایج آزمایش بلافاصله در هر نقطه از جهان در دسترس است. چنین سیستم اینترنت اشیایی، ابزاری بسیار مهم برای پزشکان به منظور مقابله با بیماری‌های عفونی است.

در این مقاله، یک چارچوب تشخیص خودکار افراد مبتلا به ویروس کرونا مبتنی بر اینترنت اشیا معرفی شده است که ابتدا اطلاعات با استفاده از اینترنت اشیا به مخزن داده ارسال شده و سپس با استفاده از الگوریتم‌های شبکه عصبی عمیق در پردازش تصویر، داده‌ها به منظور استخراج دانش پردازش می‌شوند. در قدم اول از چهار مدل شبکه عصبی پیچشی از پیش آموزش دیده شده استفاده می‌شود. روش پیشنهادی پس از تنظیم دقیق متغیرهای مهم مساله با استفاده از یادگیری انتقالی برای تشخیص موارد مبتلا به ویروس کرونا از تصاویر اشعه ایکس قفسه سینه و CT Scan استفاده کرده و در انتها یک طبقه‌بندی چندکلاسه را بکار می‌گیرد. هدف اصلی طبقه‌بندی، تشخیص صحیح تصاویر به سه کلاس بیمار (کرونا) و بیمار ریوی (غیرکرونا) و سالم می‌باشد. دلیل استفاده از طبقه‌بندی سه کلاسه تصاویر پزشکی،




■ COVID-19 ■ Pneumonia ■ NORMAN

شکل (۲): ساختار مجموعه داده تصاویر پزشکی رادیوگرافی

۴.۳. تقویت داده


حجم عظیم تصاویر آموزشی یکی از الزامات یادگیری عمیق است که در همین راستا فرآیند تقویت داده به منظور افزایش عملکرد طبقه‌بندی استفاده شده است. این فرآیند با هدف افزایش مصنوعی مجموعه داده‌های آموزشی انجام شده [۱] و مجموعه داده آزمایش ثابت باقی می‌ماند. مجموعه‌ای از عملیات‌های هندسی متفاوتی به منظور افزایش مجموعه داده قابل استفاده است. این مقاله از پشت‌ورو کردن افقی تصاویر و نیز بزرگنمایی استفاده کرده است. شکل (۳) برخی از تصاویر هر سه کلاس را نمایش می‌دهد.



شکل (۳): نمونه‌هایی از تصاویر مجموعه داده بعد از اعمال فرآیند تقویت داده

تاکنون کارهای زیادی در مورد پیش‌پردازش تصاویر ارائه شده است. در این مقاله، ابتدا تصاویر مجموعه داده به اندازه ورودی شبکه‌های مورد آموزش تغییر یافته و در ادامه تمامی تصاویر از

کمک به متخصصان رادیولوژی برای اولویت‌بندی بیماران کرونایی به منظور جلوگیری از شیوع بیشتر بیماری و همچنین درمان موثر و سریع افراد مبتلا و حفاظت جامعه سالم است. روند کار مدل پیشنهادی در شکل (۴) نشان داده شده است. همان‌طور که مشاهده می‌شود، داده‌های جمع‌آوری شده به کمک اینترنت اشیا به دو بخش داده‌های آموزش (۷۰ درصد) و داده‌های آزمایش (۳۰ درصد) تقسیم می‌شوند. ابتدا پیش‌پردازش و تقویت داده روی داده‌ها انجام شده و سپس مدل آموزش داده می‌شود. در نهایت نتایج به دست می‌آید تا مشخص شود آیا شخص کرونا دارد یا به بیماری ریوی مبتلا است.



شکل (۴): روند کلی مدل پیشنهادی

۱.۴. اینترنت اشیا

امروزه اینترنت اشیا کاربردهای مختلفی مانند حمل و نقل، شهرهای هوشمند، نظارت و مراقبت‌های بهداشتی را متناسب با نیازهای جامعه پوشش می‌دهد. به عنوان مثال، در صنعت مراقبت‌های بهداشتی، اینترنت اشیا می‌تواند نقشی مهم در نظارت از راه دور در بیمارستان و به ویژه در خانه برای سالمندان مبتلا به بیماری‌های مزمن داشته باشد. همچنین با استفاده از اینترنت اشیا و سیستم‌های تشخیص خودکار بیماری می‌توان افراد مبتلا به ویروس کرونا را در مراحل اولیه تشخیص داده و از انتشار بی‌رویه این بیماری جلوگیری کرد. با استفاده از این فناوری، در آینده سیستم‌های مراقبت‌های بهداشتی اثرات عمده‌ای مانند کاهش زمان پاسخ برای تشخیص ناهنجاری‌ها، مراقبت با کیفیت بالا، هزینه‌های پایین بستری در بیمارستان و امید به زندگی بالا را تجربه خواهند کرد.

اینترنت اشیا نظارت بر تعداد زیاد بیماران در خانه یا بیمارستان را امکان‌پذیر می‌سازد. همچنین علاوه بر داده‌های اصلی بکار رفته امکان انتقال سایر داده‌های بیومتریک بیماران به مخزن اصلی داده‌ها به منظور تجزیه و تحلیل و استخراج دانش بدون اینکه کارکنان مراقبت‌های درمان در معرض عفونت قرار دهند وجود دارد. با توجه به این ویژگی، کادر درمان به آسانی و با سرعت بیشتری می‌توانند اطلاعات بیمار را از طریق شبکه بیمارستان به دست آورند. در زمینه اینترنت اشیا در پزشکی، هوش مصنوعی نقشی بسیار مهمی ایفا می‌کند، چرا که تعداد دستگاه‌های اینترنت اشیا پزشکی^۱ روز به روز در حال افزایش است و اینجاست که توانایی پردازش داده اهمیت زیادی در موفقیت دستگاه‌ها دارد. برای جابجا کردن داده‌های اینترنت اشیا پزشکی از یک نقطه به نقطه‌ای دیگر، دستگاه‌های اینترنت اشیا در پزشکی باید از پروتکل‌های ارتباطی مختلفی استفاده کنند. به عبارت دیگر، همه این تلاش‌ها برای رساندن داده‌ها به اینترنت است. پیچیدگی اصلی هنگامی است که داده به اینترنت برسند، از آن مرحله به بعد، داده به دست پزشکان یا خدمات درمانی مختلف می‌رسد. معماری‌های متفاوتی برای اینترنت اشیا ارائه شده است، اما به طور کلی اینترنت اشیا از چهار لایه اصلی به شکل زیر تشکیل شده است.

۱. لایه ادراک^۲: پایین‌ترین لایه در معماری اینترنت اشیا است که شامل حسگرها، عملگرها و دستگاه‌ها است و وظیفه سنجش داده‌های محیطی و اندازه‌گیری متغیرها را بر عهده دارد.
۲. لایه شبکه: لایه میانی در معماری اینترنت اشیا است. این لایه وظیفه ارسال اطلاعات از حسگرها و دستگاه‌ها به بستر و مراکز ابری را بر عهده دارد و جهت تحقق این امر فناوری‌های متعددی در آن بکار گرفته می‌شود.
۳. لایه پلتفرم: در این لایه تمامی اطلاعات ارسال شده؛ ذخیره، جمع‌آوری و پردازش می‌شوند و سپس با توجه به تحلیل داده‌ها و هوش مصنوعی، فرمان‌های کنترلی

^۱ Internet of Medical Thing

^۲ Preception

صادر می‌شوند.

۴. لایه کاربرد^۱: بالاترین لایه در ساختار اینترنت اشیا است. این لایه به مجموعه بزرگی از برنامه‌های کاربردی که ممکن است مختص یک صنعت خاص و یا چندین صنعت طراحی و پیاده‌سازی شده باشند، اشاره دارد و عهده‌دار نمایش گرافیکی اطلاعات است. معماری اینترنت اشیا مبتنی بر مدل پیشنهادی شکل (۵) نشان داده شده است. همان‌طور که در این شکل قابل مشاهده است، به منظور جمع‌آوری و انتقال بلادرنگ داده‌ها برای تصمیم‌گیری در مورد وضعیت بیمار از اینترنت اشیا استفاده می‌شود تا با توجه به نتایج به دست آمده با استفاده از مدل پیشنهادی و اطلاع‌رسانی وضعیت بیمار به پزشک معالج، ادامه روند درمانی بیمار سریع‌تر طی شود.



شکل (۵): معماری اینترنت اشیا

در طول همه‌گیری ویروس کرونا، هوش مصنوعی و اینترنت اشیا در حوزه مراقبت‌های بهداشتی مورد توجه بیشتری قرار گرفته‌اند، جایی که روش‌های غربالگری و تشخیص را می‌توان با خیال راحت‌تر انجام داد. تصویربرداری حرارتی و نظارت بر فاصله اجتماعی نیز از عملکردهایی هستند که عمدتاً در مرحله غربالگری ویروس کرونا مورد توجه قرار می‌گیرند. در واقع، اهداف استفاده از این دستگاه‌ها تشخیص دمای بدن، غربالگری افرادی که ماسک زده‌اند و همچنین کنترل فاصله اجتماعی است. در نهایت، اینترنت اشیا می‌تواند در کاهش هزینه‌ها و کاهش پیچیدگی زیرساخت‌ها کمک کند [۱۸].

تکامل سریع و پذیرش اینترنت اشیا، به ویژه در زمان همه‌گیر، ممکن است نگرانی‌های امنیتی بیشتری ایجاد کند، بنابراین چالش

اصلی حفظ حریم خصوصی داده‌های مهم و حساس پزشکی می‌باشد. حملات، تهدیدها و خطرات متعددی می‌توانند بر لایه‌های مختلف معماری اینترنت اشیا تأثیر بگذارند. از این رو، یک اکوسیستم اینترنت اشیا باید امن باشد و از پروتکل‌های حریم خصوصی سختگیرانه پیروی کند [۲۴]. در برنامه اینترنت اشیا، ایمنی نقش مهمی ایفا می‌کند زیرا می‌تواند بر وضعیت فیزیولوژیکی، روانی و بیولوژیکی انسان تأثیر منفی بگذارد، حتی ممکن است منجر به از دست دادن جان افراد شود. دستگاه‌های اینترنت اشیا با امنیت ضعیف یکی از تأثیرگذارترین کانال‌ها برای مجرمان سایبری برای افشای داده‌های مشتری از طریق جریان‌های ارتباطی هستند [۲۵]. از این رو مراکز مراقبت‌های پزشکی باید دستورالعمل‌های ارزیابی خطر را برای تضمین حفاظت داده‌ها ایجاد کنند.

۲.۴. طبقه‌بندی تصاویر پزشکی

شبکه عصبی پیچشی معتبرترین الگوریتم یادگیری عمیق است [۹] و از آن برای پردازش حجم عظیمی از داده‌ها استفاده می‌شود و نیازی به استخراج دستی ویژگی‌ها ندارد. معماری یک شبکه عصبی پیچشی به دو بخش یادگیری ویژگی و طبقه‌بندی تقسیم می‌شود. به طور کلی این شبکه‌ها به صورت سلسله مراتبی از سه نوع لایه تشکیل می‌شوند: لایه پیچشی^۲ و لایه ادغام به منظور استخراج ویژگی‌ها و لایه کاملاً متصل به منظور طبقه‌بندی آنها. طبقه‌بندی شکلی از تحلیل داده‌ها است که در آن مدل‌هایی برای توصیف کلاس‌های مختلفی از داده‌ها استخراج می‌شوند. چنین مدل‌هایی که با نام دسته‌بند شناخته می‌شوند، برچسب‌های طبقه‌بندی شده کلاس‌ها را پیشگویی می‌کنند [۲۶]. معماری پیشنهادی شامل چهار مرحله می‌باشد. ابتدا تصاویر افراد مشکوک به ویروس کرونا که به مراکز درمانی جهت عکس‌برداری قفسه سینه مراجعه می‌کنند، با استفاده از دستگاه‌های مجهز به فناوری اینترنت اشیا به صورت بلادرنگ جهت پردازش به مجموعه داده ارسال می‌شوند. سپس تصاویر مجموعه داده پیش‌پردازش شده و در مرحله بعد توسط شبکه عصبی پیچشی فرآیند آموزش

² Convolutional

¹ Application

جدول (۳): لایه‌ها و تعداد پارامترها در INCEPTIONV3		
نوع لایه	خروجی	تعداد پارامتر
InceptionV3	(None, 5, 5, 2048)	۲۱۸۰۲۷۸۴
GlobalAveragePooling2D	(None, 2048)	۰
Flatten	(None, 2048)	۰
Dropout_1	(None, 2048)	۰
Dense_1	(None, 1024)	۲۰۹۸۱۷۶
Dense_2	(None, 1024)	۱۰۴۹۶۰۰
Dropout_2	(None, 1024)	۰
Dense_3	(None, 3)	۳۰۷۵
تعداد کل پارامترها: ۲۴۹۵۳۶۶۵		
پارامترهای آموزش پذیر: ۳۱۵۰۸۸۱		
پارامترهای غیر قابل آموزش: ۲۱۸۰۲۷۸۴		


جدول (۴): لایه‌ها و تعداد پارامترها در INCEPTIONV3		
نوع لایه	خروجی	تعداد پارامتر
VGG19	(None, 5, 5, 2048)	۲۰۰۲۴۳۸۴
GlobalAveragePooling2D	(None, 2048)	۰
Flatten	(None, 2048)	۰
Dropout_1	(None, 2048)	۰
Dense_1	(None, 1024)	۲۰۹۸۱۷۶
Dense_2	(None, 1024)	۱۰۴۹۶۰۰
Dropout_2	(None, 1024)	۰
Dense_3	(None, 3)	۳۰۷۵
تعداد کل پارامترها: ۲۱۶۰۲۴۰۱		
پارامترهای آموزش پذیر: ۱۵۷۸۰۱۷		
پارامترهای غیر قابل آموزش: ۲۰۰۲۴۳۸۴		

جدول (۵): لایه‌ها و تعداد پارامترها در INCEPTIONRESNETV2		
نوع لایه	خروجی	تعداد پارامتر
InceptionResNetV2	(None, 5, 5, 1536)	۵۲۳۳۶۷۳۶
GlobalAveragePooling2D	(None, 1536)	۰
Flatten	(None, 1536)	۰
Dropout_1	(None, 1536)	۰
Dense_1	(None, 1024)	۱۵۷۳۸۸۸
Dense_2	(None, 1024)	۱۰۴۹۶۰۰
Dropout_2	(None, 1024)	۰
Dense_3	(None, 3)	۳۰۷۵
تعداد کل پارامترها: ۵۶۹۶۳۳۲۹		
پارامترهای آموزش پذیر: ۲۶۲۶۵۹۳		
پارامترهای غیر قابل آموزش: ۵۴۳۳۶۷۳۶		


صورت گرفته است. در این مرحله از چهار معماری InceptionResNetV2، VGG19، ResNet152 و InceptionV3، با استفاده از روش یادگیری انتقالی به همراه تنظیم دقیق متغیرهای اصلی مساله برای استخراج بهترین ویژگی‌ها استفاده شده است. همچنین در انتهای هر معماری به منظور بهبود دقت شبکه برای طبقه‌بندی داده‌ها از یک لایه GlobalAveragePooling2D و سپس سه لایه کاملاً متصل استفاده شده است. علاوه بر آن، به منظور جلوگیری از بیش‌برازش^۱ لایه Dropout(0.5) بکار برده شده است. در مرحله آخر شبکه‌های پیشنهادی توسط تصاویر مجموعه آزمایش مورد بررسی قرار می‌گیرد. همچنین از توابع فعال‌سازی ReLU و سیگموید در این شبکه استفاده شده است و وزن‌ها با استفاده از بهینه‌ساز adam با نرخ یادگیری اولیه ۰/۰۰۳ تولید می‌شوند. شبکه‌های بکار رفته در ۳۰ دور آموزش با نرخ یادگیری پویا به منظور افزایش دقت و جلوگیری از بیش‌برازش اجرا شده است. با توجه به روند آموزش از نرخ یادگیری کاهشی نیز استفاده شده است. در طول فرآیند آموزش نقطه‌ای وجود دارد که خروجی مدل بهبود نمی‌یابد، به همین منظور از روش توقف زودهنگام بر اساس کمترین میزان خطای اعتبارسنجی استفاده شده است. ساختار مدل‌های پیشنهادی در جدول‌های (۲) تا (۵) و ساختار شبکه‌های بکار رفته در مدل‌های پیشنهادی شکل (۶) قابل رویت می‌باشد.

جدول (۲): لایه‌ها و تعداد پارامترها در ResNet152		
نوع لایه	خروجی	تعداد پارامتر
ResNet152	(None, 7, 7, 2048)	۵۸۳۷۰۹۴۴
GlobalAveragePooling2D	(None, 2048)	۰
Flatten	(None, 100352)	۰
Dropout_1	(None, 100352)	۰
Dense_1	(None, 2048)	۱۸۳۶۰۳۲
Dense_2	(None, 1024)	۱۰۴۹۶۰۰
Dropout_2	(None, 1024)	۰
Dense_3	(None, 3)	۳۰۷۵
تعداد کل پارامترها: ۲۶۶۴۰۸۸۳۵		
پارامترهای آموزش پذیر: ۲۶۵۹۶۵۳۱۵		
پارامترهای غیر قابل آموزش: ۱۷۶۷۳۸۱۳		


^۱ Overfitting




الف) InceptionV3 network



ب) VGG19 network



ج) ResNet152 network



د) InceptionResNetV2

۵. نتایج

در این بخش، عملکرد روش پیشنهادی که در بخش قبل توضیح داده شد، ارزیابی می‌شود. برای این منظور، ابتدا معیارهای ارزیابی مورد استفاده شرح داده شده و سپس در بخش بعد عملکرد طبقه‌بندی سه مدل پیشنهادی در دو مجموعه داده تصاویر پزشکی اشعه ایکس و CT Scan شرح داده خواهد شد و در نهایت این نتایج با دیگر کارهای انجام شده در این زمینه مقایسه می‌شود.

۱.۵. معیارهای ارزیابی

برای ارزیابی مدل پیشنهادی از معیارهای استاندارد دقت^۱، صحت^۲، بازخوانی^۳ و معیار F، استفاده شده است. روابط (۱) تا (۴) این معیارهای ارزیابی را تعریف می‌کنند.

$$Accuracy = \frac{(TP + TN)}{Total\ examples} \quad (1)$$

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

$$Recall = \frac{(TP)}{(TP + FN)} \quad (3)$$

$$F-score = \frac{2 * (Precision * Recall)}{(Precision + Recall)} \quad (4)$$

که در این روابط، True Positive (TP) پیش‌بینی درست (کلاس واقعی مثبت)، True Negative (TN) پیش‌بینی درست (کلاس واقعی منفی)، False Positive (FP) پیش‌بینی غلط (کلاس واقعی منفی) و False Negative (FN) پیش‌بینی غلط (کلاس واقعی مثبت) است.

۲.۵. ارزیابی مدل‌ها

در این طبقه‌بندی سه نوع داده وجود دارد: (۱) بیماران مبتلا به ویروس کرونا، (۲) بیماران ریوی و (۳) افراد سالم. در رویکرد پیشنهادی از چهار مدل شبکه عصبی پیچشی شامل ResNet152، VGG19، InceptionV3 و InceptionResNetV2 به کمک

استفاده از روش یادگیری انتقالی، روی دو مجموعه داده تصاویر رادیوگرافی و CT Scan آموزش داده و به منظور بهبود عملکرد شبکه پس از پیش‌پردازش داده‌ها از روش تقویت داده، استفاده شده است. از بین داده‌ها ۷۰٪ برای آموزش شبکه، ۲۰٪ به منظور آزمایش و ۱۰٪ باقی‌مانده برای اعتبارسنجی مورد استفاده قرار گرفته است. آموزش در ۳۰ مرحله و با استفاده از نرخ یادگیری کاهشی با توجه به عملکرد مدل در هنگام آموزش به همراه توقف زودهنگام بر اساس کمترین میزان خطای اعتبارسنجی انجام شده است. برای جلوگیری از مشکل بیش‌برازش از روش generalization نیز استفاده شده است. علاوه بر آن برای به دست آوردن بهترین دقت، hyper-parameterها روی چهار مدل شبکه عصبی پیچشی تنظیم شده‌اند. همچنین نتایج به دست آمده به صورت کلی در جدول (۶) و برای هر کلاس در جدول (۷) قابل رویت است. بهترین عملکرد برای مجموعه داده رادیوگرافی مربوط به معماری InceptionV3 با دقت ۹۶/۹۴۳٪ می‌باشد و برای مجموعه داده CT Scan معماری InceptionResnetV2 با دقت ۹۹/۳۶۶٪ بهترین عملکرد را دارد. این امر نشان‌دهنده کارایی بالای چارچوب پیشنهادی برای کمک‌رسانی به کادر درمان برای شناسایی موارد مبتلا در مراحل اولیه بیماری است. همچنین با توجه به نتایج به دست آمده از دو مجموعه داده می‌توان نتیجه گرفت که تصاویر CT Scan از جزئیات بیشتری نسبت به تصاویر اشعه ایکس به منظور تشخیص بیماری‌های ریوی برخوردار هستند. علاوه بر آن، مدل InceptionV3 سریع‌تر از دیگر مدل‌ها یاد گرفته، به نقطه پایان زودهنگام رسیده و نیازمند دوره‌های آموزش کمتری می‌باشد. شکل (۷) نتایج طبقه‌بندی تصاویر اشعه ایکس را در قالب ماتریس درهم‌ریختگی نشان می‌دهد و شکل (۸) مربوط به تصاویر CT Scan می‌باشد. ماتریس درهم‌ریختگی بیانگر عملکرد مدل پیشنهادی می‌باشد به این شکل که کلاس واقعی تصاویر مجموعه آزمایش در سطرها و کلاس پیش‌بینی شده توسط مدل پیشنهادی در ستون‌ها آورده شده است. داده‌هایی که روی قطر اصلی قرار دارند، به درستی پیش‌بینی شده و مابقی داده‌ها در سلول‌های دیگر به صورت اشتباه پیش‌بینی شده‌اند.

¹ Accuracy

² Precision


³ Recall

جدول (۶): نتایج به دست آمده روی مجموعه داده‌های X-RAY و CT SCAN


نوع داده	رویکرد	Precision	Recall	F-score	Accuracy
X-ray	ResNet152	۰/۹۵	۰/۹۵	۰/۹۵	۹۴/۵۵۵
	InceptionResNetV2	۰/۹۷	۰/۹۵	۰/۹۵	۹۵/۹۸۸
	VGG19	۰/۹۳	۰/۹۳	۰/۹۳	۹۳/۳۱۴
	InceptionV3	۰/۹۷	۰/۹۷	۰/۹۷	۹۶/۹۴۳
CT scan	ResNet152	۰/۹۹	۰/۹۹	۰/۹۹	۹۹/۳۱۷
	InceptionResNetV2	۰/۹۹	۰/۹۹	۰/۹۹	۹۹/۳۶۶
	VGG19	۰/۹۹	۰/۹۹	۰/۹۹	۹۸/۷۳۲
	InceptionV3	۰/۹۹	۰/۹۹	۰/۹۹	۹۹/۱۷۱

جدول (۷): نتایج به دست آمده به ازای هر کلاس با استفاده از مدل‌های پیشنهادی


نوع داده	رویکرد	کلاس	Precision	Recall	F-score
X-ray	ResNet152	COVID-19	۰/۹۸	۰/۹۸	۰/۹۸
		Pneumonia	۰/۹۶	۰/۸۹	۰/۹۳
		Normal	۰/۹۰	۰/۹۷	۰/۹۴
	InceptionResNetV2	COVID-19	۰/۹۹	۰/۹۸	۰/۹۸
		Pneumonia	۰/۸۹	۰/۸۹	۰/۹۴
		Normal	۰/۹۸	۰/۹۸	۰/۹۵
	VGG19	COVID-19	۰/۹۸	۰/۹۶	۰/۹۷
		Pneumonia	۰/۹۲	۰/۹۰	۰/۹۱
		Normal	۰/۹۲	۰/۹۴	۰/۹۱
	InceptionV3	COVID-19	۱/۰۰	۰/۹۸	۰/۹۹
		Pneumonia	۰/۹۴	۰/۹۴	۰/۹۶
		Normal	۰/۹۸	۰/۹۸	۰/۹۶
CT scan	ResNet152	COVID-19	۰/۹۹	۰/۹۹	۰/۹۹
		CAP	۱/۰۰	۱/۰۰	۱/۰۰
		Normal	۰/۹۸	۰/۹۹	۰/۹۹
	InceptionResNetV2	COVID-19	۰/۹۹	۰/۹۹	۰/۹۹
		CAP	۱/۰۰	۰/۹۹	۱/۰۰
		Normal	۰/۹۹	۰/۹۸	۰/۹۹
	VGG19	COVID-19	۰/۹۹	۰/۹۸	۰/۹۹
		CAP	۱/۰۰	۱/۰۰	۱/۰۰
		Normal	۰/۹۷	۰/۹۸	۰/۹۷
	InceptionV3	COVID-19	۰/۹۹	۰/۹۹	۰/۹۹
		CAP	۱/۰۰	۰/۹۹	۱/۰۰
		Normal	۰/۹۸	۰/۹۷	۰/۹۸




ب) InceptionResNetV2 network



الف) ResNet152 network



د) InceptionV3 network



ج) VGG19 network

شکل (۷): ماتریس درهم‌ریختگی مجموعه آزمایش داده‌های رادیوگرافی

۳.۵. ارزیابی نتایج

همچنین پیچیدگی زمانی^۱ بر حسب ثانیه در هر دور برای هر مدل در جداول (۱۱) و (۱۲) نشان داده شده است. نتایج نشان می‌دهد که رویکرد پیشنهادی به طور دقیق تصاویر را در همه کلاس‌ها به عنوان COVID19 و افراد سالم را با دقت بالایی طبقه‌بندی می‌کند. لذا می‌توان نتیجه گرفت که تنظیم دقیق معماری CNN از قبل آموزش دیده می‌تواند به عنوان یکی از روش‌های مفید در زمینه پزشکی برای طبقه‌بندی تصاویر اشعه ایکس قفسه سینه بکار گرفته شود. امروزه استفاده از روش‌های یادگیری ماشین در تشخیص بیماری با استقبال بسیاری زیادی رو به رو شده است. ترکیب هوش مصنوعی با اینترنت اشیا در تسریع بخشیدن به این امر کمک می‌کند به نحوی که تشخیص


تحلیل مقایسه‌ای برای نشان دادن اثربخشی رویکرد پیشنهادی انجام شده است. نتایج به دست آمده توسط رویکرد پیشنهادی با استفاده از تصاویر رادیوگرافی و CT Scan با برخی از روش‌های موجود در جدول کارهای مرتبط شامل مراجع [۱]، [۳]–[۶]، [۸]–[۱۰] و [۱۲] مقایسه شده است که در جداول (۸) و (۹) نشان داده شده است. همچنین مجموعه داده معرفی شده بر روی برخی شبکه‌های بکار رفته در کارهای مرتبط آموزش داده شده و نتایج حاصل برای مجموعه تصاویر رادیوگرافی در جدول (۱۰) و برای مجموعه تصاویر CT Scan در جدول (۱۱) با نتایج به دست آمده از مدل‌های پیشنهادی مقایسه شده است.

^۱ Time execution


پیشنهادی در شناسایی موارد مبتلا در مراحل اولیه بیماری است. در جدول (۱۰)، مجموعه داده رادیوگرافی روی شبکه‌های بکار رفته در مراجع [۶] و [۸] آموزش داده شده و نتایج حاصل با نتایج به دست آمده از رویکرد پیشنهادی مبتنی بر مدل‌های شبکه عصبی پیچشی عمیق مقایسه شده است. نتایج نشان می‌دهد که رویکرد پیشنهادی به طور دقیق تصاویر را در همه کلاس‌ها به عنوان COVID19 و افراد سالم را با دقت بالایی طبقه‌بندی می‌کند. بنابراین می‌توان نتیجه گرفت که تنظیم دقیق متغیرهای مدل‌های شبکه عصبی پیچشی عمیق می‌تواند به عنوان یکی از روش‌های مفید در زمینه پزشکی برای طبقه‌بندی تصاویر رادیوگرافی قفسه سینه بکار گرفته شود. همچنین پیچیدگی زمانی بر حسب ثانیه در هر دور برای هر یک از رویکردهای شبکه عصبی پیچشی محاسبه شده است که در جدول (۱۰) نشان داده شده است.

انواع آزمایش‌های پزشکی اعم از رادیولوژی و پاتولوژی به صورت بلادرنگ مبتنی بر اینترنت اشیا منجر به کاهش نرخ مرگ‌ومیر و بالا بردن کیفیت خدمات درمانی می‌شود. با توجه به نتایج به دست آمده می‌توان نتیجه گرفت با استفاده از تجهیزات مناسب و زیرساخت‌های مورد نظر، امکان پردازش داده‌های پزشکی با دقت بالا دور از انتظار نبوده و می‌توان از آن در شرایط بحرانی نقطه اوج همه‌گیری بیماری‌های ویروسی که سلامت جامعه را تهدید می‌کنند، بهره برد.


همان‌طور که در جداول (۸) و (۹) نشان داده شده است، کارایی رویکرد پیشنهادی با استفاده از تصاویر رادیوگرافی و CT Scan با روش‌های دیگر مقایسه شده است. نتایج نشان می‌دهد دقت رویکرد پیشنهادی مبتنی بر مدل‌های شبکه عصبی پیچشی عمیق (InceptionResNetV2, VGG19, InceptionV3, ResNet152) بالاتر از روش‌های دیگر است که بیانگر کارایی بالای رویکرد




ب) InceptionResNetV2 network



الف) ResNet152 network



د) InceptionV3 network



ج) VGG19 network

جدول (۸): مقایسه نتایج حاصل از مجموعه داده تصاویر رادیوگرافی با دیگر کارهای مرتبط

منبع	رویکرد	تعداد داده	نتایج
[۳]	VGG19	۴۵۰۰	۸۶٪
	InceptionV3		۹۵٪
[۴]	مدل ترکیبی (ensemble)	۱۵۶۸۸	۸۸٪
[۱۰]	AlexNet	۵۴۳۶	۸۶٪
	VGG16		۸۷٪
	ResNet50		۹۱٪
	ResNet101		۹۳٪
	ResNet152		۹۵٪
[۱۱]	VGG16	۳۸۰	۸۵٪
	VGG19		۸۹٪
	ResNet18		۸۸٪
	ResNet50+SVM		۹۴٪
	ResNet101		۸۷٪
[۶]	مدل ترکیبی (ensemble)	۱۵۷۶۰	۹۸٪
مدل پیشنهادی	ResNet152	۵۲۲۸	۹۴/۵٪
	InceptionV3		۹۶/۹٪
	VGG19		۹۳/۳٪
	InceptionResNetV2		۹۵/۹٪

جدول (۹): مقایسه نتایج حاصل از مجموعه داده تصاویر CT SCAN با دیگر کارهای مرتبط

منبع	رویکرد	تعداد داده	نتایج
[۷]	مدل پیشنهادی مقاله	۶۳۵۴	۹۸٪
[۸]	مدل پیشنهادی مقاله	۸۰۵۵	۹۷٪
	ResNet50		۹۶٪
	ResNet101		۹۵٪
	GoogLeNet		۹۶٪
	AlexNet		۹۳٪
[۹]	DenseNet201	۵۴۷۱	۹۶٪
	ShuffleNet		۹۱٪
	MobileNet		۹۲٪
	MobShufNet		۹۳٪
	ResNet152		۹۹/۳٪
مدل پیشنهادی	InceptionV3	۱۰۲۳۹	۹۹/۱٪
	VGG19		۹۸/۷٪
	InceptionResNetV2		۹۹/۳٪

همان‌طور که در جدول (۱۱) نشان داده شده است، مجموعه داده CT Scan در رویکرد [۸] آموزش داده شده و نتایج حاصل با نتایج به دست آمده از رویکرد پیشنهادی مبتنی بر مدل‌های شبکه عصبی پیچشی عمیق مقایسه شده است. نتایج نشان می‌دهد که رویکرد پیشنهادی با دقت بالاتری نسبت به مرجع [۸] تصاویر را طبقه‌بندی می‌کند که نشان‌دهنده کارایی بالای رویکرد پیشنهادی در طبقه‌بندی تصاویر CT Scan است.

برای مقایسه الگوریتم‌های مورد بررسی، آزمون آماری با استفاده از STAC^۱ در نظر گرفته شده است [۲۷]. STAC یک وب‌گاه در بستر وب برای مقایسه روش‌ها با در نظر گرفتن آزمون‌های آماری است. اگر داده‌ها دارای توزیع (معمولاً نرمال) باشند، می‌توان از آزمون پارامتریک استفاده کرد. در غیر این صورت، اگر توزیع داده‌ها مشخص نباشد، از آزمون غیرپارامتریک استفاده می‌شود. هدف از آزمون آماری مقایسه دقت الگوریتم‌ها است، بنابراین الگوریتم‌ها دو به دو با یکدیگر مقایسه می‌شوند. ابتدا، دقت‌های جدول (۶) بین [0 1] نرمال می‌شوند و سپس مقادیر به محیط STAC به عنوان ورودی داده می‌شوند. آزمون رتبه‌بندی هم‌سطح اعمال شده و پارامتر Post-hoc روی Holm و سطح معنی‌دار روی ۰/۰۵ تنظیم می‌شود که در جدول (۱۲) نشان داده شده است. فرضیه H0 یعنی معنادار بودن اختلاف نتایج به دست آمده از مقایسه روش‌ها، زمانی پذیرفته می‌شود که مقدار P-value بیشتر از سطح معنی‌دار یعنی ۰/۰۵ باشد. با توجه به داده‌های به دست آمده، نتیجه گرفته می‌شود که فرضیه H0 قابل پذیرش است.

جدول (۱۳) رتبه معماری‌های مورد مقایسه را در STAC نشان می‌دهد. همان‌طور که در این جدول مشاهده می‌شود، برای مجموعه داده رادیوگرافی InceptionV3 حداقل امتیاز و VGG19 حداکثر امتیاز و برای مجموعه داده CT Scan معماری VGG19 بیشترین امتیاز و InceptionResNetV2 و ResNet152 به صورت مشترک کمترین امتیاز را کسب می‌کنند. خروجی دیگری برای مقایسه دوبه‌دوی الگوریتم‌ها به دست آمده است که در جدول (۱۴) نشان داده شده است.

¹ Statistical Tests for Algorithms Comparison

جدول (۱۰): مقایسه نتایج به دست آمده با استفاده از مجموعه داده رادیوگرافی با استفاده از برخی مدل‌های یادگیری عمیق

منبع	رویکرد	تعداد لایه	تعداد پارامتر	پیچیدگی زمانی در هر دور	نتیجه
[۶]	VGG16	۱۶	بیش از ۱۳۸ میلیون	۲۱۰	۹۶/۴٪
[۸]	ResNet50	۵۰	بیش از ۲۳ میلیون	۱۹۰	۹۴/۶٪
مدل پیشنهادی	ResNet152	۱۵۲	بیش از ۶۰ میلیون	۶۱۰	۹۴/۵٪
	InceptionV3	۱۸۹	بیش از ۲۳ میلیون	۱۹۶	۹۶/۹٪
	VGG19	۱۹	بیش از ۱۴۳ میلیون	۲۷۰	۹۳/۳٪
	InceptionResNetV2	۴۴۹	بیش از ۵۵ میلیون	۸۵	۹۵/۹٪

جدول (۱۱): مقایسه نتایج به دست آمده با استفاده از مجموعه داده CT SCAN با استفاده از برخی مدل‌های یادگیری عمیق

منبع	رویکرد	تعداد لایه	تعداد پارامتر	پیچیدگی زمانی در هر دور	نتیجه
[۸]	VGG16	۱۶	بیش از ۱۳۸ میلیون	۸۰	۹۱/۷٪
	ResNet50	۵۰	بیش از ۲۳ میلیون	۷۵	۹۹٪
مدل پیشنهادی	ResNet152	۱۵۲	بیش از ۶۰ میلیون	۲۵۰	۹۹/۳٪
	InceptionV3	۱۸۹	بیش از ۲۳ میلیون	۱۱۰	۹۹/۱٪
	VGG19	۱۹	بیش از ۱۴۳ میلیون	۳۶۰	۹۸/۷٪
	InceptionResNetV2	۴۴۹	بیش از ۵۵ میلیون	۳۸۰	۹۹/۳٪

جدول (۱۲): نتایج آزمون رتبه بندی هم سطح

مجموعه داده	Statistic	P-value	نتیجه
X-ray	۳/۰۰۰۰۰	۰/۳۹۱۶۳	H0 is accepted
CT Scan	۲/۷۰۰۰۰	۰/۴۴۰۲۳	H0 is accepted

جدول (۱۳): رتبه معماری‌ها در STAC

مجموعه داده	معماری	رتبه
X-ray	VGG19	۱
	ResNet152	۲
	InceptionResNetV2	۳
	InceptionV3	۴
CT Scan	VGG19	۱
	InceptionV3	۲
	InceptionResNetV2	۳
	ResNet152	۳

۶. نتیجه‌گیری و کارهای آینده

اینترنت اشیا یک بستر یکپارچه برای تسهیل تعاملات بین انسان‌ها و انواع بسترهای فیزیکی و مجازی است و این بستر با توجه به شرایط بحرانی همه‌گیری ویروس کرونا می‌تواند در حوزه مراقبت‌های درمانی نقش حیاتی ایفا کند و در نتیجه کاهش

فشار بر سیستم‌های درمانی را به همراه داشته باشد. امروزه با توجه به پیشرفت فناوری، اینترنت اشیا پزشکی به همراه روش‌های هوش مصنوعی از قبیل یادگیری ماشین و یادگیری عمیق امکانات جدیدی فراهم آورده است که طیف گسترده‌ای از کاربردها در حوضه مراقبت‌های درمانی را در بر می‌گیرد. دستگاه‌های پزشکی و حسگرها با استفاده از اتصال به اینترنت می‌توانند داده‌های ارزشمندی را جمع‌آوری کنند که در مراحل بعد به کمک روش‌های هوش مصنوعی پردازش شده و دانش آنها استخراج شود.

تشخیص ویروس کرونا از طریق تصاویر قفسه سینه یک مساله چالش برانگیز است و هنوز باید بر بسیاری از مشکلات غلبه کرد. در این مقاله، یک سیستم مراقبت بهداشتی هوشمند پیشنهاد شده است که از فناوری‌های اینترنت اشیا برای ارزیابی اولیه ویروس کرونا با استفاده از شبکه عصبی و به کمک تصاویر پزشکی قفسه سینه استفاده می‌کند. این سیستم از حسگرهای هوشمند برای جمع‌آوری داده‌ها بهره می‌برد. این داده‌ها در مخزن داده ذخیره شده و برای ارزیابی وضعیت بیماران استفاده می‌شود. در ابتدا تصاویر پزشکی قفسه سینه با استفاده از دستگاه‌های

در کارهای آینده تصاویر بیشتری جمع‌آوری خواهد شد و مدل‌های عمیق‌تری برای تشخیص ویروس کرونا مورد بررسی قرار خواهد گرفت. به دلیل وضعیت اضطراری بهداشت عمومی فعلی، گردآوری مجموعه داده‌های گسترده برای آموزش مدل یادگیری عمیق از اهمیت زیادی برخوردار است. به علاوه، سایر بیماری‌های ریوی نیز در مطالعات آینده گنجانده خواهد شد و نیز توسعه رابط گرافیکی برای کمک به متخصصان رادیولوژی در شناسایی ویروس کرونا می‌تواند هدف مطالعه آینده باشد.

جدول (۱۴): مقایسه دو به دو الگوریتم‌ها				
H0	P-value	Statistic	معماری	مجموعه داده
Accepted	۰/۶۰۲۰۹	۱/۶۴۳۱۷	VGG19 vs InceptionV3	X-ray
Accepted	۱/۰۰۰۰۰	۱/۰۹۵۴۵	VGG19 vs InceptionResNetV2	
Accepted	۱/۰۰۰۰۰	۱/۰۹۵۴۵	ResNet152 vs InceptionV3	
Accepted	۱/۰۰۰۰۰	۰/۵۴۷۷۲	VGG19 vs ResNet152	
Accepted	۱/۰۰۰۰۰	۰/۵۴۷۷۲	InceptionResNetV2 vs ResNet152	
Accepted	۱/۰۰۰۰۰	۰/۵۴۷۷۲	InceptionResNetV2 vs InceptionV3	
Accepted	۱/۰۰۰۰۰	۱/۳۶۹۳۱	VGG19 vs InceptionResNetV2	CT Scan
Accepted	۱/۰۰۰۰۰	۱/۳۶۹۳۱	VGG19 vs ResNet152	
Accepted	۱/۰۰۰۰۰	۰/۸۲۱۵۸	InceptionResNetV2 vs InceptionV3	
Accepted	۱/۰۰۰۰۰	۰/۸۲۱۵۸	ResNet152 vs InceptionV3	
Accepted	۱/۰۰۰۰۰	۰/۵۴۷۷۲	VGG19 vs InceptionV3	
Accepted	۱/۰۰۰۰۰	۰/۰۰۰۰۰	InceptionResNetV2 vs ResNet152	

تعارض منافع: نویسندگان اعلام می‌کنند که هیچ تعارض منافی ندارند.

مجهز به فناوری اینترنت اشیا به مخزن داده ارسال می‌شوند. در ادامه، تصاویر پزشکی به منظور استخراج دانش پیش‌پردازش شده و به شبکه یادگیری عمیق فرستاده می‌شود که ویروس کرونا را شناسایی می‌کند. استفاده از ظرفیت‌های فناوری‌هایی مانند اینترنت اشیا و هوش مصنوعی در شرایط بحرانی همچون پاندمی ویروس کرونا با توجه به کمبود کادر درمان در مقایسه با مراجعات روزانه و همچنین کاهش نرخ همه‌گیری این ویروس و حفظ سلامت جامعه از اهمیت بالایی برخوردار است. توجه به این نکته مهم است که معماری‌های شبکه عصبی پیچشی عمیق زمانی که با تعداد دوره‌های بیشتری آموزش داده می‌شوند تمایل به بیش‌برازش دارند. به منظور جلوگیری از این امر از روش‌هایی مانند توقف زودهنگام و تقویت داده استفاده شده است، هرچند استفاده از روش حذف تصادفی (Dropout)، در اغلب اوقات راه‌حل مناسبی است. مدل پیشنهادی بهترین دقت که برابر با ۹۶/۹۴۳٪ برای تصاویر رادیوگرافی قفسه سینه پزشکی و ۹۹/۳۶۰٪ برای تصاویر CT Scan ارائه کرد. هرچند مجموعه داده‌های موجود هنوز قوی نیستند، اما دانش تجربی در مورد برنامه‌های کاربردی شبکه‌های عصبی پیچشی بیان می‌کند که افزایش تعداد نمونه‌ها و کیفیت مجموعه داده تاثیر مستقیم بر دقت به دست آمده دارد. روش پیشنهادی مبتنی بر یادگیری عمیق در تحقیقات تشخیص پزشکی و سیستم‌های مراقبت‌های بهداشتی مفید خواهد بود. همچنین ابزار دقیقی برای کارشناسان پزشکی به منظور غربالگری ویروس کرونا می‌باشد و منجر به نظر ثانویه پزشکی می‌شود.

مراجع

- [1] World Health Organization, (2022, Dec. 01). Coronavirus disease 2019 (covid-19) [Online]. Available: <https://www.who.int>.
- [2] A. Akrami and M. Parsamanesh, "Investigation of a mathematical fuzzy epidemic model for the spread of coronavirus in a population," *Soft Comput. J.*, vol. 11, no. 1, pp. 2-9, 2022, doi: 10.22052/scj.2022.246053.1045 [In Persian].
- [3] I. Ahmed, G. Jeon, and A. Chehri, "An IoT-enabled smart health care system for screening of COVID-19 with multi layers features fusion and selection," *Computing*, vol. 105, no. 4, pp. 743-760, 2023, doi: 10.1007/s00607-021-00992-0.
- [4] S.D. Deb, R.K. Jha, K. Jha, and P.S. Tripathi, "A multi model ensemble based deep convolution neural network structure for detection of COVID19," *Biomed. Signal Process. Control*, vol. 71, p. 103126, 2022, doi: 10.1016/j.bspc.2021.103126.
- [5] M.R. Islam and M. Nahiduzzaman, "Complex features extraction with deep learning model for the detection of

- COVID19 from CT scan images using ensemble based machine learning approach,” *Expert Syst. Appl.*, vol. 195, p. 116554, 2022, doi: 10.1016/j.eswa.2022.116554.
- [6] N.S. Kavva, T. Shilpa, N. Veeranjanyulu, and D.D. Priya, “Detecting covid19 and pneumonia from chest x-ray images using deep convolutional neural networks,” *Materials Today: Proc.*, vol. 64, pp. 737-743, 2022, doi: 10.1016/j.matpr.2022.05.199.
- [7] S. Thakur and A. Kumar, “X-ray and CT-scan-based automated detection and classification of covid-19 using convolutional neural networks (CNN),” *Biomed. Signal Process. Control*, vol. 69, p. 102920, 2021, doi: 10.1016/j.bspc.2021.102920.
- [8] M.S. Elpeltagy and H. Sallam, “Automatic prediction of COVID-19 from chest images using modified ResNet50,” *Multim. Tools Appl.*, vol. 80, no. 17, pp. 26451-26463, 2021, doi: 10.1007/s11042-021-10783-6.
- [9] M. Owais, H.S. Yoon, T. Mahmood, A. Haider, H. Sultan, and K.R. Park, “Light-weighted ensemble network with multilevel activation visualization for robust diagnosis of COVID19 pneumonia from large-scale chest radiographic database,” *Appl. Soft Comput.*, vol. 108, p. 107490, 2021, doi: 10.1016/j.asoc.2021.107490.
- [10] I. Lorencin et al., “Automatic Evaluation of the Lung Condition of COVID-19 Patients Using X-ray Images and Convolutional Neural Networks,” *J. Pers. Med.*, vol. 11, no. 1, p. 28, 2021, doi: 10.3390/jpm11010028.
- [11] A.M. Ismael and A. Sengur, “Deep learning approaches for COVID-19 detection based on chest X-ray images,” *Expert Syst. Appl.*, vol. 164, p. 114054, 2021, doi: 10.1016/j.eswa.2020.114054.
- [12] X. Ouyang et al., “Dual-sampling attention network for diagnosis of COVID-19 from community acquired pneumonia,” *IEEE Trans. Medical Imaging*, vol. 39, no. 8, pp. 2595-2605, 2020, doi: 10.1109/TMI.2020.2995508.
- [13] J.P. Cohen, P. Morrison, L. Dao, K. Roth, T.Q. Duong, and M. Ghassemi, “Covid-19 image data collection: Prospective predictions are the future,” *arXiv preprint arXiv: 2006.11988*, 2020.
- [14] Sarscov2-ctscan-dataset, (2022, Dec. 01). [Online]. Available: <https://www.kaggle.com/datasets/plameneduardo/sarscov2-ctscan-dataset>
- [15] Mendeley Data. Extensive COVID-19 X-Ray and CT Chest Images Dataset, (2022, Dec. 01). [Online]. Available: <https://doi.org/10.17632/8h65ywd2jr.3>
- [16] COVID-19 image data collection, (2022, Dec. 01). [Online]. Available: <https://github.com/ieee8023/covid-chestxray-dataset/tree/master/images>
- [17] Chest-xray-pneumonia, (2022, Dec. 01). [Online]. Available: <https://www.kaggle.com/paultimothymooney/chest-xray-pneumonia>
- [18] S. Kumar, “COVID19+PNEUMONIA+NORMAL Chest X-Ray Images,” (2022, Dec. 01). [Online]. Available: <https://www.kaggle.com/sachinkumar413/covid-pneumonia-normal-chest-xray-images>.
- [19] M.H. Kashani, M. Madanipour, M. Nikravan, P. Asghari, and E. Mahdipour, “A systematic review of IoT in healthcare: Applications, techniques, and trends,” *J. Netw. Comput. Appl.*, vol. 192, p. 103164, 2021, doi: 10.1016/j.jnca.2021.103164.
- [20] M.M. AlyanNezhadi, M. Hosseini, H. Qazanfari, and A. Kamandi, “Content-based image retrieval using support vector machine and texture difference histogram features,” *Soft Comput. J.*, vol. 11, no. 1, pp. 10-21, doi: 10.22052/scj.2022.246175.1053 [In Persian].
- [21] B. McFee, C. Raffel, D. Liang, D.P.W. Ellis, M. McVicar, E. Battenberg, and O. Nieto, “Librosa: audio and music signal analysis in Python,” in *Proc. 14th Python Sci. Conf. (SciPy)*, Austin, Texas, 2015, pp. 18-24, doi: 10.25080/majora-7b98e3ed003.
- [22] Large COVID-19 CT scan slice dataset, (2022, Dec. 01). [Online]. Available: <https://www.kaggle.com/datasets/maedemaftouni/large-covid19-ct-slice-dataset>
- [23] H. Zhu et al., “IoT PCR for pandemic disease detection and its spread monitoring,” *Sens. Actuators B Chem.*, vol. 303, p. 127098, 2020, doi: 10.1016/j.snb.2019.127098.
- [24] T. Yaqoob, H. Abbas, and M. Atiquzzaman, “Security vulnerabilities, attacks, countermeasures, and regulations of networked medical devices—A review,” *IEEE Commun. Surv. Tutorials*, vol. 21, no. 4, pp. 3723-3768, 2019, doi: 10.1109/COMST.2019.2914094.
- [25] M. Adil and M.K. Khan, “Emerging iot applications in sustainable smart cities for covid-19: Network security and data preservation challenges with future directions,” *Sustainable Cities and Soc.*, vol. 75, p. 103311, 2021, doi: 10.1016/j.scs.2021.103311.
- [26] A. Mirzakhani and M. Mohammadpoor, “Detection of disc destruction between lumbar vertebrae using mri images,” *Soft Comput. J.*, vol. 9, no. 1, pp. 114-123, 2020, doi: 10.22052/scj.2021.111454 [In Persian].
- [27] I. Rodriguez-Fdez, A. Canosa, M. Mucientes, and A. Bugarin, “STAC: A web platform for the comparison of algorithms using statistical tests,” in *IEEE Int. Conf. Fuzzy Syst. (FUZZ-IEEE)*, Istanbul, Turkey, 2015, pp. 1-8, doi: 10.1109/FUZZ-IEEE.2015.7337889.