

مقاله علمی-ترویجی

یادگیری عمیق در پردازش تصاویر سی تی اسکن ریه بیماران مبتلا به کرونا

دکتر علی کارساز، دانشیار موسسه آموزش عالی خراسان، a.karsaz@khorasan.ac.ir

رقیه اکبریانی^{*}، کارشناسی ارشد موسسه آموزش عالی خراسان، fl.kbarian@gmail.com

علی خرمی، استادیار موسسه آموزش عالی خراسان، Khorami@khorasan.ac.ir

^{*}نویسنده مسئول

چکیده

بیماری کرونا، از ژانویه ۲۰۲۰ در بازار عمده فروشان ماهی در شهر وهان چین شروع و سازمان بهداشت جهانی آن را به عنوان یک بیماری عمومی و یک مخاطره بین‌المللی معرفی و در فوریه ۲۰۲۰ آن را کرونا یا کووید-۱۹ نامگذاری نمود. با گسترش روزافزون بیماری کرونا در سراسر دنیا، استفاده از تکنیک‌ها و الگوریتم‌های هوش مصنوعی به خصوص شبکه‌های عصبی کانولوشن مبتنی بر یادگیری عمیق جهت غربالگری تصاویر سی تی اسکن قفسه سینه بیماران مبتلا به کووید-۱۹ ضرورت بیش از پیش یافته و سهم عمده‌ای از مقالات چاپ شده در این حوزه را به خود اختصاص داده‌اند. در حال حاضر دقت‌های تشخیص و غربالگری گزارش شده در مقالات علمی مبتنی بر روش‌های هوش مصنوعی و یادگیری عمیق از روی تصاویر سی تی اسکن قفسه سینه بیماران، به بیش از ۹۵ درصد رسیده است. یکی از معضلات موجود در زمینه روش‌های مبتنی بر هوش مصنوعی، به مساله آموزش شبکه‌های عصبی کانولوشن و نیازمندی آنها به تعداد بالایی از داده‌های آموزش باز می‌گردد. تلفیق چندین معماری مختلف از شبکه‌های عصبی کانولوشن، منجر به افزایش دقت در این نوع از شبکه‌ها به بیش از ۹۹ درصد گردیده است.

کلمات کلیدی: کووید-۱۹، شبکه‌های عصبی کانولوشن، یادگیری عمیق، تصاویر سی تی اسکن قفسه سینه (CXR).

Deep learning in chest CT-scan images processing of covid-19 patients

Ali Karsaz, Associate Professor, Khorasan Institute of Higher Education, a.karsaz@khorasan.ac.ir

Roghayeh Akbarian^{*}, Master of Science, Khorasan Institute of Higher Education, fl.kbarian@gmail.com

Ali Khorami, Associate Professor, Khorasan Institute of Higher Education, Khorami@khorasan.ac.ir

^{*}Corresponding Author

Abstract

Corona disease started in January 2020 in the wholesale fish market in Wuhan, China, and the World Health Organization declared it as a public disease and an international hazard, and in February 2020 named it Corona or Covid-19. Under this global pandemic, using artificial intelligence techniques especially convolutional neural networks based on deep learning for screening chest CT images are becoming more vital as before. The most studies in this field belong to the articles based on the deep learning methodologies using convolution neural

networks. Already, obtained accuracies of detection and screening have been reported in the article based on artificial intelligence and deep learning are more than 95 percent. The lack of comprehensive datasets of CT images with a large amount of samples is one of the most important problems in this field. Using hybrid architectures of convolutional neural networks have been increased the accuracy of these networks up to 99 percent.

Keywords: Covid-19, convolutional neural networks, deep learning, chest CT images.

۱- مقدمه

این فرایند آزمایشی دارای نتایج منفی کاذب بوده و گاهی عفونت را تشخیص نمی‌دهد. نتایج منفی کاذب به معنی عدم تشخیص بیماری در افراد مبتلا گفته می‌شود. با استفاده از این آزمایش، واکنش زنجیره پلیمرز توسط مولکول‌های گزارشگر فلورسنت انجام و از این طریق، تولید فرآورده‌های تکثیری طی هر چرخه واکنش PCR گزارش می‌شود [۳، ۴]. تحقیقات نشان می‌دهد که دقت آزمایش RT-PCR در تشخیص بیماری کرونا، در بازه ۵۹٪ تا ۷۱٪ متغیر است [۵، ۶].


۲- تشخیص کووید-۱۹ مبتنی بر تصاویر سی تی اسکن قفسه سینه (CXR)

در حال حاضر در دنیا برای تشخیص بیماری کرونا و ویروس کووید-۱۹ روش‌های بسیار زیادی وجود دارد، اما بر اساس تایید انجمن رادیولوژی آمریکا، اسکن قفسه سینه بهترین راه برای تشخیص ابتلا به این ویروس است و یک روش کم‌هزینه‌تر و ایمن‌تر نسبت به روش RT-PCR محسوب می‌شود [۵]. در شکل (۲) تصاویر CT^۷ اسکن مربوط به یک خانم ۴۷ ساله که به مدت سه روز تب بالای ۳۸ درجه سانتی‌گراد داشته، نشان داده شده است. این تصاویر به صورت رایج در بیماران کرونایی دیده می‌شوند. در تصویر a که سه روز پس از بروز علائم از قفسه سینه بیمار گرفته شده است، ناحیه لکه‌های زمینه شیشه‌ای^۸ (GGO) با تراکم جزئی در قسمت تحتانی لوب راست ریه مشاهده می‌شود. تصویر b مربوط به سی تی اسکن روز هفتم بیماری است که در آن وسعت یافتن GGOها و انتشار آنها، نشانه‌ی تورم فضای بینابینی^۹ به‌طور کامل مشخص است. تصویر c، سی تی اسکن بیمار در روز یازدهم بیماری را نشان می‌دهد که در آن GGOها با تراکم‌های جدید دیده می‌شوند. در تصویر بخش d که مربوط به


ویروس کرونا یا کووید-۱۹ متعلق به خانواده‌ای از ویروس‌ها از قبیل سندروم تنفسی حاد^۲ (SARS)، سندروم تنفسی خاورمیانه^۳ (MERS) و نیز سندرم دیسترس تنفسی^۴ (ARDS) است که نخستین بار در سال ۱۹۶۰ مورد مطالعه قرار گرفته و تاکنون هفت نمونه مختلف از این ویروس‌ها کشف شده است. این بیماری از ۱۰ ژانویه ۲۰۲۰ در وهان چین شروع و در تاریخ ۳۰ ژانویه ۲۰۲۰ سازمان بهداشت جهانی آن را به‌عنوان بیماری عمومی و یک مخاطره بین‌المللی معرفی و در فوریه ۲۰۲۰ آن را کرونا یا کووید-۱۹ نامگذاری کرد. اگرچه منشأ اصلی این ویروس جانوران هستند ولی در حال حاضر این ویروس از انسان به انسان منتقل می‌شود. از نظر ساختمانی این ویروس از یک رشته RNA، پروتئین پوششی و پروتئین شاخکی مطابق شکل (۱) تشکیل یافته است پروتئین شاخکی به گیرنده آنزیم نوع ۲ مبدل آنژیوتانسین^۵ در سطح سلول‌های ریه، کلیه و یا قلب متصل شده و از طریق رشته RNA وارد سلول می‌شود [۱].

در داخل سلول میزبان رشته RNA توسط آنزیم Reverse Tran-criptase به DNA دو رشته‌ای تبدیل شده و در هسته سلول میزبان شروع به همانندسازی می‌کند. پس از همانندسازی مواد وراثتی ویروس از امکانات سلول میزبان استفاده کرده و پروتئین‌های ویروس سنتز می‌شوند. پس از این مرحله اجزاء سنتز شده ویروس به هم پیوسته و به این ترتیب ویروس‌های جدید در داخل سلول میزبان به‌وجود آمده و آماده آلوده کردن بقیه سلول‌ها می‌شوند [۲].


یکی از رایج‌ترین راه‌های تشخیص بیماری کرونا، از طریق نمونه‌های گرفته شده از سواب‌های بینی و حلق، تحت آزمایشی با عنوان واکنش زنجیره‌ای پلیمرز ترانس کریپتاز معکوس^۶ (RT-PCR) است.



شکل ۲: تصاویر CXR یک بیمار مبتلا به کرونا (a) روز سوم ابتلا، (b) روز هفتم ابتلا، (c) روز یازدهم ابتلا و (d) روز بیستم ابتلا [۵]



شکل ۱: ساختار ویروس کرونا تشکیل یافته از رشته RNA، پروتئین پوششی و پروتئین شاخکی [۱]




شکل ۳: معماری Alex Net به عنوان یکی از ابتدایی ترین معماری های CNN و مورد استفاده در تشخیص کووید-۱۹ [۱۰]

استخراج ویژگی های^{۱۵} آن تصویر می پردازد. هر فیلتر کانولوشن، شامل مجموعه ای عدد است با قرار گرفتن فیلتر روی هر بخش از تصویر، اعداد در فیلتر درایه به درایه در پیکسل های متناظر تصویر ضرب می شوند و در نهایت همه اعداد با هم جمع می شوند. جهت کاهش حجم محاسبات از لایه ای موسوم به لایه تجمعی استفاده می شود. دو نوع لایه تجمعی وجود دارد Max Pooling و Average Pooling. لایه تجمعی Max Pooling مقدار بیشینه را از قسمتی از تصویر باز می گرداند که توسط کرنل یا ماسک مورد نظر، پوشش داده شده است و لایه Average Pooling میانگین همه مقادیری را که ماسک مورد نظر روی آن قرار گرفته، باز می گرداند. لایه های به طور کامل متصل یا FC در شبکه کانولوشن، به عنوان طبقه بندی یا کلاسیفایر^{۱۶} عمل می کنند. یعنی مجموعه ویژگی های استخراج شده با استفاده از لایه های کانولوشنی در نهایت تبدیل به یک بردار می شوند و در نهایت این بردار ویژگی به لایه FC داده می شود تا کلاس درست را شناسایی کند. در ادامه به معرفی مهمترین معماری های CNN در طول چند سال اخیر پرداخته می شود [۹].

۳-۱- معماری Net Alex

درخشش اصلی CNNها در سال ۲۰۱۲ در جریان رویداد "ImageNet- Large Scale Recognition Challenge" همان مسابقه ImageNet اتفاق افتاد. اتفاقی که توجه جامعه محققان را به خود جلب کرد. در مسابقه ImageNet، Alex Krizhevsky از دانشگاه تورنتو با شبکه AlexNet وارد مسابقه پیچیده ImageNet شد. مسابقه ImageNet یک چالش دسته بندی با ۱/۲ میلیون تصویر در ۱۰۰۰ کلاس بود. شبکه AlexNet با خطای ۱۶,۴٪ به رتبه نخست مسابقه رسید. AlexNet به عنوان نقطه آغازین در استفاده از CNNها، محسوب



شکل ۴: معماری VGG16 به عنوان یکی از معماری های پر کاربرد حوزه تشخیص

کووید-۱۹ [۱۱]

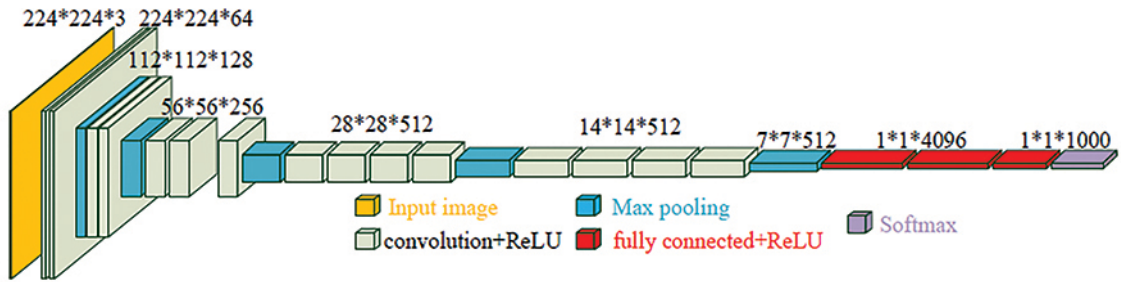
سی تی اسکن بیمار در روز بیستم است، GGOها در حال پراکندگی هستند و باندهای پارانشیمی مشاهده می شود [۵].

در سی تی اسکن قفسه سینه، سرعت ایجاد تصاویر با کیفیت از بافت ریه بالا است و رادیولوژیست می تواند به سرعت میزان درگیری ریه با بیماری را مشخص کند. سی تی اسکن قفسه سینه ویژگی های رادیولوژیکی رایج در بیماران مبتلا به ذات الریه ناشی از کووید-۱۹ را مشخص می کند. این ویژگی ها شامل نقاط توده ای تاریک^{۱۱}، لکه های چند کانونی^{۱۱} و تغییرات بینابینی با توزیع محیطی^{۱۲} است. برای تشخیص سریع و دقیق و مبارزه موثر با کرونا متخصصان شروع به استفاده از روش های تصویربرداری رادیولوژی کرده اند. این روش ها با روش های توموگرافی کامپیوتری (CT) یا تصویربرداری اشعه ایکس انجام می شود. مراحل بیماری اولیه و آخر کرونا دارای ویژگی های مشابهی در تصاویر CT هستند. در مطالعه ای که محققان چینی بر روی ۱۰۱۴ بیمار مشکوک به کرونا ویروس انجام دادند، مشخص شد که حساسیت سی تی اسکن در تشخیص بیماری کرونا، ۹۰ درصد بوده است [۶, ۷].


۳-۲- شبکه های عصبی کانولوشن نو ظهور

یکی از مهم ترین مزایای استفاده از شبکه های عصبی کانولوشن^{۱۳} توانایی آنها در استخراج ویژگی های تصاویر به صورت خودکار با استفاده از مفهوم یادگیری عمیق است. مفهوم شبکه CNN در سال ۱۹۹۰ با الهام گیری از آزمایش های انجام شده توسط Hubel و Wiesel روی قشر بینایی^{۱۴} معرفی شد. یکی از نخستین پروژه های انجام شده با این شبکه CNN پروژه معروف شناسایی ارقام دست نویس MNIST در سال ۱۹۹۸ توسط Yann Lecun بود که نتایج امیدوار کننده ای به همراه داشت، مانند یادگیری در مغز انسان که بسیاری از فرایندهای پیچیده به خاطر سپاری توسط لایه های درونی تر و عمیق تر مغز انسان صورت می پذیرد، یادگیری عمیق با استفاده از ساختارهای شبکه های عصبی کانولوشن و با بهره گیری از زیر لایه های بیشتر می تواند به آموزش الگوهای پیچیده تر کمک نماید. شبکه های عصبی کانولوشن مدلی از شبکه های عصبی مصنوعی بوده که همانند شبکه های عصبی معمولی از نورون، لایه و وزن ها تشکیل یافته و علاوه بر این دارای لایه های کانولوشن و تماما متصل است [۸].

اصلی ترین لایه در یک CNN، لایه کانولوشن است که درصد اعظم محاسبات شبکه عصبی کانولوشن را به خود اختصاص داده است. شبکه کانولوشن تصاویر را به صورت قطعه به قطعه مقایسه می کند. یک CNN با ماسک گذاری بر روی قطعات مختلف، به




شکل ۵: شبکه عصبی کانولوشن VGG19، نسخه عمیق تر VGG16 [۱۲]



(ب)

شکل ۶: الف) معماری SqueezeNet، ب) ماژول آتش در معماری SqueezeNet تشکیل شده از لایه squeeze و expand [۱۳]



(الف)

می‌یابد و با یک لایه کانولوشن نهایی پایان می‌یابد (شکل ۶). برای کاهش تعداد کانال‌های ورودی به فیلتر 3×3 از لایه‌ای به نام squeeze استفاده می‌شود. این لایه‌ها در واقع از مجموعه فیلترهای 1×1 تشکیل شده‌اند. لایه دیگری که در این شبکه وجود دارد لایه expand است. این لایه ترکیبی از تعدادی فیلترهای 3×3 و 1×1 است مجموعه این دو لایه را بلاک آتش می‌نامند [۱۳، ۱۴].

۳-۵- معماری GoogLeNet

GoogLeNet جزو نخستین و عمیق‌ترین معماری‌های CNN محسوب می‌شود که توسط یکی از محققان شرکت گوگل طراحی شده است. آنچه که این معماری را با سایر معماری‌های مشابه متفاوت کرده، استفاده از بلاکی به نام Inception در این معماری است (شکل ۷). به شکل کلی یک شبکه کانولوشن GoogLeNet دارای دو لایه کانولوشن، دو لایه پولینگ و ۹ لایه Inception بوده هر لایه Inception خود دارای ۶ لایه کانولوشن و یک لایه پولینگ است. شکل (۸) ساختار یک GoogLeNet را نشان می‌دهد. مدل Inception-v3 به‌عنوان یک مدل پیشرفته از شبکه عصبی کانولوشن گوگل‌نت، نخستین بار توسط Szegedy و همکاران در سال ۲۰۱۵ معرفی گردید [۱۳].

۳-۶- معماری MobileNet-V2

یک شبکه CNN با ۵۳ لایه عمیق است. شبکه با سه لایه کانولوشن آغاز می‌شود که پس از آن ۱۶ لایه معکوس قرار دارند و با یک لایه کانولوشن و یک لایه به‌طور کامل متصل پایان می‌یابند. این نوع یادگیری می‌تواند آموزش شبکه‌ها را با در نظر گرفتن ورودی‌های لایه به‌عنوان مرجع آسان کند (شکل ۹). معماری کامل موبایل‌نت شامل یک لایه پیچش معمولی 3×3 به عنوان نخستین لایه و به دنبال آن مجموعه‌ای از بلاک‌ها می‌باشد و لایه آخر یک لایه کلی حداکثر تجمع^{۱۸} است [۱۶].

می‌شود. معماری AlexNet شامل پنج لایه کانولوشن و سه لایه به‌طور کامل متصل مطابق شکل (۳) است [۱۰].

۳-۲- معماری VGG 16


شبکه VGG^{۱۷} توسط محققانی از دانشگاه آکسفورد به‌عنوان یکی از موفق‌ترین شبکه‌های عصبی کانولوشنی که موفق به کسب رتبه بالایی در مسابقه ImageNet گردید، در سال ۲۰۱۵ معرفی شد [۱۱]. این ساختار CNN مانند معماری AlexNet از پنج بلوک کانولوشن و سه لایه به‌طور کامل متصل مطابق شکل (۴) تشکیل شده است.

۳-۳- معماری VGG 19

VGG19 نسخه عمیق‌تر با تعداد لایه بیشتر نسبت به VGG16 محسوب شده و از ۱۹ لایه شامل ۱۶ لایه کانولوشن و ۳ لایه به‌طور کامل متصل تشکیل شده است (شکل ۵).

۳-۴- معماری SqueezeNet

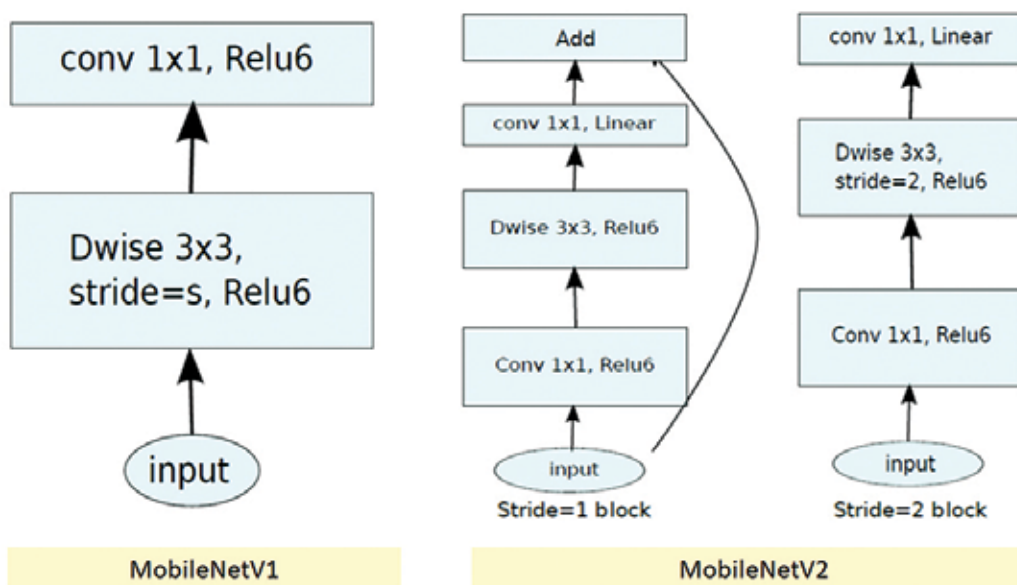
یک CNN فشرده با بیش از ۱۸ لایه قابل آموزش عمیق برای طبقه‌بندی تصاویر به ۱۰۰۰ کلاس مختلف است. شبکه با یک لایه کانولوشن مستقل آغاز می‌شود و با هشت ماژول آتش ادامه



شکل ۷: یک ماژول Inception-a3 از شبکه عصبی کانولوشن GoogLeNet [۱۵]



شکل ۸: مدل شبکه عصبی کانولوشن گوگلنت با ماژول‌های Inception به عنوان عمیق‌ترین CNN موجود [۱۵]



شکل ۹: معماری MobileNet-V1 در مقایسه با معماری MobileNet-V2 [۱۶]

تمامی انواع ResNet18، ResNet50، و ResNet101 نسخه‌هایی از ResNet هستند که بلوک باقیمانده خاص خود را دارند. ResNet18 با ۲۲ لایه عمیق است. با یک لایه کانولوشن آغاز می‌شود و با ۸ بلوک باقیمانده ادامه می‌یابد و با یک لایه به‌طور کامل متصل پایان می‌یابد. ResNet50 شامل ۵۰ لایه است و همین امر برای ResNet101 نیز صادق است که دارای ۱۰۱ لایه عمیق با ۳۳ بلوک باقیمانده است [۱۷].


۳-۸ معماری‌های Inception

Inception v1 همان GoogLeNet است در معماری‌های Inception v2-V3 از الگوریتم بچ نرمالیزیشن استفاده شده است و لایه‌های

۳-۷ معماری ResNet

در این شبکه در کنار لایه‌های مختلف، ارتباطات و اتصالاتی خارج از ساختار کانولوشن در نظر گرفته شده تا ورودی‌های لایه قبلی را بدون واسطه به لایه بعدی منتقل کند تا بتوان شبکه را عمیق‌تر کرد و آن را سریع‌تر آموزش داد. به این ارتباطات skip connections و به ساختار حاصل از آن Residual block می‌گویند. ایده اصلی یک بلاک residual این است که ورودی توسط یک لایه کانولوشن، لایه ReLU و یک لایه کانولوشن پردازش می‌شود. نتیجه این تبدیلات یک تابع $F(x)$ تولید می‌گردد و نتیجه این تابع با ورودی لایه قبل جمع می‌شود (شکل (۱۰)).


ResNet-50 Model Architecture




شکل ۱۰: معماری ResNet [۱۷]



(a) Inception v2



A simplified Inception module.



(b) Inception v3



(c) Inception v4

شکل ۱۱: معماری‌های Inception v2-v3-v4 [۱۸].

عمیق با عمق $1 \times (n \times n \times 1)$ و سپس با یک کانولوشن نقطه‌ای با طول و عرض $1 \times (n \times 1)$ (شکل ۱۲) مربوط به معماری Xception است اطلاعات از سه قسمت عبور می‌کنند که بخش میانی ۸ بار تکرار شده است. بعد از هر لایه depthwise یک لایه pointwise و batch normalization قرار گرفته است. (شکل ۱۲). در ماژول Xception هیچ تابع فعال‌ساز بین کانولوشن depthwise و pointwise وجود ندارد [۲۰].

۳-۱۱- معماری CNN + LSTM

LSTM یک شبکه عصبی مصنوعی است که می‌تواند وابستگی‌های طولانی‌مدت را یاد بگیرد تا بتواند کل توالی داده‌ها را پردازش کند. یک واحد LSTM مشترک از یک سلول، یک گیت ورودی، یک گیت فراموشی و یک گیت خروجی تشکیل شده است. گیت ورودی مشخص می‌کند که کدام اطلاعات باید وارد وضعیت سلول شوند. گیت فراموشی، مشخص می‌کند که کدام اطلاعات باید از حالات سلول قبلی حذف شوند تا فقط اطلاعات مربوطه را حفظ کنند. گیت خروجی مشخص می‌کند که چه مقدار از وضعیت داخلی باید در معرض لایه‌های بالاتر قرار گیرد. [21].

۳-۱۲- معماری EffNet

EffNet یک روش شبکه عصبی کانولوشنال و روش مقیاس‌گذاری است که از یک ضریب ترکیبی استفاده می‌کند تا عرض، عمق

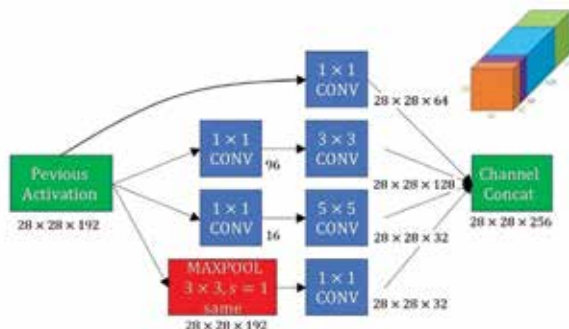
کانولوشن (5×5) با دو کانولوشن (3×3) جایگزین می‌شود (شکل ۱۱). این امر باعث افزایش سرعت و کاهش زمان، محاسبات می‌شود. این معماری فاکتورهای $(n \times n)$ را به فاکتورهای $(n \times 1)$ و $(1 \times n)$ تبدیل می‌کند تا پیچیدگی محاسبات کاهش یابد. Inception v4 ترکیبی از ماژول‌های Inception- v3 و معماری ResNet است [۱۸].

۳-۹- معماری‌های DenseNet


در این معماری هر لایه ورودی، از تمام لایه‌های قبلی به دست می‌آید و نقشه ویژگی‌های خاص خود را به همه موارد بعدی منتقل می‌کند. بین هر دو بلاک Dense لایه‌هایی به نام Transition وجود دارد که عملیات Pooling را انجام می‌دهد و سایز نگاشت ویژگی‌ها را کاهش می‌دهد (شکل ۱۲). می‌توان گفت DenseNet با برخی تفاوت‌ها به‌طور کامل شبیه ResNet است [۱۹].

۳-۱۰- معماری Xception

شبکه عصبی کانولوشن Xception مبتنی بر Inception است که ماژول‌های آن با کانولوشن کانال‌های تفکیک‌پذیر جایگزین می‌شوند. کانولوشن کانال‌های تفکیک‌پذیر یک نتیجه‌گیری ۳ بعدی استاندارد را به دو عمل جابه‌جایی جداگانه تبدیل می‌کند که از نظر محاسباتی کارآمدتر هستند: نخست یک کانولوشن



شکل ۱۳: معماری شبکه عصبی عمیق Xception [۲۰].




شکل ۱۴: یک معماری DenseNet با پنج لایه، هر لایه ویژگی‌های تمامی لایه‌های قبلی را دریافت می‌کند [۱۹].

فعال‌ساز Relu است نقش اصلی این لایه استخراج ویژگی‌های محلی^{۲۳} از پیکسل‌های تصاویر ورودی و انتقال آنها به کپسول می‌باشد. کپسول‌ها در لایه دوم با عنوان PrimaryCaps شناخته می‌شود که این لایه از ۳۲ واحد کپسول تشکیل شده که هر کدام از این واحدها خروجی لایه Conv1 که یک تنسور ویژگی با ابعاد [۲۵۶, ۲۰, ۲۰] را دریافت و یک عملیات کانولوشن دو بعدی بر روی این تنسور انجام می‌دهد (اندازه فیلتر ۹ در ۹ و طول گام ۲ است) و خروجی با ابعاد [۸, ۶, ۶] را تولید می‌کند. خروجی‌های لایه PrimaryCaps قبل از انتقال به لایه بعد فشرده می‌شوند. در این معماری از تابع Squash به‌عنوان تابع فعال‌ساز استفاده شده است. لایه DigitCaps از ۱۰ کپسول ۱۶ بعدی تشکیل شده است. اگر بخواهیم این لایه را با یک لایه به‌طور کامل متصل در شبکه‌های معمولی با نرون‌های اسکالر مقایسه کنیم، لایه DigitCaps را می‌توان یک شبکه عصبی به‌طور کامل متصل با خروجی از نرون‌های ۱۶ بعدی در نظر گرفت که این نرون‌ها همان کپسول می‌باشد. در این لایه ورودی [۸, ۱۱۵۲] دریافت می‌شود و به ۱۰ کپسول ارسال می‌گردد [۲۴].

نقشه ویژگی پردازش شده از لایه global average pooling و لایه‌های متراکم پیوسته عبور می‌کند. تابع Relu بعد از هر کانولوشن برای فعال‌سازی غیرخطی استفاده می‌شود ConvNet قادر است به‌طور موفق و وابستگی‌های زمانی و فضایی را در یک تصویر با استفاده از فیلترهای مرتبط ثبت کند و همچنین، معماری فیلترگذاری بهتری را روی مجموعه داده تصویر به دلیل کاهش تعداد پارامترهای درگیر و استفاده دوباره از وزن‌ها انجام می‌دهد. به بیان دیگر، شبکه می‌تواند برای درک تصاویر پیچیده به‌طور بهتری آموزش ببیند [۲۴].

۳-۱۵- معماری Net CovX

واحدهای باقیمانده^{۲۳} و شیفت‌دهنده^{۲۴} اصلی‌ترین بلاک‌های معماری CovXNet می‌باشند (شکل (۱۸)). در مرحله نخست، تصویر ورودی با هسته‌های^{۲۵} پردازش می‌شود. سپس تصویر از مجموعه واحدهای باقیمانده عبور می‌کند. واحدهای شیفت‌دهنده تغییرات ابعادی را برای تعمیم بیشتر اطلاعات استخراج شده معرفی می‌کند. نقشه ویژگی پردازش شده از لایه global average pooling و لایه‌های متراکم پیوسته عبور می‌کند. تابع Relu بعد از هر کانولوشن برای فعال‌سازی غیر خطی این معماری استفاده می‌شود. این شبکه توانایی آموزش برای درک تصاویر پیچیده را دارد [۲۵].



شکل ۱۴: معماری CNN + LSTM [۲۱].


و وضوح شبکه را به‌صورت اصولی مقیاس‌بندی کند. روش مقیاس‌گذاری EfficNet به‌طور یکنواخت عرض، عمق و وضوح شبکه را با مجموعه‌ای از ضرایب ثابت مقیاس‌بندی می‌کند. به‌عنوان مثال، اگر بخواهیم منابع محاسباتی 2^N برابر بیشتر استفاده کنیم، بنابراین می‌توانیم عمق شبکه را با α^N ، عرض توسط β^N و اندازه تصویر را توسط γ^N افزایش دهیم، که α ، β ، γ ضرایب ثابت هستند. روش مقیاس‌بندی مرکب با این بینش توجیه می‌شود اگر تصویر ورودی بزرگتر باشد، شبکه به لایه‌های بیشتری برای افزایش زمینه پذیرش و کانال‌های بیشتری برای جذب الگوهای ریزساختار در تصویر بزرگتر نیاز دارد. پایه شبکه EfficientNet-B بر اساس بلوک‌های باقی‌مانده گلوگاه معکوس است در حالی که پایه شبکه MobileNetV2 براساس اضافه شدن بلوک‌های squeeze و excitation است [۲۲].

۳-۱۳- معماری Dark Covid net

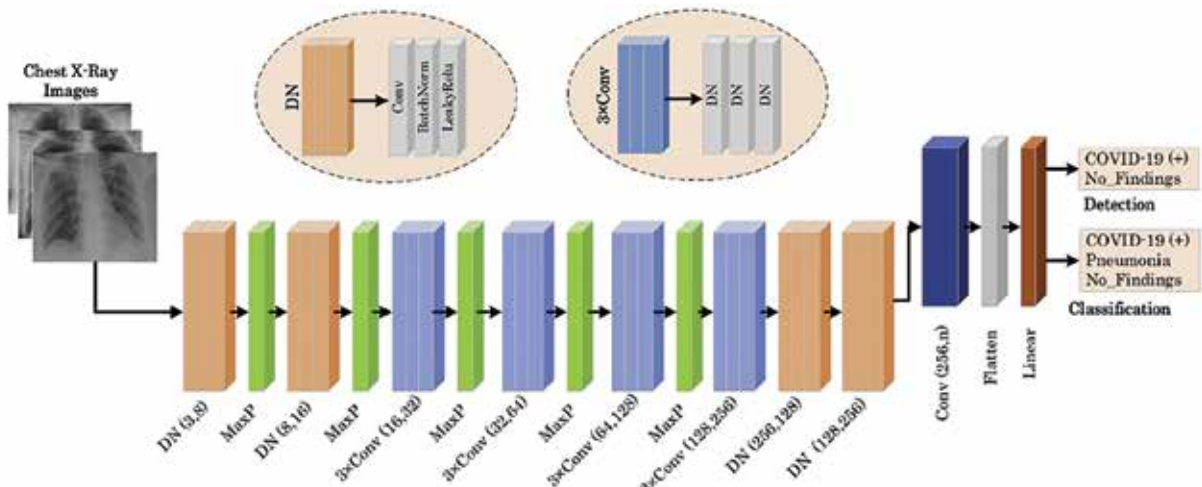
شبکه Dark Covid net مطابق شکل (۱۸)، دارای ۱۷ لایه کانولوشن است. لایه 2^N دارای یک لایه کانولوشنی، یک لایه نرمال‌سازی دسته‌ای^{۲۱} و تابع عملیاتی LeakyReLU است که سه بار به‌صورت متوالی راه‌اندازی می‌شود. از لایه نرمال‌سازی دسته‌ای برای استاندارد شدن ورودی، کاهش زمان آموزش و افزایش پایداری شبکه استفاده می‌شود مدل پیشنهادی وظیفه تشخیص کرونا را انجام می‌دهد. اگر سه مورد متفاوت باشد کلاسه‌بندی تصاویر در ورودی استفاده می‌شوند، این کلاس‌بندی تعیین برچسب‌های تصاویر اشعه ایکس ورودی قفسه سینه به‌عنوان Covid-19، Pneumonia یا rate-Findings-No را انجام می‌دهد [۲۳].

۳-۱۴- معماری Caps net

معماری Caps net از سه لایه Conv1، Caps Primry و DigitCaps تشکیل شده است (شکل (۱۸)). Conv1 یک لایه کانولوشن معمولی دو بعدی با فیلترهای 9×9 ، طول گام ۲، عمق ۲۵۶ و تابع




شکل ۱۵: معماری EfficNet (a)، شبکه پایه است (b-c) مقیاس‌بندی کانولوشنی، با افزایش وضوح در یک بعد از عرض، عمق یا وضوح شبکه را افزایش می‌دهد. روش مقیاس‌بندی مرکب است که به‌طور یکنواخت هر سه بعد را با یک نسبت ثابت مقیاس‌بندی می‌کند [۲۲]. (d-e)



شکل ۱۶: معماری Dark COVID-19 net [۲۳]

جدول ۱: معیارهای ارزیابی عملکرد روش‌های دسته‌بندی داده [۲۷]

رابطه	معیار ارزیابی
$\frac{TP + TN}{P + N}$	دقت (ACC)
$\frac{TP}{TP + FP}$	قابلیت پیش‌بینی یا صحت (Sp)
$\frac{TP}{TP + FN}$	حساسیت (Se)
$\frac{2TP}{2TP + FP + FN}$	میانگین معیار رتبه (F1 (AvF1))



شکل ۱۷: معماری Caps net [۲۴]


۱۶-۳- معماری Covid-Net

Covid-Net براساس ساختار ریزمعماری^{۲۶} طراحی شده است و عمده‌تاز لایه‌های کانولوشن 1×1 و لایه‌های کانولوشن depth-wise تشکیل شده است. استفاده از الگوی (PEPX)^{۲۷}، بازدهی عملکرد را بهتر می‌کند و همچنین حساسیت و پیش‌بینی مثبت (PPV^{۲۸}) به Covid-19 را افزایش می‌دهد. این مدل شامل اتصال long-range است که این اتصال پیچیدگی محاسبات را کاهش می‌دهد و آموزش را آسان‌تر می‌کند [۲۶].

۴- بکارگیری معماری‌های مختلف CNN در تشخیص کووید-۱۹

تحقیقات زیادی در خصوص استفاده از CNNها برای تشخیص بیماری‌های تنفسی مختلف با استفاده از تصاویر CXR ساده انجام شده است. در ادامه به بررسی برخی از آخرین دستاوردهای به‌کارگیری این روش‌های مبتنی بر یادگیری عمیق در مقالات پرداخته می‌شود. تحقیقات در این حوزه از به‌کارگیری یک معماری ساده تا ترکیبی از دو یا چند معماری متفاوت است.


معیارهای ارزیابی عملکرد الگوریتم‌های غربالگری کرونا مانند بسیاری از روش‌های دسته‌بندی و غربالگری به‌طور معمول شامل دقت^{۲۹}، قابلیت پیش‌بینی^{۳۰} یا صحت^{۳۱}، حساسیت^{۳۲} و معیار امتیاز یا رتبه F1 می‌باشند. با توجه به نتایج این معیارها می‌توان در مورد عملکرد الگوریتم‌ها و ساختارهای پیشنهادی رایج شده بحث نمود. برای توضیح این چهار معیار باید ابتدا اجزای مورد استفاده برای محاسبه آن‌ها بررسی شوند. این اجزا شامل چهار مورد مثبت درست^{۳۳} (TP) یعنی آن دسته از نمونه‌هایی که دارای بیماری کووید-۱۹ بوده و به درستی تشخیص داده شده و به عنوان بیمار دسته‌بندی شده‌اند، مثبت نادرست^{۳۴} (FP) اشاره به آن دسته از تصاویر سی‌تی‌اسکن دارد که بیمار کرونا بوده و به اشتباه در دسته غیرکروناها قرار گرفته‌اند، منفی درست^{۳۵} (TN) اشاره



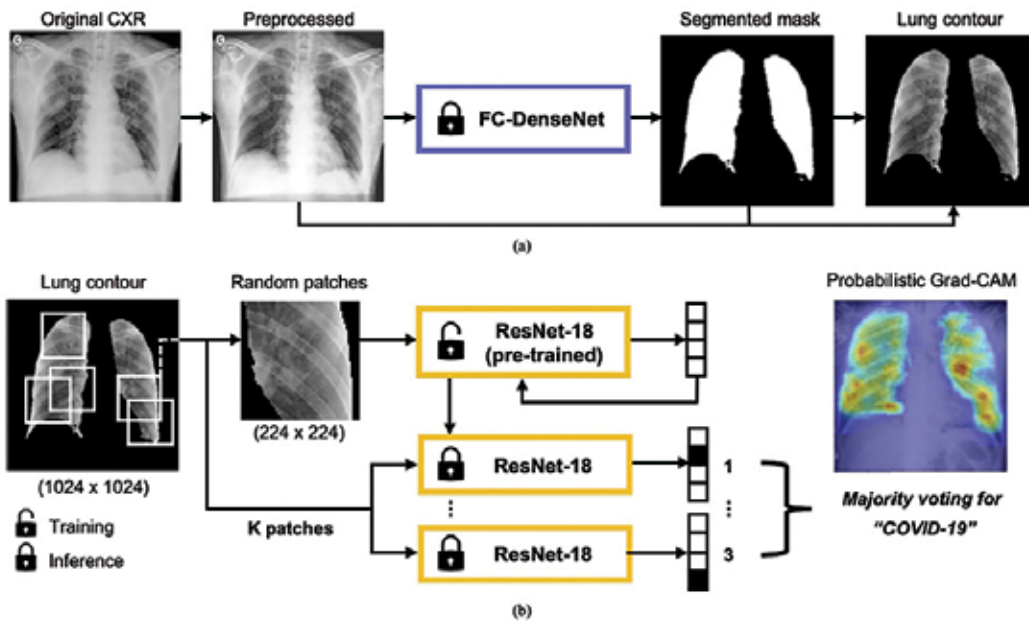
شکل ۱۸: معماری Net CovX [۲۵]

جدول ۲: دسته‌بندی مقالات حوزه غربالگری کرونا با معماری‌های مختلف CNN، تعداد تصاویر بکارگیری شده و معیار دقت بدست‌آمده [۲۷]

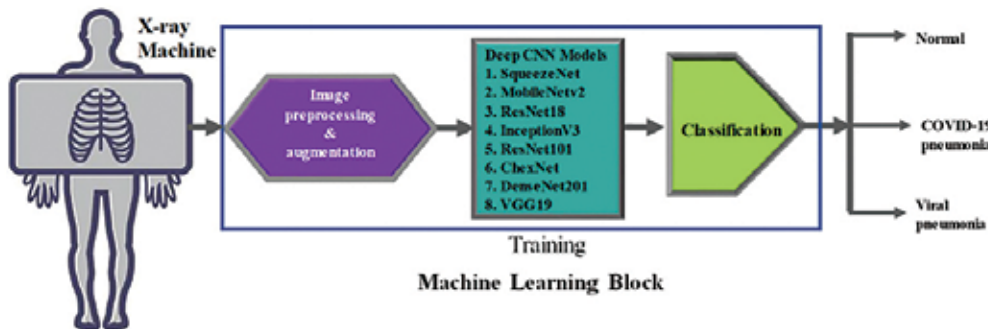
شماره مرجع	معیار عملکرد	تعداد تصاویر بانک اطلاعات تصاویر			نوع معماری CNN	ردیف
		نرمال	سرماخوردگی	کرونا		
[۲۸]	ACC=%۹۸	-	۵۰	۵۰	InceptionV3 InceptionResNetV2 ResNet50	۱
[۲۹]	AvF1=۰,۹۰	-	۵۰	۲۵	VGG19 Dense Net	۲
[۳۰]	ACC=%۹۳,۳	۵۵۳۸	۸۰۶۶	۳۵۸	Covid-Net ResNet50 VGG19	۳
[۳۱]	Se=%۹۶ Sp=%۷۰	-	۱۴۳۱	۱۰۰	Efficient Net	۴
[۳۲]	ACC=%۹۹	۱۵۲۵	۱۵۲۵	۱۵۲۵	CNN + LSTM	۵
[۳۳]	ACC=%۱۰۰	۱۳۲	۱۳۲	۱۳۲	VGG16	۶
[۳۴]	ACC=%۹۷	۵۰۰	۵۰۰	۱۲۷	Xception	۷
[۳۵]	ACC=%۸۷	۵۰۰	۵۰۰	۱۲۷	Dark net	۸
[۳۶]	ACC=%۹۳	۶۵۷	۳۱۰	۲۹۰	Xception	۹
[۳۷]	Se=%۹۸ Sp=%۹۲,۹	۲۶۰۰	۲۴۰۰	۱۸۴	ResNet18 ResNet50 Squeeze Net DenseNet121	۱۰
[۳۸]	ACC=%۹۴	۷۰۰	۵۰۴	۲۲۴	VGG19 MobileNetV2 Inception Xception Inception ResNetV2	۱۱
[۳۹]	ACC=%۹۹	۴۶۵۰	۲۰۰۳	۱۶۲	Inception	۱۲
[۴۰]	ACC=%۹۹	۹۸	۶۵	۲۹۵	MobileNetV2 Squeeze Net	۱۳
[۴۱]	ACC=%۹۵	-	۱۱۲۴	۴۰۳	VGG16	۱۴
[۴۲]	ACC=%۹۹	۱۵۸	۷۹	۶۹	Alex net Google net ResNet18	۱۵
[۴۳]	ACC=%۸۴	۱۰۵۰	۱۰۵۰	۲۳۱	Caps net	۱۶
[۴۴]	ACC=%۹۰,۲	۶۱۰	۳۰۵	۳۰۵	Covx Net	۱۷
[۴۵]	ACC=%۸۹	۱۳۱	۱۹۱	۱۸۰	ResNet18	۱۸
[۴۶]	ACC=%۹۹	۱۳۴۵	۱۳۴۱	۲۱۹	Efficient Net-B	۱۹
[۴۷]	AvF1=۰,۶۵	۶۸۷	۱۰۰۰	۹۰	Inception-V3	۲۰
[۴۸]	ACC=%۹۷	۲۷۵۳	۳۵۲۵	۲۵۰	VGG16	۲۱
[۴۹]	ACC=%۹۹,۷	۱۵۷۹	۱۴۸۵	۴۲۳	SqueezeNet MobileNet, ResNet18 InceptionV3 ResNet10, ChexNet, DenseNet201, VGG19	۲۲



شکل (۱۹): معماری Covid-Net [۲۶]



شکل ۲۰: باارگیری دو معماری ResNet18 و DenseNet در تشخیص کرونا بر اساس بانک اطلاعات تصاویر ۳۰۵ فرد مبتلا به کرونا [۴۴]



شکل ۲۱: باارگیری ترکیبی معماری‌های VGG19 و SqueezeNet, MobileNet, ResNet18, InceptionV3, ResNet10, ChexNet, DenseNet201 در تشخیص کرونا بر اساس بانک اطلاعات تصاویر ۴۲۳ فرد مبتلا به کرونا [۵۰]

جدول ۳: خلاصه ای از مجموعه تصاویر Covid-19 در پایگاه های اطلاعات [۵۱].

نام	تعداد	فرمت تصاویر	کشور	لینک تصاویر
AIforCOVID imaging archive	983 patients	DICOM	Italy	https://aiforcovid.radiomica.it
MosMed COVID-19 Chest CT database	patients 1110	NIfTI	Russia	https://mosmed.ai/datasets/covid19_1110
MosMed COVID-19 Chest CT database	patients 1110	NIfTI	Russia	https://mosmed.ai/datasets/covid19_1110
SIRM database	68 patients	JPG	Italy	https://www.sirm.org/en/category/articles/covid-19-database
Radiopaedia database	101 patients	JPG	Global	https://radiopaedia.org/articles/covid-19-3
BSTI COVID-19 database	59 patients	online only	UK	https://bit.ly/BSTICovid19_Teaching_Library
UCSD COVID-CT database	349 images from 216 patients	PNG	Global	https://github.com/UCSD-AI4H/COVID-CT
Coronacases.org	10 patients	online only	China	https://coronacases.org
Eurorad database	50 patients	JPG	Global	https://www.eurorad.org/advanced-search?search=COVID
CT machine learning dataset	930 images from 461 patients, 20 volumes	JPG, NIfTI	Global	https://github.com/ieee8023/covid-chestxray-dataset
CT segmentation dataset 1	100 images from 40 patients	NIfTI	Italy	http://medicalsegmentation.com/covid19
CT segmentation dataset 2	800 slices from 9 patients	NIfTI	Global	http://medicalsegmentation.com/covid19
CT segmentation dataset 3	20 cases	NIfTI	Global	https://zenodo.org/record/3757476

موفقی از دو معماری ResNet18 و DenseNet را در تشخیص کرونا بر اساس بانک اطلاعات تصاویر شامل ۳۰۵ فرد مبتلا به کرونا نشان می‌دهد بر اساس ردیف ۱۷ جدول (۲) دقت در این روش به بیش از ۹۰ درصد رسیده است [۴۴]. تصویر شماره (۲۱) ترکیب کاملی از معماری‌های In-ResNet18, MobileNet, SqueezeNet, ceptionV3, ResNet10, ChexNet, DenseNet201, و VGG19 را در تشخیص کرونا بر اساس بانک اطلاعات با ۴۲۳ تصویر افراد مبتلا به کرونا نشان می‌دهد [۵۰]. بر اساس اطلاعات ردیف ۲۲ جدول (۲)، دقت به‌دست آمده در این ترکیب به بیش از ۹۹ درصد رسیده است.

جدول (۳) خلاصه‌ای از مجموعه داده‌های، تصویربرداری Covid-19 را ارائه می‌دهد. از این پایگاه‌ها برای تشخیص در رادیولوژی، آموزش، تحقیق و همچنین برای توسعه ابزارهای هوش مصنوعی

به نمونه‌هایی دارد که کرونا نداشته و به درستی در دسته غیر کرونایی‌ها طبقه‌بندی شده‌اند و در نهایت منفی نادرست (FN) ^{۴۶} اشاره به نمونه‌هایی دارد که غیر کرونا بوده و به اشتباه کرونایی کلاسه‌بندی شده‌اند [۲۴]. با توجه به توضیحات مطرح شده روابط ارزیابی عملکرد سیستم در جدول (۱) تعریف می‌گردد. در این جدول، P+N نشان‌دهنده‌ی تمام نمونه‌ها می‌باشد.

جدول (۲) خلاصه‌ای از مهم‌ترین مقالاتی که به بررسی و تشخیص خودکار کرونا بر اساس تصاویر CXR و یادگیری عمیق پرداخته‌اند، را نشان می‌دهد [۲۷]. معیارهای ارزیابی در این دسته از مقالات بر اساس جدول (۱) در بهترین شرایط عملکردی گزارش شده‌اند. در ادامه دو نمونه از تحقیقات ترکیبی که از تلفیق چند معماری مختلف برای تشخیص دقیق‌تر کووید-۱۹ استفاده نموده‌اند در شکل‌های (۲۰) و (۲۱) نشان داده شده است. شکل (۲۰) تلفیق

- 31 Accuracy
- 32 Predictive value
- 33 Precision
- 34 Sensitivity
- 35 True Positive (TP)
- 36 False Positive (FP)
- 37 True Negative (TN)
- 38 False Negative (FN)

۵- نتیجه گیری

بیماری کرونا در حال حاضر یکی از شایع‌ترین بیماری‌های ویروسی در سراسر جهان است که تسهیل و تسریع تشخیص آن نتایج بسیار مطلوبی بر روند درمان و غربالگری بیماران در جامعه خواهد داشت. استخراج ویژگی‌های تصاویر X-ray با به‌کارگیری شبکه‌های متعدد مبتنی بر شبکه‌های عصبی کانولوشن (CNN) مانند گوگل‌نت، وی جی جی، الکسنت، کویدنت و ... در تشخیص بیماری کرونا بسیار توانمندتر از آزمایش متداول (R.TPCR) reaction chain polymerase transcription Reverse است. با توجه به نتایج مقالات حوزه غربالگری کرونا، معیارهای ارزیابی Accuracy، میانگین معیار رتبه F1 (AvF1)، قابلیت پیش‌بینی یا صحت (Sp) و حساسیت (Se) با بهترین مقادیر به ترتیب برابر با ۱۰۰٪، ۹۰٪، ۹۶٪ و ۹۲٪ می‌باشد که نتایج به‌دست آمده حاکی از آن است که تکنیک‌های یادگیری ماشین در تشخیص بیماری کرونا بسیار موفق است.

اما نیاز به تصاویر پزشکی و توسعه بانک‌های اطلاعات تصاویر در شبکه‌های عصبی کانولوشن همواره یک چالش محسوب می‌گردد. زیرا تهیه تصاویر پزشکی از بیماران مختلف، فرایندی زمان‌بر و هزینه‌بر بوده و مشکلی جدی در کاربرد الگوریتم‌های یادگیری عمیق برای طبقه‌بندی تصاویر پزشکی محسوب می‌گردد.

پی‌نوشت‌ها

- مراجع
- [1] I. Khan, Z. Ahmed, A. Sarwar, A. Jamil, and F. Anwer, "The Potential Vaccine Component for COVID-19: A Comprehensive Review of Global Vaccine Development Efforts," *Cureus*, vol. 12, no. 6, 2020.
 - [2] H. A. Rothan and S. N. Byrareddy, "The epidemiology and pathogenesis of coronavirus disease (COVID-19) outbreak," *Journal of autoimmunity*, vol. 109, p. 102433, 2020.
 - [3] M. Keshavarz, M. Karbalaie Niya, A. Tavakoli, H. Keyvani, and A. Kachooei Mohagheghi Yaghubi, "A review on different types of Real-time PCR methods and its optimization," *Journal of Inflammatory Disease*, vol. 21, no. 3, pp. 90-76, 2017.
 - [4] F. Ucar and D. Korkmaz, "COVIDiagnosis-Net: Deep Bayes-SqueezeNet based diagnosis of the coronavirus disease 2019 (COVID-19) from X-ray images," *Medical Hypotheses*, vol. 140, p. 109761, 2020.
 - [5] B. S. Tan et al., "Rsn international trends: A global perspective on the covid-19 pandemic and radiology in late 2020," *Radiology*, vol. 299, no. 1, pp. E193-E203, 2021.
 - [6] Y. Fang et al., "Sensitivity of chest CT for COVID-19: comparison to RT-PCR," *Radiology*, vol. 296, no. 2, pp. E115-E117, 2020.
 - [7] M. Yu et al., "Thin-section chest CT imaging of COVID-19 pneumonia: a comparison between patients with mild and severe disease," *Radiology: Cardiothoracic Imaging*, vol. 2, no. 2, p. e200126, 2020.
 - [8] Y. LeCun, Y. Bengio, and G. Hinton, "Deep learning," *ACM*, vol. 54, no. 10, pp. 95-103, 2011.
 - [9] C. Farabet, C. Couprie, L. Najman, and Y. LeCun, "Learning hierarchical features for scene labeling," *IEEE Trans. Pattern Anal. Mach. Intell.* 35, 1915-1929 (2013).
 - [10] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "ImageNet classification with deep convolutional neural networks," *Communications of the ACM*, vol. 60, no. 6, pp. 84-90, 2017.
 - [11] K. Simonyan and A. Zisserman, "Very deep convolutional networks for large-scale image recognition," *arXiv preprint arXiv:1409.1556*, 2014
 - [12] J. Xiao, J. Wang, Sh. Cao, and B. Li1, "Application of a Novel and Improved VGG-19 Network in the Detection of Workers Wearing Masks," *Journal of Physics: Conference Series*, 1518, p.012041.2020
 - [13] T. H. B. Nguyen, E. Park, X. Cui, V. H. Nguyen, and H. Kim, "fPADnet: small and efficient convolutional neural network for presentation attack detection," *Sensors*, vol. 18, no. 8, p. 2532, 2018.
 - [14] F. N. Iandola, S. Han, M. W. Moskewicz, K. Ashraf, W. J. Dally, and K. Keutzer, "SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and < 0.5 MB model size," *arXiv preprint arXiv:1602.07360*, 2016.
 - [15] C. Szegedy et al., "Going deeper with convolutions," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2015, pp. 1-9.
 - [16] M. Sandler, A. Howard, M. Zhu, and A. Zhmoginov, "Mobilenet2: inverted residuals and linear bottlenecks", in: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 4510-4520. 20

- 1 Covid-19
- 2 Severe Acute Respiratory Syndrome (SARS)
- 3 Middle East Respiratory Syndrome (MERS)
- 4 Acute Respiratory Distress Syndrome (ARDS)
- 5 Angiotensin Converting Enzyme 2 (ACE2)
- 6 Reverse-transcription polymerase chain reaction (RT-PCR)
- 7 Computerized Tomography
- 8 Ground-glass opacity (GGO)
- 9 interstitial changes (with peripheral distribution)
- 10 Ground-glass opacity (GGO)
- 11 Multifocal patchy consolidation
- 12 interstitial changes (with peripheral distribution)
- 13 Ground-glass opacity (GGO)
- 14 Multifocal patchy consolidation
- 15 Interstitial changes with peripheral distribution
- 16 Convolutional neural network (CNN)
- 17 Visual Cortex 6-Feature
- 18 VGG Deep Neural Network
- 19 Global Max Pooling
- 20 feature map
- 21 Depthwise Separable Convolutional Neural Network
- 22 DarkNet
- 23 Batch normalization
- 24 Local
- 25 Residual units
- 26 shifter unit
- 27 kernels
- 28 micro-architecture
- 29 projection-expansion-projection
- 30 Positive Predictive Value

- 18
- [35] T. Ozturk, M. Talo, E. A. Yildirim, U. B. Baloglu, O. Yildirim, and U. Rajendra Acharya, "Automated detection of COVID-19 cases using deep neural networks with X-ray images," *Computers in Biology and Medicine*, vol. 121, 2020
- [36] A. I. Khan, J. L. Shah, and M. M. Bhat, "CoroNet: A deep neural network for detection and diagnosis of COVID-19 from chest x-ray images," *Computer Methods and Programs in Biomedicine*, vol. 196, p. 105581, 2020.
- [37] S. Minaee, R. Kafieh, M. Sonka, S. Yazdani, and G. J. Soufi, "Deep-covid: Predicting covid-19 from chest x-ray images using deep transfer learning," *Medical image analysis*, vol. 65, p. 101794, 2020.
- [38] 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.
- [39] D. Das, K. Santosh, and U. Pal, "Truncated inception net: COVID-19 outbreak screening using chest X-rays," *Physical and engineering sciences in medicine*, vol. 43, no. 3, pp. 915-925, 2020.
- [40] M. Toğaçar, B. Ergen, and Z. Cömert, "COVID-19 detection using deep learning models to exploit Social Mimic Optimization and structured chest X-ray images using fuzzy color and stacking approaches," *Computers in biology and medicine*, vol. 121, p. 103805, 2020.
- [41] A. Waheed, M. Goyal, D. Gupta, A. Khanna, F. Al-Turjman, and P. R. Pinheiro, "Covidgan: data augmentation using auxiliary classifier gan for improved covid-19 detection," *IEEE Access*, vol. 8, pp. 91916-91923, 2020.
- [42] M. Loey, F. Smarandache, and N. E. M. Khalifa, "Within the lack of chest COVID-19 X-ray dataset: a novel detection model based on GAN and deep transfer learning," *Symmetry*, vol. 12, no. 4, p. 651, 2020.
- [43] S. Toraman, T. B. Alakus, and I. Turkoglu, "Convolutional capsule net: A novel artificial neural network approach to detect COVID-19 disease from X-ray images using capsule networks," *Chaos, Solitons & Fractals*, vol. 140, p. 110122, 2020.
- [44] T. Mahmud, M. A. Rahman, and S. A. Fattah, "CovXNet: A multidilation convolutional neural network for automatic COVID-19 and other pneumonia detection from chest X-ray images with transferable multireceptive feature optimization," *Computers in Biology and Medicine*, vol. 122, 2020
- [45] Y. Oh, S. Park, and J. C. Ye, "Deep learning covid-19 features on cxr using limited training data sets," *IEEE Transactions on Medical Imaging*, vol. 39, no. 8, pp. 2688-2700, 2020.
- [46] A. Altan and S. Karasu, "Recognition of COVID-19 disease from X-ray images by hybrid model consisting of 2D curvelet transform, chaotic salp swarm algorithm and deep learning technique," *Chaos, Solitons & Fractals*, vol. 140, p. 110071, 2020.
- [47] R. M. Pereira, D. Bertolini, L. O. Teixeira, C. N. Silla Jr, and Y. M. Costa, "COVID-19 identification in chest X-ray images on flat and hierarchical classification scenarios," *Computer Methods and Programs in Biomedicine*, vol. 194, p. 105532, 2020.
- [48] L. Brunese, F. Mercaldo, A. Reginelli, and A. Santone, "Explainable deep learning for pulmonary disease and coronavirus COVID-19 detection from X-rays," *Computer Methods and Programs in Biomedicine*, vol. 196, p. 105608, 2020.
- [49] S. H. Yoo et al., "Deep learning-based decision-tree classifier for COVID-19 diagnosis from chest X-ray imaging," *Frontiers in medicine*, vol. 7, p. 427, 2020.
- [50] M. E. Chowdhury et al., "Can AI help in screening viral and COVID-19 pneumonia?," *IEEE Access*, vol. 8, pp. 132665-132676, 2020.
- [51] <https://www.eibir.org/covid-19-imaging-datasets>
- [17] K. He, X. Zhang, Sh. Ren, and J. Sun Microsoft Research, "Deep Residual Learning for Image Recognition," in: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 770-778. 2016
- [18] C. Szegedy, S. Ioffe, V. Vanhoucke, and A. Alexander, "Inception-v4, Inception-Res Net and the Impact of Residual Connections on Learning," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2018, pp. 4510-4520
- [19] G. Huang, Z. Liu, L. Van Der Maaten, and K. Q. Weinberger, "Densely connected convolutional networks," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2017, pp. 4700-4708.
- [20] F. Chollet, "Xception: Deep learning with depthwise separable convolutions," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2017, pp. 1251-1258.
- [21] F. Shahid, A. Zameer, and M. Muneeb, "Predictions for COVID-19 with deep learning models of LSTM, GRU and BiLSTM," *Chaos, Solitons & Fractals*, vol. 140, p. 110212, 2020.
- [22] T. Mingxing, V. LeQuoc, "EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks," *Proceedings of the 36th International Conference on Machine Learning*, Long Beach, California, PMLR 97, 2019
- [23] T. Ozturk, M. Talo, E. A. Yildirim, U. B. Baloglu, O. Yildirim, and U. R. Acharya, "Automated detection of COVID-19 cases using deep neural networks with X-ray images," *Computers in biology and medicine*, vol. 121, p. 103792, 2020.
- [24] T. Vijayakumar, "Comparative study of capsule neural network in various applications," *Journal of Artificial Intelligence*, vol. 1, no. 01, pp. 19-27, 2019.
- [25] T. Mahmud, M. A. Rahman, and S. A. Fattah, "CovXNet: A multi-dilation convolutional neural network for automatic COVID-19 and other pneumonia detection from chest X-ray images with transferable multi-receptive feature optimization," *Computers in biology and medicine*, vol. 122, p. 103869, 2020.
- [26] L. Wang, Z. Q. Lin, and A. Wong, "Covid-net: A tailored deep convolutional neural network design for detection of covid-19 cases from chest x-ray images," *Scientific Reports*, pp. 1-14, 2021.
- [27] J. D. Arias-Londoño, J. A. Gomez-Garcia, L. Moro-Velázquez, and J. I. Godino-Llorente, "Artificial Intelligence applied to chest X-Ray images for the automatic detection of COVID-19. A thoughtful evaluation approach," *IEEE Access*, 2020.
- [28] 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.
- [29] E. E.-D. Hemdan, M. A. Shouman, and M. E. Karar, "Covidxnet: A framework of deep learning classifiers to diagnose covid-19 in x-ray images," *arXiv preprint arXiv:2003.11055*, 2020.
- [30] L. Wang, Z. Q. Lin, and A. Wong, "Covid-net: A tailored deep convolutional neural network design for detection of covid-19 cases from chest radiography images," *Scientific Reports*, vol. 10, no. 19549, 2020.
- [31] J. Zhang, Y. Xie, Y. Li, C. Shen, and Y. Xia, "Covid-19 screening on chest x-ray images using deep learning based anomaly detection," *arXiv preprint arXiv:2003.12338*, vol. 27, 2020.
- [32] M. Z. Islam, M. M. Islam, and A. Asraf, "A combined deep CNN-LSTM network for the detection of novel coronavirus (COVID-19) using X-ray images," *Informatics in medicine unlocked*, vol. 20, p. 100412, 2020.
- [33] J. Civit-Masot, F. Luna-Perejón, M. Domínguez Morales, and A. Civit, "Deep learning system for COVID-19 diagnosis aid using X-ray pulmonary images," *Applied Sciences*, vol. 10, no. 13, p. 4640, 2020.
- [34] N. N. Das, N. Kumar, M. Kaur, V. Kumar, and D. Singh, "Automated deep transfer learning-based approach for detection of COVID-19 infection in chest X-rays," *Irbm*, 2020.
