

تشخیص کووید-۱۹ مبتنی بر یادگیری انتقالی متخاصم چند منبعی و تابع خطای مرکزی

هادی الحارس^۱، جعفر تنها^۲ و محمدعلی بالافرا^۲

چکیده

در سال‌های اخیر، از تکنیک‌های یادگیری عمیق به‌وفور برای تشخیص کووید با استفاده از تصاویر پزشکی استفاده می‌شود. با این حال در تشخیص بیماری کووید ۱۹ به دلیل داده‌های ناکافی، آموزش مدل به‌درستی انجام نمی‌شود و در نتیجه‌ی آن تعمیم‌پذیری مدل کاهش می‌یابد. برای پرداختن به این مسئله، می‌توان داده‌های چندین منبع مختلف را با استفاده از یادگیری انتقالی ترکیب کرد. در این مقاله برای بهبود کیفیت انتقال بین چند منبع داده، ما یک مدل یادگیری انتقالی متخاصم چند منبعی را پیشنهاد می‌کنیم. در این روش شبکه هم‌زمان با تلاش برای دسته‌بندی صحیح داده‌ها، سعی در هر چه شبیه‌تر ساختن ویژگی‌های مجموعه داده‌ی مبدأ و مقصد به یکدیگر را دارد تا نتایج یکسانی از نظر کمی و کیفی حاصل شود. همچنین در روش پیشنهادی از تابع خطای مرکزی برای آموزش مدل استفاده می‌کنیم. استفاده از تابع خطای مرکزی به تمییز هرچه بهتر کلاس‌ها از یکدیگر کمک شایانی می‌کند. ارزیابی روش پیشنهادی با بررسی سناریوهای مختلف انتقال با دو مجموعه داده SARS-CoV-2 CT Scan و COVID19-CT با تعداد محدود تصاویر انجام گرفته و با نتایج سایر الگوریتم‌های موفق مقایسه می‌شود. روش پیشنهادی به‌ازای معیارهای accuracy، precision، recall و F1 به بهبود ۲، ۱۵، ۱۵ و ۸ درصدی نسبت به بهترین نتایج سایر روش‌های مقایسه شده، دست یافته است. کد پیاده‌سازی روش پیشنهادی در آدرس گیت‌هاب زیر در دسترس است:

<https://github.com/HadiAlhares/Covid19>

کلیدواژه‌ها

تشخیص بیماری، تشخیص COVID-19، یادگیری عمیق، تطبیق دامنه متخاصم چند منبعی

۱- مقدمه

اول ژوئن ۲۰۲۱ قریب به ۱۷۲ میلیون نفر در سراسر جهان به طور قطعی به این بیماری مبتلا شده و بیش از ۳ میلیون و ۷۰۰ هزار نفر رسماً بر اثر کرونا ویروس جان باخته‌اند. تشخیص سریع با قابلیت اطمینان بالای ویروس کووید در مراحل ابتدایی از اهمیت بسیار بالایی برخوردار است. رایج‌ترین روش برای تشخیص این ویروس، آزمایش RT-PCR است. برخی مطالعات نشان می‌دهند این روش آزمایشگاهی قادر به تشخیص بیماری در مراحل اول نیست و برخی مطالعات حساسیت کم آن را در مراحل اولیه گزارش می‌دهند [۱-۳].

یکی از راه‌های مرسوم برای شناسایی الگوهای مورفولوژیکی ضایعات ریوی مرتبط با کووید استفاده از تصاویر اسکن قفسه

در مارس ۲۰۲۰، کووید به‌عنوان یک بیماری همه‌گیر اعلام شد. بر اساس آمار منتشر شده توسط وب‌سایت WorldoMeters تا

این مقاله در اردیبهشت‌ماه ۱۴۰۱ دریافت شد در تیرماه بازنگری و در مردادماه همان سال پذیرفته شد.

^۱ دانشجوی دکتری مهندسی کامپیوتر گرایش نرم‌افزار، دانشکده مهندسی برق و کامپیوتر، دانشگاه تبریز، تبریز، ایران

رایانامه: Hadixhares@gmail.com

^۲ دانشکده مهندسی برق و کامپیوتر، دانشگاه تبریز، تبریز، ایران

رایانامه: [@tabrizu.ac.ir](mailto:{tanha, balafarila}@tabrizu.ac.ir) {tanha, balafarila}

نویسنده مسئول: هادی الحارس

dorl.net/dor/20.1001.1.23831197.1402.10.1.3.1

داده‌ها به‌تنهایی برای آموزش مدل کافی نباشند. با این حال، ماهیت دامنه‌های مبدأ می‌تواند بسیار متفاوت باشد، و کارایی انتقال به‌شدت به شباهت بین وظیفه منبع و وظیفه هدف بستگی دارد. به طوری که در برخی مواقع یادگیری انتقالی به‌جای به کمک به فرایند یادگیری به آن صدمه می‌زند. همچنین این خطر وجود دارد که مدل یاد بگیرد چگونه داده‌ها را از منابع مختلف متمایز کند، بنابراین به تعمیم مدل آموخته شده آسیب می‌رساند. این امر به‌ویژه در زمینه تشخیص کووید ۱۹ که در آن تفاوت‌های ساختاری و ذاتی تصاویر در مجموعه‌داده‌های موجود که از ابزارها و روش‌های متفاوت تصویربرداری پزشکی نشئت می‌گیرد، صادق است.

در برخی مقالات از جمله پژوهش [۱] ملاحظه می‌شود نتایج ارزیابی به دست آمده بر روی نمونه‌های آزمون متعلق به همان مجموعه‌داده‌ی مورد استفاده برای آموزش، به طور قابل توجهی بهتر از سایر مجموعه‌داده‌ها است. پژوهش‌های زیادی از جمله [۱۷، ۱۸] نشان می‌دهند که اکثر رویکردهای فعلی در ادبیات موضوع قابل اطمینان نیستند. به‌عنوان مثال دو پژوهش مطرح در این حوزه [۱۹، ۲۰] در مواجهه با داده‌های جدید (مجموعه‌داده‌ای که مدل با آن آموزش داده نشده است) عملکردی نزدیک به دسته‌بندی تصادفی از خود نشان می‌دهند. به‌عنوان مثال صحت دسته‌بندی در پژوهش [۱] از ۹۸٫۵٪ روی مجموعه‌داده آموزشی، در بهترین حالت به ۵۹٫۱۲٪ روی مجموعه‌داده خارجی می‌رسد. در نگاه اول این طور به نظر می‌رسد که تفاوت‌های ساختاری و ذاتی تصاویر در مجموعه‌داده‌های موجود علت این موضوع است. با بررسی دقیق‌تر مشاهده می‌کنیم اغلب روش‌های پیشنهادی تشخیص و دسته‌بندی کووید با مجموعه‌ای از تصاویر یک مجموعه‌داده، آموزش و آزمایش می‌شوند. استفاده از یک مجموعه‌داده باعث کاهش تعمیم‌پذیری این روش‌ها می‌شود. به طوری‌که عملکرد این روش‌ها در کاربردهای دنیای واقعی به‌شدت کاهش می‌یابد.

در این مقاله، با الهام از روش ارائه شده در [۲۱] قصد داریم مشکل مذکور را حل کنیم. در [۲۱] برای حل مشکل مذکور از دو مجموعه‌داده برای آموزش شبکه بهره برده است. ما نیز قصد داریم برای افزایش تعمیم‌پذیری شبکه از دو مجموعه‌داده استفاده کنیم. هدف این است که بازنمایی‌های یکسان از بین دو مجموعه‌داده یاد گرفته شود. روش پیشنهادی با روش [۲۱] چند تفاوت اساسی دارد: (۱) در کاربرد مختلف استفاده شده است. روش پیشنهادی برای دسته‌بندی تصاویر کرونا است، در حالی که روش [۲۱] بر پایه کاربرد خاص نیست و یک رویکرد کلی است. (۲) توابع خطا استفاده شده در هر دو روش متفاوت است. ما در روش پیشنهادی از توابعی استفاده می‌کنیم که برای تمییز بهتر تصاویر کرونا مناسب باشد. (۳) دقت و کارایی روش پیشنهادی بسیار بهتر از روش مقابل است.

سینه است. دو تکنیک مرسوم برای اسکن قفسه سینه وجود دارد: ایکس ری و سی‌تی‌اسکن. برای تشخیص کووید با استفاده از تصاویر قفسه سینه، وجود یک متخصص در این حوزه ضروری است. دقت تشخیص کووید به‌شدت به نظر این متخصص بستگی دارد [۴، ۵]. اخیراً روش‌هایی بر پایه یادگیری عمیق برای کمک به جامعه‌ی پزشکی در تشخیص سریع‌تر و دقیق‌تر و همچنین خودکارسازی تشخیص کووید با استفاده از تصاویر پزشکی مطرح شده است [۶، ۷].

یادگیری عمیق اخیراً در زمینه‌های مختلف پردازش تصویر به موفقیت‌های چشمگیری دست پیدا کرده است. به‌ویژه در تصاویر پزشکی نیز از یادگیری عمیق به‌وفور استفاده می‌شود (به‌عنوان مثال، تشخیص رتینوپاتی دیابتی [۸]، طبقه‌بندی سرطان پوست [۹] یا تشخیص سرطان سینه [۱۰]). با این حال، یادگیری عمیق با چالش‌های متعددی مواجه است. برخی از آنها به ماهیت خود مدل‌های عمیق مرتبط هستند، برای مثال، برای موفقیت مدل‌های مبتنی بر یادگیری عمیق، داده‌های زیادی مورد نیاز است. اکثر برنامه‌های کاربردی موفق حوزه پزشکی بر پایه یادگیری عمیق، موفقیت خود را مدیون داده‌هایی هستند که در طول سال‌ها جمع‌آوری شده است (مانند تشخیص از روی تصاویر سرطان سینه). این در حالی است که جمع‌آوری داده‌های پزشکی کافی برای آموزش مدل دشوار است. این به دلیل هزینه برچسب‌گذاری آنها است که به دانش تخصصی نیاز دارد [۱۱]. در تشخیص دقیق کووید با استفاده از تصاویر قفسه سینه نیز، کمبود مجموعه‌داده‌های جامع با کیفیت خوب، مسئله اصلی این حوزه تحقیقاتی است.

برای حل این مشکل، روش‌های مختلفی مطرح شده است. یکی از این روش‌ها داده‌افزایی است. در این روش داده‌ها را می‌توان با استفاده از برخی تکنیک‌های تغییر شکل دادن افزایش داد نظیر زوم کردن، چرخش تصویر و غیره [۱۲]. همچنین با استفاده از تکنیک‌هایی نظیر یادگیری few-shot می‌توان کارایی داده را افزایش داده داد [۱۳]. برخی روش‌ها نیز، دانش قبلی را به مدل‌های عمیق القا می‌کنند. هدف از این کار این است که مدل را با داده‌های کم آموزش داد. این دانش می‌تواند با آموزش مدل بر روی سایر داده‌های نیمه مرتبط و سپس تنظیم دقیق آن با داده‌های مورد مطالعه به دست آید [۱۴، ۱۵] که این روش با عنوان یادگیری انتقالی شناخته می‌شود.

یادگیری انتقالی به دلیل تنوع منابع موجود در زمینه‌ی پزشکی بسیار مناسب است. به عنوان مثال، ما می‌توانیم دانش را بین مجموعه‌داده‌های مختلف انتقال دهیم. همچنین، می‌توان از یادگیری انتقالی چند منبعی برای ترکیب منابع متعدد و استخراج دانش از چند منبع استفاده کرد [۱۶]. مزیت استفاده از یادگیری انتقالی چند منبعی این است که امکان استفاده از چندین منبع داده متفاوت را فراهم می‌کند که ممکن است هر یک از این

COVID-Net [۱۹]، یکی از اولین شبکه‌های کانولوشنی است که به طور خاص برای شناسایی کووید طراحی شده است. در این روش برای آموزش شبکه از تصاویر اشعه اکس استفاده شده است. عملکرد شبکه دقت ۸۴ درصد و حساسیت ۱۰۰ درصد را برای نمونه‌های کووید نشان داده است. در [۲۷] یک شبکه جدید به نام CVR-Net ارائه شده است. این شبکه مبتنی بر CNN بر روی مجموعه داده‌ای که ترکیبی از تصاویر اشعه ایکس و CT است، آموزش و ارزیابی شده است. در این روش میانگین دقت ۷۸٪ برای مجموعه داده تصاویر CT گزارش شده است. نسخه‌ی بهبود یافته COVID-Net در [۳۱] توسعه داده شده است. در این روش بازنمایی‌های تولید شده بهتر شده و کارایی شبکه از نظر محاسباتی بهبود یافته است.

در [۳۲] نویسندگان مجموعه‌ای از الگوریتم‌ها به نام CovidCTNet را توسعه داده‌اند. این روش‌ها برای تمییز کووید از CAP و سایر بیماری‌های ریوی توسعه داده شده‌اند. این مدل‌ها برای کار با مجموعه داده‌هایی با اندازه‌های ناهمگن و کوچک طراحی شده‌اند. در [۳۳] برای قطعه‌بندی و طبقه‌بندی هم‌زمان تصاویر CT از یک معماری بر پایه خود رمزگذار استفاده کرده‌اند. در معماری پیشنهادی آنها خروجی تصویر قطعه‌بندی شده و برجسب پیش‌بینی شده است. این معماری متشکل از یک رمزگذار و سه رمزگشا است؛ این رمزگشاها به ترتیب برای بازسازی تصویر و قطعه‌بندی و طبقه‌بندی تصویر استفاده می‌شود.

۲-۱- روش‌های مبتنی بر معماری سفارشی شده

COVID-Net [۱۹]، یکی از اولین شبکه‌های کانولوشنی است که به طور خاص برای شناسایی کووید طراحی شده است. در این روش برای آموزش شبکه از تصاویر اشعه اکس استفاده شده است. عملکرد شبکه دقت ۸۴ درصد و حساسیت ۱۰۰ درصد را برای نمونه‌های کووید نشان داده است. در [۲۷] یک شبکه جدید به نام CVR-Net ارائه شده است. این شبکه مبتنی بر CNN بر روی مجموعه داده‌ای که ترکیبی از تصاویر اشعه ایکس و CT است، آموزش و ارزیابی شده است. در این روش میانگین دقت ۷۸٪ برای مجموعه داده تصاویر CT گزارش شده است. نسخه‌ی بهبود یافته COVID-Net در [۳۱] توسعه داده شده است. در این روش بازنمایی‌های تولید شده بهتر شده و کارایی شبکه از نظر محاسباتی بهبود یافته است.

در [۳۲] نویسندگان مجموعه‌ای از الگوریتم‌ها به نام CovidCTNet را توسعه داده‌اند. این روش‌ها برای تمییز کووید از CAP و سایر بیماری‌های ریوی توسعه داده شده‌اند. این مدل‌ها برای کار با مجموعه داده‌هایی با اندازه‌های ناهمگن و کوچک طراحی شده‌اند. در [۳۳] برای قطعه‌بندی و طبقه‌بندی هم‌زمان تصاویر CT از یک معماری بر پایه خود رمزگذار

هدف کلی این تحقیق ارائه یک چارچوب موفق برای تشخیص ویروس کووید-۱۹ بر پایه یادگیری عمیق است که:

(۱) تأثیر تفاوت‌های ساختاری و ذاتی تصاویر که با ابزارها و روش‌های متفاوت تصویربرداری پزشکی به دست آمده‌اند، در نتیجه‌ی نهایی حداقل شود.

(۲) در فرایند آموزش شبکه از دو مجموعه داده با دامنه‌های ورودی متفاوت استفاده می‌شود. هدف این است که بازنمایی‌های یاد گرفته شده وابسته به دامنه‌ی یک مجموعه داده خاص نباشد. در واقع هدف این است که بازنمایی‌هایی تولید شود که مستقل از دامنه‌ی مجموعه داده‌ها بوده و شامل ویژگی‌های مشترک برای دسته‌بندی هر دو مجموعه داده باشد.

(۳) عملکرد روش پیشنهادی در کاربردهای دنیای واقعی بهتر از سایر الگوریتم‌های موفق باشد.

ادامه مقاله به این صورت سازمان‌دهی شده است که در بخش ۲، ابتدا یک مروری جزئی از الگوریتم‌های ارائه شده در این حوزه ارائه می‌شود، در بخش ۳ روش پیشنهادی ارائه می‌گردد، بخش ۴ شامل نتایج آزمایش‌ها است و نهایتاً بخش ۵ به نتیجه‌گیری و معرفی محورهای مطالعه و توسعه بیشتر می‌پردازد.

۲- کارهای مرتبط

استفاده کردن از یادگیری عمیق برای تصاویر پزشکی اولین بار توسط [۶]، معرفی شد. در این مقاله از معماری‌های مختلف CNN و تصاویر CT اسکن برای تشخیص غده لنفوی سینه و کلاس‌بندی بیماری ریه استفاده کردند. محققان در این روش از تکنیک یادگیری انتقالی استفاده کردند. مطالعه آنها نشان داد معماری‌های CNN حتی با وجود داده آموزشی محدود (که یک ایراد برای یادگیری عمیق است)، برای مسائل نظارت پزشکی اثر بخش‌تر از سایر روش‌های یادگیری ماشین است. در [۲۲]، برای تشخیص انواع مختلف ذات‌الریه از تصاویر اشعه ایکس، مدل CheXNet ارائه شد. مدل CheXNet از ۱۲۱ لایه تشکیل شده بود و روی مجموعه داده‌ای با بیش از ۱۰۰۰۰۰ نمونه و ۱۴ کلاس، آموزش دیده است.

با همه‌گیر شدن بیماری کووید، روش‌هایی گوناگونی برای تشخیص کووید معرفی شده‌اند [۲۳-۲۶]. این روش‌ها را می‌توان در سه دسته کلی طبقه‌بندی کرد: (۱) روش‌های مبتنی بر معماری سفارشی شده مانند COVID-Net [19]، CVR-Net [27]، روش‌های مبتنی بر مدل‌های از پیش آموزش دیده مانند ReseNet [28]، Xception [29]، Capsule Networks [20، 30] و (۳) روش‌های مبتنی بر استخراج دستی ویژگی‌ها. در ادامه هر یک از این را بررسی می‌کنیم.

۲-۱- روش‌های مبتنی بر معماری سفارشی شده

داده شده است. این روش قادر است بازنمایی‌های سه بعدی و دو بعدی را استخراج کند. در این روش از معماری ResNet استفاده شده است.

۳-۲- روش‌های مبتنی بر استخراج دستی ویژگی‌ها

برخی روش‌ها از استخراج ویژگی به صورت دستی استفاده کرده‌اند. در [۴۹]، ابتدا ویژگی‌های مختلف بافت از تصاویر اشعه ایکس استخراج شده و سپس این ویژگی‌ها با ویژگی‌های استخراج شده از شبکه پیش آموزش داده شده InceptionV3 ترکیب می‌شوند. ویژگی‌های نهایی به دست آمده به دسته‌بندی‌های مختلف برای تمییز موارد سالم با سایر موارد داده می‌شوند. در [۵۰]، روشی برای کلاس‌بندی موارد مثبت و منفی کووید با استفاده از تصاویر سی تی اسکن پیشنهاد شده است. ویژگی‌های مختلف بافت از تصاویر CT با استفاده از فیلتر گابور استخراج شده و سپس از روش SVM برای دسته‌بندی این تصاویر استفاده شده است.

اگرچه اکثر روش‌های ذکر شده عملکرد قابل قبولی روی مجموعه داده‌ی ارزیابی از خود نشان داده‌اند اما همگی یک مشکل مشترک دارند و آن این است که این مدل‌ها در مرحله‌ی استخراج ویژگی بسیار وابسته به دامنه‌ی تصاویر مجموعه داده مورد آموزش بوده و عملکرد خوبی در مواجهه با مجموعه داده‌های دیگر ندارند. در عمل نیز با ارزیابی بین مجموعه داده‌ای این ضعف مهم را از خود نشان می‌دهند.

۳- روش پیشنهادی

همان‌طوری که در بخش مقدمه و کارهای مرتبط بیان شد، روش‌های که برای تشخیص کووید بر پایه یادگیری عمیق ارائه شده‌اند، اغلب روی یک مجموعه داده آموزش و ارزیابی می‌شوند. این موضوع باعث می‌شود مدل ویژگی‌های خاص مجموعه داده را یاد بگیرد و در مواجهه با داده جدید اغلب پیش‌بینی تصادفی انجام می‌دهد. به همین دلیل در کاربردهای دنیای واقعی نیز که داده‌های مورد استفاده، داده‌های جدید و مستقلی از داده‌های آموزشی‌اند مورد اعتماد نیستند برای افزایش تعمیم‌پذیری مدل، در روش پیشنهادی از تکنیک تحت عنوان تطبیق دامنه برای آموزش شبکه استفاده می‌کنیم. در این تکنیک، در فرایند آموزش شبکه از دو مجموعه داده با دامنه‌ی ورودی متفاوت استفاده می‌شود. هدف این است که بازنمایی‌های تولید شده وابسته به دامنه‌ی یک مجموعه داده‌ی خاص نباشد. به عبارتی دیگر بازنمایی‌های تولید شده بین مجموعه داده‌ها مشترک بوده و بازنمایی‌های بهتری برای دسته‌بندی هر دو مجموعه داده تولید شود. از طرفی برای آموزش شبکه از تابع خطای مرکزی استفاده می‌کنیم. با استفاده از این تابع خطا برای نمونه‌های یک کلاس بازنمایی‌های نزدیک به هم و برای

استفاده کرده‌اند. در معماری پیشنهادی آنها خروجی تصویر قطعه‌بندی شده و برچسب پیش‌بینی شده است. این معماری متشکل از یک رمزگذار و سه رمزگشا است؛ این رمزگشاها به ترتیب برای بازسازی تصویر و قطعه‌بندی و طبقه‌بندی تصویر استفاده می‌شود.

۲-۲- روش‌های مبتنی بر مدل‌های از پیش آموزش دیده

برخلاف دسته‌ی اول، در این دسته از روش‌ها با استفاده از رویکرد یادگیری انتقالی از معماری‌های رایج CNN و شبکه‌های از پیش آموزش دیده شده برای تشخیص کووید استفاده می‌شود. روش ارائه شده در [۳۴] برای تشخیص موارد مثبت و منفی ویروس کرونا بر روی تصاویر CT از شبکه‌های کانولوشنی استفاده کرده است. در [۳۵] از شبکه‌های کانولوشنی در کنار یادگیری انتقالی برای طبقه‌بندی نمونه‌ها به سه دسته‌ی کووید، ذات‌الریه باکتریایی و موارد سالم استفاده شده است. در این مقاله از معماری‌های VGG19 [36]، MobileNet v2 [37]، Inception ResNetv2 [38]، Xception [39] و [۴۰] برای شناسایی کووید، از یادگیری انتقالی با تنظیم مجدد استفاده شده است. آنها روش پیشنهادشان را روی چهار معماری محبوب CNN یعنی ResNet18 [41]، SqueezeNet، ResNet50 [۴۲] و DenseNet-121 [۴۳] مورد ارزیابی قرار دادند. این روش روی یک مجموعه داده از تصاویر اشعه ایکس با ۵۰۰۰ نمونه آزمایش شده است. برونز و همکاران [۴۴] برای شناسایی خودکار کووید، از آموزش انتقالی روی یک شبکه آموزش دیده VGG-16 استفاده کردند [۳۶]

در [۴۵] از مدل‌های یادگیری عمیق و تصاویر CT قفسه سینه برای تمییز کووید از آنفولانزا استفاده شده است. این مطالعه بر روی تصاویر CT بیماران مبتلا به کووید که از بیمارستان‌های مختلف چین جمع‌آوری شده است، انجام شده است. مطالعات آنها اثر بخشی تصاویر CT بر تشخیص بیماری کووید را ثابت کرده است.

DeepPneumonia [۴۶] روش دیگری است که برای شناسایی کووید، ذات‌الریه باکتریایی و موارد سالم بر اساس تصاویر CT توسعه داده شده است. این مدل توانست دقت ۸۶/۵ درصد برای تمییز کردن ذات‌الریه باکتریایی و کووید و دقت ۹۴ درصد برای تشخیص کووید و موارد سالم به دست آورد. در [۴۷] از تصاویر CT برای طبقه‌بندی کووید با غیر کووید با استفاده از یک شبکه آموزش دیده DenseNet201 استفاده کرده‌اند.

در [۴۸] یک روش جدید با عنوان CONVNet بر پایه چارچوب یادگیری سه بعدی عمیق برای تشخیص کووید توسعه

می‌یابند. در کارهای اخیر در حوزه تشخیص کووید از ورودی ۲۲۴ در ۲۲۴ استفاده می‌کنند، ما نیز برای مقایسه عادلانه، تصاویر را در ابعاد ۲۲۴ در ۲۲۴ استفاده می‌کنیم.

نرمال‌سازی

در این مرحله، یک نرمال‌سازی ساده شدت پیکسل در محدوده ۰ تا ۱ اعمال می‌شود. این پیش‌پردازش برای همگرایی مدل در مرحله آموزش لازم است. جهت نرمال‌سازی داده‌ها، ابتدا میانگین و انحراف معیار سطح پیکسل برای تمامی تصاویر مجموعه‌ی آموزش محاسبه می‌شوند؛ سپس با استفاده از رابطه‌ی (۱)، داده‌ها نرمال‌سازی می‌شوند که در آن x میانگین مجموعه تصاویر X ، σ انحراف معیار و $\varepsilon = 1e-10$ مقدار ناچیزی جهت جلوگیری از صفر شدن مخرج است.

$$X_i = \frac{X_i - \bar{x}}{\sigma + \varepsilon} \quad (1)$$

داده‌افزایی

داده‌افزایی شامل افزایش نمونه‌های آموزش از طریق تبدیل تصاویر بدون از دست دادن اطلاعات معنایی است. در این کار، ما از پنج تغییر که به طور تصادفی روی نمونه‌های مجموعه‌داده آموزشی اعمال می‌شود، استفاده می‌کنیم. داده‌افزایی در حین آموزش شبکه انجام می‌شود، یعنی در هر تکرار (Epoch) داده‌های جدید تولید و به شبکه داده می‌شوند؛ بنابراین در هر تکرار تصاویری که به شبکه داده می‌شود متفاوت است. جدول ۱ جزئیات این تغییرات را نشان می‌دهد.

این جدول نشان می‌دهد درخشندگی و کنتراست تصویر در بازه ۲۰- تا ۲۰+ درصد تغییر می‌کند. در تصاویر کرونا قسمت سفیدرنگ ریه نمایانگر مناطق درگیر کرونا است. اگر درخشندگی بیش از ۲۰ درصد برسد تصویر حاصل تقریباً متمایل به سفید می‌شود که این امر ممکن است برای تشخیص درست مناسب نباشد و شبکه به‌درستی آموزش نبیند. از چرخش تصویر (Rotation) نیز برای تولید داده‌های جدید استفاده کرده‌ایم. بازه چرخش تصویر ۲۰- تا ۲۰+ درجه انتخاب شده است. چرخش بیش‌تر از ۲۰ درجه یا کمتر از آن ممکن است باعث تغییر فرم شکل ریه شود و ممکن است به آموزش درست شبکه آسیب بزند. همچنین تصاویری که در فاز آزمایش شبکه استفاده می‌شود تصاویر هستند که هیچ چرخشی ندارند و تصویر ورودی کاملاً مطابق با تصویر حاصل از دستگاه تصویربرداری است؛ بنابراین چرخش بیش از حد تصویر برای آموزش شبکه بر روی داده‌های پزشکی مناسب نیست. تفسیر شیب به چرخش (Rotation) برای چرخش (flip) نیز صادق است. ما فقط می‌توانیم تصاویر ریه را به‌صورت افقی بچرخانیم. چرخش عمودی باعث می‌شود تصویر حاصل کاملاً متفاوت با آن چیزی باشد که در فاز کاربرد شبکه استفاده می‌شود؛ بنابراین تمام تغییرات اعمال شده بر روی تصاویر به‌گونه‌ای است که

نمونه‌های کلاس‌های مختلف بازنمایی‌های دور از هم تولید می‌شود.

۳-۱- ساختار کلی روش پیشنهادی

شکل ۱ ساختار کلی روش پیشنهادی را نمایش می‌دهد. همان‌طور که در این شکل مشاهده می‌شود در فرایند تشخیص کووید جهت بهره‌بردن از دو دامنه‌ی ورودی متفاوت و نزدیک کردن توزیع آماری این دامنه‌های مختلف به هم از دو مجموعه‌داده استفاده می‌شود. از مجموعه‌داده منبع برای آموزش شبکه و از مجموعه‌داده هدف برای مقاوم کردن، انتقال‌پذیری و تعمیم‌پذیری بهتر شبکه بر روی مجموعه‌داده‌های جدید استفاده می‌شود. مرحله بعد، مرحله پیش‌پردازش است. این مرحله شامل رمزگشایی، تغییر سایز، نرمال‌سازی و داده‌افزایی است. بعد از پیش‌پردازش‌های اولیه بر روی تصاویر ورودی، این تصاویر به‌عنوان ورودی برای معماری پیشنهادی استفاده می‌شود. معماری پیشنهادی از سه قسمت کلی تشکیل شده است. قسمت CNN-based Feature Extractor که وظیفه استخراج ویژگی‌های مستقل از دامنه ورودی را بر عهده دارد، قسمت classifier و وظیفه طبقه‌بندی داده‌ها به دو کلاس کووید یا غیر کووید را بر عهده دارد و discriminator وظیفه تشخیص و تمییز داده‌های منبع از داده‌های هدف را بر عهده دارد. در ادامه، در بخش ۳-۲ فرایند پیش‌پردازش تصاویر معرفی می‌شود. در قسمت ۳-۳ معماری پیشنهادی را معرفی خواهیم نمود.

۳-۲- پیش‌پردازش

پیش‌پردازش فرایندی بسیار رایج در کاربردهای بینایی ماشین است. تکنیک‌های پیش‌پردازش با هدف از بین بردن نویز، تشخیص بهتر با تأکید بر ویژگی‌های مفید تصویر استفاده می‌شود. در روش پیشنهادی از سه مرحله برای پیش‌پردازش داده استفاده شده است. این مراحل در اکثر معماری‌های یادگیری عمیق استفاده می‌شود.

رمزگشایی

اغلب تصاویر پزشکی در فرمت DICOM ذخیره و ارائه می‌شوند؛ بنابراین این تصاویر، در فرمت‌های رایج تصاویر مانند PNG یا JPG نیستند. برای کار با این‌گونه مجموعه‌داده‌ها نیاز داریم فایل DICOM را به فرمت‌های رایج تصویر تبدیل کنیم. برای داده‌های به دست آمده از مجموعه‌داده‌های [۵۱] و [۵۲]، ما تصاویر را به فرمت PNG در مقیاس خاکستری تبدیل می‌کنیم.

تغییر سایز

در شبکه‌های کانولوشنی، تصاویر ورودی اغلب برای حفظ سازگاری با معماری شبکه و کاهش محاسبات تغییر اندازه

وظیفه تشخیص و تمییز داده‌های منبع از داده‌های هدف را بر عهده دارد و مازول طبقه‌بندی کننده‌ی خروجی وظیفه دسته‌بندی داده‌ها به دو گروه کرونا و غیر کرونا را بر عهده دارد. نمایش گرافیکی کلی از مدل پیشنهادی با استفاده از رویکرد آموزش خصمانه در یک محیط یادگیری انتقال چند منبعی در شکل ۳ نمایش داده شده است. مازول طبقه‌بندی کننده خروجی و مازول طبقه‌بندی کننده دامنه به طور هم‌زمان از ویژگی‌های استخراج شده برای پیش‌بینی برچسب کلاس و دامنه‌ای که داده‌ها از آن آمده‌اند، استفاده می‌کنند. پیش‌بینی کننده خروجی و طبقه‌بندی کننده دامنه هر دو به طور کلاسیک با پس انتشار کردن خطا مربوطه خود، آموزش داده می‌شوند، هنگام رسیدن به مازول استخراج ویژگی، خطا طبقه‌بندی کننده دامنه با استفاده از لایه معکوس کننده گرادیان (GRL) معکوس می‌شود (در منفی یک ضرب می‌شود).

معماری مازول طبقه‌بندی کننده خروجی و مازول طبقه‌بندی کننده دامنه دقیقاً شبیه به هم است. ویژگی‌های استخراج شده از گام CNN-based feature extractor را به دو بلوک متوالی که از لایه‌های Dense، Batch-normalization، Dropout، Relu تشکیل شده است، پاس می‌دهیم. شکل ۴ جزئیات این مراحل را نشان می‌دهد. خروجی حاصل از بلوک ۲ شکل ۴، بازنمایی‌های جدید از داده‌های ورودی است. تابع softmax را بر روی این بازنمایی‌های جدید اعمال می‌کنیم. در مازول طبقه‌بندی کننده دامنه، این تابع احتمال تخصیص هر نمونه به کلاس منبع و هدف را مشخص می‌کند و در طبقه‌بندی کننده خروجی، این تابع احتمال تخصیص هر نمونه به کلاس کرونا و غیر کرونا را مشخص می‌کند.

توابع خطا

برای افزایش تعمیم‌پذیری و قابلیت انتقال مدل، در فرایند آموزش شبکه از دو تابع خطا به صورت مشترک استفاده می‌شود و شبکه به صورت هم‌زمان با استفاده از این دو تابع خطا آموزش داده می‌شود. رابطه ۲ نشان دهنده‌ی تابع خطا روش پیشنهادی است. از تابع خطای CenterLoss برای محاسبه خطا قسمت پیش‌بینی کننده‌ی خروجی (L_c) و از تابع خطای Cross-entropy برای محاسبه خطا قسمت طبقه‌بندی کننده‌ی دامنه L_d استفاده می‌کنیم. λ_d ضریبی است که به خطا طبقه‌بندی کننده‌ی دامنه داده می‌شود و λ_c ضریب خطای طبقه‌بندی کننده خروجی است. هدف از این وزن‌دهی یافتن تعادل بهینه بین واریانس و بایاس برای تعمیم‌پذیری بهتر مدل است.

$$\mathcal{L} = \lambda_c \mathcal{L}_c + \lambda_d \mathcal{L}_d \quad (2)$$

L_d تابع خطای Cross-entropy است که از طریق رابطه ۳ محاسبه می‌شود. در این رابطه y_d نشان دهنده‌ی کلاس صحیح (مجموعه داده هدف یا منبع) و \hat{y}_d نشان دهنده‌ی پیش‌بینی

باعث تفسیر متفاوت توسط پزشکان و متخصصان نمی‌شود و به آموزش شبکه آسیب نمی‌زند.

۳-۳- معماری پیشنهادی

همان‌طوری که در شکل ۱ مشاهده می‌شود. معماری پیشنهادی از سه قسمت اصلی تشکیل شده است. مازول استخراج ویژگی وظیفه استخراج ویژگی‌ها را بر عهده دارد، مازول طبقه‌بندی کننده دامنه (discriminator) وظیفه تشخیص و تمییز داده‌های دو دامنه مختلف از هم را بر عهده دارد و مازول طبقه‌بندی کننده‌ی خروجی (Classification) وظیفه طبقه‌بندی داده‌ها به دو کلاس کووید و غیر کووید را بر عهده دارد. در این بخش هر یک از این قسمت‌ها مفصلاً بحث می‌شود.

مازول استخراج ویژگی

این قسمت وظیفه استخراج ویژگی‌های مستقل از دامنه‌ی تصاویر را بر عهده دارد. در این مرحله فارغ از اینکه تصویر ورودی متعلق به کدام منبع ورودی است (مجموعه داده منبع یا هدف)، هدف یادگیری بازنمایی‌های مشترک بین دو مجموعه داده است و تلاش می‌شود برای هر تصویر ویژگی‌هایی استخراج شود که مستقل از دامنه مجموعه داده‌ای باشد که به آن تعلق دارد و فقط ویژگی‌های اصلی لازم برای تشخیص کرونا رو در بر بگیرد، نه ویژگی‌های منحصر به یک مجموعه داده خاص.

در این قسمت می‌توان از معماری‌های رایج کانولوشنی نظیر Resnet، VGG16 یا ... استفاده کرد. این معماری‌ها برای آموزش بهتر نیاز به داده‌های آموزشی زیادی دارند. این در حالی است که در مسئله تشخیص کووید تعداد نمونه‌های آموزشی بسیار کم است. یک تکنیک رایج برای حل این مشکل استفاده از رویکرد یادگیری انتقالی است. این تکنیک، رویکرد متداول و پرکاربردی است که در یادگیری عمیق روی مجموعه داده‌های کوچک تصویر مورد استفاده قرار می‌گیرد.

در روش پیشنهادی پس از آزمایش اکثر شبکه‌های از پیش آموزش دیده شده رایج، ما از معماری ResNet50 که بر روی امجنت آموزش دیده است به عنوان استخراج کننده‌ی ویژگی استفاده می‌کنیم. این معماری نسبت به سایر معماری‌های بر پایه ResNet کوچک‌تر است و پارامترهای کمتری دارد؛ بنابراین به دلیل هزینه محاسباتی کمتر، امکان استفاده از تصاویر ورودی با وضوح بالاتر را فراهم می‌کند. شمای کلی این معماری در شکل ۲ نمایش داده شده است؛ جزئیات بلوک‌های Conv و Identity عیناً مطابق مرجع اصلی است [۴۱].

مازول طبقه‌بندی کننده دامنه و طبقه‌بندی کننده‌ی خروجی

همان‌طوری که در بخش ۳-۱ توضیح داده شد، از دامنه‌های ورودی متفاوت (مجموعه داده منبع و هدف) برای تشخیص کرونا استفاده می‌شود. مازول طبقه‌بندی کننده دامنه

ترکیبی از داده‌های مجموعه داده هدف و مجموعه داده منبع است.

۴- آزمایش‌ها

در این بخش کارایی روش پیشنهادی مورد ارزیابی قرار گرفته و نتایج آن با تعدادی از موفق‌ترین روش‌های پیشین مقایسه می‌شود.

۴-۱- تنظیم پارامترها

برای آموزش شبکه، تمام پارامترها با وزن‌های تصادفی شروع به کار می‌کنند. پارامترهای موجود در روش پیشنهادی شامل تعداد تکرار و اندازه دسته (batch) با مقادیر ۲۰۰۰۰ و ۳۲ تنظیم شده است. با توجه به تعداد کم تصاویر اولیه، ممکن است مسئله بیش برآزش رخ دهد. برای رفع این مسئله در کنار تکنیک داده‌افزایی از Dropout استفاده شده است. نرخ Dropout با مقدار ۰/۵ تنظیم شده است. در روش پیشنهادی از adam $\lambda_D=1$ و $\lambda_Y=4$ استفاده شده است. بهینه‌ساز استفاده شده adam است و نرخ یادگیری اولیه برابر با e^{-21} است.

۴-۲- مجموعه داده

برای آموزش و ارزیابی کارایی الگوریتم پیشنهادی و همچنین مقایسه نتایج آن با سایر مجموعه داده‌ها از مجموعه داده SARS-CoV-2 CT Scan [۵۱] به عنوان مجموعه داده منبع و از مجموعه داده COVID19-CT [۵۲] به عنوان مجموعه داده هدف استفاده می‌کنیم. جزئیات این مجموعه داده‌ها در جدول ۲ نشان داده شده است. از آنجا که تصاویر CT از منابع مختلف گرفته شده است، اندازه آنها متفاوت است. در آزمایش‌ها ۸۰ درصد مجموعه داده به عنوان مجموعه آموزش، ۲۰ درصد به عنوان مجموعه آزمایش انتخاب شده است.

۴-۳- معیارهای اندازه‌گیری کارایی

برای ارزیابی مدل پیشنهادی و مقایسه آن با سایر روش‌ها از معیارهای مختلف ارزیابی استفاده می‌کنیم. برای اندازه‌گیری کارایی ۴ پارامتر نیاز است: مثبت صحیح، مثبت کاذب، منفی صحیح و منفی کاذب.

معیار Accuracy، بیان‌کننده تعداد «پیش‌بینی‌های صحیح انجام شده» تقسیم بر تعداد «کل پیش‌بینی‌های انجام شده» است [۵۵]. رابطه ۵ چگونگی محاسبه Accuracy را نشان می‌دهد:

$$\text{Accuracy} = \frac{TN + TP}{TN + TP + FN + FP} \quad (5)$$

معیار دیگر برای ارزیابی روش پیشنهادی معیار Precision است. مقدار بالا برای معیار Precision، بیانگر تعداد کم

مدل است که آیا داده ورودی متعلق به مجموعه داده هدف است یا مجموعه داده منبع

$$L_c = -y_c \log(\hat{y}_c) \quad (3)$$

L_c تابع خطای مرکزی است که از طریق رابطه ۴ محاسبه می‌شود. در این رابطه y_c نشان دهنده‌ی کلاس صحیح (کرونا و غیر کرونا) و \hat{y}_c نشان دهنده‌ی پیش‌بینی مدل است.

$$L_c = -y_c \log(\hat{y}_c) + \frac{1}{2} \|x_i - c_{y_i}\|^2 \quad (4)$$

C_{y_i} مرکز کلاس y_i است. تابع خطای مرکزی ابتدا در مقاله [۵۳] ارائه شده است. ایده اصلی استفاده از این تابع خطا این است که نمونه‌ها در یک کلاس باید بازنمایی شبیه به هم و نمونه‌ها در کلاس‌های مختلف باید بازنمایی‌های متفاوتی در فضای تعبیه شده داشته باشند. بر این اساس تابع خطا دو هدف دارد که هم‌زمان برای بهینه‌سازی آن‌ها تلاش می‌کند: (۱) کاهش واریانس درون کلاسی و (۲) افزایش واریانس بین کلاسی. هدف اول با قسمت دوم رابطه ۴ تحقق می‌یابد یعنی کاهش فاصله نمونه‌های یک کلاس با مرکز آن کلاس و هدف دوم با قسمت اول رابطه ۴ تحقق می‌یابد یعنی افزایش فاصله بین کلاسی. برای جزئیات بیشتر در مورد این تابع خطا به مقاله [۵۳] مراجعه کنید. به علت وجود شباهت‌های ذاتی و ساختاری زیاد در تصاویر پزشکی، به نظر استفاده از این تابع خطا می‌تواند در تمایز بهتر داده‌هایی که در عین شباهت، از دو کلاس متفاوت هستند مفید باشد. نتایج درخشان استفاده از این تابع در کاربرد حاضر صحت این فرضیه را قوت می‌بخشد.

باید به این نکته توجه داشت که در خطا مربوط به دامنه (L_D) هدف کمینه کردن خطا نیست. حالت ایده‌آل این است که این خطا بیشتر باشد. یعنی ویژگی‌هایی در مرحله استخراج ویژگی یاد گرفته شوند که شبکه به وسیله این ویژگی‌ها قادر نباشد نمونه‌های دو مجموعه داده ورودی (منبع و هدف) را از هم تشخیص دهد. به عبارتی هدف روش پیشنهادی این است که ویژگی‌های مشترک دو مجموعه داده یاد گرفته شود، نه ویژگی‌های مختص یک دامنه ورودی خاص. شاید این سوال مطرح باشد که این امر ممکن است به بهینه‌سازی پارامترهای شبکه آسیب بزند. باید به نکته توجه کرد که در پس انتشار کردن خطا، خطا مربوط به دامنه (L_D) هنگام رسیدن به ماژول استخراج ویژگی، به وسیله لایه معکوس‌کننده گرادیان (GRL) معکوس می‌شود؛ بنابراین مشکلی در بهینه‌سازی شبکه به وجود نمی‌آید. با استفاده از این تکنیک ویژگی‌هایی یاد گرفته می‌شوند که مختص دامنه یک مجموعه داده خاص نباشند.

در آموزش شبکه برای مجموعه داده منبع از برچسب کلاس (کرونا و غیر کرونا) و برچسب دامنه ورودی (منبع و هدف) استفاده می‌کنیم و برای مجموعه داده هدف فقط از برچسب دامنه ورودی (منبع و هدف) استفاده می‌شود. داده‌های ورودی شبکه

به‌ازای تمامی معیارها دارد. در این معماری به طور متوسط، دو تصویر کووید به طور نادرست به‌عنوان غیر کووید پیش‌بینی شده است. بعد از معماری‌های مذکور، روش‌های [51] xDNN، میانگین نتایج را دارند. در میان نتایج گزارش شده بدترین نتیجه مربوط به الگوریتم Decision Tree است.

برای ارائه‌ی یک دید کلی و مقایسه با اکثر روش‌های مطرح پیشین، روش پیشنهادی را با دسته‌بندی‌های موجود که در بخش کارهای مرتبط بیان شد مقایسه می‌کنیم. ابتدا با روش‌هایی مورد ارزیابی قرار می‌دهیم که در آن مدل‌ها از قبل روی مجموعه‌داده امچنت آموزش دیده‌اند. هدف این است که روش پیشنهادی با معماری‌های رایج مقایسه شود. همان‌طوری که در جدول ۳ مشاهده می‌شود این روش‌های نظیر ShuffleNet، ResNet50V2، ResNet50، EfficientNetB0 نسبتاً بالایی دارند. میانگین به دست آمده برای روش پیشنهادی و سایر روش‌های از پیش آموزش داده‌شده روی مجموعه‌داده SARS-CoV-2 CT-scan نشان می‌دهد با وجود اینکه تعداد تصاویر در این مجموعه‌داده نسبتاً کم است (که یک نکته منفی برای روش‌های بر پایه یادگیری عمیق است) ولی نتایج رضایت‌بخش است. به طور کلی زمانی که داده برای آموزش شبکه کم است یادگیری انتقالی بهترین روش برای آموزش شبکه است. نتایج روش‌های از پیش آموزش داده شده نسبت به نتایج روش‌هایی که به طور خاص برای تشخیص کووید توسعه داده شده‌اند، نظیر Contrastive Learning، به طور قابل توجهی بالاست. از این رو به نظر می‌رسد فارغ از مشارکت کیفی و نوآوری‌های ارائه شده در این روش‌ها که راه‌حلی کم‌هزینه و عملی برای غلبه بر مشکل در این حوزه پیشنهاد می‌دهند، روش پیشنهادی و به طور کلی روش‌های بر پایه یادگیری انتقالی از نظر کمی نسبت به سایر روش‌ها عملکرد بهتری دارد. با مقایسه روش‌های بر پایه یادگیری عمیق و روش‌های غیر عمیق (مانند Decision Tree) مشاهده می‌شود روش‌های غیر عمیق قادر نیستند با دقت بالایی موارد کرونا از غیر کرونا را تمییز دهند. دلیل این امر واضح است. روش‌های غیر عمیق برای دسته‌بندی مسائل پیچیده (مانند تصاویر) مناسب نیستند.

۴-۵- آزمایش ۲: ارزیابی عملکرد روش پیشنهادی

بر روی مجموعه‌داده هدف

در این قسمت روش پیشنهادی روی مجموعه‌داده هدف مستقلاً آموزش و ارزیابی می‌کنیم. جدول ۴ مقادیر نتایج ارزیابی حاصل از شبکه‌های عمیق مختلف و روش‌های مقایسه شده را نشان می‌دهد. همه‌ی روش‌های مقایسه شده، روی مجموعه‌داده هدف آموزش و ارزیابی شده‌اند. با توجه به این جدول مشاهده

داده‌هایی است که به‌اشتباه در کلاس خاص طبقه‌بندی شده‌اند [56, 57]. این معیار به‌صورت رابطه ۶ محاسبه می‌شود:

$$\text{Precision} = \frac{TP}{TP + FP} \quad (6)$$

معیار بعدی Recall است. مقدار بالا برای این معیار، بیانگر تعداد کم داده‌هایی است که به‌اشتباه، در یک کلاس خاص طبقه‌بندی نشده [58] و به‌صورت رابطه ۷ محاسبه می‌شود:

$$\text{Recall (sensitivity)} = \frac{TP}{TP + FN} \quad (7)$$

معیار F1، یک معیار مناسب برای ارزیابی کارایی است. این معیار پارامترهای Precision و Recall را با هم ترکیب می‌کند تا مشخص شود یک مدل تا چه حد عملکرد خوبی را از خود نشان می‌دهد [59] و به‌صورت رابطه ۸ محاسبه می‌شود:

$$\text{F1 Measure} = 2 \times \frac{\text{Recall} \times \text{Precision}}{\text{Recall} + \text{Precision}} \quad (8)$$

آخرین معیار Specificity است. این معیار نشان دهنده‌ی نرخ پاسخ‌های منفی درست است. چگونگی محاسبه این معیار در رابطه ۹ نشان داده شده است.

$$\text{Specificity} = \frac{TN}{TN + FP} \quad (9)$$

معیارهای مذکور در بهترین حالت، یک و در بدترین حالت صفر هستند. در این مقاله این معیارها به‌صورت درصد بیان شده‌اند

۴-۴- آزمایش ۱: ارزیابی عملکرد روش پیشنهادی

بر روی مجموعه‌داده منبع

در این قسمت روش پیشنهادی را با معماری‌های مختلف و روش‌های موفق مقایسه می‌کنیم. تمامی روش‌ها بر روی مجموعه‌داده منبع آموزش و ارزیابی شده‌اند. جدول ۳ مقادیر معیارهای ارزیابی حاصل از شبکه‌های عمیق مختلف و روش‌های مقایسه شده را نشان می‌دهد. تمام مقادیر به‌صورت درصدی بیان شده و بهترین نتایج پر رنگ نوشته شده است. با توجه به این جدول مشاهده می‌شود الگوریتم پیشنهادی در مقایسه با سایر معماری‌های یادگیری عمیق و روش‌های مقایسه شده بهترین عملکرد را دارد.

با توجه به جدول ۳، در مجموعه‌داده‌ی منبع، روش پیشنهادی، به‌ازای تمامی معیارهای ارزیابی، بهترین عملکرد کلی را دارد و به‌ازای معیارهای Accuracy، Precision و F1-score مقدار ۹۹/۹ درصد به دست آمده است. میانگین حساسیت ۹۹/۸ نشان می‌دهد به طور متوسط، فقط یک تصویر کووید به طور نادرست به‌عنوان غیر کووید پیش‌بینی شده است. همچنین مدل پیشنهادی به طور صحیح همه‌ی موارد غیر کووید را فقط با یک مثبت کاذب شناسایی کرده است. بعد از روش پیشنهادی معماری EfficientNetB0 میانگین بهترین عملکرد کلی را

هدف آموزش داده و روی مجموعه داده منبع ارزیابی می‌کنیم. نتایج حاصل را با روش پایه [۲۱] نیز مقایسه می‌کنیم. همین طوری که از این جدول مشخص است روش پیشنهادی زمانی که روی مجموعه داده منبع آموزش می‌بیند و روی مجموعه داده هدف ارزیابی می‌شود نسبت به حالت بر عکس آن عملکرد بهتری دارد. دلیل این موضوع این است که مجموعه داده هدف از نظر اندازه بسیار کوچک‌تر از مجموعه داده منبع است. همچنین داده جمع‌آوری شده در این مجموعه داده از منابع مختلف، در کنتراست مختلف، ویژگی‌های بصری مختلف است. از این جهت یک مجموعه داده مناسب برای آموزش شبکه نیست.

روش مقاله [۲۱] بر روی مجموعه داده‌های بنچمارک نظیر MNIST-M، MNIST ارزیابی شده است، در حالی که روش پیشنهادی ما در حوزه تصاویر کرونا است. در روش پیشنهادی از توابع هدف متفاوت از [۲۱] برای آموزش شبکه استفاده می‌شود. باید به این نکته توجه داشت که شباهت ساختاری بیش از حد تصاویر پزشکی در مقایسه با سایر داده‌های تصویری در حوزه‌ی بینایی ماشین مانند MNIST-M، MNIST (که در مقاله [۲۱] استفاده شده است)، باعث می‌شود دسته‌بندی تصاویر پزشکی به مراتب سخت‌تر از تصاویر بنچمارک باشد. به همین دلیل استفاده از تابع خطا استفاده شده در روش پیشنهادی به تمییز هرچه بهتر کلاس‌ها از یکدیگر کمک شایانی می‌کند.

روشی پیشنهادی از معماری ResNet50 استفاده می‌کند. این معماری دو مزیت دارد: (۱) تعداد پارامتر کمتر و در نتیجه‌ی آن آموزش سریع‌تر نسبت به سایر معماری‌های مطرح، (۲) برای دسته‌بندی تصاویر کرونا نتایج بهتری دارد. در حالی که روش مقاله [۲۱] از معماری‌های قدیمی غیر از ResNet50 استفاده می‌کند مانند LeNet-5 یا معماری‌های تمام متصل که برای دسته‌بندی تصاویر مناسب نیستند (مانند معماری‌های تمام متصل) یا نتایج خوبی بر روی تصاویر کرونا ندارند.

مهم‌ترین مزیت روش پیشنهادی نسبت به مقاله [۲۱] کارایی بهتر الگوریتم پیشنهادی است. به طوری که در ارزیابی بین مجموعه داده‌ای میانگین حاصل شده برای سه معیار Accuracy، Sensitivity و Precision برای روش پیشنهادی ۹۰/۴۶ درصد است. در حالی که در روش [۲۱] با همان معماری استفاده شده در روش پیشنهادی (ResNet50) میانگین حاصل شده ۸۴،۵۵ درصد است؛ بنابراین نتایج روش پیشنهادی نسبت به روش ۱۶ به طور نزدیک به ۷ درصد بهبود یافته است.

از این آزمایش نتیجه می‌گیریم روش پیشنهادی مستقل از مجموعه داده منبع عمل کرده و کارایی بهتری هم برای مجموعه داده منبع و هم مجموعه داده هدف دارد. تکنیک یادگیری انتقالی متخاصم چند منبعی پیشنهادی توانست به خوبی

می‌شود الگوریتم پیشنهادی در مقایسه با سایر معماری‌های یادگیری عمیق و روش‌های مقایسه شده بهترین عملکرد را دارد. رویکرد پیشنهادی در مقایسه با سایر روش‌ها و مدل‌ها به‌ازای تمامی معیارهای ارزیابی، بهترین عملکرد را دارد به طوری که به‌ازای معیارهای Sensitivity، Accuracy، Specificity و F1-score به ترتیب مقدار ۹۵/۹، ۹۴/۸، ۹۶/۱ و ۹۵/۱ درصد به دست آمده است. میانگین حساسیت ۹۴/۸ درصد نشان می‌دهد به طور متوسط، ۶ تصویر کووید به طور نادرست به‌عنوان غیر کووید پیش‌بینی شده است. همچنین میانگین ۹۶ Specificity نشان می‌دهد همه‌ی موارد غیر کووید را فقط با ۵ نمونه مثبت کاذب شناسایی می‌کند.

بعد از روش پیشنهادی معماری‌های ResNet-50، ResNeXt-101 و ResNeXt-50 میانگین بهترین عملکرد کلی را به‌ازای تمامی معیارها دارند. در این معماری‌ها میانگین حساسیت ۹۲/۱۶ درصد نشان می‌دهد به طور متوسط، بیش از ۱۲ تصویر کووید به طور نادرست به‌عنوان غیر کووید پیش‌بینی شده است. همچنین میانگین Specificity ۹۰/۲ درصد نشان می‌دهد همه‌ی موارد غیر کووید با ۱۵ نمونه مثبت کاذب شناسایی می‌کند. بعد از معماری‌های مذکور، روش‌های DenseNet-201، DenseNet-169، بهترین میانگین نتایج را دارند. در میان نتایج گزارش شده بدترین نتیجه مربوط AlexNet است.

با مقایسه دو جدول ۳ و ۴ مشاهده می‌شود متوسط نتایج تمامی روش‌ها در جدول ۴ (مجموعه داده هدف) تقریباً ۵ درصد کمتر از جدول ۳ (مجموعه داده منبع) است. دلیل این موضوع کوچک‌تر بودن مجموعه داده هدف نسبت به مجموعه داده منبع است. روش‌های بر پایه یادگیری عمیق برای یادگیری بازنمایی‌های بهتر نیاز به داده‌های زیاد دارند. از طرفی زمانی که شبکه بر روی مجموعه داده کوچک آموزش داده می‌شود، تعمیم‌پذیری روش پیشنهادی نیز کاهش می‌یابد. در جدول ۴ مشاهده می‌شود روش‌های بر پایه معماری‌های مختلف ResNet عملکرد بالایی نسبت به سایر روش‌ها دارند. دلیل موفقیت معماری‌های ResNet این است که به ما امکان آموزش شبکه‌های عصبی بسیار عمیق با لایه‌های بیشتر را می‌دهند. قبل از ResNet شبکه‌های عصبی بسیار عمیق، به دلیل مشکل محوشدگی گرادیان، دچار مشکل می‌شدند و وزن‌های لایه‌های اول به درستی آموزش نمی‌دیدند.

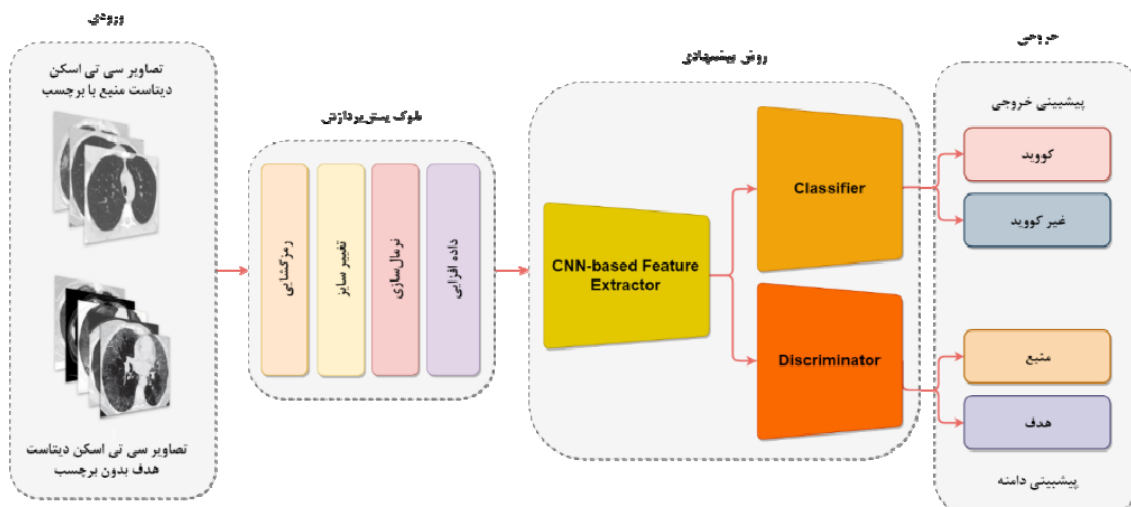
۴-۶- آزمایش ۳: ارزیابی بین مجموعه داده‌ای

در این آزمایش روش پیشنهادی را ابتدا بدون رویکرد انطباق دامنه و سپس پس از انطباق دامنه ارزیابی می‌کنیم. این آزمایش را یک بار روی مجموعه داده منبع آموزش داده و روی مجموعه داده هدف ارزیابی می‌کنیم و بار دیگر روی مجموعه داده

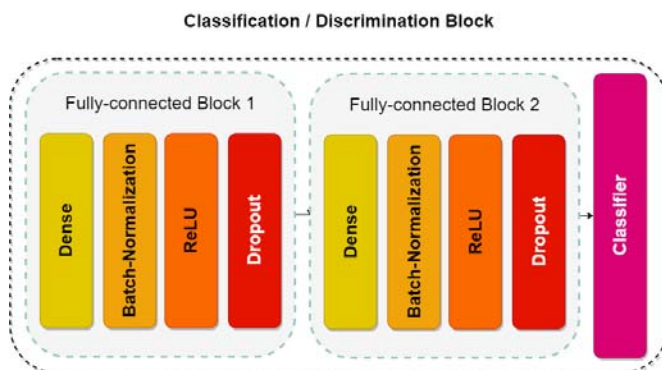
ویژگی‌های مشترک بین دو مجموعه داده را یاد بگیرد. همچنین مشاهده کردیم با آموزش شبکه روی یک مجموعه داده و آزمایش بر روی یک مجموعه داده دیگر نتایج تقریباً کاملاً تصادفی تولید می‌شود به طوری که دقت حدود ۳۰ درصد کاهش می‌یابد.

۵- نتیجه‌گیری

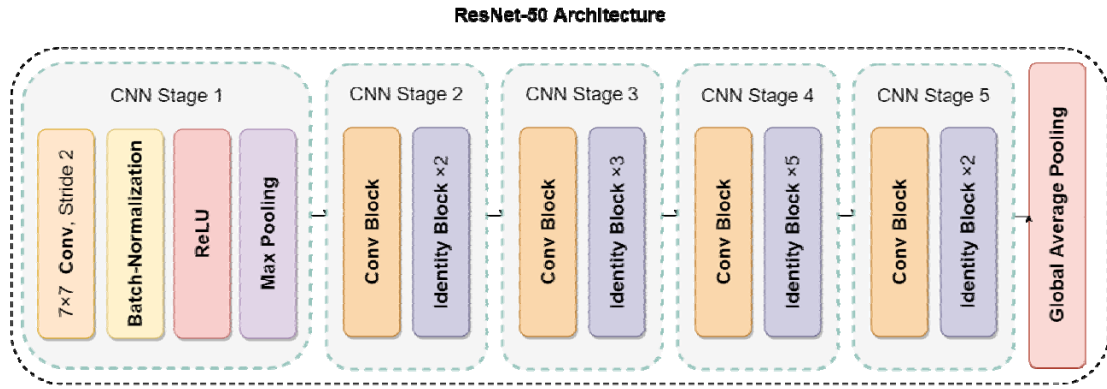
در این تحقیق، ما یک مدل یادگیری انتقالی متخاصم چند منبعی را برای تشخیص بیماری کووید-۱۹ پیشنهاد کردیم، مسئله‌ای که در آن تعمیم‌پذیری مدل به دلیل کمبود داده بسیار کاهش می‌یابد. روش‌های موجود در ادبیات موضوع به دلیل نبود داده‌های کافی نتایج خوبی در داده‌های دیده نشده ندارند؛ بنابراین، آنها در برنامه‌های کاربردی دنیای واقعی قابل اعتماد نیستند. به لطف استفاده از دو منبع مختلف در چارچوب تشخیص کووید ۱۹ پیشنهادی، تضمین می‌شود که بازنمایی‌های آموخته‌شده در بین هر دو مجموعه داده مشترک هستند و مختص دامنه یک مجموعه داده خاص نیستند. به عبارت دیگر در روش پیشنهادی تعمیم‌پذیری و انتقال‌پذیری مدل بهبود یافته و نتایج درخشانی برای داده‌های دیده نشده دارد. عملکرد روش پیشنهادی با بسیاری از مدل‌های پیشرفته مقایسه شد. نتایج نشان داد که روش پیشنهادی قابلیت تعمیم و انتقال بالایی دارد.



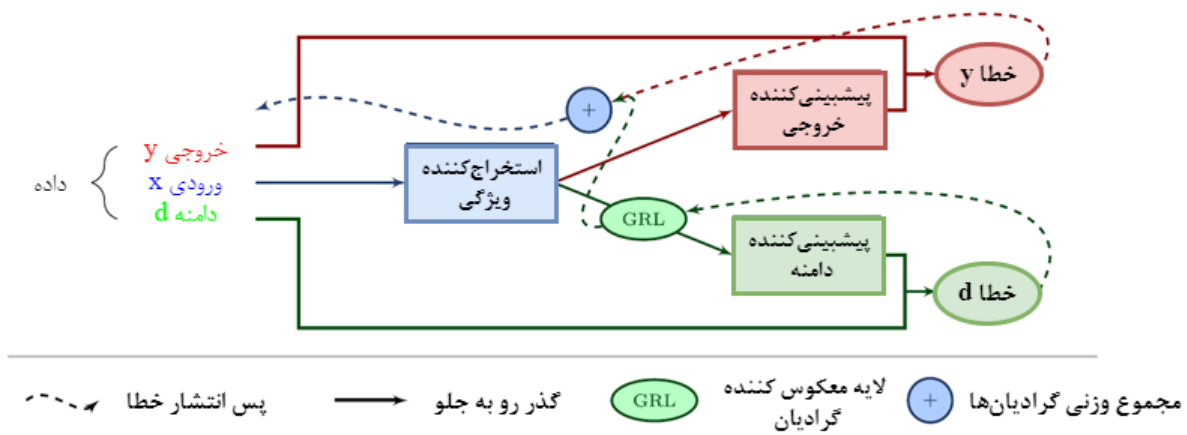
شکل ۱. رویکرد کلی مدل پیشنهادی



شکل ۴. بلوک Classifier و discriminator



شکل ۲. معماری ResNet-50



شکل ۳. مدل پیشنهادی را در یک محیط یادگیری انتقال چند منبعی الهام گرفته شده از [۲۱]

جدول ۱. شرح تکنیک‌ها و پارامترهای داده‌افزایی

تغییر	بازه/نوع
درخشندگی	۲۰٪ تا -۲۰٪
کنتراست	۲۰٪ تا -۲۰٪
چرخش (Rotation)	۲۰ تا +۲۰ درجه
چرخش (Flip)	افقی

جدول ۲. جزئیات مجموعه داده‌های COVID-19-CT و SARS-CoV-2 CT Scan

مجموعه داده	تعداد نمونه	تعداد نمونه‌های کووید ۱۹	تعداد نمونه‌های غیر کووید ۱۹	سایز تصویر
SARS-CoV-2 CT Scan [51, 54] (مجموعه داده منبع)	۲۴۸۲	۱۲۵۲	۱۲۳۰	۱۱۹ × ۱۰۴ ۴۱۶ × ۵۱۲
COVID-19-CT [52] (مجموعه داده هدف)	۷۴۶	۳۴۹	۳۹۷	۱۲۴ × ۱۵۳ ۱۴۸۵ × ۱۸۵۳

جدول ۳. ارزیابی روی مجموعه داده منبع SARS-CoV-2 CT Scan

متد/روش	معیارهای ارزیابی			
	Accuracy	Precision	Recall	F ₁ -score
AdaBoost	95.1	93.6	96.7	95.1
AlexNet	93.7	94.9	92.2	93.6
Decision Tree	79.4	76.8	83.1	79.8
EfficientNetB0	98.9	99.1	98.9	99.0
GoogleNet	91.7	90.2	93.5	91.8
ResNet50	94.9	93.0	97.1	95.0
ResNet50V2	94.2	92.8	96.7	94.1
ShuffleNet	97.5	96.1	99.0	97.5
SqueezeNet	95.1	94.2	96.2	95.2
VGG-16	94.9	94.0	95.4	94.9
Xception	98.8	99.0	98.6	98.8
Contrastive Learning [31]	90.8	95.7	85.8	90.8
COVID CT-Net [60]	90.7	88.5	85.0	90.0
DenseNet201-Based [47]	96.2	96.2	96.2	96.2
ed VGG19 [61] Modi	95.0	95.3	94.0	94.3
xDNN [51]	97.3	99.1	95.5	97.3
روش پیشنهادی	99.9	99.9	99.8	99.9

جدول ۴. ارزیابی روی مجموعه داده هدف COVID19-CT

متد/روش	معیارهای ارزیابی			
	Accuracy	Sensitivity	Specificity	F ₁ -score
AlexNet	74.5	70.4	79.0	75.0
DenseNet-121	88.9	88.8	88.9	88.2
DenseNet-169	91.2	93.3	88.9	90.8
DenseNet-201	91.7	88.6	94.1	91.9
GoogleNet	78.9	75.9	82.3	79.0
Inception-ResNet-v2	86.3	88.1	84.2	87.0
Inception-v3	89.4	90.0	88.9	88.8
MobileNet-v2	87.2	93.2	77.6	89.0
NasNet-Large	85.2	79.3	91.9	84.0
NasNet-Mobile	83.4	84.8	81.9	85.0
ResNet-101	89.7	82.2	89.2	89.0
ResNet-18	90.1	89.4	90.9	91.0
ResNet-50	90.8	90.0	91.0	90.1

ResNeXt-101	90.9	93.1	88.9	90.6
ResNeXt-50	90.6	93.4	88.2	90.3
ShuffleNet	86.1	83.5	89.0	86.0
SqueezeNet	78.5	86.5	63.8	82.0
VGG-16	78.5	74.6	82.8	76.0
VGG-19	83.2	90.7	74.7	85.0
Xception	85.6	88.3	80.6	87.7
Contrastive Learning [31]	78.6	78.0	77.0	78.8
Decision function [6]	88.3	87.0	87.9	86.7
DenseNet-121+SVM [62]	85.9	84.9	86.8	86.2
DenseNet-169-Based [52]	83.0	84.8	85.5	81.0
DenseNet-169-Based [63]	87.7	85.6	86.9	87.8
ResNet-101-Based [64]	80.3	85.7	86.0	81.8
روش پیشنهادی	95.9	94.8	96.1	95.1

جدول ۵. ارزیابی بین مجموعه داده‌ای (آموزش بر روی مجموعه داده SARS-CoV-2 CT Scan و ارزیابی روی مجموعه داده COVID19-CT و برعکس)

روش	مجموعه داده آموزش	مجموعه داده آزمایش	معیارهای ارزیابی		
			Accuracy	Sensitivity	Precision
روش [۲۱]	منبع	هدف (مجموعه آموزش)	86.56	87.32	87.48
	منبع	هدف (مجموعه آزمایش)	85.65	86.91	86.42
	منبع	هدف (کل مجموعه داده)	87.85	88.12	87.15
	هدف	منبع	75.48	79.21	76.51
روش پیشنهادی (بدون تطبیق دامنه)	منبع	هدف (مجموعه آموزش)	65.11	66.16	65.21
	منبع	هدف (مجموعه آزمایش)	63.01	64.09	62.06
	منبع	هدف (کل مجموعه داده)	64.28	65.19	66.50
	هدف	منبع	58.01	60.30	57.10
روش پیشنهادی (با تطبیق دامنه)	منبع	هدف (مجموعه آموزش)	91.61	92.88	92.32
	منبع	هدف (مجموعه آزمایش)	90.97	91.06	91.84
	منبع	هدف (کل مجموعه داده)	92.79	93.59	92.65
	هدف	منبع	83.23	87.57	84.10

- [2] M. Ghaderzadeh, F. Asadi, R. Jafari, D. Bashash, H. Abolghasemi, and M. Aria, "Deep Convolutional Neural Network-Based Computer-Aided Detection System for COVID-19 Using Multiple Lung Scans: Design and Implementation Study," *J Med Internet Res*, vol. 23, no. 4, p. e27468, 2021/4/26 2021, doi: 10.2196/27468.
- [3] M. Aria, E. Nourani, and A. Golzari Oskouei, "ADA-COVID: Adversarial Deep Domain Adaptation-Based

مراجع

- [1] P. Silva et al., "COVID-19 detection in CT images with deep learning: A voting-based scheme and cross-datasets analysis," *Informatics in Medicine Unlocked*, vol. 20, p. 100427, 2020/01/01/ 2020, doi: <https://doi.org/10.1016/j.imu.2020.100427>.

- model for B-ALL diagnosis and its subtypes classification using peripheral blood smear images," *International Journal of Intelligent Systems*, vol. 37, no. 8, pp. 5113–5133, 2022, doi: <https://doi.org/10.1002/int.22753>.
- [16] S. Christodoulidis, M. Anthimopoulos, L. Ebner, A. Christe, and S. Mougiakakou, "Multisource transfer learning with convolutional neural networks for lung pattern analysis," *IEEE journal of biomedical and health informatics*, vol. 21, no. 1, pp. 76–84, 2016.
- [17] E. Tartaglione, C. A. Barbano, C. Berzovini, M. Calandri, and M. Grangetto, "Unveiling covid-19 from chest x-ray with deep learning: a hurdles race with small data," *International Journal of Environmental Research and Public Health*, vol. 17, no. 18, p. 6933, 2020.
- [18] S. Tabik et al., "COVIDGR dataset and COVID-SDNet methodology for predicting COVID-19 based on Chest X-Ray images," *IEEE Journal of Biomedical and Health Informatics*, vol. 24, no. 12, pp. 3595–3605, 2020.
- [19] 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*, vol. 10, no. 1, pp. 1–12, 2020.
- [20] P. Afshar, S. Heidarian, F. Naderkhani, A. Oikonomou, K. N. Plataniotis, and A. Mohammadi, "COVID-CAPS: A capsule network-based framework for identification of COVID-19 cases from X-ray images," *Pattern Recognition Letters*, vol. 138, pp. 638–643, 2020/10/01/ 2020, doi: <https://doi.org/10.1016/j.patrec.2020.09.010>.
- [21] Y. Ganin et al., "Domain-adversarial training of neural networks," *The journal of machine learning research*, vol. 17, no. 1, pp. 2096–2030, 2016.
- [22] P. Rajpurkar et al., "Chexnet: Radiologist-level pneumonia detection on chest x-rays with deep learning," *arXiv preprint arXiv:1711.05225*, 2017.
- [23] L. Li et al., "Using artificial intelligence to detect COVID-19 and community-acquired pneumonia based on pulmonary CT: evaluation of the diagnostic accuracy," *Radiology*, vol. 296, no. 2, pp. E65–E71, 2020.
- [24] X. Xu et al., "A deep learning system to screen novel coronavirus disease 2019 pneumonia," *Engineering*, vol. 6, no. 10, pp. 1122–1129, 2020.
- [25] C. Zheng et al., "Deep learning-based detection for COVID-19 from chest CT using weak label," *MedRxiv*, 2020.
- [26] F. Shan et al., "Lung infection quantification of COVID-19 in CT images with deep learning," *arXiv preprint arXiv:2003.04655*, 2020.
- [27] M. Hasan, M. Alam, M. Elahi, E. Toufick, S. Roy, and S. R. Wahid, "CVR-Net: A deep convolutional neural network for coronavirus recognition from chest radiography images," *arXiv preprint arXiv:2007.11993*, 2020.
- Diagnosis of COVID-19 from Lung CT Scans Using Triplet Embeddings," *Computational Intelligence and Neuroscience*, vol. 2022, p. 2564022, 2022/02/08 2022, doi: 10.1155/2022/2564022.
- [4] M.-Y. Ng et al., "Imaging profile of the COVID-19 infection: radiologic findings and literature review," *Radiology: Cardiothoracic Imaging*, vol. 2, no. 1, p. e200034, 2020.
- [5] M. Ghaderzadeh and M. Aria, "Management of Covid-19 Detection Using Artificial Intelligence in 2020 Pandemic," presented at the 2021 5th International Conference on Medical and Health Informatics, Kyoto, Japan, 2021. [Online]. Available: <https://doi.org/10.1145/3472813.3472820>.
- [6] A. K. Mishra, S. K. Das, P. Roy, and S. Bandyopadhyay, "Identifying COVID19 from chest CT images: a deep convolutional neural networks based approach," *Journal of Healthcare Engineering*, vol. 2020, 2020.
- [7] M. Ghaderzadeh, M. Aria, and F. Asadi, "X-Ray Equipped with Artificial Intelligence: Changing the COVID-19 Diagnostic Paradigm during the Pandemic," *BioMed Research International*, vol. 2021, p. 9942873, 2021/08/26 2021, doi: 10.1155/2021/9942873.
- [8] M. Polsinelli, L. Cinque, and G. Placidi, "A light CNN for detecting COVID-19 from CT scans of the chest," *Pattern recognition letters*, vol. 140, pp. 95–100, 2020.
- [9] A. Esteva et al., "Dermatologist-level classification of skin cancer with deep neural networks," *Nature*, vol. 542, no. 7639, pp. 115–118, 2017/02/01 2017, doi: 10.1038/nature21056.
- [10] D. Wang, A. Khosla, R. Gargeya, H. Irshad, and A. H. Beck, "Deep learning for identifying metastatic breast cancer," *arXiv preprint arXiv:1606.05718*, 2016.
- [11] F. Wang, L. P. Casalino, and D. Khullar, "Deep Learning in Medicine—Promise, Progress, and Challenges," *JAMA Internal Medicine*, vol. 179, no. 3, pp. 293–294, 2019, doi: 10.1001/jamainternmed.2018.7117.
- [12] N. Dhungel, G. Carneiro, and A. P. Bradley, "A deep learning approach for the analysis of masses in mammograms with minimal user intervention," *Medical Image Analysis*, vol. 37, pp. 114–128, 2017/04/01/ 2017, doi: <https://doi.org/10.1016/j.media.2017.01.009>.
- [13] H. Altae-Tran, B. Ramsundar, A. S. Pappu, and V. Pande, "Low data drug discovery with one-shot learning," *ACS central science*, vol. 3, no. 4, pp. 283–293, 2017.
- [14] Y. Bar, I. Diamant, L. Wolf, and H. Greenspan, "Deep learning with non-medical training used for chest pathology identification," in *Medical Imaging 2015: Computer-Aided Diagnosis*, 2015, vol. 9414: International Society for Optics and Photonics, p. 94140V.
- [15] M. Ghaderzadeh, M. Aria, A. Hosseini, F. Asadi, D. Bashash, and H. Abolghasemi, "A fast and efficient CNN

- 19 from chest X-ray images using deep transfer learning," *Medical Image Analysis*, vol. 65, p. 101794, 2020/10/01/ 2020, doi: <https://doi.org/10.1016/j.media.2020.101794>.
- [41] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2016, pp. 770–778.
- [42] 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.
- [43] 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.
- [44] 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, 2020/11/01/ 2020, doi: <https://doi.org/10.1016/j.cmpb.2020.105608>.
- [45] M. Zhou et al., "Improved deep learning model for differentiating novel coronavirus pneumonia and influenza pneumonia," *medRxiv*, 2020.
- [46] Y. Song et al., "Deep learning enables accurate diagnosis of novel coronavirus (COVID-19) with CT images," *IEEE/ACM transactions on computational biology and bioinformatics*, vol. 18, no. 6, pp. 2775–2780, 2021.
- [47] A. Jaiswal, N. Gianchandani, D. Singh, V. Kumar, and M. Kaur, "Classification of the COVID-19 infected patients using DenseNet201 based deep transfer learning," *Journal of Biomolecular Structure and Dynamics*, pp. 1–8, 2020, doi: 10.1080/07391102.2020.1788642.
- [48] L. Li et al., "Artificial intelligence distinguishes COVID-19 from community acquired pneumonia on chest CT," *Radiology*, 2020.
- [49] R. M. Pereira, D. Bertolini, L. O. Teixeira, C. N. Silla, and Y. M. G. 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, 2020/10/01/ 2020, doi: <https://doi.org/10.1016/j.cmpb.2020.105532>.
- [50] D. Al-Karawi, S. Al-Zaidi, N. Polus, and S. Jassim, "Machine learning analysis of chest CT scan images as a complementary digital test of coronavirus (COVID-19) patients," *MedRxiv*, 2020.
- [51] P. Angelov and E. Almeida Soares, "SARS-CoV-2 CT-scan dataset: A large dataset of real patients CT scans for SARS-CoV-2 identification," *MedRxiv*, 2020.
- [52] X. He et al., "Sample-efficient deep learning for COVID-19 diagnosis based on CT scans," *medrxiv*, 2020.
- [28] M. Farooq and A. Hafeez, "Covid-resnet: A deep learning framework for screening of covid19 from radiographs," *arXiv preprint arXiv:2003.14395*, 2020.
- [29] 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, 2020/11/01/ 2020, doi: <https://doi.org/10.1016/j.cmpb.2020.105581>.
- [30] S. Toraman, T. B. Alakus, and I. Turkoglu, "Convolutional capsnet: 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.
- [31] Z. Wang, Q. Liu, and Q. Dou, "Contrastive cross-site learning with redesigned net for covid-19 ct classification," *IEEE Journal of Biomedical and Health Informatics*, vol. 24, no. 10, pp. 2806–2813, 2020.
- [32] T. Javaheri et al., "Covidctnet: An open-source deep learning approach to identify covid-19 using ct image," *arXiv preprint arXiv:2005.03059*, 2020.
- [33] A. Amyar, R. Modzelewski, H. Li, and S. Ruan, "Multi-task deep learning based CT imaging analysis for COVID-19 pneumonia: Classification and segmentation," *Computers in Biology and Medicine*, vol. 126, p. 104037, 2020.
- [34] D. Singh, V. Kumar, and M. Kaur, "Classification of COVID-19 patients from chest CT images using multi-objective differential evolution-based convolutional neural networks," *European Journal of Clinical Microbiology & Infectious Diseases*, vol. 39, no. 7, pp. 1379–1389, 2020.
- [35] 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, 2020/06/01 2020, doi: 10.1007/s13246-020-00865-4.
- [36] K. Simonyan and A. Zisserman, "Very deep convolutional networks for large-scale image recognition," *arXiv preprint arXiv:1409.1556*, 2014.
- [37] A. G. Howard et al., "Mobilenets: Efficient convolutional neural networks for mobile vision applications," *arXiv preprint arXiv:1704.04861*, 2017.
- [38] C. Szegedy, S. Ioffe, V. Vanhoucke, and A. A. Alemi, "Inception-v4, inception-resnet and the impact of residual connections on learning," in *Thirty-first AAAI conference on artificial intelligence*, 2017.
- [39] 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.
- [40] S. Minaee, R. Kafieh, M. Sonka, S. Yazdani, and G. Jamalipour Soufi, "Deep-COVID: Predicting COVID-

- [64] M. Saqib, S. Anwar, A. Anwar, and M. Blumenstein, "COVID19 detection from Radiographs: Is Deep Learning able to handle the crisis?," TechRxiv, 2020.
- هادی الحارس دانشجوی سال آخر دکتری مهندسی کامپیوتر گرایش نرم افزار در دانشگاه تبریز است. زمینه های پژوهشی ایشان یادگیری ماشین، پردازش تصویر و بینایی ماشین است.
- جعفر تنها مدرک دکتری خود را از دانشگاه آمستردام هلند دریافت کرده و در حال حاضر دانشیار دانشکده مهندسی برق و کامپیوتر، دانشگاه تبریز، ایران است. در حال حاضر ایشان در زمینه های تحقیقاتی زیر در حال مطالعه و تحقیق هستند: یادگیری بدون نظارت، پردازش داده ها نامتعادل، یادگیری نیمه نظارت شده.
- محمدعلی بالافر در حال حاضر استاد تمام دانشکده مهندسی برق و کامپیوتر، دانشگاه تبریز، ایران است. از سال ۱۳۹۱ ایشان سرپرست آزمایشگاه تحقیقاتی فناوری اطلاعات و چندرسانه ای هوشمند است. زمینه های تحقیقاتی ایشان هوش مصنوعی، یادگیری ماشین، تشخیص الگو و بینایی ماشین است.
- [53] Y. Wen, K. Zhang, Z. Li, and Y. Qiao, "A discriminative feature learning approach for deep face recognition," in European conference on computer vision, 2016: Springer, pp. 499-515.
- [54] E. Soares, P. Angelov, S. Biaso, M. H. Froes, and D. K. Abe, "SARS-CoV-2 CT-scan dataset: A large dataset of real patients CT scans for SARS-CoV-2 identification," medRxiv, 2020.
- [55] A. Golzari Oskouei, M. A. Balafar, and C. Motamed, "EDCWRN: efficient deep clustering with the weight of representations and the help of neighbors," Applied Intelligence, 2022/07/05 2022, doi: 10.1007/s10489-022-03895-5.
- [56] A. Golzari Oskouei, M. A. Balafar, and C. Motamed, "FKMAWCW: Categorical fuzzy k-modes clustering with automated attribute-weight and cluster-weight learning," Chaos, Solitons & Fractals, vol. 153, p. 111494, 2021/12/01/ 2021, doi: <https://doi.org/10.1016/j.chaos.2021.111494>.
- [57] A. Golzari Oskouei and M. Hashemzadeh, "CGFFCM: A color image segmentation method based on cluster-weight and feature-weight learning," Software Impacts, vol. 11, p. 100228, 2022/02/01/ 2022, doi: <https://doi.org/10.1016/j.simpa.2022.100228>.
- [58] A. Golzari Oskouei, M. Hashemzadeh, B. Asheghi, and M. A. Balafar, "CGFFCM: Cluster-weight and Group-local Feature-weight learning in Fuzzy C-Means clustering algorithm for color image segmentation," Applied Soft Computing, vol. 113, p. 108005, 2021/12/01/ 2021, doi: <https://doi.org/10.1016/j.asoc.2021.108005>.
- [59] M. Hashemzadeh, A. Golzari Oskouei, and N. Farajzadeh, "New fuzzy C-means clustering method based on feature-weight and cluster-weight learning," Applied Soft Computing, vol. 78, pp. 324-345, 2019/05/01/ 2019, doi: <https://doi.org/10.1016/j.asoc.2019.02.038>.
- [60] S. Yazdani, S. Minaee, R. Kafieh, N. Saeedizadeh, and M. Sonka, "Covid ct-net: Predicting covid-19 from chest ct images using attentional convolutional network," arXiv preprint arXiv:2009.05096, 2020.
- [61] H. Panwar, P. Gupta, M. K. Siddiqui, R. Morales-Menendez, P. Bhardwaj, and V. Singh, "A deep learning and grad-CAM based color visualization approach for fast detection of COVID-19 cases using chest X-ray and CT-Scan images," Chaos, Solitons & Fractals, vol. 140, p. 110190, 2020.
- [62] A. S. Jokandan et al., "An uncertainty-aware transfer learning-based framework for covid-19 diagnosis," arXiv preprint arXiv:2007.14846, 2020.
- [63] A. R. Martinez, "Classification of covid-19 in ct scans using multi-source transfer learning," arXiv preprint arXiv:2009.10474, 2020.