



تشخیص Covid-19 بر اساس داده های تصویری X-ray و CT با استفاده از الگوریتم شبکه عمیق U-Net

سعید مهرجو^۱، فاطمه سرنامه^۲

۱- گروه کامپیوتر، واحد داریون، دانشگاه آزاد اسلامی، شیراز، ایران.

۲- دانشجوی مهندسی نرم افزار، گروه کامپیوتر، مؤسسه آموزش عالی پیشتازان، شیراز، ایران.

چکیده

در این پژوهش هدف رفع کردن عدم تعادل داده های تصویری است. روش های هوشمند مصنوعی به تعداد زیادی تصویر نیاز دارند. با این حال، در طول یک بیماری همه گیر امکان پذیر نیست. مراحل انجام روش پیشنهادی شامل سه مرحله با گام های متفاوتی است، که این مراحل شامل: ۱-افزایش داده ها ۲-پیش پردازش داده ها ۳-پردازش داده ها. در این مطالعه یک شبکه عمیق کارآمد با پیش پردازش های به خصوص پیشنهاد شده است. نتایج روند پیشنهادی نشان می دهد که این روند نتایج مناسبی را داشته است. هدف از این مطالعه تشخیص بیماری COVID-19 با استفاده از بهبود شبکه عمیق U-Net، استفاده از رویکردهای یادگیری عمیق برای تشخیص عفونت، شناسایی تفاوت های تصاویر عفونت های متفاوت با عفونت کرونا، قدرت تشخیص بیماری COVID-19 با استفاده از رویکردهای یادگیری عمیق. با توجه به این که در این روند از روند الگوریتمیک برای شناسایی بیماری کرونا از روی تصاویر ایجاد شده صورت می گیرد. هدف این است که به صورت معنایی ویژگی های متمایز یا رزولوشن پایین آموخته شده توسط رمزگذار بر روی فضای پیکسل (رزولوشن بالاتر) نمایش داده شود تا یک طبقه بندی متراکم به دست آید. رمزگشا از نمونه برداری و الحاق و به دنبال آن عملیات کانولوشن منظم تشکیل شده است. در این پژوهش از این الگوریتم استفاده شده است و نتایج نشان دهنده برتری رویکرد پیشنهادی است.

کلمات کلیدی: تشخیص ویروس کرونا، داده های تصویری، الگوریتم شبکه عمیق

۱. مقدمه

بیماری covid-19 تأثیرات زیان باری بر سلامت و رفاه جمعیت سراسری، ناشی از آلودگی افراد به سندرم حاد تنفسی SARS-COV-2 داشته است. یک گام مهم در مبارزه با ویروس کرونا غربالگری موثر بیماران آلوده است [۱-۲]. به طوری که افراد مبتلا بتوانند تحت درمان و مراقبت فوری قرار گیرند و همچنین برای کاهش شیوع ویروس از دیگران جدا شوند. روش



هشتمین کنفرانس بین‌المللی ترکیبیات، رمزنگاری، علوم کامپیوتر و محاسبات

۲۴ و ۲۵ آبان ۱۴۰۲



اصلی غربالگری مورد استفاده برای تشخیص ویروس covid-19، آزمایش RT-PCR گرفته می‌شود که می‌تواند SARS-COV-2 ریبونوکلیتیک اسید RNA را از نمونه‌های تنفسی (جمع‌آوری شده از طریق روش‌های مختلف) شناسایی کند. تست RT-PCR بسیار خاص است، اما فرآیند دستی بسیار زمان‌بر، پر زحمت و پیچیده‌ای دارد. علاوه بر این مورد، حساسیت آزمایش RT-PCR بسیار متغیر است و تا به امروز به شیوه‌ای واضح و ثابت گزارش نشده است و یافته‌های اولیه در چین نتایج خروجی ضعیفی را نشان می‌دهد [۳]. علاوه بر این، یافته‌های پژوهشگران، میزان تاثیر مثبت با شرایط بسیار متغیر، بسته به نحوه جمع‌آوری نمونه و همچنین کاهش نرخ مثبت شناسایی در زمان شروع علائم را نشان می‌دهد [۴].

یک روش غربالگری جایگزین که برای غربالگری covid-19 نیز استفاده می‌شود، معاینه رادیوگرافی است، که در آن تصویربرداری رادیوگرافی قفسه سینه (به عنوان مثال، تصویربرداری با اشعه ایکس قفسه سینه CXR یا تصویربرداری توموگرافی کامپیوتری CT توسط رادیولوژیست‌ها انجام و تجزیه و تحلیل می‌شود. در مطالعات اولیه مشخص شد که ناهنجاری‌هایی در تصاویر رادیوگرافی قفسه سینه بیماران وجود دارد که مشخصه افراد مبتلا به ویروس کرونا است، معاینه رادیوگرافی می‌تواند به عنوان ابزار اولیه برای غربالگری covid-19 در مناطق اپیدمی استفاده شود. به عنوان مثال، هانگ^۱ و همکاران [۵] در مطالعه خود شناسایی کردند که اکثر موارد مثبت COVID-19 ناهنجاری‌های رادیوگرافی در تصاویر CXR دارند و گان^۲ و همکاران [۶] موارد مثبت کوید را در مطالعه خود شناسایی کردند. با این حال، با توجه به امکانات موجود در رابطه با تصویربرداری و شناسایی موارد مبتلا به کرونا بر اساس تصاویر توموگرافی کامپیوتری، یکی از بزرگترین چالش‌هایی که وجود دارد نیاز به رادیولوژیست‌های خبره برای تفسیر تصاویر رادیوگرافی است، زیرا شاخص‌های بصری می‌توانند حساس باشند. به این ترتیب، سیستم‌های تشخیصی به کمک رایانه، می‌توانند به رادیولوژیست‌ها کمک کنند تا تصاویر رادیوگرافی را سریع‌تر و دقیق‌تر تفسیر کنند تا نمونه‌های ویروس covid-19 را شناسایی کنند و این مسئله بسیار ضروری است. بنابراین در این پژوهش به تشخیص covid-19 بر اساس داده‌های تصویری با استفاده از الگوریتم شبکه عمیق U-Net پرداخته شد. در میان الگوریتم‌های یادگیری عمیق، الگوریتم U-Net بدلیل پاسخ دقیق، دقت بالا، سرعت بالای پردازش و یادگیری، عدم نیاز به مجموعه داده‌های بزرگ برای یادگیری و عدم نیاز به سخت‌افزارهای پیچیده و گران قیمت، در چند سال اخیر به الگوریتم محبوب شناسایی اجزای تصویر و قطعه‌بندی کردن آنها در پردازش تصاویر پزشکی بدل شده است. مدل U-Net چندین مزیت را برای وظایف بخش‌بندی ارائه می‌کند: اول، این مدل امکان استفاده از مکان و زمینه سراسری را به طور همزمان فراهم می‌کند. دوم، با نمونه‌های آموزشی بسیار کمی کار می‌کند و عملکرد بهتری را برای وظایف تقسیم‌بندی ارائه می‌دهد [۷].

مهم‌ترین چالشی که در این مسئله وجود دارد میزان دقت پایین است که به دلیل استخراج ویژگی تصویری است که در روند مقاله پایه به آن توجه نشده است، چالش دومی که در این پژوهش وجود دارد عدم توجه به تعادل در داده‌ها است که منجر به بی‌ثباتی در قوانین ایجاد شده می‌شود. روش‌های یادگیری عمیق فعلی از یک معماری شبکه کاملاً کانولوشن FCN هستند، در آن لایه‌های کاملاً متصل با لایه‌های کانولوشن جایگزین می‌شوند. U-Net یک نوع FCN پرکاربرد است که به دلیل اتصالات چند مقیاسی و لایه‌های کانولوشن بالا خروجی‌های مناسبی دارد.

بنابراین در این مقاله هدف رفع کردن عدم تعادل داده‌های تصویری است. تابع مرکزی که نوعی تابع آنتروپی است با یک توان تعدیل‌کننده تغییر خواهیم داد که با تغییر تابع مرکزی مانع از تمرکز تعداد زیادی از نمونه‌های بیشتر موجود در مجموعه داده خواهیم شد که عدم تعادل داده کاهش می‌یابد.

¹ Huang

² Guan



هشتمین کنفرانس بین‌المللی ترکیبیات، رمزنگاری، علوم کامپیوتر و محاسبات

۲۴ و ۲۵ آبان ۱۴۰۲



با توجه به همه‌گیری ویروس کرونا نیاز سریعی به توسعه راه‌حل‌هایی برای کمک به مبارزه با همه‌گیریکوید ۱۹، با دسترسی به داده‌های جدید جامعه تحقیقاتی در کاوش در کارآیی سیستم‌های هوش مصنوعی با استفاده از سیستم‌های شناسایی ویروس ضروری است. با توجه به حساس بودن و نیاز به خبرگان متفاوت برای شناسایی این ویروس با استفاده از تصاویر ارائه رویکردهایی برای شناسایی بسیار ضروری است.

۲. روش کار

مراحل انجام کار در این مقاله شامل سه مرحله با گام‌های متفاوتی است، که در ادامه این مراحل مطرح شده است:

۱- افزایش داده‌ها

۲- پیش‌پردازش داده‌ها

۳- پردازش داده‌ها

مرحله اول: افزایش داده

کمبود مجموعه داده در حوزه تصاویر پردازشی مشکلی است که شاید باعث عدم پیشرفت این حوزه شود. همانطور که بدیهی است، هر چه یک الگوریتم به داده‌های بیشتری دسترسی داشته باشد، (حتی زمانی که داده‌ها کیفیت پایین تری دارند) می‌تواند موثرتر باشد. در این صورت الگوریتم‌ها می‌توانند عملکرد بهتری داشته باشند و پیش‌پردازش‌ها تا زمانی که داده‌های مفید توسط مدل از مجموعه داده‌های اصلی استخراج شود، صورت می‌گیرد. برای مثال، مدل‌های تبدیل متن به گفتار و مبتنی بر متن به دلیل انتشار یک مجموعه تریلیون کلمه توسط گوگل به طور قابل توجهی بهبود یافته‌اند. این نتیجه نشان‌دهنده این واقعیت است که داده‌ها از صفحات وب فیلتر نشده جمع‌آوری شده و حاوی خطاهای زیادی است. با این حال، با چنین مجموعه داده‌های بزرگ و بدون ساختار، وظیفه یافتن ساختار در دریایی از داده‌های بدون ساختار است. با این حال، رویکردهای جایگزین وجود دارد. بنابراین به جای شروع با مجموعه بسیار بزرگی از داده‌های بدون ساختار و بدون برچسب، می‌توانیم مجموعه کوچکی از داده‌های ساختاریافته را انتخاب کنیم و به گونه‌ای آن را افزایش دهیم که عملکرد مدل‌های طراحی شده بر روی آن افزایش یابد. این رویکرد در مشکلات متعدد مؤثر بوده است. با توجه به حوزه انتخابی افزایش و بهبود داده‌ها در روش‌های متفاوتی صورت گرفته است به عنوان مثال تقویت داده‌ها توسط دانش متخصص، تقویت تصویر عمومی تر، کنترل می‌شود و این کار در طبقه‌بندی تصویر مؤثر نشان داده شده است.

در این روند شبکه پیشنهادی برای انجام یک طبقه‌بندی آموزش داده می‌شود. سپس با استفاده از تکنیک‌های معمولی افزایش داده‌ها و آموزش مجدد مدل‌های خود کار را ادامه می‌دهیم. در مرحله بعد، از CycleGAN برای تقویت داده‌های خود با انتقال سبک‌ها از تصاویر موجود در مجموعه داده به یک تصویر از پیش تعیین شده ثابت استفاده خواهیم کرد. در نهایت، ما نوع متفاوتی از تقویت داده را ایجاد کرده ایم که در آن شبکه عمیق پیشنهادی را که سبک و طبقه‌بندی را منتقل می‌کنند، ترکیب می‌کنیم، بنابراین به جای ترفندهای تقویت استاندارد، شبکه عمیق تقویت‌هایی را می‌آموزد که به بهترین نحو عملکرد طبقه‌بندی را افزایش می‌دهند.



هشتمین کنفرانس بین‌المللی ترکیبیات، رمزنگاری، علوم کامپیوتر و محاسبات

۲۴ و ۲۵ آبان ۱۴۰۲



مشکل مجموعه داده‌های کوچک این است که مدل‌هایی که با آنها آموزش داده شده‌اند، داده‌های اعتبارسنجی و مجموعه تست را به خوبی تعمیم نمی‌دهند. از این رو، این مدل‌ها مشکلات متفاوتی دارند. ساده‌ترین راه می‌تواند اضافه کردن یک پارامتر تنظیم‌کننده به هنجار وزن‌های شبکه باشد. یکی دیگر از تکنیک‌های رایج حذف احتمالی یک نورون از لایه‌های تعیین‌شده در طول تمرین یا حذف اتصال خاص نورون‌ها است. یکی دیگر از روش‌های رایج، نرمال‌سازی دسته‌ای است که لایه‌ها را نرمال می‌کند و به ما اجازه می‌دهد تا وزن‌های نرمال‌سازی را آموزش دهیم. نرمال‌سازی دسته‌ای را می‌توان برای هر لایه در شبکه اعمال کرد و از این رو بسیار مؤثر است حتی زمانی که در شبکه‌های متخاصم مولد مانند CycleGAN استفاده شود. در نهایت، یادگیری انتقال تکنیکی است که در آن ما از قبل آموزش دیده‌ایم. وزن‌های یک شبکه عمیق بر روی برخی داده‌های مشابه یا جامع‌تر آموزش داده شده و پارامترهای خاصی را به‌خوبی تنظیم می‌کنند تا یک مشکل خاص‌تر را به بهترین شکل حل کنند.

افزایش داده‌ها روش دیگری است که ما می‌توانیم برازش بیش از حد را در مدل‌ها کاهش دهیم، بنابراین مقدار داده‌های آموزشی را فقط با استفاده از اطلاعات موجود در داده‌های آموزشی خود افزایش می‌دهیم. رویکرد و روش افزایش داده‌ها جدید نیست و در واقع تکنیک‌های مختلفی برای تقویت داده‌ها برای مشکلات خاص به کار گرفته شده است. تکنیک‌های اصلی در دسته بندی داده‌ها قرار می‌گیرند، که رویکردی است که به دنبال افزایش مستقیم داده‌های ورودی به مدل در فضای داده است.


یک روش بسیار عمومی و پذیرفته شده فعلی برای تقویت داده‌های تصویر، انجام تقویت هندسی و رنگی، مانند انعکاس تصویر، برش و جایگزینی تصویر و تغییر پالت رنگ تصویر است. همه‌ی تبدیل‌ها شکل دهی شبیه به تصویر اصلی هستند که شکل زیر را دارند:

$$=Y Wx +b$$

این ایده در پژوهش‌هایی که نرخ خطا ۰ است، بیشتر انجام شده است. ۳۵٪ با تولید نمونه‌های آموزشی جدید با استفاده از تکنیک‌های تقویت داده‌ها در هر لایه از یک شبکه عمیق به دست آمده است. به طور خاص، داده‌های رقمی با تغییر شکل‌های الاستیک، علاوه بر تبدیل معمولی، افزوده شدند. علاوه بر این، افزایش داده‌ها در ناحیه‌های خارجی تصویر به سادگی ایجاد داده‌های بیشتر قابل استفاده است.

در این بخش از کار هدف نه تنها کاهش بیش از حد برازش از طریق افزایش، بلکه افزایش داده‌ها به گونه‌ای است که طبقه بندی کننده را به بهترین نحو بهبود بخشد. این روش‌ها لزوماً مانند تکنیک‌هایی مانند تبدیل affine یا GAN، تصاویری شبیه مجموعه آموزشی تولید نمی‌کنند. بنابراین، در تلاش نیاز به تبدیل دستی یا همبستگی بین تصاویر تولید شده با روشی مانند GAN و تصویر اصلی است.

تبدیل‌های درون الگوریتمی شامل استفاده از ترکیبی از تبدیل‌های وابسته برای دستکاری داده‌های آموزشی است. برای هر تصویر ورودی، یک تصویر تکراری ایجاد می‌شود که با تغییر، بزرگ‌نمایی/کوچک‌نمایی، چرخاندن، برگرداندن، تحریف یا سایه‌دار شدن با رنگ، تغییر می‌کند. هر دو تصویر و تکرار به شبکه عصبی وارد می‌شوند. برای یک مجموعه داده با اندازه N ، یک مجموعه داده با اندازه N^2 ایجاد می‌شود.



شکل ۱: نمونه ای از تغییرات تصاویر مجموعه داده

برای هر تصویر ورودی، یک سبک تصویر از زیر مجموعه ای از ۶ سبک مختلف انتخاب می کنیم: Cezanne، Van Gogh، Ukiyoe، Monet، Enhance و Winter. یک تغییر شکل از تصویر اصلی ایجاد می شود. هر دو تصویر اصلی و مدل دار برای آموزش شبکه تغذیه می شوند.

در مرحله آموزش، دو بخش شبکه وجود دارد. شبکه تقویت دو تصویر از همان کلاس تصویر ورودی می گیرد و لایه ای به اندازه یک تصویر واحد را برمی گرداند. این لایه به عنوان یک تصویر بهبود یافته در نظر گرفته می شود. سپس تصویر افزوده شده و همچنین تصویر ورودی اصلی به شبکه دوم، شبکه طبقه بندی منتقل می شود. از دست دادن طبقه بندی در انتهای شبکه تقویت محاسبه می شود تا مشخص شود که تصویر تقویت شده چقدر باید شبیه تصویر ورودی باشد. loss کلی حاصل جمع وزنی این دو loss است. هنگامی که تصاویر جدید ایجاد شد، آنها را به یک شبکه عصبی که طبقه بندی می کند وارد می کنیم.

مرحله دوم: پیش پردازش مدل


شکل ۲ (الف تا ج) نمونه هایی از سه تصویر قفسه سینه مربوط به هر مجموعه داده را نشان می دهد. همانطور که در این تصاویر مشهود است، قسمت پایینی تصاویر شامل ناحیه دیافراگمی با شدت بالا یا پیکسل های روشن است که ممکن است تأثیر منفی بر تشخیص الگوهای بالقوه بیماری در نواحی ریه داشته باشد که منجر به تشخیص اشتباه مسئله می شود. از این رو، یک الگوریتم پیش پردازش تصویر را برای شناسایی و حذف ناحیه دیافراگمی که روی تصویر نشان داده شده است، اضافه می کنیم. بر اساس مقاله [۷]، به طور خاص، الگوریتم حداکثر یعنی درخشان ترین $max V$ و حداقل یعنی تاریک ترین $min V$ را تشخیص می دهد، سپس از آستانه ای استفاده می کند که برابر T که برابر با $max V \times 9.0 + min V$ (برای تقسیم تصویر اصلی به یک تصویر باینری است. در مرحله بعد، فیلترهای مورفولوژیکی برای تشخیص اجزای مختلف متصل با شدت (روشنایی) بالاتر در تصویر اعمال می شوند. از بین تمام ناحیه های متصل شناسایی شده، بزرگترین ناحیه در تصویر انتخاب شده و از تصویر حذف می شود زیرا مقدار با شدت بالای پیکسل ها در تصویر به عنوان ناحیه دیافراگم تعریف می شود. این فرآیند برای همه موارد موجود در مجموعه داده اعمال می شود [۱۰].



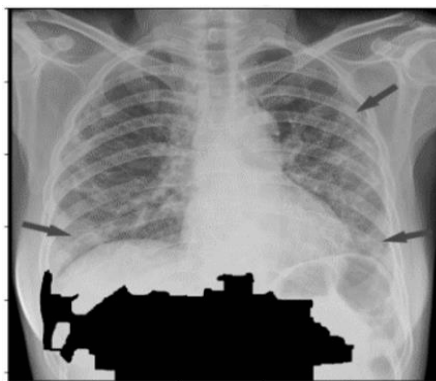
شکل ۲- یک مورد عادی



شکل ۳- یک مورد با ذات‌الریه ویروسی




شکل ۴- یک مورد مبتلا به ویروس کرونا که مناطق مشکوک با فلش قرمز مشخص شده است.



شکل ۵- فرآیند حذف شی با شدت بالا

در مرحله بعدی، تصاویر تقسیم‌بندی شده در مقیاس خاکستری را به تصاویر ۳ کانالی مناسب برای تنظیم دقیق یک مدل شبکه عمیق مبتنی که با استفاده از مجموعه داده آموزش داده شده بود، تبدیل می‌کنیم. برای انجام این کار، به جای کپی کردن تصویر اصلی اشعه ایکس قفسه سینه پس از برداشتن دیافراگم در ۳ کانال مختلف، دو فیلتر نویز تصویر و روش یکسان سازی هیستوگرام را روی تصویر اصلی اعمال می‌کنیم. اول، از آنجایی که تصاویر اشعه ایکس اغلب شامل نویز افزودنی هستند، ما یک فیلتر دو طرفه را اعمال می‌کنیم که یک فیلتر غیر خطی است و در حذف نویز بسیار موثر است و در عین حال اطلاعات بافتی را در مقایسه با سایر فیلترهای پایین گذر حفظ می‌کند. به عبارت دیگر، این فیلتر مقادیر شدت را به صورت محلی تجزیه و تحلیل می‌کند و تغییرات شدت ناحیه محلی را در نظر می‌گیرد تا مقدار شدت هر پیکسل را با مقدار شدت متوسط پیکسل‌ها در ناحیه محلی جایگزین کند. برای محاسبه وزن‌ها، از فیلتر پایین گذر گاوسی در حوزه فضا استفاده می‌کنیم. این مرحله یک تصویر کاهش نویز تولید می‌کند. دوم، تصاویر اشعه ایکس قفسه سینه ممکن است کنتراست یا روشنایی تصویر متفاوتی داشته باشند به دلیل تفاوت در اندازه بدن بیمار و یا تغییر اشعه ایکس ایجاد می‌شود. به منظور جبران چنین تأثیر منفی بالقوه، از یک روش معادله هیستوگرام برای نرمال کردن تصویر استفاده می‌کنیم. بنابراین، اعمال یکسان سازی هیستوگرام به اصلاح کنتراست کمک می‌کند که می‌تواند الگوهای بافت ریه و ویژگی‌های مرتبط با عفونت کرونا ویروس را بهبود بخشد [۱۱].

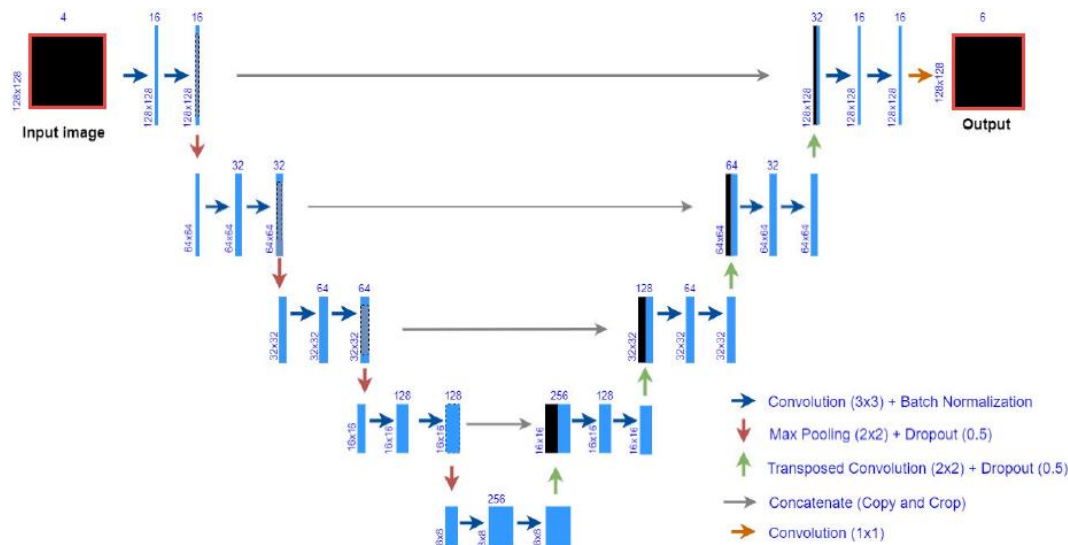
سپس سه تصویر یعنی یک- تصویر اصلی اشعه ایکس قفسه سینه پس از برداشتن ناحیه دیافراگم دوم- تصویر فیلتر شده دو طرفه با استفاده از فیلتر پایین گذر گاوسی و سوم- تصویر عادی شده با استفاده از تساوی هیستوگرام، به ترتیب به سه کانال RGB ورودی مدل پیشنهادی وارد می شود. اندازه تصاویر در هر ۳ کانال به 224×224 پیکسل تغییر داده می شود تا با مدل از پیش آموزش دیده مطابقت داشته باشد. شکل ۶ مراحل پیش پردازش تصویر برای تولید ۳ تصویر را نشان می دهد که به سه کانال از مدل پیشنهادی وارد می شود.



شکل ۶- یک نمودار جریان برای نشان دادن مراحل پیش پردازش تصویر برای تولید ورودی مدل که در آن اول- تصویر اصلی در مجموعه داده دوم- تصویری خروجی پس از اعمال تساوی هیستوگرام و سوم- تصویر خروجی پس از فیلتر دو طرفه

مرحله سوم : پردازش مدل

مدل U-NET برای اولین بار برای تقسیم بندی بر روی تصاویر پزشکی و زمین شناسی توسعه یافت. این مدل شامل یک مسیر انقباضی (در سمت چپ) و یک مسیر انبساطی (در سمت راست) است. مسیر انقباض را می توان به عنوان یک استخراج کننده معمولی مانند مدل های شبکه عصبی کانولوشن معمولی CNN در نظر گرفت. سمت راست مراحل نمونه برداری را انجام می دهد یا مقادیر پیش بینی را به اندازه تصویر اصلی تبدیل می کند. معماری U-NET در شکل ۷ نشان داده شده است.



شکل ۷- معماری U-NET

لایه های U-NET مانند یک شبکه عصبی کانولوشن، به عنوان دنباله ای از لایه های مختلف از نورون های سه بعدی تشکیل شده است که دارای عرض، طول و عمق هستند. عمق تصویر تعداد باندها یا متغیرهای ورودی است. به عنوان مثال، پارامتر عمق تصویر در این مطالعه تعداد مدل رنگی قرمز، سبز، آبی است. بنابراین، سه بعد تصاویر فرعی ورودی $128 \times 128 \times 3$ به ترتیب عرض، ارتفاع، عمق است. نورون های یک لایه با ماتریس های کوچکی از تصاویر فرعی به جای شبیه سازی آنها با کل تصاویر فرعی به یکباره شبیه سازی شدند.

هر لایه از U-NET داده های اصلی را بر اساس یک تابع انتخابی به حالت های جدید تبدیل می کند. شش نوع لایه متوالی که معمولاً برای ساخت معماری های U-NET اعمال می شوند عبارتند از: ۱- لایه ورودی، ۲- لایه کانولوشن CONV، ۳- لایه نرمال سازی دسته ای، ۴- لایه ترکیبی POOL و ۵- الحاق لایه و ۶- لایه حذفی. این شش لایه برای تشکیل یک معماری U-Net کامل به شرح زیر ادغام شدند:

- لایه ورودی برای درج مقادیر پیکسل خام تمام تصاویر فرعی $128 \times 128 \times 3$ به مدل آموزشی استفاده می شود. در این حالت، بعد تصاویر فرعی دارای 128 پیکسل عرض، 128 پیکسل ارتفاع و سه بعد طیفی است.
- لایه های CONV نتایج نورون ها را از طریق مجموعه ای از فیلترها محاسبه می کنند. لایه های CONV استاندارد نتایج جدید را با همان اندازه با ورودی محاسبه می کنند، در حالی که یک ماتریس کانولوشن جابجا شده برای نمونه برداری از یک ماتریس کوچک تر به یک ماتریس بزرگ تر استفاده می شود. وزن و طول فیلتر باید کوچکتر از تصاویر فرعی ورودی باشد. فیلتر روی تصاویر فرعی حرکت می کند و بر روی ناحیه های تصاویر فرعی ورودی انتقال پیدا می کند. با ورودی، مقادیر پیکسل جدید بر اساس توابع فعال سازی انتخاب شده برای فیلترها تعیین می شود در این پژوهش ۱۹ لایه CONV را برای ساخت U-NET انتخاب می کنیم. برای به حداقل رساندن زمان آموزش و اعتبارسنجی، 16 ، 32 ، 64 ، 128 و 256 فیلتر برای ۱۹ لایه CONV انتخاب شدند. عرض و طول هر فیلتر به ترتیب در مقیاس 3×3 است.

- لایه NORMALIZATION BATCH برای عادی سازی خروجی از لایه به همان مقیاس CONV، استفاده می شود. این لایه می تواند تغییرات توزیع مقادیر فعال سازی را در طول فرآیند آموزش به حداقل برساند.

معمولاً به عنوان یک مسئله تغییر متغیر داخلی شناخته می‌شود. هر لایه ورودی با استفاده از پارامتر میانگین (β) و انحراف استاندارد (یا واریانس - γ) مقادیر در دسته فعلی بر اساس فرمول ۱-۳ نرمال می‌شود:

$$y_i = \gamma x_i + \beta \quad (1)$$

γ و β پارامترهای قابل آموزش هستند، X را می‌توان با استفاده از میانگین (μ_B) و واریانس (σ_B) دسته کوچک $\{x_1 \dots x_m\}$ به صورت فرمول ۲-۳ محاسبه کرد:

$$\mu_B = \frac{1}{m} \sum_{i=1}^m x_i \quad (2)$$

$$\sigma_B^2 = \frac{1}{m} \sum_{i=1}^m (x_i - \mu_B)^2 \quad (3)$$

$$x_i = \frac{X_i - \mu_B}{\sqrt{\sigma_B^2 + \epsilon}} \quad (4)$$

در مجموع، نرمال سازی دسته ای شامل چهار پارامتر است که پس از تمام لایه های آموزش CONV داده می‌شود.

- عملیات کاهش مقیاس لایه POOL به ماتریس های فضایی 2×2 ، به ترتیب مانند عرض و ارتفاع صورت می‌گیرد. این لایه همچنین از توابع فعال سازی فرآیند کاهش مقیاس خاص استفاده می‌کند که در ادامه بیان می‌شود.
- لایه CONCATENATE برای الحاق اطلاعات تصویر از مسیر انقباض به مسیر انبساط استفاده می‌شود. با توجه به ساده سازی داده‌های اصلی به داده‌های جدید در طول فرآیند، مدل های U-NET داده‌های لایه‌های قبلی را برای دستیابی به پیش‌بینی دقیق‌تر ترکیب می‌کنند.
- لایه DROPOUT برای غیرفعال کردن تصادفی نورون‌ها در هر مرحله آموزشی به جای آموزش داده‌ها در شبکه اولیه استفاده می‌شود. در طول فرآیند تکراری، نورون‌های غیرضروری را می‌توان غیرفعال کرد تا خطاهای تعمیم و برازش بیش از حد کاهش یابد. مقدار حذف معمولاً ۰.۵ برای نگه داشتن خروجی هر گره در یک لایه پنهان استفاده می‌شود. در مقابل، مقداری نزدیک به ۰.۱ معمولاً برای حفظ ورودی از لایه های قابل مشاهده استفاده می‌شود.

جدول ۱ روش پردازش تصویر معماری U-NET را با ۷۶ لایه نشان می‌دهد. خروجی لایه دیگر داده های ورودی لایه زیر است. ۳۲ لایه اول مسیر انقباض را انجام می‌دهند، در حالی که ۳۶ لایه آخر مسیر انبساط را انجام می‌دهند. تعداد فیلترها در لایه زیر در توسعه U-NET دو برابر لایه قبلی در مسیر انقباض و نیمی از لایه قبلی در مسیر انبساط در مقایسه با مدل های CNN است در شکل ۱-۳، در مقابل، عرض و ارتفاع لایه پیشین در مسیر انقباض، نصف لایه قبلی و در لایه انبساط دو برابر لایه قبلی است.

جدول ۱- ساختار ریاضی U-net توسعه یافته برای طبقه بندی داده ها

| No. | Layer | Output shape | Parameter |
|-----|-------|--------------|-----------|
|-----|-------|--------------|-----------|



هشتمین کنفرانس بین‌المللی
ترکیبیات، رمزنگاری، علوم کامپیوتر و محاسبات
۲۴ و ۲۵ آبان ۱۴۰۲



| | | | |
|----|-----------------------|--------------|---------|
| 1 | InputLayer | 128, 128, 4 | 0 |
| 2 | Conv2D_1 | 128, 128, 16 | 592 |
| 3 | BatchNormalization_1 | 128, 128, 16 | 64 |
| 4 | Activation_1 | 128, 128, 16 | 0 |
| 5 | Conv2D_2 | 128, 128, 16 | 2,320 |
| 6 | BatchNormalization_2 | 128, 128, 16 | 64 |
| 7 | Activation_2 | 128, 128, 16 | 0 |
| 8 | MaxPooling2D_1 | 64, 64, 16 | 0 |
| 9 | Dropout_1 | 64, 64, 16 | 0 |
| 10 | Conv2D_3 | 64, 64, 32 | 4,640 |
| 11 | BatchNormalization_3 | 64, 64, 32 | 128 |
| 12 | Activation_3 | 64, 64, 32 | 0 |
| 13 | Conv2D_4 | 64, 64, 32 | 9,248 |
| 14 | BatchNormalization_4 | 64, 64, 32 | 128 |
| 15 | Activation_4 | 64, 64, 32 | 0 |
| 16 | MaxPooling2D_2 | 32, 32, 32 | 0 |
| 17 | Dropout_2 | 32, 32, 32 | 0 |
| 18 | Conv2D_5 | 32, 32, 64 | 18,496 |
| 19 | BatchNormalization_5 | 32, 32, 64 | 256 |
| 20 | Activation_5 | 32, 32, 64 | 0 |
| 21 | Conv2D_6 | 32, 32, 64 | 36,928 |
| 22 | BatchNormalization_6 | 32, 32, 64 | 256 |
| 23 | Activation_6 | 32, 32, 64 | 0 |
| 24 | MaxPooling2D_3 | 16, 16, 64 | 0 |
| 25 | Dropout_3 | 16, 16, 64 | 0 |
| 26 | Conv2D_7 | 16, 16, 128 | 73,856 |
| 27 | BatchNormalization_7 | 16, 16, 128 | 512 |
| 28 | Activation_7 | 16, 16, 128 | 0 |
| 29 | Conv2D_8 | 16, 16, 128 | 147,584 |
| 30 | BatchNormalization_8 | 16, 16, 128 | 512 |
| 31 | Activation_8 | 16, 16, 128 | 0 |
| 32 | MaxPooling2D_4 | 8, 8, 128 | 0 |
| 33 | Dropout_4 | 8, 8, 128 | 0 |
| 34 | Conv2D_9 | 8, 8, 256 | 295,168 |
| 35 | BatchNormalization_9 | 8, 8, 256 | 1,024 |
| 36 | Activation_9 | 8, 8, 256 | 0 |
| 37 | Conv2D_10 | 8, 8, 256 | 590,080 |
| 38 | BatchNormalization_10 | 8, 8, 256 | 1,024 |
| 39 | Activation_10 | 8, 8, 256 | 0 |
| 40 | Conv2DTrans_1 | 16, 16, 128 | 295,040 |
| 41 | Concatenate_1 | 16, 16, 256 | 0 |
| 42 | Dropout_5 | 16, 16, 256 | 0 |
| 43 | Conv2D_11 | 16, 16, 128 | 295,040 |
| 44 | BatchNormalization_11 | 16, 16, 128 | 512 |
| 45 | Activation_11 | 16, 16, 128 | 0 |

| | | | |
|----|-----------------------|-------------|---------|
| 46 | Conv2D_12 | 16, 16, 128 | 147,584 |
| 47 | BatchNormalization_12 | 16, 16, 128 | 512 |
| 48 | Activation_12 | 16, 16, 128 | 0 |
| 49 | Conv2DTrans_2 | 32, 32, 64 | 73,792 |
| 50 | Concatenate_2 | 32, 32, 128 | 0 |
| 51 | Dropout_6 | 32, 32, 128 | 0 |
| 52 | Conv2D_13 | 32, 32, 64 | 73,792 |
| 53 | BatchNormalization_13 | 32, 32, 64 | 256 |
| 54 | Activation_13 | 32, 32, 64 | 0 |
| 55 | Conv2D_14 | 32, 32, 64 | 36,928 |
| 56 | BatchNormalization_14 | 32, 32, 64 | 256 |
| 57 | Activation_14 | 32, 32, 64 | 0 |
| 58 | Conv2DTrans_3 | 64, 64, 32 | 18,464 |
| 59 | Concatenate_3 | 64, 64, 64 | 0 |
| 60 | Dropout_7 | 64, 64, 64 | 0 |
| 61 | Conv2D_15 | 64, 64, 32 | 18,464 |
| 62 | BatchNormalization_15 | 64, 64, 32 | 128 |
| 63 | Activation_15 | 64, 64, 32 | 0 |

۳. یافته‌ها

در این پژوهش مجموعه داده پیشنهادی جمع‌آوری خواهد شد و در ادامه پیش‌پردازش داده‌ها انجام شده و با پردازش داده‌ها و آماده‌سازی آن برای ورود به الگوریتم داده‌ها به الگوریتم شبیه‌سازی شده داده خواهد شد و خروجی آن بر اساس داده‌های تست بررسی خواهد شد.

جدول ۲: مجموعه داده مورد استفاده

| Type | Amount | Size | Covid-19 | Negative | VP |
|--------------------|--------|-------|----------|----------|------|
| CT ³ | ۷۴۶ | M۶.۹۲ | ۳۴۹ | ۳۹۷ | ۰ |
| X-ray ⁴ | ۲۹۰۵ | M۱۱۶۸ | ۲۱۹ | ۱۳۴۱ | ۱۳۴۵ |
| X-ray ⁵ | ۵۵ | M۲.۱۴ | ۵۵ | ۰ | ۰ |

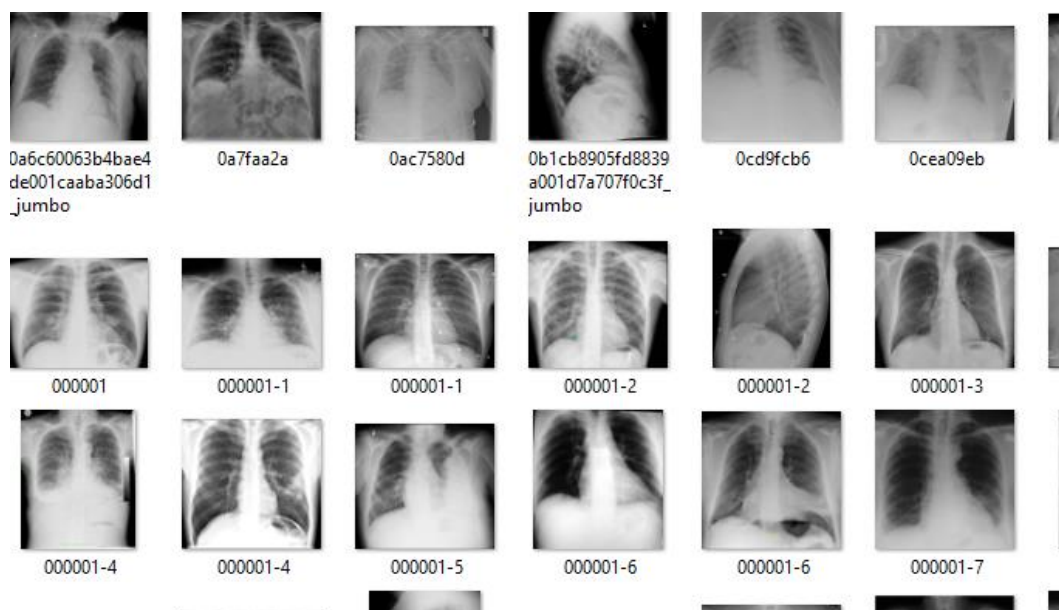
همان‌طور که از مجموعه داده مشخص است جدول یک دسته از مجموعه داده‌های تصاویر تشخیصی پزشکی را برای تشخیص Covid-19 خلاصه می‌کند که شامل ۷۴۶ تصویر CT و ۲۹۶۰ تصویر اشعه ایکس است. رویکرد پیشنهادی از طریق آزمایش‌های کمی با استفاده از مجموعه داده‌ها همان‌طور که در جدول ۲ نشان داده شده است، ارزیابی می‌شود. مجموعه داده ۷۴۶ CT شامل ۳۴۹ تصویر از موارد مثبت Covid-19 و ۳۹۷ تصویر از موارد منفی است. تصاویر اشعه ایکس قفسه

³ <https://github.com/UCSD-AI4H/COVID-CT>

⁴ <https://www.kaggle.com/tawsifurrahman/covid19-radiography-database>

⁵ <https://github.com/agchung/Figure1-COVID-chestxray-dataset>

سینه از دو مجموعه داده است. اولین مجموعه داده اشعه ایکس دارای ۲۹۰۵ تصویر است که شامل ۲۱۹ تصویر از موارد مثبت Covid-19 ، ۱۳۴۱ تصویر از موارد منفی و ۱۳۴۵ تصویر از ویروس ذات‌الریه^۶ VP است. دومین مجموعه داده X-Ray شامل ۵۵ تصویر از موارد مثبت است.



شکل ۸: فایل مجموعه داده مورد استفاده

⁶ viral pneumonia




هشتمین کنفرانس بین‌المللی
ترکیبیات، رمزنگاری، علوم کامپیوتر و محاسبات
۲۴ و ۲۵ آبان ۱۴۰۲




خروجی شبیه‌سازی روش پیشنهادی

```
Epoch 81/100
100/100 - 23s - loss: 0.3032 - acc: 0.8715 - val_loss: 0.6551 - val_acc: 0.9570
Epoch 82/100
100/100 - 22s - loss: 0.3220 - acc: 0.8675 - val_loss: 0.5673 - val_acc: 0.9480
Epoch 83/100
100/100 - 22s - loss: 0.2735 - acc: 0.8810 - val_loss: 0.7546 - val_acc: 0.9540
Epoch 84/100
100/100 - 23s - loss: 0.3000 - acc: 0.8805 - val_loss: 0.6749 - val_acc: 0.9580
Epoch 85/100
100/100 - 22s - loss: 0.2763 - acc: 0.8845 - val_loss: 0.9643 - val_acc: 0.9390
Epoch 86/100
100/100 - 23s - loss: 0.2892 - acc: 0.8925 - val_loss: 0.7276 - val_acc: 0.9500
Epoch 87/100
100/100 - 22s - loss: 0.2739 - acc: 0.8860 - val_loss: 0.8202 - val_acc: 0.9500
Epoch 88/100
100/100 - 23s - loss: 0.2544 - acc: 0.8965 - val_loss: 0.9308 - val_acc: 0.9500
Epoch 89/100
100/100 - 22s - loss: 0.3240 - acc: 0.8690 - val_loss: 0.8993 - val_acc: 0.9380
Epoch 90/100
100/100 - 22s - loss: 0.3034 - acc: 0.8760 - val_loss: 0.8042 - val_acc: 0.9490
Epoch 91/100
100/100 - 23s - loss: 0.2886 - acc: 0.8780 - val_loss: 1.2066 - val_acc: 0.9320
Epoch 92/100
100/100 - 22s - loss: 0.2777 - acc: 0.8870 - val_loss: 0.9584 - val_acc: 0.9400
Epoch 93/100
100/100 - 22s - loss: 0.3034 - acc: 0.8825 - val_loss: 2.1935 - val_acc: 0.9000
Epoch 94/100
100/100 - 22s - loss: 0.2886 - acc: 0.8830 - val_loss: 0.7883 - val_acc: 0.9500
Epoch 95/100
100/100 - 22s - loss: 0.2717 - acc: 0.8945 - val_loss: 0.9335 - val_acc: 0.9460
Epoch 96/100
100/100 - 23s - loss: 0.2612 - acc: 0.8985 - val_loss: 0.7933 - val_acc: 0.9510
Epoch 97/100
100/100 - 22s - loss: 0.2958 - acc: 0.8800 - val_loss: 0.7560 - val_acc: 0.9490
Epoch 98/100
100/100 - 23s - loss: 0.2858 - acc: 0.8865 - val_loss: 0.7513 - val_acc: 0.9560
Epoch 99/100
100/100 - 22s - loss: 0.2830 - acc: 0.8910 - val_loss: 0.8382 - val_acc: 0.9510
Epoch 100/100
100/100 - 23s - loss: 0.2770 - acc: 0.8910 - val_loss: 1.2002 - val_acc: 0.9300
```

شکل ۹: خروجی روند شبیه‌سازی



شکل ۱۰: خروجی روند شبیه سازی



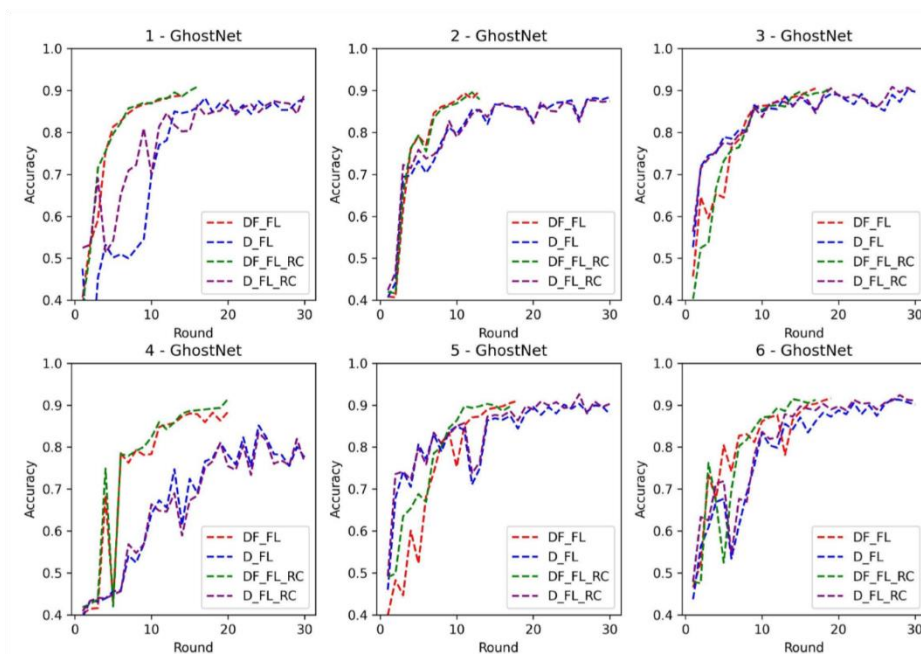
شکل ۱۱: خروجی روند شبیه سازی

یادگیری عمیق بر روی تصاویر بسیار خوب عمل می‌کند. این مسئله بیشتر بر اساس شبکه‌های عصبی کانولوشن است که به طور خاص برای استخراج ویژگی‌ها از تصاویر طراحی شده‌اند. شبکه‌های عصبی کلاسیک هیچ رابطه زمانی یا مکانی بین ویژگی‌ها فرض نمی‌کنند، ویژگی A و ویژگی B به طور مستقل در نظر گرفته می‌شوند. از آنجایی که وقتی در تصاویر با نویزها سروکار داریم این طرز بررسی نتایج صحیحی را در بر ندارد، بخش‌های نمونه‌برداری تصادفی صداها ممکن است به خودی خود بی‌معنی باشند، اما اگر به ترتیب و با سرعت مناسب در نظر گرفته شوند، ممکن است کلمات یا آهنگ‌ها را نشان دهند. این در مورد تصاویر نیز مشابه است یک پیکسل تصادفی ممکن است چیزی را نشان ندهد، اما با همسایگان می‌تواند یک شی یا یک حیوان را نشان دهد. به همین دلیل، معماری شبکه‌های جدیدی برای در نظر گرفتن انسجام زمانی و مکانی پیشنهاد شده است.

مقایسه کار

بر اساس روند پیشنهادی در مقایسه با مقاله پایه تفاوت‌هایی در مراحل پیش پردازش و پردازش آن‌ها وجود دارد که می‌توان به متفاوت بودن ساختار فیلترهای مورد استفاده در هر کدام از روش‌ها اشاره کرد. با رویکرد چند وضوحی در روش پیشنهادی نتایج مناسب‌تری ایجاد شد. در رویکرد پیشنهادی نحوه نمونه‌گیری پایین‌شبه به یک فضای با مقیاس بزرگ است که به تدریج در ازای ویژگی‌های سطح بالاتر یا ناحیه وسیع‌تر، ویژگی‌های محلی حذف می‌کند و این مسئله باعث می‌شود که ویژگی‌های مربوط به پیکسل اصلی را در نظر بگیرد.

مسیر افقی موجود در مدل (از یک سطح رو به پایین تا سطح رو به بالا مربوطه) جزئیات از دست رفته در مرحله نمونه برداری را دوباره به مدل اضافه می‌کند. خروجی الگوریتم شبیه‌سازی مقاله پایه [۸]، در شکل ۱۲ نشان داده شده است:



شکل ۱۲: خروجی دقت مقاله پایه [۸]

جدول ۳: مقایسه روند پیشنهادی و مقاله پایه

| میزان دقت | الگوریتم |
|-----------|----------------|
| ۹۵ | روش پیشنهادی |
| ۹۱ | روش مقاله پایه |

۴. نتیجه‌گیری

یادگیری عمیق زیرشاخه‌ای از یادگیری ماشین است که از لایه‌های متعدد تبدیلات خطی به منظور پردازش سیگنال‌های حسی مانند صدا و تصویر استفاده می‌کند. ماشین در این روش هر مفهوم پیچیده را به مفاهیم ساده‌تری تقسیم می‌کند، و با ادامه این روند به مفاهیم پایه‌ای می‌رسد که قادر به تصمیم‌گیری برای آن‌ها است و بدین ترتیب نیازی به نظارت کامل انسان برای مشخص کردن اطلاعات لازم ماشین در هر لحظه نیست. موضوعی که در یادگیری عمیق اهمیت زیادی دارد، نحوه‌ی ارائه‌ی اطلاعات است. ارائه دادن اطلاعات به ماشین باید به شیوه‌ای باشد که ماشین در کمترین زمان اطلاعات کلیدی را که می‌تواند با استناد به آن‌ها تصمیم بگیرد را دریافت کند. الگوریتم U-Net در سال ۲۰۱۵ در دانشگاه فرایبورگ آلمان توسط اولاف رنه برگر، فیلیپ فیشر و توماس بروکس برای افزایش دقت و سرعت پردازش و یادگیری، با استفاده از شبکه‌های کانولوشنی طراحی شد، از نکات قابل توجه در معماری این شبکه، می‌توان به عدم وجود لایه‌های کاملاً متصل اشاره کرد، که باعث شده میزان پیچیدگی شبکه را کاهش دهد. ایده نهفته در این الگوریتم، ایجاد یک مسیر انقباضی متوالی است که با جایگزین کردن لایه‌های Pooling به جای لایه‌های sampling رخ داده است. U-net در ابتدا برای اولین بار برای بخش بندی تصاویر زیست پزشکی استفاده شد. معماری آن را می‌توان به طور گسترده به عنوان یک شبکه رمزگذار و پس از آن یک شبکه رمزگشا در نظر گرفت. برخلاف طبقه‌بندی که در آن نتیجه نهایی شبکه عمیق تنها چیز مهم است، تقسیم‌بندی معنایی نه تنها به تمایز در سطح پیکسل نیاز دارد، بلکه به مکانیزمی برای نمایش ویژگی‌های متمایز آموخته‌شده در مراحل مختلف رمزگذار بر روی فضای پیکسل نیاز دارد.

رمزگذار نیمه اول در نمودار معماری است. معمولاً یک شبکه طبقه‌بندی از قبل آموزش‌دیده شده است که در آن بلوک‌های کانولوشن و به دنبال آن یک نمونه‌برداری کوچک maxpool برای رمزگذاری تصویر ورودی در بازنمایی ویژگی‌ها در سطوح مختلف مختلف اعمال می‌شود.

رمزگشا نیمه دوم معماری است. هدف این است که به صورت معنایی ویژگی‌های متمایز یا رزولوشن پایین آموخته شده توسط رمزگذار بر روی فضای پیکسل (رزولوشن بالاتر) نمایش داده شود تا یک طبقه‌بندی متراکم به دست آید. رمزگشا از نمونه برداری و الحاق و به دنبال آن عملیات کانولوشن منظم تشکیل شده است. در این پژوهش از این الگوریتم استفاده شده است و نتایج نشان دهنده برتری رویکرد پیشنهادی است.

مراجع

- [1] W. Wang, Y. Xu, R. Gao, R. Lu, K. Han, G. Wu, & W. Tan, (2020). Detection of SARS-CoV-2 in different types of clinical specimens. *Jama*, vol. 323, no. 18, pp.1843-1844, 2020.
- [2] C. P. West, V. M. Montori, & P. Sampathkumar, COVID-19 testing: the threat of false-negative results. In *Mayo Clinic Proceedings*. vol. 95, no. 6, pp. 1127-1129, 2020. Elsevier.
- [3] Y. Fang, Y. Fang H. Zhang, J. Xie et al., Sensitivity of chest CT for COVID-19: comparison to RT-PCR. *Radiology*, 200432, 2020.
- [4] Y. Yang, M. Yang, J. Yuan, F. Wang, Z. Wang, J. Li, & Y. Liu, Laboratory diagnosis and monitoring the viral shedding of SARS-CoV-2 infection. *The innovation*, vol. 1, no. 3, p. 100061, 2020.



- [5] P. Wikramaratna, R. S. Paton, M. Ghafari, & J. Lourenco, Estimating false-negative detection rate of SARS-CoV-2 by RT-PCR. MedRxiv, 2020.
- [6] M. Y. Ng, E. Y. Lee, J. Yang, F. Yang, X. Li, H. Wang, & M. D. Kuo, Imaging profile of the COVID-19 infection: radiologic findings and literature review. Radiology: Cardiothoracic Imaging, vol. 2, no. 1, e200034, 2020.
- [7] Y. Zoabi, S. Deri-Rozov, & N. Shomron, Machine learning-based prediction of COVID-19 diagnosis based on symptoms. npj digital medicine, vol. 4, no.1, pp.1-5, 2021.
- [8] Y. Song, S. Zheng, L. Li, X. Zhang, X. Zhang, Z. Huang, & Y. Yang, Deep learning enables accurate diagnosis of novel coronavirus (COVID-19) with CT images. IEEE/ACM Transactions on Computational Biology and Bioinformatics, 2021.
- [9] M. Loey, G. Manogaran, M. H. N. Taha, & N. E. M. Khalifa, A hybrid deep transfer learning model with machine learning methods for face mask detection in the era of the COVID-19 pandemic. Measurement, vol. 167, p. 108288, 2021.
- [10] A. Saygılı, A new approach for computer-aided detection of coronavirus (COVID-19) from CT and X-ray images using machine learning methods. Applied Soft Computing, vol. 105, p. 107323, 2021.
- [11] S. Zheng, X. Lin, W. Zhang et al., “MDCC-Net: multiscale double-channel convolution U-Net framework for colorectal tumor segmentation,” Computers in Biology and Medicine, vol. 130, p. 104183, 2021.
- [12] X. Liu, L. Song, S. Liu, and Y. Zhang, “A review of deeplearning-based medical image segmentation methods,” Sustainability, vol. 13, no. 3, p. 1224, 2021.
- [13] O. Çiçek, A. Abdulkadir, S. S. Lienkamp, T. Brox, and O. Ronneberger, “3D U-net: learning dense volumetric segmentation from sparse annotation,” in Proceedings of the Medical Image Computing and Computer-Assisted Intervention – MICCAI 2016, S. Ourselin, L. Joskowicz, M. Sabuncu, G. Unal, and W. Wells, Eds., October, 2016.