

تشخیص بیماری کووید-۱۹ با استفاده از شبکه‌های عصبی کانولوشنال بهینه‌سازی شده

علی محمدی^۱، دانشجو، غلامرضا کریمی^۲، استاد

۱- دانشکده فنی مهندسی - دانشگاه رازی - کرمانشاه - ایران - a.mohammadi@stu.razi.ac.ir

۲- دانشکده فنی مهندسی - دانشگاه رازی - کرمانشاه - ایران - ghkarimi@razi.ac.ir

چکیده: پاندمی کووید-۱۹ بیش از ۲ سال است که سبب مشکلات فراوانی در تمام دنیا بوده است. از این رو مبارزه با این بیماری به یکی از اولویتهای مهم جامعه بشری برای غلبه بر این مشکلات تبدیل شده است. یکی از اولین گامها برای مبارزه با این بیماری، تشخیص صحیح و سریع این بیماری است که روشهای مختلفی برای تشخیص این بیماری پیشنهاد و ارائه گردیده است. از طرفی یکی از مهمترین ابزارهای دسته‌بندی و تشخیص تصاویر، استفاده از شبکه‌های عصبی کانولوشنال می‌باشد. در این مقاله با استفاده از شبکه‌های عصبی کانولوشنال، ساختاری پیشنهاد شده است که اطلاعات تصاویر اسکن شده از ریه افراد را دریافت کرده و پس از پردازش، وضعیت فرد را در ۳ دسته کووید-۱۹، سالم و پنومونی در خروجی نشان می‌دهد. از مهمترین مزایای این شبکه می‌توان به دقت بالا نسبت به سایر روشهای موجود اشاره نمود. همچنین شبکه پیشنهادی در این مقاله، با استفاده از الگوریتمهای گرگ خاکستری و ژنتیک بهینه‌سازی شده و در نتیجه ساختار نهایی آن هم از نظر دقت و هم از نظر پیچیدگی به حد مناسبی رسیده است تا جایی که تعداد لایه‌ها و تعداد فیلترهای آن نسبت به شبکه‌های پیش از خود بسیار کمتر است در حالی که از نظر دقت میزان قابل قبولی به نسبت شبکه‌های بسیار گسترده‌تر از خود دارا می‌باشد. شبکه پیشنهادی با استفاده از مجموعه داده‌های کگل آموزش داده شده و در نهایت دقت ۹۵/۳۴٪ برای آن بدست آمده است که در صورت افزایش مقدار داده‌های آموزش می‌توان به دقت بالاتری نیز دست یافت.

واژه‌های کلیدی: شبکه‌های عصبی کانولوشنال، کووید-۱۹، بهینه‌سازی، الگوریتم‌های فراابتکاری

Diagnosis of Covid-19 Disease Using Optimized Convolutional Neural Networks

Ali Mohammadi, student¹, Gholamreza Karimi², professor²

1- Faculty of Engineering, Razi University, Kermanshah, Iran, Email: a.mohammadi@stu.razi.ac.ir

2- Faculty of Engineering, Razi University, Kermanshah, Iran, Email: ghkarimi@razi.ac.ir

Abstract: The covid-19 pandemic has caused many problems around the world for more than 2 years, so combating with this disease has become one of the important priorities of the human society to overcome these problems. One of the first steps to fight against this disease is the correct and quick diagnosis of this disease, and various methods have been proposed and presented to diagnose this disease. On the other hand, one of the most crucial tools to classification and recognition of images is the use of Convolutional Neural Networks. In this article, using convolutional neural networks, a structure is proposed that receives scanned images of people's lungs and after processing shows the person's status in 3 categories: Covid-19, healthy and pneumonia at the output. One of the most important advantages of this network refers to the high range of accuracy in comparison with other available ways. In addition, the suggested network in this article has been optimized with the use of grey wolf and genetic algorithms. As a result, its final structure has reached a suitable level in terms of complexity, while having much less the number of layers and the number of filters compared to previous networks, and has an acceptable level of accuracy compared to much wider networks. The suggested network has been trained by the Kaggle data set and finally, an accuracy of 95.34% has been obtained for it, which can be achieved higher accuracy if the amount of training data is increased.

Keywords: Convolutional Neural Networks, Covid-19, Optimization, Meta-heuristic algorithms

تاریخ ارسال مقاله: ۱۴۰۱/۰۴/۲۲

تاریخ اصلاح مقاله: ۱۴۰۱/۰۷/۱۳

تاریخ پذیرش مقاله: ۱۴۰۱/۰۸/۲۱

نام نویسنده مسئول: غلامرضا کریمی

نشانی نویسنده مسئول: ایران-کرمانشاه دانشگاه رازی- دانشکده برق و کامپیوتر- گروه مهندسی برق



۱- مقدمه

بیماری کووید-۱۹ در طی سال‌های اخیر مشکلات بسیاری را در زمینه‌های مختلف سبب شده است. این بیماری که در تاریخ ۳۱ دسامبر ۲۰۱۹ برای نخستین بار در شهر ووهان چین شناسایی گردید [۲۰] که به سرعت، همه جهان را فرا گرفت و افراد بسیاری را در نقاط مختلف دنیا درگیر این بیمار نمود که این امر نشان دهنده سرعت بسیار بالای انتقال این بیماری بوده و باعث شد تلاش‌های بسیاری در زمینه‌های مختلف جهت مقابله با گسترش بیشتر آن صورت پذیرد. با گذشت زمان، جهش‌های مختلف سویه‌های جدیدتری از این بیماری ایجاد و شناسایی شدند که برخی از این سویه‌ها سرعت انتقال بسیار بالاتری نسبت به سویه‌های قبل از خود داشته و از طرفی برخی از آن‌ها نیز بسیار تهاجمی‌تر بودند که میزان قربانیان این بیماری را به شدت افزایش داد.

با توجه به خصوصیات این بیماری، تشخیص سریع و دقیق افراد بیمار به عنوان یکی از اساسی‌ترین و مهم‌ترین راه‌ها برای مبارزه و جلوگیری از گسترش این بیماری عفونی شناخته شد [۳]. از این رو روش‌های مختلفی برای تشخیص این بیماری ارائه گردید که هر کدام از آن‌ها از نظر دقت، سرعت، دسترسی آسان و... دارای مزایا و معایب مختص به خود هستند.

یکی از روش‌هایی که برای تشخیص این بیماری مورد توجه قرار گرفت روش‌های تصویربرداری ریه می‌باشد. از طرفی، روش‌های هوش مصنوعی از جمله شبکه‌های عصبی می‌توانند در تشخیص خودکار این بیماری از روی تصاویر پزشکی بسیار کمک کننده باشند. این شبکه‌ها به دلیل توانایی‌هایی که در زمینه پردازش و دسته‌بندی تصاویر مختلف دارند مورد توجه قرار گرفتند. یکی از انواع شبکه‌های عصبی مختص انجام این کار است شبکه‌های عصبی کانولوشنال هستند. شبکه‌های عصبی کانولوشنال یکی از مهم‌ترین شبکه‌ها در حوزه یادگیری عمیق محسوب می‌شوند. از آنجا که این شبکه‌ها دستاوردهای بسیار تاثیر گذاری را در حوزه‌های مختلف مانند بینایی ماشین^۱ و پردازش زبان طبیعی^۲ بدست آورده‌اند، در سال‌های اخیر در صنعت و در محافل آکادمیک توجه بسیاری را به خود جلب کرده‌اند [۴]. در این روش با استفاده از پردازش دقیق تصاویر بدست آمده از ریه توسط رادیو گرافی و اشعه ایکس، می‌توان برای تشخیص هر چه سریع‌تر بیماری استفاده کرد، به این صورت که اطلاعات این تصاویر به ورودی شبکه داده شده و شبکه در خروجی مشخص می‌کند که فرد به بیماری مبتلا است یا خیر یا حتی می‌توان دسته‌بندی‌های دیگری نیز برای شبکه تعریف نمود که سایر بیماری‌های ریوی را نیز تشخیص دهد. شبکه‌های عصبی کانولوشنال^۳ به دلیل دقت بالا و همچنین سرعت قابل قبول، در پردازش تصاویر بسیار مورد توجه بوده‌اند. این شبکه‌ها، تصاویر مختلف را دریافت کرده و براساس طبقه‌بندی‌هایی که کاربر در کلاس‌های مختلف برای آن‌ها در نظر می‌گیرد پس از پردازش در خروجی دسته‌بندی می‌کنند.

تا کنون شبکه‌های مختلفی برای تشخیص بیماری کووید-۱۹ پیشنهاد شده‌اند که هر کدام از آن‌ها دارای مزایا و معایبی هستند در این مقاله سعی بر آن شده است که شبکه‌ای پیشنهاد شود تا مشکلات شبکه‌های پیشین را در نظر گرفته و تا حد امکان آن‌ها را برطرف نماید. مزایای اصلی شبکه پیشنهادی در این پژوهش عبارت‌اند از:

- کاهش قابل توجه لایه‌های پنهان شبکه پیشنهادی نسبت به شبکه‌های پیشین
- کاهش تعداد فیلترهای اعمال شده در لایه کانولوشن جهت استخراج ویژگی
- استفاده از یک لایه حذف کننده^۴ در ساختار شبکه پیشنهادی جهت حذف تصادفی برخی از نورون‌ها و در نتیجه ساده‌تر شدن ساختار جهت پیاده‌سازی

شبکه پیشنهادی، گزینه مناسب‌تری برای پیاده سازی نسبت به شبکه‌های ارائه شده پیش از خود می‌باشد، زیرا که ساختار آن بسیار ساده‌تر شده و در نتیجه پیاده‌سازی آن ساده‌تر است.

دقت و سرعت آموزش شبکه به نسبت شبکه‌های پیشین مقدار قابل قبولی داشته و حتی نسبت به بعضی از آن‌ها عملکرد بهتری را دارا می‌باشد.

یکی دیگر از مزایای جالب این شبکه‌ها این است که می‌توانند برای کاربردهای مختلفی به کار گرفته شوند. برای مثال شبکه پیشنهادی در این پژوهش می‌تواند برای تشخیص سایر بیماری‌ها یا حتی دسته‌بندی تصاویر غیر پزشکی نیز مورد استفاده قرار گیرد که البته برای این کار ممکن است تغییرات بسیار کوچکی در شبکه مورد نیاز باشد.

در ادامه این مقاله، ابتدا به بررسی برخی از کارهای پیشین انجام شده در این حوزه خواهیم پرداخت و مزایا و معایب هر کدام را بررسی خواهیم نمود. سپس روش پیشنهادی خود را بصورت کامل تشریح نموده و نتایج شبیه‌سازی شبکه را ارائه خواهیم نمود. در ادامه مقایسه‌ای بین شبکه پیشنهادی با سایر شبکه‌های بررسی شده ارائه خواهد شد که در آن مزایای روش پیشنهادی در این مقاله نسبت به سایر روش‌ها قابل مشاهده خواهد بود. در پایان، پیشنهاداتی جهت انجام پژوهش‌های آینده ارائه خواهد شد.

۲- مروری بر کارهای پیشین

در این بخش به مرور چند نمونه از پژوهش‌هایی که در حوزه تشخیص بیماری کووید-۱۹ از طریق شبکه‌های کانولوشن انجام شده‌اند خواهیم پرداخت و ساختار شبکه‌های پیشنهادی در این پژوهش‌ها را بررسی خواهیم نمود.

در سال ۲۰۲۰ لیندا وانگ^۵ و همکاران در مقاله مرجع [۵]، یک شبکه عصبی پیچیده عمیق تحت عنوان Covid-Net ارائه کردند که دارای ۸۹ لایه بود که برای یک مجموعه داده ۳ کلاس (کووید-۱۹ شامل ۳۵۸ تصویر، غیر کووید ۵۵۳۸ تصویر و پنومونی ۸۰۶۶ تصویر)

استفاده از الگوریتم‌های فراابتکاری به دو روش، بهینه‌سازی شده است که یکی از آن‌ها الگوریتم گرگ خاکستری^{۱۴} و دیگری الگوریتم ترکیبی خفاش-نهنگ^{۱۵} است. در این مقاله از دو مجموعه داده جداگانه و به صورت مجزا استفاده شده است که از منابع مختلف شامل مجموعه داده جوزف پائول^[۹]، انجمن پزشکی ایتالیا^[۱۱] و وب سایت کگل^[۱۲] گردآوری شده‌اند که مجموعه داده اول دارای ۲۹۰۵ تصویر (۲۱۹ تصویر آن مربوط به کووید-۱۹، ۱۳۴۱ تصویر مربوط به نرمال و ۱۳۴۵ تصویر مربوط به پنومونی) و مجموعه داده دوم دارای ۶۳۴۲ تصویر (۵۷۶ تصویر آن مربوط به کووید-۱۹، ۱۵۸۳ تصویر مربوط به نرمال و ۴۲۷۳ تصویر مربوط به پنومونی) هستند که ۸۰٪ از این مجموعه داده‌ها برای آموزش شبکه و ۲۰٪ باقیمانده برای آزمایش و بررسی عملکرد شبکه بکار گرفته شده‌اند. شبکه بهینه‌سازی شده با الگوریتم گرگ خاکستری با استفاده از مجموعه داده اول به دقت ۹۸٪ و با استفاده از مجموعه داده دوم به دقت ۹۵٪ دست یافته است. شبکه بهینه‌سازی شده با الگوریتم خفاش - نهنگ با استفاده از هر دو مجموعه داده به صورت مجزا دقت ۹۶٪ را بدست آورده است. از مزایای روش‌های پیشنهادی در این مرجع می‌توان به دقت مناسب، ۳ کلاسه بودن دسته‌بندی در خروجی و تنظیم برخی از پارامترهای آموزش شبکه به صورت خودکار اشاره کرد. از معایب این روش‌ها نیز می‌توان به تعداد لایه زیاد شبکه، تعداد بسیار زیاد فیلترهای مورد استفاده در لایه کانولوشن و همچنین کاهش دقت در بهینه‌سازی با الگوریتم گرگ خاکستری با افزایش مجموعه داده اشاره کرد.

در سال ۲۰۲۰، تریپتی گوئل^{۱۶} و همکاران در مقاله مرجع^[۱۳] شبکه‌ای را به نام OptCoNet ارائه کردند که دارای ۲۳ لایه بوده و برخی از ابرپارامترهای آموزش آن با استفاده از الگوریتم گرگ خاکستری بهینه‌سازی شده است. برای آموزش و سنجش عملکرد این شبکه از چندین مجموعه داده از جمله داده‌های موجود در مراجع^[۱۱، ۱۲] استفاده شده است که از هر مجموعه داده ۲۷۰۰ تصویر در ۳ کلاس در آمده است که سهم هر کلاس (کووید-۱۹، پنومونی و نرمال) ۹۰۰ تصویر بوده است که ۷۰٪ از آن‌ها برای آموزش شبکه و ۳۰٪ باقیمانده برای ارزیابی عملکرد شبکه بکار گرفته شده‌اند. پس از سنجش عملکرد شبکه دقت ۹۷/۷۸٪ برای آن بدست آمده است. از مزایای این شبکه می‌توان به تعداد لایه‌های کمتر، ۳ کلاسه بودن و دقت مناسب نسبت به تعداد داده مورد استفاده برای آموزش شبکه، اشاره نمود. از معایب این شبکه نیز می‌توان به تعداد زیاد فیلترهای مورد استفاده در لایه‌های کانولوشن اشاره نمود.

محصل فقهی و همکاران در مقاله‌های مراجع^[۲۱ و ۲۲]، روش‌های جدید به نام ترکیب الگوی باینری محلی یکنواخت مقاوم در برابر چرخش و نویز دو صفحه‌ی زمانی و ResNet 50 و نیز

به دقت ۹۲/۴٪ رسید. از مزایای این شبکه می‌توان به ۳ کلاسه بودن و دقت نسبتاً خوب اشاره نمود، همچنین از معایب این شبکه می‌توان به تعداد داده بسیار زیاد برای آموزش و ارزیابی و تعداد لایه‌های نسبتاً زیاد که سبب افزایش حجم شبکه شده‌اند، اشاره نمود و همچنین سبب فیلترهای اعمالی در لایه کانولوشن نیز بزرگ می‌باشد.

تالین اوزترک^۷ و همکاران در سال ۲۰۲۰ در مقاله مرجع^[۶]، ساختاری با ۳۴ لایه را تحت عنوان Dark Covid Net به دو صورت ۲ کلاسه و ۳ کلاسه ارائه کردند که در حالت ۲ کلاسه دقت شبکه به ۹۸/۰۸٪ رسیده و در حالت ۳ کلاسه به میزان ۸۷/۰۲٪ دست پیدا کرده است. از مزایای این شبکه می‌توان به دقت مناسب در حالت ۲ کلاسه و همچنین تعداد لایه‌های نسبتاً کم اشاره نمود و از معایب آن نیز اختلاف زیاد دقت در حالت ۲ کلاسه و ۳ کلاسه و همچنین سبب بزرگ فیلتر اعمالی در لایه کانولوشن اشاره کرد.

مورگان^۸ و همکاران در سال ۲۰۲۰ در مقاله^[۷]، از یکی از شبکه‌های آماده به نام Resnet50 استفاده کردند که تعدادی از ابرپارامترهای آموزش شبکه توسط یکی از الگوریتم‌های فراابتکاری^۸ به نام الگوریتم نهنگ^۹ بهینه‌سازی شد. برای آموزش این شبکه از یک مجموعه داده ۲ کلاسه که شامل کووید-۱۹ و غیر کووید بوده استفاده شده است که هر کلاس دارای ۳۵۰ تصویر بوده است که پس از بهینه‌سازی و آموزش شبکه، دقت ۹۸/۷۸٪ بدست آمده است. از مزایای این کار می‌توان به دقت بالای شبکه و عدم نیاز به تنظیم دستی هاپرپارامترهای شبکه اشاره کرد اما تعداد لایه‌های شبکه خیلی زیاد است و همچنین به دلیل این که دسته‌بندی ۲ کلاسه را انجام می‌دهد ممکن است برخی بیماری‌های ریوی را به اشتباه کووید-۱۹ تشخیص دهد.

در مقاله مرجع^[۸] که توسط رافیول حسن^{۱۰} و همکاران در سال ۲۰۲۱ ارائه گردید یک شبکه با ۵۳ لایه که با بهره‌گیری از الگوریتم ژنتیک^{۱۱} اندازه فیلتر لایه‌های کانولوشن آن بهینه شده است، پیشنهاد شده است. در این مرجع نیز عمل دسته‌بندی برای ۲ کلاس کووید-۱۹ و غیر کووید انجام شده است. برای آموزش شبکه از یک مجموعه داده شامل ۹۲۵ تصویر که توسط جوزف پائول^{۱۲} و همکاران در مرجع^[۹] ارائه گردیده است، استفاده شده است که سهم کووید ۴۲۰ تصویر و سهم غیر کووید ۵۰۵ تصویر بوده است که پس از آموزش شبکه، دقت آن به ۹۸،۵٪ رسیده است. از مزایای این کار می‌توان به دقت بالای شبکه و تنظیم خودکار سبب فیلتر لایه‌های کانولوشن اشاره کرد، اما از معایب آن نیز می‌توان به ۲ کلاسه بودن دسته‌بندی و همچنین تعداد لایه‌های زیاد شبکه اشاره کرد.

سامینا پاتان^{۱۳} و همکاران در مقاله مرجع^[۱۰] که در سال ۲۰۲۱ ارائه کردند سه روش برای تشخیص کووید-۱۹ با استفاده از شبکه‌های کانولوشنال پیشنهاد کردند که در روش اول از یک شبکه Resnet50 همراه با یک ECOC Classifier استفاده شده است و در دو مورد بعدی یک شبکه کانولوشنال پیشنهاد شده که دارای ۵۳ لایه می‌باشد و با

یکی از مشکلات حوزه یادگیری عمیق محدودیت در تعداد داده‌ها است. یکی از پرکاربردترین روش‌ها برای رفع این مشکل، ایجاد داده‌های جدید با روش افزایش داده^{۱۶} است. در این روش تعداد داده‌های موجود با روش‌هایی مانند چرخش، جابجایی، انعکاس، بزرگ‌نمایی، کوچک‌نمایی، اعمال اعوجاج و... افزایش پیدا می‌کند [۱۴] که نمونه‌هایی از آن در شکل ۲ قابل مشاهده است. افزایش داده می‌تواند به عنوان یک تنظیم‌کننده به منظور جلوگیری از بیش‌برازش^{۱۸} در شبکه و همچنین بهبود عملکرد در مشکلات کلاس نامتعادل عمل کند [۱۵].



شکل ۲) نمونه‌هایی از داده‌های Augmented

۲-۳- ساختار شبکه پیشنهادی

شبکه پیشنهادی ما یک شبکه کانولوشنال دارای ۲۰ لایه می‌باشد که ساختار آن در جدول ۱ و نمای کلی از آن در شکل ۳ و همچنین نحوه عملکرد لایه کانولوشن و لایه نمونه‌گیر برای پردازش تصویر و استخراج ویژگی‌های آن در شکل ۴ قابل مشاهده می‌باشد. بخش اول شبکه لایه ورودی است که تصاویر با سایز $227 \times 227 \times 3$ را به عنوان ورودی دریافت کرده و آن‌ها را به لایه‌های بعدی (پنهان) برای پردازش می‌فرستد. در بخش دوم لایه‌های پنهان شبکه قرار دارند که شامل لایه کانولوشن^{۱۹}، لایه نرمال‌ساز دسته‌ای^{۲۰}، لایه RELU، لایه نمونه‌گیر^{۲۱}، لایه حذف‌کننده و لایه اتصال کامل^{۲۲} می‌باشند که عملکرد و وظایف آن‌ها در ادامه تشریح خواهد شد. در بخش آخر لایه‌های خروجی شبکه شامل Soft Max و دسته‌بندی‌کننده قرار دارند که لایه Soft Max به صورت یک تابع عمل می‌کند و اعداد اختصاص داده شده به تصویر را به اعداد قابل فهم برای شبکه و لایه دسته‌بندی تبدیل می‌کند تا لایه دسته‌بندی‌کننده عمل دسته‌بندی را انجام دهد. این شبکه نسبت به شبکه‌های پیشین دارای تعداد لایه‌ها و فیلترهای کمتری می‌باشد و همچنین یک لایه حذف‌کننده در ساختار آن در نظر گرفته شده که با نرخ ۰/۰۵ نورون‌های لایه آخر کانولوشن را حذف می‌کند.

۱-۲-۳- لایه کانولوشن

عملگر کانولوشن، یک راه برای پردازش سایز متغیرهای ورودی با استفاده از هسته‌های پیچش فراهم می‌کند و ویژگی‌های ورودی متفاوتی از عمل پیچش در لایه پیچش استخراج می‌شود. لایه‌های اول، ویژگی‌های سطح پایین‌تر مانند لبه‌ها، نقاط و گوشه‌ها را استخراج می‌کنند و سپس لایه‌های بالاتر، ویژگی‌های پیچیده‌تر و سطح بالاتر را


روش ترکیبی RIULBP-TP and 3D-DenseNet پیشنهاد کردند که بر روی تصاویر متوالی اولتراسوند ریه اعمال شد. از مزایای این روش میتوان به مقاوم بودن در برابر نویز داده‌های اولتراسوند و صرف زمان کمتر برای تشخیص اشاره کرد. با بررسی پژوهش‌های پیشین معایبی برای شبکه‌های پیشنهاد شده شناسایی شد که از جمله آن‌ها می‌توان تعداد زیاد لایه‌ها و فیلترها، ۲ کلاسه بودن برخی از آن‌ها و همچنین دقت پایین بعضی نسبت به تعداد داده مورد استفاده برای آموزش شبکه، اشاره نمود. برخی از معایب اشاره شده سبب ایجاد مشکل برای پیاده‌سازی سخت افزاری شبکه‌های پیشنهادی می‌گردند که این امر سبب ایجاد هزینه‌های زیادی برای پیاده‌سازی و بکارگیری آن‌ها خواهد شد.

۳- روش پیشنهادی

در این مقاله سعی بر آن خواهد بود که شبکه‌ای ارائه گردد که معایب بیان شده در پژوهش‌های پیشین را تا حد امکان مرتفع نموده و همچنین از دقت مناسبی برخوردار باشد. شبکه پیشنهادی در این مقاله، یک شبکه کانولوشنال خواهد بود که به وسیله الگوریتم‌های فراابتکاری بهینه‌سازی شده و هدف آن این است که از لحاظ پیچیدگی ساختار از شرایط مناسب‌تری نسبت به شبکه‌های پیشین برخوردار بوده و همچنین دقت مناسبی نیز داشته باشد. در ادامه ساختار شبکه پیشنهادی و توضیحات مربوط به لایه‌های آن و الگوریتم‌های بهینه‌سازی ارائه خواهند شد.

۱-۳- مجموعه داده‌ها

مجموعه داده‌های استفاده شده در پژوهش حاضر از مجموعه داده وب سایت کگل [۱۲] جمع‌آوری شده است که در بسیاری از مقالات مربوط به کووید-۱۹ به عنوان مجموعه داده استفاده می‌گردد. از این مجموعه داده ۲۱۵۰ تصویر شامل ۷۵۰ تصویر مربوط به کووید-۱۹ و دو دسته نرمال و پنومونی هر کدام ۷۰۰ تصویر انتخاب شده است که ۸۰٪ آن برای آموزش و ۲۰٪ باقیمانده برای ارزیابی عملکرد شبکه استفاده شده است. نمونه‌ای از هر کدام از دسته‌های مجموعه داده استفاده شده در شکل ۱ آمده است.



شکل ۱) نمونه‌هایی از مجموعه داده (الف) کووید-۱۹ (ب) نرمال (پ) پنومونی [۱۲]

جدول ۱) ساختار شبکه پیشنهادی قبل از بهینه سازی

Layer	Type	Filter Size	Number of filters	stride	Padding
Input	227*227*3				
Conv_1	CL + BN + Relu	3*3	8	-	1*1
APL		2*2		2*2	-
Conv_2	CL + BN + Relu	3*3	10	-	1*1
MPL_1		2*2		2*2	-
Conv_3	CL + BN + Relu	3*3	14	-	1*1
MPL_2		2*2		2*2	-
Conv_4	CL + BN + Relu	3*3	16	-	1*1
Drop out	0.05				
Fully Connected Output	Output size =3				
	Classification layer	Soft-max			

BN: Batch Normalization Layer

۳-۲-۵- لایه حذف کننده

این لایه به صورت تصادفی تعدادی از نورون های هر لایه را حذف می کند و باعث افزایش سرعت آموزش می شود و همچنین از بیش برآزش شبکه جلوگیری می کند [۱۶].

۳-۲-۶- لایه اتصال کامل

این لایه معمولاً به عنوان آخرین لایه پنهان شبکه به کار رفته و با تمام اجزا لایه پیش از خود به صورت کامل اتصال دارد. این لایه تمام ویژگی های استخراج شده توسط لایه های پیشین را تحلیل کرده و پس از آن اطلاعات را به تمام کلاس های خروجی می فرستد تا دسته بندی شوند [۱۷].

۴- الگوریتم های فراابتکاری


یکی از روش های پر کاربرد برای بهینه سازی شبکه های عصبی استفاده از الگوریتم های فراابتکاری است. این الگوریتم ها که در طول چند دهه اخیر به شهرت بسیاری دست یافته اند دارای دسته بندی های مختلفی می باشند که بر پایه ویژگی های آن ها این دسته بندی ها پیشنهاد شده اند. از انواع الگوریتم های فراابتکاری می توان به الگوریتم ازدحام ذرات [۲۳]، الگوریتم کلونی مورچگان [۲۴]، الگوریتم گرگ خاکستری، الگوریتم ژنتیک [۲۵] و ... اشاره نمود.

در پژوهش حاضر از دو الگوریتم گرگ خاکستری و ژنتیک جهت بهینه سازی شبکه پیشنهادی استفاده شده است که در ادامه به بررسی مختصر آن ها خواهیم پرداخت.

۴-۱- الگوریتم گرگ خاکستری

این الگوریتم در سال ۲۰۱۴ توسط سیدعلی میرجلیلی و همکاران در مقاله مرجع [۱۸] ارائه گردید. این الگوریتم که در دسته الگوریتم های مبتنی بر هوش جمعی قرار می گیرد که در سال های اخیر به یک الگوریتم قابل اعتماد برای بهینه سازی شبکه های عصبی تبدیل شده است.

این الگوریتم از رفتار گرگ های خاکستری در طبیعت الهام گرفته شده است. سلسله مراتب اجتماعی گرگ های خاکستری در درون دسته های خود در شکل ۵ قابل مشاهده است.



شکل ۵) سلسله مراتب اجتماعی گرگ های خاکستری [۱۸]

با پردازش ویژگی های سطح پایین محاسبه می کنند [۱۶]. برای استخراج این ویژگی ها، فیلترهایی بر روی ماتریس ورودی اعمال می شود که تعداد، گام حرکت، اندازه و مقادیر درایه های این فیلترها متغیر است و مقدار آن ها تعیین کننده نوع ویژگی های استخراج شده ورودی ها است.

۳-۲-۲- لایه نرمال ساز دسته ای

این لایه یک عمل نرمال سازی روی تصاویر انجام می دهد و ورودی ها را به مقادیر متناسب برای ورودی شبکه عصبی تبدیل می کند که در واقع با این کار حساسیت شبکه نسبت به مقادیر اولیه کاهش می یابد و سرعت آموزش شبکه بالاتر می رود.


۳-۲-۳- لایه RELU

این لایه یک نوع لایه فعال ساز است که کار تصمیم گیری در شبکه عصبی را انجام می دهد و به یادگیری ویژگی های پیچیده از روی تصویر ورودی کمک می کند. انتخاب تابع فعال ساز مناسب می تواند منجر به افزایش سرعت فرایند آموزش در یادگیری الگوهای پیچیده از روی ورودی های خام شود. رابطه این تابع به صورت معادله (۱) است.


$$f(x) = \begin{cases} 0, & x < 0 \\ x, & x \geq 0 \end{cases} \quad (1)$$

۳-۲-۴- لایه نمونه گیر

این لایه مانند یک فیلتر عمل می کند که پارامترهای شبکه و امان های محاسباتی را کاهش می دهد. با توجه به سائز فیلتر نمونه گیر و همچنین گام حرکت آن بر روی ماتریس ورودی، می تواند سائز ماتریس ورودی را تغییر دهد که یک نمونه کوچک شده از ورودی است [۱۶]. این لایه انواع مختلفی دارد که دو نوع از آن ها به نام های نمونه گیر میانگین و نمونه گیر بیشترین در شبکه پیشنهادی ما استفاده شده است.



شکل ۳) نمای کلی از شبکه پیشنهادی



شکل ۴) نحوه عملکرد لایه کانولوشن و لایه نمونه گیر

یا ماده باشند و همچنین بهترین گزینه برای برعهده گرفتن نقش آلفا در صورت مرگ یا پیر شدن آلفای گروه هستند.

گرگ‌های امگا پایین‌ترین رتبه را در گروه دارا هستند. این گرگ‌ها همیشه مجبور هستند که از دستورات سایر گرگ‌های دسته پیروی کنند. آن‌ها آخرین گرگ‌هایی هستند که اجازه غذا خوردن دارند. شاید این‌گونه به نظر برسد که امگا به تنهایی در دسته اهمیتی ندارد اما مشاهده شده است که در صورت از دست رفتن امگا تمام دسته گرگ‌ها با نزاع داخلی و مشکلات دیگری روبه‌رو می‌شود.

گرگ‌های آلفا که معمولاً یک نفر و یک ماده هستند به عنوان رهبران گروه شناخته می‌شوند که وظیفه تصمیم‌گیری در مورد شکار کردن، محل خواب، زمان بیدار شدن و... را برعهده دارند. این گرگ‌ها لزوماً قوی‌ترین عضو گروه نیستند بلکه بهترین توانایی را از لحاظ مدیریت گله، دارا هستند که این مسئله بیانگر این است که سازماندهی و نظم در درون دسته بسیار مهم‌تر از قوی بودن است. گرگ‌های بتا نقش گرگ‌های تابع را دارند که آلفاها را در تصمیم‌گیری‌ها و سایر فعالیت‌های دسته کمک می‌کنند و می‌توانند

$$X(t+1) = \frac{X_1 + X_2 + X_3}{3} \quad (۸)$$

در رابطه ۴ مقدار A در بازه $[2a, -2a]$ قرار می‌گیرد که در آن a از مقدار ۲ تا صفر در طی تکرارها کاهش می‌یابد. هنگامی که مقدار A در بازه $[-1, 1]$ قرار می‌گیرد مانند این است که گرگ به طعمه حمله می‌کند و این بدان معناست که عمل استخراج (یافتن پاسخ بهینه) انجام می‌گیرد و اگر $|A| > 1$ باشد، عمل استخراج انجام نمی‌شود و به جای آن گرگ به دنبال طعمه می‌گردد یعنی عمل اکتشاف را انجام می‌دهد. در واقع در این حالت در مدل ریاضی به دنبال پاسخ‌های احتمالی دیگر می‌باشد.

۴-۲- الگوریتم ژنتیک

الگوریتم ژنتیک یکی دیگر از الگوریتم‌های فراابتکاری است که برای بهینه‌سازی شبکه پیشنهادی از آن بهره گرفته‌ایم. این الگوریتم در دسته الگوریتم‌های مبتنی بر تکامل قرار می‌گیرد. برای شبیه‌سازی و استفاده از این الگوریتم، درک مفاهیم زیر ضروری است.

کروموزوم: هر کروموزوم در الگوریتم ژنتیک مانند یک نقطه در فضای جست‌وجو است و به عنوان یک راه‌حل بالقوه برای مسئله در نظر گرفته می‌شود [۱۹].

جمعیت: مجموعه‌ای از کروموزوم‌ها جمعیت را تشکیل می‌دهند [۱۹].

تابع هزینه: تابعی است که برای هر مسئله به صورت خاص تعریف می‌شود که کروموزوم‌های یک جمعیت به آن اعمال می‌شوند و به هر کدام یک عدد (امتیاز) نسبت می‌دهد که در مراحل بعدی می‌توان از این عدد برای توقف عمل بهینه‌سازی بهره گرفت [۱۹].

عملگر: یک سری عملگرهای ژنتیکی وجود دارند که با اعمال آن‌ها بر روی هر جمعیت، جمعیت جدیدی با همان تعداد کروموزوم تشکیل می‌شود [۱۹].

نسل: هر بار که جمعیت تغییر کند، یک جمعیت جدید تولید شود این جمعیت جدید را یک نسل می‌نامیم [۱۹].

در الگوریتم ژنتیک جمعیت اولیه به صورت تصادفی تولید می‌شود، سپس با اعمال کروموزوم‌های این جمعیت به تابع هزینه برای هر کروموزوم یک امتیاز محاسبه می‌شود. در ادامه با اعمال عملگرها جمعیت جدید تشکیل شده و فرایند بالا ادامه می‌یابد یعنی مجدداً جمعیت جدید به تابع هزینه اعمال شده و این فرایند ادامه دارد تا به یک امتیاز معین برسیم یا این که عملیات تولید نسل به تعداد مورد نظر ما برسد و الگوریتم متوقف گردد.

در ادامه به بررسی انواع عملگرهایی می‌پردازیم که از آن‌ها برای تولید نسل جدید می‌توان بهره گرفت:

- عملگر انتخاب^۶: این عملگر از بین کروموزوم‌های موجود در جمعیت، تعدادی را برای تولید نسل بعدی انتخاب می‌کند. مانند

اگر یک گرگ آلفا، بتا یا امگا نباشد، تابع نامیده می‌شود که البته در برخی مراجع به عنوان دلتا از آن یاد می‌شود. گرگ‌های دلتا باید پیرو آلفاها و بتاها باشند اما به امگا دستور می‌دهند.

رفتار اجتماعی جالب دیگری در گرگ‌های خاکستری وجود دارد، شکار گروهی است که دارای مراحل زیر است:

- ردیابی، تعقیب و نزدیک شدن به شکار
- دنبال کردن، محاصره و آزار و اذیت شکار تا زمانی که از حرکت بایستد.
- حمله به سمت شکار

در مقاله مرجع [۱۸] مدل‌سازی ریاضی رفتارها و سلسه مراتب اجتماعی گرگ‌های خاکستری ارائه گردید که در ادامه، آن‌ها را ارائه خواهیم نمود. برای درک و پیاده‌سازی بهتر، چند فرض در نظر گرفته شده است که آلفا به عنوان بهترین راه‌حل و پس از آن بتا و دلتا به عنوان دومین و سومین راه‌حل در نظر گرفته شده است و امگا نیز آخرین راه‌حل محسوب می‌گردد. در الگوریتم گرگ خاکستری شکار کردن (بهینه‌سازی) به وسیله آلفا، بتا و دلتا هدایت می‌شود و گرگ‌های امگا آن‌ها را تعقیب می‌کنند.

روابط زیر نحوه محاصره کردن طعمه توسط گرگ‌های خاکستری را مدل‌سازی می‌کنند:

$$D(t) = |C \cdot X_p(t) - X(t)| \quad (۲)$$

$$X(t+1) = X_p(t) - A \cdot D \quad (۳)$$

در روابط ۲ و ۳ متغیر t بیانگر تعداد تکرار، A و C بردارهای ضریب ثابت، X_p نشان‌دهنده بردار موقعیت طعمه و X نشان‌دهنده بردار موقعیت گرگ خاکستری هستند و همچنین مقادیر A و C از روابط زیر بدست می‌آیند:

$$A = 2a \cdot r_1 - a \quad (۴)$$

$$C = 2 \cdot r_2 \quad (۵)$$

در این روابط مقدار a به صورت خطی از ۲ تا صفر در طول تکرارها کاهش می‌یابد و r_1 و r_2 بردارهای تصادفی در بازه $[-1, 1]$ می‌باشند.

به دلیل این که اطلاعات دقیقی در مورد نقطه بهینه در دسترس نیست، در نتیجه برای بدست آوردن مقدار آن بر اساس موقعیت گرگ‌های خاکستری، روابط شکار کردن طعمه که در الگوریتم به معنای همان نقطه بهینه است به صورت زیر بازنویسی می‌شوند:

$$\begin{cases} D_\alpha = |C_1 \cdot X_\alpha - X| \\ D_\beta = |C_1 \cdot X_\beta - X| \\ D_\delta = |C_1 \cdot X_\delta - X| \end{cases} \quad (۶)$$

$$\begin{cases} X_1 = X_\alpha - A_1 \cdot D_\alpha \\ X_2 = X_\beta - A_1 \cdot D_\beta \\ X_3 = X_\delta - A_1 \cdot D_\delta \end{cases} \quad (۷)$$

برای بدست آوردن نتایج بهتر و بهینه کردن ساختار شبکه پیشنهادی در بخش ۳-۲ با استفاده از دو الگوریتم گرگ خاکستری و ژنتیک، شبکه را بهینه کرده‌ایم.

با استفاده از الگوریتم گرگ خاکستری اندازه فیلترهای لایه‌های کانولوشن و در مرحله بعد برخی از ابرپارامترهای آموزش شبکه توسط الگوریتم ژنتیک بهینه‌سازی شده که در بخش نتایج مقادیر بهینه بدست آمده ارائه خواهند شد.

۵- نتایج روش پیشنهادی

برای ارزیابی مدل پیشنهادی از یک سیستم مجهز به واحد پردازنده گرافیکی (CPU) Core i5-8250U با رم ۸ گیگا بایت و کارت گرافیکی Nvidia GeForce MX110 با حافظه گرافیکی دو گیگا بایت استفاده شده است. برای شبیه سازی این روش، ما از برنامه متلب استفاده کرده‌ایم و همچنین پردازش توسط GPU انجام شده است.

برای ارزیابی عملکرد شبکه معیارهای زیادی وجود دارد که در این پژوهش ما علاوه بر معیار دقت از معیاری های Recall, Precision و F1-Score استفاده کرده‌ایم که نحوه محاسبه آن‌ها در جدول ۲ قابل مشاهده می‌باشد.

جدول ۲) نحوه محاسبه مقادیر معیارهای ارزیابی عملکرد شبکه

Parameters	Formula
Accuracy	$\frac{TP + TN}{TP + TN + FP + FN}$
Recall	$\frac{TP}{TP + FN}$
Precision	$\frac{TP}{TP + FP}$
F1-Score	$2 \frac{\text{Precision} \cdot \text{Recall}}{\text{Precision} + \text{Recall}}$

در این جدول منظور از TP موارد مثبت درست، TN موارد منفی درست، FP موارد مثبت اشتباه و FN موارد منفی اشتباه است که آن‌ها را می‌توان از روی ماتریس درهم ریختگی^{۲۰} نیز محاسبه کرد.

هایپرپارامترهای آموزش شبکه در ابتدا پیش فرض در نظر گرفته شده‌اند و فقط چند مورد از آن‌ها به صورت دستی با یک مقدار مناسب تنظیم شده است که این مقادیر از جدول ۳ قابل مشاهده است.


جدول ۳) هایپرپارامترهای تنظیم شده آموزش شبکه

Training algorithm	Mini Batch size	Initial learning rate	Momentum	Maximum epoch	Validation frequency
Sgdm	80	1e-4	0.9	6	3

با استفاده از الگوریتم گرگ خاکستری سائز فیلتر لایه‌های کانولوشن شبکه پیشنهادی در جدول ۱ را بهینه سازی کردیم که پس از انجام عمل بهینه سازی، اندازه فیلترهای لایه کانولوشن شبکه پیشنهادی تغییر کرد که مشخصات جدید شبکه در جدول ۴ ارائه شده است.

انتخاب طبیعی، در این جا نیز کروموزوم‌هایی با ویژگی‌های برتر شانس بیشتری برای انتخاب شدن دارند.

این عملگر انواع مختلفی دارد که از مهم‌ترین آن‌ها می‌توان به چرخ رولت^{۲۷} اشاره کرد.



شکل ۶) عملگر انتخاب چرخ رولت [۱۹]

- عملگر تلفیق^{۲۸}: در عمل تلفیق به صورت اتفاقی بخش‌هایی از دو کروموزوم با یکدیگر تعویض می‌شوند. به مانند آن‌چه که در تولید نسل به صورت طبیعی اتفاق می‌افتد این امر باعث می‌شود فرزندان (نسل جدید) دقیقاً مشابه یکی از والدین نباشند و ترکیبی از خصوصیات آن‌ها را با خود داشته باشند. با انجام این عمل امید به آن می‌رود که خصوصیات برتر موجود در نسل گذشته در نسل جدید جمع شده و نسل بهتری ایجاد گردد. این عملگر به ۳ صورت، تلفیق تک نقطه‌ای، تلفیق دو نقطه‌ای و تلفیق تصادفی اعمال می‌شود که نمونه‌ای از تلفیق تک نقطه‌ای در شکل ۷ قابل مشاهده است.

Chromosome 1 11011100100110110

Chromosome 2 1101111000011110

Offspring 1 1101111000011110

Offspring 2 11011100100110110

شکل ۷) تلفیق یک نقطه‌ای [۱۹]

- عملگر جهش^{۲۹}: کاربرد عملگر جهش در این است که اجازه نمی‌دهد که الگوریتم در نقاط بهینه محلی متوقف شود [۲۰]. این عملگر به صورت تصادفی تعدادی از ژن‌ها را انتخاب کرده و محتوای آن‌ها را تغییر می‌دهد، به این صورت که می‌تواند با سایر ژن‌های همان کروموزوم جابه‌جا شوند یا این‌که با یک عدد در همان محدوده عوض شوند. نمایی از این عملگر در شکل ۸ قابل مشاهده می‌باشد.

Original offspring 1 1101111000011110

Original offspring 2 1101100100110110

Mutated offspring 1 1100111000011110

Mutated offspring 2 1101101100110110

شکل ۸) نمایی از عملگر جهش [۲۰]

در ادامه ابرپارامترهای آموزش شبکه ارائه شده در جدول ۴ را که پیش از این به صورت دستی تنظیم شده بودند را به وسیله الگوریتم ژنتیک بهینه سازی کردیم که سبب بهبود عملکرد شبکه گردید. مقادیر ابرپارامترهای آموزش پس از اعمال الگوریتم ژنتیک از جدول ۶ قابل مشاهده است.

جدول ۶) ابرپارامترهای آموزش بهینه سازی شده با الگوریتم ژنتیک

Training algorithm	Mini Batch size	Initial learning rate	Momentum
Sgdm	166	0.028	0.7135

ماتریس درهم ریختگی بعد از اعمال الگوریتم ژنتیک در شکل ۱۰ قابل مشاهده است که با استفاده از این ماتریس معیارهای ارزیابی نهایی شبکه بدست آمده که در جدول ۷ ارائه شده است.

Accuracy = 95.34%

Viral Pneumonia Class 1	134 31.2%	3 0.7%	3 0.7%
	3 0.7%	145 33.7%	2 0.5%
	6 1.4%	3 0.7%	131 30.5%
	Viral Pneumonia	covid-19	normal

Target Class

شکل ۱۰) ماتریس درهم ریختگی شبکه پیشنهادی در حالت نهایی

جدول ۷) نتایج شبکه پیشنهادی در حالت نهایی

	Viral Pneumonia	Covid-19	Normal
Precision	93.7	96.02	96.32
Recall	95.71	96.66	93.57
F1_Score	94.7	96.34	94.92

Accuracy = 95.34%

همان طور که از جدول ۷ نیز قابل مشاهده است دقت شبکه پیشنهادی با مجموعه داده های استفاده شده به میزان ۹۵/۳۴٪ رسیده است.

در ادامه از لحاظ دقت، تعداد داده استفاده شده، تعداد لایه، حداکثر فیلترهای مورد استفاده در یک لایه کانولوشن و تعداد کلاس دسته بندی، مقایسه ای بین شبکه پیشنهادی در این مقاله با شبکه های مورد اشاره در بخش ۲ صورت گرفته است که از جدول ۸ قابل مشاهده است. لازم به ذکر است دلیل بکارگیری مجموعه داده با تعداد کمتر برای آموزش شبکه پیشنهادی ما محدودیت در ظرفیت پردازش در سیستم سخت

برای محاسبه معیارهای ارزیابی عملکرد شبکه می توان از ماتریس درهم ریختگی استفاده کرد که این ماتریس در شکل ۹ و نتایج معیارهای ارزیابی در جدول ۵ قابل مشاهده است.

جدول ۴) ساختار شبکه پیشنهادی بعد از اعمال الگوریتم گرگ

خاکستری

Layer	Type	Filter Size	Number of filters	stride	Padding
Input	227*227*3				
Conv_1	CL + BN + Relu	7*7	8	-	1*1
APL		2*2		2*2	-
Conv_2	CL + BN + Relu	7*7	10	-	1*1
MPL_1		2*2		2*2	-
Conv_3	CL + BN + Relu	3*3	14	-	1*1
MPL_2		2*2		2*2	-
Conv_4	CL + BN + Relu	5*5	16	-	1*1
Drop out	0.05				
Fully Connected Output	Output size =3				
	Classification layer	Soft-max			

BN: Batch Normalization Layer

Accuracy = 92.79%

Viral Pneumonia Class 1	129 30.0%	4 0.9%	7 1.6%
	6 1.4%	141 32.8%	3 0.7%
	7 1.6%	4 0.9%	129 30.0%
	Viral Pneumonia	covid-19	normal

Target Class

شکل ۹) ماتریس درهم ریختگی بعد از بهینه سازی با الگوریتم گرگ

خاکستری

جدول ۵) نتایج شبکه بهینه سازی شده با الگوریتم گرگ خاکستری

	Viral Pneumonia	Covid-19	Normal
Precision	90.84	94.63	92.8
Recall	92.14	94	92.14
F1_Score	91.48	94.31	92.47

Accuracy= 92.8%

تا این مرحله ما یک بهینه سازی بر روی خود شبکه انجام دادیم که دقت آن به ۹۲/۸٪ رسید.

افزاری در دسترس، برای اجرای شبیه‌سازی بوده است که مشخصات آن در ابتدای این بخش بیان شده است.

با نگاهی به جدول ۸ ممکن است این گونه به نظر برسد که شبکه پیشنهادی ما از نظر دقت، عملکرد ضعیف‌تری نسبت به سایر شبکه‌ها دارد. اما باید به این نکته توجه نمود که شبکه پیشنهادی ما دارای تعداد لایه کمتر و تعداد فیلتر استفاده شده بسیاری کمتر قابل ملاحظه‌ای در لایه کانولوشن است و همچنین دلیل تفاوت اندک دقت شبکه‌ها، میزان داده استفاده شده برای آموزش آن‌ها بوده است و اگر شبکه پیشنهادی ما نیز با تعداد داده بالاتری آموزش پیدا کند می‌تواند دقت بهتری را داشته باشد. برای اثبات این ادعا چند مورد از شبکه‌های جدول ۸ با استفاده از سیستم سخت افزاری و مجموعه داده استفاده شده برای آموزش شبکه پیشنهادی ما، آموزش داده شدند که پس از شبیه‌سازی آن‌ها، نتایج جدول ۹ بدست آمد.

جدول ۹) مقایسه دقت شبکه پیشنهادی با سایر شبکه‌ها

شبکه پیشنهادی	شبکه - WOA-BAT [10]	شبکه GWO [10]	شبکه [۱۳]	شبکه
95.34%	94.18%	95.8%	95.11%	دقت

همان‌گونه که از جدول ۹ قابل مشاهده است، پس از شبیه‌سازی با شرایط برابر و یکسان دقت نهایی شبکه‌ها تفاوت چندانی با هم ندارند در نتیجه می‌توان دریافت در صورت استفاده از سیستم سخت افزاری با مشخصات بالاتر که امکان استفاده از مجموعه داده بیشتر را فراهم می‌کند، دقت شبکه پیشنهادی ما بالاتر رفته و می‌تواند به مقادیر بهتری نسبت به سایر شبکه‌های موجود دست پیدا کند.

۶- نتیجه‌گیری و پیشنهادات

پس از ارزیابی شبکه و بررسی نتایج بدست آمده، مشاهده گردید که شبکه پیشنهادی از نظر دقت، شرایط مناسبی را دارا می‌باشد، از طرفی از نظر تعداد لایه و فیلترهای استفاده شده شبکه پیشنهادی حالت بسیار بهینه‌تری نسبت به سایر شبکه‌های بررسی شده دارد و همچنین در این شبکه از یک لایه حذف‌کننده استفاده کردیم که تعدادی از نورون‌ها را حذف کرده و ساختار شبکه را ساده‌تر می‌کند.

در نتیجه می‌توان گفت که شبکه پیشنهادی ما در این مقاله شرایط بهتر جهت پیاده‌سازی سخت افزاری نسبت به سایر شبکه‌ها را دارا می‌باشد چرا که هم ساختار ساده‌تری دارد و هم از دقت مناسبی برخوردار است.

اکنون با توجه به مباحث مطرح شده می‌توان پیشنهاداتی را برای پژوهش‌های آینده و همچنین بهبود پژوهش حاضر ارائه نمود که به صورت زیر هستند:

- کاهش در تعداد لایه‌های پنهان برای ساده‌تر کردن ساختار شبکه که البته این امر ممکن است به کاهش توانایی شبکه منجر شود که می‌توان با روش‌هایی که برخی از آن‌ها نیز در پژوهش حاضر نیز تشریح گردید تا حدی این مشکل را برطرف نمود.
- استفاده از شبکه با ساختار موازی که می‌تواند منجر به افزایش سرعت پردازش و دقت شبکه گردد.
- بهینه‌سازی پارامترهای بیشتری از شبکه‌های موجود و یا ابرپارامترهای آموزش آن‌ها به وسیله روش‌های مانند الگوریتم‌های فراابتکاری که این امر نیز می‌تواند سبب افزایش دقت و بهبود عملکرد سایر معیارهای نتایج خروجی شبکه گردد.
- می‌توان از سایر الگوریتم‌های فراابتکاری بر اساس ویژگی‌های آن‌ها در بهینه‌کردن ابرپارامترهای مختلف شبکه استفاده کرد.

جدول ۸) مقایسه شبکه پیشنهادی با شبکه‌های بررسی شده

دقت	تعداد داده	حداکثر فیلتر استفاده شده در یک لایه کانولوشن	تعداد لایه	تعداد کلاس	شبکه
92.4%	13962	424	89	3	شبکه [۵] Covid-Net
98.08%	625	256	34	2	شبکه [۶] Dark covid-Net
87.02%	1125	256	34	3	شبکه [۶] Dark covid-Net
98.78%	700	2048	177	2	شبکه [۷]
98.5%	925	256	53	2	شبکه [۸]
98%	2905	1024	36	3	شبکه [۱۰] GWO-
95%	6342	1024	36	3	شبکه [۱۰] GWO-
96%	2905	1024	36	3	شبکه [۱۰] WOA-BAT
96%	6342	1024	36	3	شبکه [۱۰] WOA-BAT
97.78%	2700	64	23	3	شبکه [۱۳]
95.34%	2150	16	20	3	شبکه پیشنهادی

- <https://www.kaggle.com/tawsifurrahman/covid19-radiographydatabase>.
- [13] Goel, T., Murugan, R., Mirjalili, S., & Chakrabartty, D. K. (2021). OptCoNet: an optimized convolutional neural network for an automatic diagnosis of COVID-19. *Applied Intelligence*, 51(3), 1351-1366.
- [14] Mikołajczyk, A., & Grochowski, M. (2018, May). Data augmentation for improving deep learning in image classification problem. In *2018 international interdisciplinary PhD workshop (IIPhDW)* (pp. 117-122). IEEE.
- [15] Wong, S. C., Gatt, A., Stamatescu, V., & McDonnell, M. D. (2016, November). Understanding data augmentation for classification: when to warp?. In *2016 international conference on digital image computing: techniques and applications (DICTA)* (pp. 1-6). IEEE.
- [16] Wang, W., Yang, Y., Wang, X., Wang, W., & Li, J. (2019). Development of convolutional neural network and its application in image classification: a survey. *Optical Engineering*, 58(4), 040901.
- [17] Habib, G., & Qureshi, S. (2020). Optimization and acceleration of convolutional neural networks: A survey. *Journal of King Saud University-Computer and Information Sciences*.
- [18] Mirjalili, S., Mirjalili, S. M., & Lewis, A. (2014). Grey wolf optimizer. *Advances in engineering software*, 69, 46-61.
- [۱۹] علی اکبر علمداری، عبدالله دوستی عارف، رابعه کریمی مهابادی، زهرا رجبی، نسرين علمداری، مباحث ویژه در مهندسی برق و کامپیوتر با MATLAB، تهران، نگارنده دانش، ۱۳۹۲.
- [20] Lambora, A., Gupta, K., & Chopra, K. (2019, February). Genetic algorithm-A literature review. In *2019 international conference on machine learning, big data, cloud and parallel computing (COMITCon)* (pp. 380-384). IEEE.
- [۲۱] ویدا اسماعیلی، محمود محصل فقهی، تشخیص بیماری کووید-۱۹ با ترکیب روش‌های دستی و یادگیری عمیق از روی تصاویر اولتراسوند، مجله ماشین بینایی و پردازش تصویر، دوره نهم، شماره ۴، صفحه ۳۱-۴۱، دیماه ۱۴۰۱.
- [22] Vida Esmaceli, Mahmood Mohassel Feghhi, Seyed Omid Shahdi, Early COVID-19 Diagnosis from Lung Ultrasound Images Combining RIULBP-TP and 3D-DenseNet, 9th Iranian Joint Congress on Fuzzy and intelligent Systems (CFIS), March 2-4, 2022.
- [1] Calvo, C., López-Hortelano, M. G., de Carlos Vicente, J. C., Martínez, J. L. V., & de trabajo de la Asociación, G. (2020). Recommendations on the clinical management of the COVID-19 infection by the «new coronavirus» SARS-CoV2. Spanish Paediatric Association working group. *Anales de Pediatría (English Edition)*, 92(4), 241-e1.
- [2] Ciotti, M., Angeletti, S., Minieri, M., Giovannetti, M., Benvenuto, D., Pascarella, S., ... & Ciccozzi, M. (2019). COVID-19 outbreak: an overview. *Chemotherapy*, 64(5-6), 215-223.
- [3] Aruleba, R. T., Adekiya, T. A., Ayawei, N., Obaido, G., Aruleba, K., Mienye, I. D., ... & Ogbuokiri, B. (2022). COVID-19 Diagnosis: A Review of Rapid Antigen, RT-PCR and Artificial Intelligence Methods. *Bioengineering*, 9(4), 153.
- [4] Li, Z., Liu, F., Yang, W., Peng, S., & Zhou, J. (2021). A survey of convolutional neural networks: analysis, applications, and prospects. *IEEE Transactions on Neural Networks and Learning Systems*.
- [5] Wang, Linda, Zhong Qiu Lin, and Alexander Wong. "Covid-net: A tailored deep convolutional neural network design for detection of covid-19 cases from chest x-ray images." *Scientific Reports* 10.1 (2020): 1-12.
- [6] Ozturk, Tulin, et al. "Automated detection of COVID-19 cases using deep neural networks with X-ray images." *Computers in biology and medicine* 121 (2020): 103792.
- [7] Murugan, R., Goel, T., Mirjalili, S., & Chakrabartty, D. K. (2021). WOANet: Whale optimized deep neural network for the classification of COVID-19 from radiography images. *Biocybernetics and Biomedical Engineering*, 41(4), 1702-1718.
- [8] Hassan, M. R., Ismail, W. N., Chowdhury, A., Hossain, S., Huda, S., & Hassan, M. M. (2022). A framework of genetic algorithm-based CNN on multi-access edge computing for automated detection of COVID-19. *The Journal of Supercomputing*, 1-25.
- [9] Cohen, J. P., Morrison, P., & Dao, L. (2020). COVID-19 image data collection. *arXiv preprint arXiv:2003.11597*.
- [10] Pathan, S., Siddalingaswamy, P. C., & Ali, T. (2021). Automated Detection of Covid-19 from Chest X-ray scans using an optimized CNN architecture. *Applied Soft Computing*, 104, 107238.
- [11] SIRM COVID-19 Database (2020, May) Italian Society of Medical and Interventional Radiology COVID-19 dataset, Version 1. Retrieved may 05, 2020, from <https://www.sirm.org/category/senza-categoria/covid-19/>
- [12] Rahman, COVID-19 Radiography Database, 2020, Retrieved October 02, 2020,

مراجع

^{۱۲} Joseph Paul Cohen

^{۱۳} Sameena Pathan

^{۱۴} Grey Wolf Optimization

^{۱۵} WOA-BAT Optimization

^{۱۶} Tripti Goel

^{۱۷} Data augmentation

^{۱۸} Overfitting

^{۱۹} Convolution layer

^{۲۰} Batch Normalization layer

^{۲۱} Pooling layer

^{۲۲} Fully Connected Layer

¹ Computer Vision

² Natural Language Processing

³ Convolutional Neural Networks

⁴ Drop Out Layer

⁶ Linda Wang

⁷ Tulin Ozturk

⁷ Raghavan Murugan

[^] Metaheuristic Algorithms

⁹ Whale optimization Algorithm

^{۱۱} Md Rafiul Hassan

^{۱۱} Genetic Algorithm

-
- | | |
|---|-----------------------------------|
| ^{۲۳} Particle Swarm Optimization (PSO) | ^{۲۷} Roulette Wheel |
| ^{۲۴} Ant Colony Optimization (ACO) | ^{۲۸} Crossover Operation |
| ^{۲۵} Genetic Algorithm (GA) | ^{۲۹} Mutation Operation |
| ^{۲۶} Selection Operation | ^{۳۰} Confusion matrix |