

روش تلفیقی یادگیری عمیق و ماشین بردار پشتیبان جهت تشخیص کووید-۱۹ بر اساس تصاویر اشعه ایکس قفسه سینه

علی کارساز^۱، دانشیار، رقیه اکبریان^۲، کارشناسی ارشد، علی خرمی^۳، استادیار

۱- گروه مهندسی پزشکی و برق، موسسه آموزش عالی خراسان، مشهد، ایران، karsaz@khorasan.ac.ir

۲- گروه مهندسی پزشکی و برق، موسسه آموزش عالی خراسان، مشهد، ایران، Akbarian@khorasan.ac.ir

۳- گروه مهندسی پزشکی و برق، موسسه آموزش عالی خراسان، مشهد، ایران، khorami@khorasan.ac.ir

چکیده: با گسترش روزافزون بیماری کرونا، استفاده از الگوریتم‌های هوش مصنوعی به خصوص شبکه‌های عصبی کانولوشنال (CNN) مبتنی بر یادگیری عمیق جهت غربالگری تصاویر اشعه ایکس قفسه سینه (CXR) بیماران مبتلا به کووید-۱۹، ضرورت بیشتری یافته و سهم عمده‌ای از مقالات در این حوزه را به خود اختصاص داده‌اند. دقت تشخیص و غربالگری مبتنی بر CNNها در مقالات علمی به بیش از ۹۵ درصد و تلفیق چندین معماری مختلف از CNNها، منجر به افزایش دقت تا ۹۹ درصد گردیده است. در این مقاله یک ساختار ترکیبی از شبکه عصبی کانولوشن الکسنت (AlexNet) با روش دسته‌بندی ماشین بردار پشتیبان (SVM) جهت غربالگری بیماران مبتلا به کووید-۱۹ با توجه به تصاویر CXR از بانک اطلاعات تصاویر GitHub پیشنهاد شده است. در بخش ورودی ساختار پیشنهادی، جهت استخراج ویژگی‌های تصاویر از هیستوگرام دو بعدی تصویر که حاوی اطلاعات تصویر در ابعاد کمتری است، استفاده شده و مشکل کمبود تصاویر با استفاده از روش داده‌افزایی مرتفع گردیده است. نتایج حاصل با سایر روش‌های دسته‌بندی معروف مانند خوشه‌بندی میانگین k (k -means)، خوشه‌بندی میانگین فازی (FCM) و خوشه‌بندی تفضلی (Subtractive) مقایسه شده است. ساختار پیشنهادی دارای عملکرد بیش از ۹۹ درصدی در تشخیص کرونا بر اساس معیار حساسیت است.

واژه‌های کلیدی: تصاویر اشعه ایکس قفسه‌سینه (CXR)، ماشین بردار پشتیبان (SVM)، کووید-۱۹، شبکه‌های عصبی کانولوشنال (CNN).

Hybrid Deep Learning and Support Vector Machine for Covid-19 diagnosis based on Chest X-ray images

Ali Karsaz, Associate Professor¹, Roghayeh Akbarian, M.Sc.²

1- Electrical, Bioelectric Engineering Department, Khorasan Institute of Higher Education, Mashhad, Iran, karsaz@khorasan.ac.ir

2- Electrical, Bioelectric Engineering Department, Khorasan Institute of Higher Education, Mashhad, Iran, akbarian@khorasan.ac.ir

Abstract: Under the daily growing of corona disease, the use of artificial intelligence algorithms especially convolutional neural networks (CNN) based on deep learning for screening chest X-ray (CXR) images of Covid-19 patients is becoming more important and encompasses the most articles in the field. CNN detection and screening accuracy in scientific articles has reached more than 95% and the combination of several different CNN architectures has resulted up to 99% accuracy. In this paper, we use a hybrid AlexNet as a convolutional neural network with support vector machine (SVM) as a classifier, to screen Covid-19 infected patients based on chest X-ray images of GitHub database. At the input part of the proposed structure, for feature extraction of images, a two-dimensional histogram which contains more image information in smaller dimensions has been used. The problem of lack of images has been solved by using the data augmentation technique. Simulation results have been compared with other clustering methods such as k-means, fuzzy C-means (FCM) and subtractive clustering. **The proposed structure has more than 99 percent sensitivity in diagnosis of corona disease.**

Keywords: Chest X-ray images (CXR), Support vector machine (SVM), Covid-19, Convolutional neural networks (CNN).

تاریخ ارسال مقاله: ۱۴۰۰/۱۲/۲۶

تاریخ اصلاح مقاله: ۱۴۰۱/۰۳/۱۴


تاریخ پذیرش مقاله: ۱۴۰۱/۰۴/۲۰

نام نویسنده مسئول: علی کارساز

نشانی نویسنده مسئول: گروه مهندسی پزشکی و برق، موسسه آموزش عالی خراسان، مشهد، ایران

۱- مقدمه

ویروس کووید-۱۹ متعلق به خانواده‌ای از ویروس‌ها از قبیل سندروم تنفسی حاد^۲ (SARS)، سندروم تنفسی خاورمیانه^۳ (MERS) و نیز سندرم دیسترس تنفسی^۴ (ARDS) است که اولین بار در سال ۱۹۶۰ مورد مطالعه قرار گرفته و تاکنون هفت نمونه مختلف از این ویروس‌ها کشف شده است. این بیماری از اواخر سال ۲۰۱۹ میلادی در وهان چین شروع و در تاریخ ۳۰ ژانویه ۲۰۲۰ سازمان بهداشت جهانی آن را به عنوان بیماری عمومی و یک مخاطره بین المللی معرفی و در فوریه ۲۰۲۰ آن را کووید-۱۹ نام گذاری کرد [۱]. از نظر ساختاری این ویروس از یک رشته RNA، با دو نوع پروتئین پوششی و پروتئین شاخکی مطابق شکل ۱ تشکیل شده است. پروتئین شاخکی به گیرنده آنزیم نوع دو مبدل آنژیوتانسین^۵ در سطح سلول‌های ریه، کلیه و یا قلب متصل می شود [۲].




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


یکی از رایج ترین راه‌های تشخیص بیماری کووید-۱۹، از طریق نمونه‌های گرفته شده از نمونه‌های بینی و حلق، تحت آزمایشی با عنوان واکنش زنجیره‌ای پلیمرز ترانس کریپتاز معکوس^۶ (RT-PCR) است. این فرآیند آزمایشی دارای نتایج منفی کاذب بوده و گاهی عفونت را تشخیص نمی‌دهد. نتایج منفی کاذب به معنی عدم تشخیص بیماری در افراد مبتلا گفته می‌شود. با استفاده از این آزمایش، واکنش زنجیره پلیمرز توسط مولکول‌های گزارش گر فلورسنت انجام و از این طریق، تولید فرآورده‌های تکثیری طی هر چرخه واکنش PCR گزارش می‌شود [۳، ۴]. تحقیقات نشان می‌دهد که دقت آزمایش RT-PCR در تشخیص بیماری کووید-۱۹، در بازه ۵۹٪ تا ۷۱٪ متغیر است [۵]. در حال حاضر در دنیا برای تشخیص بیماری کووید-۱۹ روش‌های بسیار زیادی وجود دارد، اما بر اساس تائید انجمن رادیولوژی آمریکا، سی تی اسکن^۷ (CT) و یا تصاویر اشعه ایکس (CXR) قفسه سینه بهترین راه برای تشخیص ابتلا به این ویروس است و یک روش کم هزینه تر و ایمن تر نسبت به روش RT-PCR محسوب می‌شود [۶]. در کنار مزیت روش‌های عکس برداری قفسه سینه در تشخیص کرونا، کالج رادیولوژی آمریکا توصیه‌ها و هشدارهایی در این زمینه دارد اولین مسئله عدم دقت بالای روش CT در تشخیص کرونا از سایر بیماری‌های عفونی مانند آنفلوآنزای فصلی است دومین نکته

وجود تصاویر CT نرمال در برخی از بیماران کرونا است که ایجاد نمونه‌های منفی کاذب می‌کند و نکته و هشدار آخر ایجاد خطر ابتلای عوامل و پرسنل عکس برداری به کرونا در اثر آلودگی دستگاه‌ها و تجهیزات تصویربرداری است [۷].

شکل ۲-الف، تصاویر CXR مربوط به یک بیمار مرد ۲۹ ساله مبتلا به کووید-۱۹ با وخامت سریع تنفسی پس از شروع علائم را نشان می‌دهد پیشرفت عفونت، تیرگی زمینه-شیشه‌ای^۸ (GGO) به ترتیب از راست به چپ در روزهای سوم، چهارم و ششم در قسمت تحتانی ریه قابل مشاهده می‌باشد. شکل ۲-ب، نیز تصاویر CXR یک مرد ۵۶ ساله مبتلا به کووید-۱۹ را به ترتیب از راست به چپ در روزهای اول، نهم و پانزدهم نشان می‌دهد اگرچه تصویر رادیوگرافی قفسه سینه در روز اول طبیعی به نظر می‌رسد ولی با پیشرفت عوارض بیماری در روزهای نهم و پانزدهم به حجم GGO قفسه سینه افزوده شده است [۷].



الف



ب

شکل ۲: الف-تصاویر CXR یک مرد ۲۹ ساله (به ترتیب از راست به چپ در روزهای سوم، چهارم و ششم) ب- تصاویر CXR یک مرد ۵۶ ساله (به ترتیب از راست به چپ در روزهای اول، نهم و پانزدهم)

در تصاویر CT قفسه سینه، امکان ایجاد تصاویر با کیفیت از بافت ریه وجود داشته و رادیولوژیست می‌تواند به سرعت میزان درگیری ریه بیمار را از ویژگی‌هایی شامل نقاط توده‌ای تار، لکه‌های چند کانونی^۹ و تغییرات بینابینی با توزیع محیطی^{۱۰} سنجش نماید. در مطالعاتی که محققان چینی بر روی ۱۰۱۴ بیمار مشکوک به کووید-۱۹ انجام دادند، مشخص شد که حساسیت تصاویر CT در تشخیص این بیماری می‌تواند به بیش از ۹۰ درصد برسد [۸، ۹]. در ایام همه‌گیری بیماری کرونا و مراجعه گسترده مبتلایان و افراد سالم به مراکز و کلینیک‌های پزشکی و نیز کمبود افراد متخصص در امر تشخیص، لزوم بکارگیری روش‌های غربالگری مبتنی بر تشخیص خودکار بیش از پیش آشکار می‌گردد.

در این مقاله در ادامه پس از بررسی شبکه‌های کانولوشن در غربالگری کووید-۱۹ براساس تصاویر CXR و CT به طور مختصر به ارزیابی معماری الکسنت مورد مطالعه این مقاله پرداخته می‌شود، در بخش

چهارم دیاگرام روش پیشنهادی ارائه می‌گردد و در نهایت در بخش پنجم نتایج شبیه سازی و جمع بندی گزارش می‌گردد.

۲- شبکه‌های عصبی کانولوشن در غربال‌گری کووید-۱۹


معیارهای ارزیابی عملکرد الگوریتم‌های غربال‌گری بیماران کرونا مانند بسیاری از روش‌های دسته‌بندی و غربال‌گری معمولاً شامل دقت^{۱۱} (Acc)، قابلیت پیش‌بینی یا صحت^{۱۲} (Sp)، حساسیت^{۱۳} (Se) یا فراخوانی و معیار رتبه F1^{۱۴} می‌باشند. با توجه به نتایج این معیارها می‌توان در مورد عملکرد الگوریتم‌ها و ساختارهای پیشنهادی ارائه شده بحث نمود. برای توضیح این چهار معیار بایستی ابتدا اجزای مورد استفاده برای محاسبه آن‌ها بررسی شوند. این اجزا شامل چهار مورد مثبت درست^{۱۵} (TP) یعنی آن دسته از نمونه‌هایی که دارای بیماری کووید-۱۹ بوده و به درستی بیمار تشخیص داده شده‌اند، مثبت نادرست^{۱۶} (FP) اشاره به آن دسته از تصاویر CT یا CXR دارد که سالم بوده و به اشتباه در دسته بیمار قرار گرفته‌اند، منفی درست^{۱۷} (TN) اشاره به نمونه‌هایی دارد که کووید-۱۹ نداشته و به درستی در دسته افراد سالم طبقه‌بندی شده‌اند و نهایتاً منفی نادرست^{۱۸} (FN) اشاره به نمونه‌های با تشخیص بیمار دارد که به اشتباه سالم تشخیص داده شده‌اند [۱۰]. با توجه به توضیحات مطرح شده روابط ارزیابی عملکرد یک ساختار غربال‌گری در جدول ۱ تعریف می‌گردد. در این جدول، P + N نشان‌دهنده تمام نمونه‌ها می‌باشد.

جدول ۱: معیارهای ارزیابی عملکرد روش‌های غربال‌گری کرونا [۱۰]

معیار ارزیابی	رابطه
دقت (Acc)	$(TP + TN) / (P + N)$
قابلیت پیش‌بینی یا صحت (Sp)	$TP / (TP + FP)$
حساسیت یا فراخوانی (Se)	$TP / (TP + FN)$
میانگین معیار رتبه FI	$2TP / (2TP + FP + FN)$

بخش عمده‌ای از مقالات تشخیص کووید-۱۹ مبتنی بر تصاویر CT، براساس مفاهیم یادگیری عمیق^{۱۹} (DL) و استفاده از CNN‌ها بنا نهاده شده‌اند. جدول ۲ خلاصه‌ای از مهم‌ترین مقالاتی که به بررسی و تشخیص خودکار کووید-۱۹ براساس یادگیری عمیق پرداخته‌اند را نشان می‌دهد. معمولاً معیارهای ارزیابی در این دسته از مقالات بر اساس جدول ۱، در بهترین شرایط عملکردی گزارش شده‌اند. در ادامه به بررسی برخی از

این روش‌ها می‌پردازیم. برای مثال، در ردیف اول جدول ۲، از هشت CNN معروف برای تشخیص در سه دسته بیمار کرونایی، بیمار ویروسی و افراد سالم استفاده نموده است نکته قابل توجه در این مقاله ترکیب چند پایگاه داده تصاویر کرونا مانند SRIM، GitHub و Kaggle بوده علاوه بر این از روش داده افزایی نیز برای افزایش تعداد نمونه‌ها و بهبود نتایج کمک گرفته است [۱۱]. روش داده‌افزایی در این مقاله شامل چرخش ۵، ۱۰ و ۱۵ درجه ساعت‌گرد و عکس ساعت‌گرد و نیز جابجایی تصویر به میزان ۵ درصد در جهت‌های عمودی و افقی می‌شود دو شبکه CheXNet و ResNet18 در حالت بدون داده‌افزایی و دو شبکه DenseNet201 و InceptionV3 در جدول پررنگ شده‌اند بهترین نتایج را داشته‌اند، شکل ۳ ساختار این معماری را نشان می‌دهد. ردیف دوم جدول ۲، یک تلفیق موفق از سه معماری InceptionV3، ResNet50، InceptionResNetV2 و با استفاده بانک اطلاعاتی شامل ۱۰۰ تصویر CT و CXR افراد سرماخوردده و یا مبتلا به کووید-۱۹ را نشان می‌دهد که بهترین نتیجه بر اساس معیار دقت به میزان ۹۸ درصد گزارش شده است [۱۲]. در ردیف چهارم این جدول نیز یک ساختار اختصاصی مبتنی بر CNN با نام COVID-Net معرفی شده که بر روی بانک اطلاعات تصاویر COVIDx شامل ۱۳۹۶۲ تصویر آموزش دیده است که البته تنها ۳۵۸ تصویر آن متعلق به بیماران کووید-۱۹ است دقت شبکه COVID-Net بر روی این بانک اطلاعات تصاویر، ۹۳/۳ درصد بدست آمده است [۱۴]. در ردیف ششم از جدول ۲، یک ساختار ترکیبی از یک CNN برای استخراج ویژگی‌ها و یک شبکه حافظه‌دار کوتاه-بلند مدت^{۲۰} (LSTM) برای دسته‌بندی، جهت تشخیص خودکار کووید-۱۹ بکار رفته است مدل ارایه شده با یک بانک اطلاعات تصاویر جمع شده از چندین بانک اطلاعاتی شامل ۴۵۷۵ تصویر، (۱۵۲۵ تصویر کووید-۱۹، ۱۵۲۵ تصویر سرماخوردگی معمولی و ۱۵۲۵ تصویر CXR افراد سالم) آموزش دیده است، مزیت روش ارایه شده در این مقاله توازن در تعداد نمونه‌های هر دسته بوده که برای این منظور از روش داده‌افزایی^{۲۱} استفاده شده است. روش داده افزایی نتایج خوبی در افزایش دقت تا ۹۹ درصد در روش‌های تشخیص کووید-۱۹ به همراه دارد [۱۶]. ردیف هشتم جدول ۲، با معماری Xception و استفاده از بانک اطلاعاتی دارای ۵۰۰ تصویر سرماخوردگی، ۱۲۷ تصویر کووید-۱۹ و ۵۰۰ تصویر افراد سالم بهترین نتیجه بر اساس معیار دقت به میزان ۹۷ درصد گزارش شده است [۱۸].




شکل ۳: تلفیق نتایج هشت CNN جهت دسته‌بندی تصاویر CT به بیمار کرونایی، ویروسی و یا سالم به کمک داده افزایی [۱۱]

جدول ۲: جدیدترین مقالات حوزه غربالگری کووید-۱۹ بر اساس معماری‌های مختلف CNN و یادگیری عمیق با استفاده از تصاویر CXR و CT [۱۱]

ردیف	نوع معماری CNN	تعداد تصاویر مورد استفاده در روش			معیار عملکرد (%)	شماره مرجع
		کووید-۱۹	سرماخوردگی	سالم		
۱	SqueezeNe, MobileNet, ResNet18, InceptionV3, ResNet10, CheXNet, DenseNet201, VGG19	۴۲۳	۱۴۸۵	۱۵۷۹	Acc = ۹۹/۷	[۱۱]
۲	InceptionV3, InceptionResNetV2, ResNet50	۵۰	۵۰	-	Acc = ۹۸	[۱۲]
۳	VGG19, Dense Net	۲۵	۵۰	-	AvF1 = ۹۰	[۱۳]
۴	Covid-Net, ResNet50, VGG19	۳۵۸	۸۰۶۶	۵۵۳۸	Acc = ۹۳/۳	[۱۴]
۵	Efficient Net	۱۰۰	۱۴۳۱	-	Se = ۹۶, Sp = ۷۰	[۱۵]
۶	CNN + LSTM	۱۵۲۵	۱۵۲۵	۱۵۲۵	Acc = ۹۹	[۱۶]
۷	VGG16	۱۳۲	۱۳۲	۱۳۲	Avf1 = ۸۵	[۱۷]
۸	Xception	۱۲۷	۵۰۰	۵۰۰	Acc = ۹۷	[۱۸]
۹	Dark net	۱۲۷	۵۰۰	۵۰۰	Acc = ۸۷	[۱۹]
۱۰	Xception	۲۹۰	۳۱۰	۶۵۷	Acc = ۹۳	[۲۰]
۱۱	ResNet18, ResNet50, Squeeze Net, DenseNet121	۱۸۴	۲۴۰۰	۲۶۰۰	Se = ۹۸, Sp = ۹۲/۹	[۲۱]
۱۲	VGG19, MobileNetV2, Inception, Xception, Inception, ResNetV2	۲۲۴	۵۰۴	۷۰۰	Acc = ۹۴	[۲۲]
۱۳	Inception	۱۶۲	۲۰۰۳	۴۶۵۰	Acc = ۹۹	[۲۳]
۱۴	MobileNetV2, Squeeze Net	۲۹۵	۶۵	۹۸	Acc = ۹۹	[۲۴]
۱۵	CovidGAN, VGG16	۴۰۳	۱۱۲۴	-	Acc = ۹۵	[۲۵]
۱۶	Alex net, Google net, Resnet18	۶۹	۷۹	۱۵۸	Acc = ۹۹	[۲۶]
۱۷	Caps net	۲۳۱	۱۰۵۰	۱۰۵۰	Acc = ۸۴	[۲۷]
۱۸	Covx Net	۳۰۵	۳۰۵	۶۱۰	Acc = ۹۰/۲	[۲۸]
۱۹	ResNet18, DenseNet	۱۸۰	۱۹۱	۱۳۱	Acc = ۸۹	[۲۹]
۲۰	Efficient Net-B	۲۱۹	۱۳۴۱	۱۳۴۵	Acc = ۹۹	[۳۰]
۲۱	Inception-V3	۹۰	۱۰۰۰	۶۸۷	AvF1 = ۶۵	[۳۱]
۲۲	VGG16	۲۵۰	۳۵۲۵	۲۷۵۳	Acc = ۹۷	[۳۲]
۲۳	AlexNet, VGG16, VGG19, SqueezeNet, GoogleNet, MobileNet-V2, ResNet18, ResNet50, ResNet10, Xception	۱۰۸	۸۶	-	Acc = ۹۹/۶۳, Sen = ۱۰۰	[۳۳]
۲۴	RLDD	۷۰	-	۸۰	Acc = ۹۱/۳, Sen = ۹۰	[۳۴]
۲۵	DenseNet, Inception, ResNet 201	۴۰	-	۱۶۷	Sen = ۹۳/۰	[۳۵]
۲۶	ADECO-CNN	۱۲۵۲	-	۱۲۳۰	Acc = ۹۸/۲, Sen = ۹۵/۷	[۳۶]
۲۷	LightEfficientNetV2	۶۰۰	۶۰۰	۶۰۰	Pre = ۹۶/۸۱	[۳۷]


است [۲۵]. یک شبکه مولد تخصصی روی مجموعه تصاویر آموزش می‌تواند به تولید تصاویر واقع‌گرایانه متعدد بپردازد به گونه‌ای که این تصاویر حداقل به طور ظاهری توسط ناظر انسانی قابل باور باشد شبکه بکار رفته جهت داده افزایی CovidGAN و شبکه تشخیص یک شبکه VGG19 بوده است. این مقاله با بکارگیری این تکنیک داده‌افزایی توانسته دقت در تشخیص را به میزان ۱۰ درصد افزایش دهد (شکل ۴).

چنانچه بیان شد یکی از معضلات تشخیص هوشمند بیماری کرونا بر اساس تصاویر CT و یا CXR، ناکافی بودن داده‌های آموزش است از آنجا که روش پیشنهادی این مقاله جهت رفع این نقیصه به افزایش تعداد نمونه‌ها با استفاده از تکنیک داده افزایی می‌پردازد مقالاتی که در این زمینه نیز کار مشابهی را انجام داده‌اند مورد بررسی دقیق‌تر قرار خواهند گرفت به عنوان نمونه مقاله مربوط به ردیف ۱۵ جدول ۲ با استفاده از یک شبکه مولد تخصصی^{۲۳} (GAN) به تولید تصاویر مصنوعی پرداخته



شکل ۴: بکارگیری معماری VGG19 جهت دسته‌بندی و شبکه مولد تخصصی CovidGAN جهت داده افزایشی [۲۵]


تصاویر، تنها به تصاویر قفسه سینه محدود نشده بلکه برای اطفال و بیماران خاص می‌توان از تکنیک اولتراسوند بدون اشعه بهره برد. تلفیق موفق از یک شبکه کانولوشن ResNet50 از پیش آموزش دیده با ویژگی‌های دستی توانسته دقت عملکرد را تا حدود ۹۸/۵ درصد افزایش دهد [۳۹-۳۸].



شکل ۶: بکارگیری ده معماری متفاوت و متداول از شبکه‌های عصبی کانولوشنال در غربال‌گری کرونا [۳۳]

از زمان شیوع بیماری کرونا در سال ۲۰۱۹ تا کنون، پایگاه‌ها اطلاعات تصاویر زیادی در مراکز پژوهشی و بیمارستان‌ها ایجاد شده‌اند. از این پایگاه‌های تصویر برای تشخیص، آموزش، تحقیق و همچنین برای

ردیف ۱۹ جدول ۲، تلفیق موفق از دو معماری ResNet18 و DenseNet در تشخیص کووید-۱۹ بر اساس ۵۰۲ تصویر تلفیق CXR که از تلفیق چند بانک اطلاعات تصاویر بدست آمده و تنها ۱۸۰ مورد آن مبتلا به کووید-۱۹ بوده‌اند را نشان می‌دهد (شکل ۵). مزیت عمده روش ارایه شده بر اساس تعداد تصاویر محدود مبتلا به کرونا بوده دقت در این روش به حدود ۹۰ درصد رسیده است [۲۹].




شکل ۵: بکارگیری دو معماری DenseNet و ResNet18 در تشخیص

کووید-۱۹ بر اساس بانک اطلاعات تصاویر شامل ۱۸۰ فرد مبتلا به کووید-۱۹ [۲۹]

در ردیف ۲۳ از جدول ۲، روش ابداعی با بکارگیری ده CNN متفاوت و متداول به موضوع غربال‌گری کرونا پرداخته است [۳۳]. نتایج نشان دهنده برتری دو روش ResNet10 و Xception در مقایسه با سایر روش‌ها است (شکل ۶). ردیف ۲۶ از جدول ۲ یک کار پژوهشی بر روی یک سیستم تشخیص اتوماتیک بیماری کرونا مبتنی بر یک شبکه CNN ابداعی به نام ADECO-CNN است که طبق ادعای نویسندگان توانسته نتایجی بهتر از شبکه‌های معروفی مانند VGG19، GoogleNet و ResNet به تنهایی در برداشته باشد. حوزه تشخیص بیماری کرونا از روی

با دخالت تابع کرنل که وظیفه نگاشت داده‌ها از یک فضای خطی یا غیرخطی به فضای غیرخطی دیگر را بر عهده دارد، حاصل می‌شود [۴۱].



شکل ۷: جداسازی داده‌ها (دوایر توخالی سبز و دوایر توپر آبی) بر اساس حداکثرسازی حاشیه ریسک عملیاتی در SVM [۴۰]

۳-۲- روش خوشه بندی k-means [۴۲]

روش خوشه‌بندی K-means یکی از روش‌های پرکاربرد در مسائل دسته‌بندی است که تعداد کلاسترها به‌عنوان پیش فرض به الگوریتم داده می‌شود. علت نام‌گذاری این روش به K-means و یا C-means استفاده از معیار میانگین برای تعیین مرکز C کلاستر موجود است. روش کار در این الگوریتم بسیار ساده بوده ابتدا به تعداد دلخواه مرکز کلاستر به شکل تصادفی در نظر گرفته می‌شود سپس داده‌های متعلق به هر دسته با توجه به نزدیکی داده‌ها به آن مرکز مشخص شده در مرحله بعد با استفاده از میانگین‌گیری روی داده‌ها، مراکز تصحیح شده و با توجه به مراکز جدید مرحله رقابت بین مراکز برای تصاحب داده‌ها تکرار می‌گردد [۴۳].

۳-۳- روش خوشه بندی Fuzzy C-means [۴۴]

علت نام‌گذاری این روش به فازی میانگین C، در واقع به موضوع بهینه‌سازی C مرکز داده با استفاده از میانگین داده‌های متعلق به آن دسته به‌روش فازی بازمی‌گردد. در این الگوریتم به‌ازای هر داده x_i یک درجه تعلق به هر مرکز کلاستر C_j به صورت u_{ij} مشخص می‌گردد که این درجه تعلق عددی بین صفر و یک خواهد بود.

$$0 \leq u_{ij} \leq 1 \quad (1)$$

در روش k-means این درجه تعلق تنها صفر یا یک بود. در هر دو روش مجموع میزان تعلق یک داده به کلیه مراکز واحد است:

$$\sum_{i=1}^c u_{ik} = 1, \forall k = 1, \dots, n \quad (2)$$

رابطه بالا بیان ساده این موضوع است که مجموع میزان تعلق یک داده به تمامی کلاسترها واحد است ولیکن این تعلق ممکن است به شکل فازی و یا درصدی باشد. تابع هدفی که برای این الگوریتم جهت کمینه‌سازی تعریف می‌شود بصورت زیر است:

$$J = \sum_{i=1}^c \sum_{k=1}^n U_{ik}^m d_{ik}^2 = \sum_{i=1}^c \sum_{k=1}^n \|x_k - v_i\|^2 \quad (3)$$

توسعه ابزارهای هوش مصنوعی در حوزه غربال‌گری استفاده می‌گردد. بانک اطلاعات تصاویر مورد استفاده در این مقاله مربوط به سایت GitHub بوده که آقای جوزف پائول کوهن و همکارانش این بانک اطلاعات تصاویر را با جمع‌آوری ۳۱۹ عکس رادیولوژی از بیماران کووید-۱۹، MERS، SARS و ARDS از منابع مختلف گردآوری نمودند. از ویژگی‌های مفید این بانک، ارائه تصاویر بیماران در روزهای مختلف درگیری و بستری با مشخصات کامل سن، جنسیت، محل مراجعه، سوابق بیماری، علائم و ... است. در آوریل ۲۰۱۷ گیت‌هاب با داشتن حدود ۲۰ میلیون کاربر و ۵۷ میلیون مخزن، به عنوان بزرگترین میزبان منبع باز پایگاه داده و کدهای برنامه نویسی در جهان شناخته شد [۴۰].


۳- روش‌های دسته‌بندی

روش‌های دسته‌بندی به دو دسته کلی یادگیری با نظارت^{۲۳} و یادگیری بدون نظارت^{۲۴} که گاهی از آنها به عنوان روش‌های خوشه‌بندی نیز یاد می‌شود، تقسیم بندی می‌شوند. در ادامه روش دسته‌بندی با نظارت ماشین بردار پشتیبان^{۲۵} (SVM) و روش‌های خوشه‌بندی بدون نظارت میانگین k (k-means)، خوشه‌بندی میانگین فازی (FCM) و خوشه‌بندی تفاضلی^{۲۶} (Subtractive) مورد بررسی قرار می‌گیرند.

۳-۱- ماشین‌های بردار پشتیبان


ماشین‌های بردار پشتیبان و یا شبکه‌های بردار پشتیبان با ارائه یک مدل نیرومند در حوزه دسته‌بندی اولین بار توسط آقای وپنیک^{۲۷} در سال ۱۹۹۵ ارائه گردید. الگوریتم SVM، به مانند شبکه‌های عصبی مصنوعی در زمینه‌های تشخیص الگو، مسائل دسته‌بندی، رگرسیون، پیش‌بینی و سایر مسائلی که در این حوزه قرار می‌گیرند، به کار می‌رود. اگرچه ماشین‌های بردار پشتیبان در بسیاری از مراجع به عنوان دسته خاصی از شبکه‌های عصبی شناخته می‌شوند اما وجه تمایز عمده آن نسبت به شبکه‌های عصبی متداول مانند شبکه‌های عصبی پرسپترون و شبکه‌های شعاعی، در کمینه‌سازی ریسک عملیاتی بجای کاهش صرف خطای تخمین است. چنانچه در شکل ۷ دیده می‌شود، هدف از الگوریتم SVM پیدا کردن خطی است که از داده‌های موجود در دو کلاس دارای بیشترین فاصله و یا دارای کمترین ریسک عملیاتی باشد (خط پررنگ در شکل ۷). معادله کلی صفحه تفکیک‌کننده به صورت $w^T x + b = 0$ بیان می‌گردد. که در آن b مقدار بایاس و w^T بیانگر ترانهاده بردار همان ضرایب معادله صفحه است. در مرحله بعد دو خط مرزی موازی با خط تفکیک‌کننده رسم می‌شود (دو خط خط‌چین شده در شکل ۷) این دو خط و یا در حالت کلی دو صفحه تا زمانی که به اولین داده دو دسته برخورد کنند از یکدیگر دور می‌شوند. صفحه تفکیک‌کننده‌ای که بیشترین فاصله را از صفحات دسته‌بندی داشته باشد، بهترین صفحه جداساز داده‌ها خواهد بود. در مسائلی که داده‌ها با چیدمان فعلی آنها قابل تفکیک نباشند، داده‌ها به فضایی با ابعاد غیرخطی بالاتر نگاشت پیدا می‌کنند تا بتوان آن‌ها را در این فضای جدید تفکیک نمود. این کار

متصل بوده و با استفاده از واحد پردازش گرافیکی (GPU) سرعت این یادگیری را تا ده برابر افزایش داد [۴۶]. شکل ۸ تصویری از معماری الکسنت را نشان می‌دهد.



شکل ۸: معماری شبکه عصبی کانوولوشن AlexNet با ۵ لایه کانوولوشن و ۳ لایه تمام متصل [۴۶]

الگوریتم پیشنهادی دارای مراحل پیش‌پردازش تصاویر، داده‌افزایی، ایجاد هیستوگرام دو بعدی، استخراج ویژگی‌ها توسط شبکه الکسنت اصلاح شده و نهایتاً دسته‌بندی تصاویر است (شکل ۹). جهت تشخیص و دسته‌بندی تصاویر رادیولوژی به دو دسته سالم و مبتلا به کووید ۱۹- از معماری اصلاح شده الکسنت در لایه نهایی و دسته‌بندی ماشین بردار پشتیبان با بکارگیری کرنل غیرخطی استفاده شده است همچنین نتایج روش پیشنهادی با روش‌های خوشه‌بندی k-means، خوشه‌بندی FCM و دسته‌بندی تفاضلی مقایسه شده است. مراحل انجام روش پیشنهادی در ادامه بیان می‌گردد.



شکل ۹: غربالگری تصاویر CXR و CT بیماران مبتلا به کرونا به روش تلفیق یادگیری عمیق و ماشین بردار پشتیبان

داده از قفسه سینه از مقاطع مختلف بوده و برای یک شخص خاص دارای تصاویر متعدد از زمان‌های مراجعه شخص است. شکل ۱۰، تعداد ۲۰ نمونه از این تصاویر را در دو دسته مبتلا به کووید-۱۹ و سالم نشان می‌دهد.

۴-۱- دریافت تصاویر CXR


جهت ارزیابی عملکرد روش پیشنهادی از مجموعه تصاویر بانک اطلاعات تصاویر GitHub، تصاویر کووید-۱۹ و نرمال به کار گرفته شده است. این پایگاه داده دارای ۳۵۰ تصویر CXR و CT مراجعین بوده که دارای علائم تنفسی مانند سرماخوردگی و یا کرونا بوده و یا اینکه عارضه‌ای نداشته و سالم بوده‌اند. همچنین مجموعه تصاویر این پایگاه

۴-۳- خوشه‌بندی تفاضلی (Subtractive) [۴۵]

در مواردی که اطلاع دقیقی از تعداد کلاسترها وجود ندارد این الگوریتم روشی سریع برای یافتن تعداد و مراکز خوشه‌ها است. برخی اوقات نقاط تخمینی این روش به عنوان نقطه شروعی برای سایر روش‌ها محسوب می‌گردد. در این روش هر داده خود دارای شانس انتخاب به عنوان مرکز خوشه را داشته ولیکن داده‌هایی انتخاب خواهند شد که دارای کمترین فاصله از سایر داده‌ها باشند به این ترتیب داده‌ای که در درون سایر داده‌ها قرار دارد شانس انتخاب بیشتری دارد و از انتخاب داده‌های حاشیه‌ای اجتناب خواهد شد. با انتخاب اولین مرکز و نیز با مشخص بودن شعاع تاثیر، این مجموعه کلاستر از مجموعه کل داده‌ها حذف و همین روش برای سایر داده‌ها ادامه می‌یابد تا تمامی کلاسترها و مراکز آن‌ها پیدا شود. از این جهت به این روش الگوریتم تفاضلی یا کاهشی نیز گویند.


۴-۲- روش تلفیق شبکه الکسنت اصلاح شده و ماشین بردار پشتیبان توسعه یافته (روش پیشنهادی)

درخشش اصلی CNN‌ها در سال ۲۰۱۲ در جریان رویداد تشخیص بصری ابعاد بزرگ ایمیجنت^{۲۸} (ILSVRC) یا همان مسابقه ImageNet اتفاق افتاد. اتفاقی که توجه جامعه محققین را به خود جلب کرد. در این مسابقه، آقای الکس کریژوسکی^{۲۹} از دانشگاه تورنتو با شبکه AlexNet وارد این مسابقه دشوار شد. مسابقه ImageNet یک چالش دسته‌بندی با ۱/۲ میلیون تصویر در ۱۰۰۰ کلاس بود. در این مسابقه شبکه پیشنهادی AlexNet با خطای حدود ۱۶ درصد به رتبه اول مسابقه رسید. معماری AlexNet شامل پنج لایه کانوولوشن و سه لایه کاملاً




(ب)

(الف)



(د)

(ج)




(و)


(ه)

شکل ۱۱ (الف) تصویر CT فرد مبتلا به کرونا (ب) تصویر حاصل از قرینه‌سازی حول محور عمودی، (ج) تصویر معکوس شده در راستای عمودی، (د) چرخش عکس ساعت‌گرد به میزان ۱۰ درجه، (ه) چرخش در جهت عکس ساعت‌گرد و جابجایی افقی، (و) تصویر قرینه‌سازی حول محور افقی و چرخش ساعت‌گرد به میزان ۵ درجه و جابجایی عمودی

با بکارگیری مناسب توابع چرخش، جابجایی و قرینه‌سازی روی تصاویر می‌توان به ازای یک تصویر موجود، ۱۲ تصویر جدید را مطابق شکل (۱۲) بدست آورد. به این ترتیب تعداد کل نمونه‌های تصاویر در اختیار، ۲۴۰ نمونه خواهد بود. شکل (۱۲)، نتیجه داده‌افزایی و استخراج ۱۲ تصویر جدید با اعمال توابع چرخش، جابجایی و قرینه‌سازی روی تصویر شماره یک بانک تصاویر GitHub را نشان می‌دهد.



(الف)



(ب)

شکل (۱۰) نمونه تصاویر CXR بانک اطلاعات تصاویر GitHub. (الف)

تصاویر مبتلا به کرونا، (ب) تصاویر افراد سالم [۴۱]

۴-۲- داده افزایی

چنانچه اشاره شد یکی از معضلات مهم در مباحث یادگیری عمیق به ویژه حوزه پزشکی، مسئله کمبود تعداد نمونه‌ها به‌ویژه در روش‌های مبتنی بر یادگیری عمیق است. معمولاً یک شبکه عصبی کانولوشن با چند میلیون وزن برای یادگیری وجود داشته و تنها تعداد بسیار کمی نمونه جهت آموزش در دسترس قرار دارد. از طرفی معمول‌ترین روش برای جلوگیری از فرایادگیری یا بیش‌برازش^{۳۰} شبکه‌های عمیق، افزایش تعداد نمونه‌های آموزش می‌باشد مسئله جلوگیری از بیش‌برازش معمولاً به دو روش عمده در منابع علمی صورت می‌پذیرند نخستین روش که در مجموعه مقالات غربال‌گری کرونا متداول‌تر بوده و در مقالات [۱۱، ۱۶، ۲۵] نیز بررسی شد به افزایش تعداد داده‌های آموزش می‌پردازد روش دوم مسئله اضافه نمودن لایه‌های dropout مناسب در بخش کاملاً متصل شبکه است. برای افزایش تعداد نمونه‌های تصاویر بیماران کووید-۱۹ و نیز افراد سالم، از روش‌های مختلفی می‌توان کمک گرفت. پرکاربردترین این روش‌ها، چرخش تصاویر، برعکس نمودن و جابجایی‌های افقی و عمودی است [۱۱] که در زمان اجرای کد شبیه‌سازی و در مرحله آموزش بر روی تصاویر اعمال می‌شود و به این ترتیب تعداد عکس‌ها افزایش می‌یابد. یکی از ویژگی‌های روش افزایش تعداد تصاویر در هنگام اجرای برنامه، به مسئله عدم تاثیر آن بر روی حافظه سیستم به علت عدم ذخیره‌سازی تک‌تک تصاویر تولید شده باز می‌گردد لذا این روش حافظه سیستم در حال شبیه‌سازی را اشغال نمی‌کند. یکی از کاربردهای مهم روش افزودن تصاویر در مواردی است که تعداد تصاویر افراد سالم و بیمار دارای توازن نبوده و قصد تنظیم تعداد نمونه‌ها در هر یک از دسته‌ها را داریم. شکل (۱۱) یک نمونه تصویر شخص مبتلا به کرونا را که در راستای محور عمودی به شکل آینه‌ای جابجا شده است را نشان می‌دهد.


الکسنت استاندارد به طور معمول یک لایه پولینگ قرار می گیرد. این لایه از آن جهت اهمیت دارد که باعث کاهش تعداد پارامترهایی آموزش می شود. بنابراین با بکارگیری این لایه ضمن کاهش محاسبات مورد نیاز در بخش آموزش، باعث کنترل فرایادگیری احتمالی در شبکه نیز می گردد. لایه های کاملاً متصل، جزو لایه های آخر یک شبکه عصبی کانوولوشن محسوب می شود و مشابه شبکه عصبی معمولی اتصالات کاملی با خروجی لایه قبلی ایجاد می کند. این لایه ورودی را دریافت می کند و سپس خروجی را به صورت برداری با N مولفه تولید می کند. تعداد کلاس هایی که شبکه مورد نظر آن را طبقه بندی می کند برابر با N است. بنابراین خروجی شبکه طراحی شده برای تصویر ورودی به شبکه، برداری با N مولفه عددی بوده، که هر عدد درصد احتمال تعلق به کلاس مورد نظر را نشان می دهد. لایه بعد از لایه های تماماً متصل، لایه Dropout است که به منظور آموزش مستقل نوروها و حذف تصادفی تعدادی از نوروها برای جلوگیری از فرایادگیری استفاده شده است. لایه FC8 آخرین لایه تمام متصل شبکه الکسنت بوده و ورودی تابع SoftMax را تامین می کند که احتمال هر کلاس را نشان می دهد. در حالت کلی می توان گفت در این قسمت ویژگی های تصاویر از لایه کاملاً متصل شبکه CNN استخراج می گردد و نتیجه شبکه در قالب یک بردار با اندازه مشخص به قسمت دسته بندی وارد می گردد. چنانچه بیان شد رویکرد بسیاری از روش های یادگیری عمیق در حوزه تشخیص و غربالگری پزشکی به مسئله انتقال یادگیری باز می گردد برای این منظور در روش پیشنهادی لایه تماماً متصل نهایی (FC8) و نیز لایه SoftMax حذف شده و لایه dropout قبل از این لایه تماماً متصل نیز اصلاح می شود در یک الکسنت استاندارد در مجموع دو لایه dropout وجود دارد که ورودی آنها یک بردار با ۴۰۹۶ مولفه خصوصیات تصاویر بوده و خروجی نیز دارای برداری با همین ابعاد است در روش پیشنهادی این بردار ورودی ۴۰۹۶ مولفه ای به ۱۰ بخش تقسیم و به ازای هر ۴۱۰ مولفه از این بردار، یک مقدار بیشینه استخراج می شود به این ترتیب یک بردار دارای ۱۰ مولفه، به عنوان بردار ویژگی تصویر داده شده در اختیار خواهد بود که می توان با بکارگیری کرنل های مناسب به بیشترین تفکیک بین دو دسته کووید و سالم دست یافت.

۴-۵- دسته بندی تصاویر

خروجی آخرین لایه شبکه برای دسته بندی تصاویر در دو گروه کووید و سالم در نظر گرفته شده است. جهت مقایسه نتایج با نتایج برخی دیگر از مقالات که دسته بندی های k-means، روش FCM و روش تفاضلی را بکارگیری نموده اند شبیه سازی با این روش ها نیز انجام شده است.

۵- شبیه سازی و بررسی نتایج:

جهت تفکیک هر چه صحیح تر مولفه های بردار خروجی از لایه drop-out کرنل های متعددی بکارگیری شد این کرنل های مختلف، تاثیرات متفاوتی روی معیارهای ارزیابی دارند. این کرنل های مختلف می توانند



شکل ۱۲: افزایش نمونه های تصاویر افراد مبتلا به کرونا و سالم با اعمال توابع چرخش، جابجایی و معکوس سازی بر روی تصویر نمونه شماره یک

۴-۳- هیستوگرام دو بعدی


تصاویر CXR یا CT بیماران کرونایی در ناحیه درگیری ریوی، الگوهای خاص خاکستری رنگ را در کانال سبز و یا در مقیاس خاکستری تصویر نشان می دهد این تغییر الگو، به عنوان یک ویژگی به خصوص در هیستوگرام تصاویر واضح تر بوده لذا در شبکه پیشنهادی به جای استفاده از تصویر اصلی، از هیستوگرام دو بعدی با ابعاد 227×227 که حاوی اطلاعات فراوانی توزیع رنگ تصویر است به عنوان ورودی به شبکه الکسنت اصلاح شده استفاده می گردد.

۴-۴- اصلاح لایه تماماً متصل، dropout و لایه softMax در الکسنت

هیستوگرام تصویر قفسه سینه به عنوان ورودی شبکه الکسنت به لایه های کانوولوشن شبکه وارد می گردد در شبکه های کانوولوشن اتصالات به صورت نواحی کوچک و محلی صورت می گیرد. به بیان دیگر هر نورو در اولین لایه مخفی به ناحیه کوچکی از نوروهای ورودی متصل می شود. این ناحیه کوچک به عنوان ناحیه ادراکی محلی^{۳۱} یا کرنل کانوولوشن^{۳۲} نامیده می شود لایه های کانوولوشن شبکه دارای کرنل های با ابعاد مختلف است لایه کانوولوشن اول دارای کرنل 11×11 ، لایه دوم کرنل 5×5 و دو لایه آخر دارای کرنل 3×3 هستند. به این ترتیب با بکارگیری کرنل های مختلف در هر لایه کانوولوشن، ویژگی های بصری ابتدایی مانند تشخیص لبه، نقاط پایانی و گوشه ها تصاویر تشخیص داده می شوند پس از لایه های کانوولوشن در یک شبکه

k-fold یا اعتبارسنجی متقابل است کل ۲۴۰ نمونه به ۶ لایه یا ۶ دسته ۴۰ تایی به شکل تصادفی تقسیم شده در هر بار اجرای برنامه یکی از ۴۰ نمونه (حدود ۱۷ درصد نمونه‌ها) به عنوان داده تست، و تعداد ۲۰۰ نمونه باقی‌مانده از مقدار کل ۲۴۰ نمونه (۸۳ درصد داده‌ها) به عنوان داده آموزش و اعتبارسنجی انتخاب می‌گردند به گونه‌ای که تمامی نمونه‌ها یکبار شانس انتخاب به عنوان داده تست را داشته باشند. از ۲۰۰ نمونه آموزش و اعتبارسنجی، ۱۹۰ نمونه به آموزش و تعداد ۱۰ نمونه تصادفی جهت اعتبارسنجی نتایج استفاده شده‌اند. به این ترتیب برنامه ۶ بار اجرا و میانگین نتایج به ازای هر روش ثبت می‌گردد.


جهت بکارگیری روش دسته‌بندی k-means، تنها پارامتر تنظیمی تعداد دسته‌های مورد نظر جهت تفکیک هستند که در موضوع غربال‌گری، دو دسته افراد سالم و بیمار مد نظر خواهند بود این روش روش دسته‌بندی بدون نظارت محسوب می‌گردد. با بکارگیری روش دسته‌بندی K-means و ۶ بار اجرای برنامه، نتایج بسته آمده برای یکی از اجراها در شکل (۱۵) مشخص شده است. آنچه از ماهیت روش دسته‌بندی K-means مشخص است این است که دو دسته با حداکثر تعداد نمونه با توجه به نزدیکی نمونه‌ها به مرکز داده، انتخاب می‌شوند. بنابراین بخش عمده‌ای از نمونه‌های نزدیک به یکدیگر را به شکل شعاعی در یک گروه قرار می‌دهد و امکان تفکیک صحیح وجود ندارد. چنانچه مشخص است مراکز دو دسته در نظر گرفته شده، نیز در شکل مشخص شده است. در این روش میانگین تعداد تشخیص‌های افراد بیمار درست $TP = 96.33$ ، میانگین تعداد تشخیص‌های عدم بیماری نادرست $FN = 23.66$ ، میانگین تعداد تشخیص‌های افراد سالم درست $TN = 48$ و نهایتاً میانگین تعداد تشخیص‌های بیماری نادرست $FP = 72$ مورد بوده‌اند.



شکل (۱۵) تفکیک نمونه‌های افراد سالم و بیمار به دو دسته کلی به روش K-means با مراکز مشخص شده با دایره مشکی رنگ


بکارگیری روش دسته‌بندی فازی با انتخاب تعداد دسته‌ها در ابتدای برنامه قابل انجام بوده هم‌چنین این روش قابلیت تخصیص درجه تعلق به یک دسته را دارد نتایج بدست آمده از این روش در شکل (۱۶) دیده می‌شود اگر چه دسته‌بندی و تفکیک در این روش به خوبی انجام شده است ولیکن به علت غیرنظارتی بودن روش دسته‌بندی نتایج حاصله جهت موضوع غربال‌گری بسیار ضعیف است به گونه‌ای که نمونه‌ها در دو

در جداسازی بردار خصوصیت تاثیر مستقیم بگذارند. آنالیزهای صورت گرفته روی نتایج و نیز به جهت اهمیت معیار حساسیت در موضوع غربال‌گری، از کرنل بیشینه و کمینه بردار خروجی لایه drop-out استفاده شد به گونه‌ای که ضمن بهبود سایر معیارهای ارزیابی، تاثیر فوق العاده‌ای در معیار حساسیت داشت. با توجه به خروجی شبکه پیشنهادی که شامل مقادیر بیشینه و کمینه بردار خصوصیت هر تصویر است شکل (۱۳) چگونگی قرارگیری کمینه و بیشینه بردار خصوصیات به ازای تمامی نمونه‌ها (۲۴۰ نمونه) را نشان می‌دهد در این شکل علامت‌های ستاره (قرمز رنگ) نشان دهنده اشخاص بیمار و نیز علائم لوزی (آبی رنگ) نشان‌دهنده افراد سالم هستند. جهت وضوح بهتر بخش داخل کادر سبز رنگ در تصویر (۱۳) در شکل (۱۴) بزرگ‌نمایی شده است. چنانچه مشاهده می‌گردد مسئله تفکیک نمونه‌ها به علت درهم آمیختگی آنها کار دشواری خواهد بود.




شکل (۱۳) خروجی شبکه پیشنهادی بر اساس کرنل غیرخطی کمینه و بیشینه بردار خصوصیت حاصل از لایه drop-out اصلاح شده

در شکل (۱۳) برخی از نمونه‌ها دارای خصوصیات نزدیک به یکدیگر بر روی محور افقی هستند.




شکل (۱۴) بزرگ‌نمایی بخش کادر سبز شکل (۱۳) جهت وضوح بهتر درهم آمیختگی نمونه‌ها و دشواری مسئله تفکیک

در ادامه به بررسی امکان تفکیک این داده‌ها به دو دسته افراد سالم و بیمار جهت غربال‌گری کووید-۱۹ با چهار روش دسته‌بندی K-means، Subtractive، FCM و SVM پرداخته می‌شود روش اعتبارسنجی، روش



شکل (۱۷) تفکیک نمونه‌های افراد سالم و بیمار به دو دسته کلی به روش تفاضلی با مراکز مشخص شده با دواير مشکی رنگ، با انتخاب شعاع تاثیر ۰.۷۷


با مقایسه تصاویر سه روش K-means، FCM و Subtractive می‌توان به این نتیجه رسید که این دسته از روش‌ها به علت غیر نظارتی بودن در مسئله غربال‌گری بیماری کرونا ناموفق عمل می‌نمایند نتایج حاصل از روش SVM به عنوان یک روش نظارتی در شکل (۱۸) آمده است. نظارتی بودن این روش به معنی این است که در زمان آموزش، کلاس دسته مورد نظر که تنها دو مقدار مثبت یک و منفی یک را دارند به شبکه داده می‌شود.



شکل (۱۸) تفکیک نمونه‌های افراد سالم و بیمار به دو دسته کلی به روش ماشین بردار پشتیبان با کرنل بهینه

اگرچه شکل ظاهری (۱۸) با شکل دسته‌بندی واقعی که در شکل (۱۳) آمد به نظر کاملاً یکسان می‌آید با بزرگ‌نمایی بخش متناظر با کادر سبز رنگ (که محل درهم آمیختگی دو دسته بوده و در شکل (۱۴) به آن اشاره شد) می‌توان به بخش‌هایی که روش SVM در آن ناموفق بوده، دست یافت (شکل ۱۹). نتایج روش SVM عبارت است از تشخیص‌های افراد بیمار درست یا $TP = 119.33$ ، تعداد تشخیص‌های عدم بیماری نادرست یا $FN = 0.66$ ، تعداد تشخیص‌های درست افراد سالم یا $TN = 84$ و نهایتاً تعداد تشخیص‌های بیماری نادرست یا $FP = 36$ مورد بوده است. نکته قابل توجه در این نتایج موضوع بالا بودن تعداد نمونه تشخیص عدم بیماری است یا $TP = 119.33$ است. که موجب می‌شود معیار حساسیت به حداکثر دقت خود یعنی صد درصد برسد. خلاصه نتایج روش پیشنهادی در مقایسه با سایر روش‌های دسته بندی در

دسته با یکدیگر کاملاً مخلوط شده‌اند برنامه در این بخش به گونه‌ای تنظیم شده است که نمونه‌های با درجه تعلق به هر یک از دسته‌ها با رنگ آنها مشخص گردند نمونه افراد بیمار با رنگ قرمز و نمونه‌های سالم با رنگ آبی مشخص گردند هرچه درجه تعلق یک نمونه از بیمار به سمت فرد سالم پیش رود، رنگ مورد نظر در شکل (۱۶) به سمت آبی تغییر پیدا می‌کند چنانچه مشاهده می‌شود تنها یک نمونه در قسمت حد فاصل دو دسته به رنگ ترکیب قرمز و آبی، یعنی بنفش درآمده است.



شکل (۱۶) تفکیک نمونه‌های افراد سالم و بیمار به دو دسته کلی به روش FCM


از مقایسه ظاهری شکل (۱۵) و شکل (۱۶) می‌توان به یکسان بودن نتایج دو روش K-means و FCM پی برد به لحاظ عددی نیز نتایج روش فازی مشابه روش K-means است.

با انتخاب مناسب شعاع عضویت در روش تفاضلی می‌توان دسته‌بندی را انجام داد یکی از مشکلات روش تفاضلی در تفکیک به دو دسته مجزا، به مسئله انتخاب مناسب این پارامتر تنظیمی شعاع عضویت باز می‌گردد اگر شعاع تاثیر عضویت بزرگ انتخاب شود روش تفاضلی تمامی داده‌ها را در یک گروه قرار می‌دهد اگر شعاع از یک حد مشخصی کوچکتر انتخاب گردد تعداد دسته‌ها بسیار بیشتر از دو گروه خواهند شد. شکل (۱۷) نتایج تفکیک نمونه‌ها با روش تفاضلی را نشان می‌دهد.

به روش سعی و خطا، شعاع مناسب برای تفکیک به تنها دو دسته مقدار ۰.۷۷ انتخاب گردید. نتایج عددی بدست آمده چنانچه تصویر نیز نشان می‌دهد بسیار به دو روش قبلی نزدیک است. نتایج روش تفاضلی عبارت است از تشخیص‌های افراد بیمار درست یا $TP = 96.33$ ، تعداد تشخیص‌های عدم بیماری نادرست یا $FN = 23.66$ ، تعداد تشخیص‌های درست افراد سالم یا $TN = 48.66$ و نهایتاً تعداد تشخیص‌های بیماری نادرست یا $FP = 71.33$ مورد بوده است. علت تغییر رنگ دو دسته در شکل (۱۷) به مسئله تصادفی بودن انتخاب نخستین دسته باز می‌گردد.

چنانچه در بخش دوم این مقاله بحث شد، مقالات مختلف با بکارگیری روش‌های متفاوت و نیز با استفاده از بانک اطلاعات تصاویر متنوع نتایج قابل توجهی را در موضوع غربال‌گری کرونا بدست آورده‌اند که کار مقایسه در این حوزه را دشوار می‌نمایند ولیکن با توجه به نتایج پایانی گزارش شده در این دسته از مقالات می‌توان تا حدودی این مقایسه را با روش پیشنهادی انجام داد به عنوان مثال در جدول ۴، نتایج تعدادی از مقالات که جزئیات بیشتری را از روش خود گزارش داده‌اند جهت مقایسه با روش پیشنهادی به همراه معیارهای ارزیابی به تفکیک هر روش آورده شده است. نتایج حاصل از روش پیشنهادی که حاصل ترکیب مناسب یک شبکه عصبی کانولوشن و روش دسته‌بندی SVM است نسبت به روش‌های مشابه به خصوص بر اساس معیار حساسیت یا معیار فراخوانی که جهت فراخوانی افراد بیمار و غربال‌گری آنها است بهتر عمل نموده این عملکرد بیش از ۹۹ درصدی به این معنی است که تقریباً تمامی افراد بیمار به درستی تشخیص داده می‌شوند و حتی یک نمونه نیز از تست غربال‌گری کنار گذاشته نمی‌شود.

جدول ۳ ذکر شده است. چهار ردیف ابتدایی جدول ۳ به بررسی نتایج بدون داده‌افزایی اختصاص دارد تعداد کل نمونه‌ها در این حال ۲۰ نمونه بوده که ۱۰ تصویر دارای بیماری کرونا و ۱۰ تصویر مربوط به افراد سالم هستند چنانچه مشاهده می‌شود نتایج به علت کمبود داده‌ها جهت آموزش مناسب چندان رضایت‌بخش نیستند.



شکل (۱۹) بزرگ‌نمایی بخشی از شکل (۱۸) جهت وضوح بهتر درهم آمیختگی نمونه‌ها و دشواری مسئله تفکیک به روش SVM

جدول ۳: مقایسه نتایج شبیه سازی روش پیشنهادی با روش‌های دسته‌بندی مشابه

روش	TP	FN	FP	TN	P	N	دقت	صحت	F1-Score	حساسیت Recall
الکسنت اصلاحی با دسته بندی فازی	7	3	8	2	10	10	45.5	46.66	56	70
الکسنت اصلاحی با دسته تفاضلی	7	3	8	2	10	10	45.5	46.66	56	70
الکسنت اصلاحی با دسته k-means	7	3	8	2	10	10	45.5	46.66	56	70
الکسنت اصلاحی با دسته بندی SVM	9	1	3	7	10	10	80	75	81.81	90
الکسنت اصلاحی با دسته بندی فازی- داده افزایی	96.33	23.33	71	49	120	120	60.69	57.65	67.20	80.55
الکسنت اصلاحی با دسته تفاضلی- داده افزایی	96.33	23.66	71.33	48.66	120	120	60.41	57.45	66.97	80.27
الکسنت اصلاحی با دسته k-means- داده افزایی	96.33	23.66	72	48	120	120	60.13	57.22	66.82	80.27
الکسنت اصلاحی با دسته بندی SVM روش پیشنهادی- داده افزایی	119.33	0.66	36	84	120	120	84.72	76.82	86.68	99.44

۶- نتیجه

هوش مصنوعی با تحلیل تصاویر CXR و CT ریه به متخصصین در تشخیص سریع و دقیق بیماری کووید-۱۹ یاری می‌رساند. استخراج ویژگی‌های تصاویر قفسه سینه با بکارگیری شبکه‌های متعدد مبتنی بر شبکه‌های عصبی کانولوشن در تشخیص بیماری کووید-۱۹ بسیار توانمندتر از آزمایش PCR است. از آنجا که در موضوع غربال‌گری بیماری‌های واگیردار به ویژه بیماری کرونا، مسئله ارجاع تمامی مراجعین مشکوک به بیماری بسیار مهم و حیاتی است و از دست دادن حتی یک نمونه بیمار و عدم ارجاع آن باعث همه‌گیری بیشتر می‌شود روش پیشنهادی با بکارگیری کرنل مناسب توانسته معیار حساسیت را به بیش از ۹۹ درصد برساند.

جدول ۴: مقایسه نتایج شبیه سازی روش پیشنهادی با روش‌های سایر مقالات

روش	دقت	صحت	امتیاز F1	حساسیت
[۲۵] Waheed	95	97	93	90
[۳۳] Ardakani	82.6	71.81	85.45	93.38
[۳۴] Zhang M	91.3	91.3	90.6	90
[۳۵] Vente	98.2	97.9	---	95.7
[۳۷] Huang	99.8	96.81	96.7	96.84
[۴۷] Krishnan	97.6	95.3	94.6	93.8
[۴۸] Wang X	92.4	94.0	90.5	93.2
[۴۹] Zhang. J	92.1	88.7	92.28	90.12
[۵۰] Yu X	96.6	96.2	96.6	97.3
[۳۷] Proposed	84.72	76.82	86.68	99.44

مراجع

- from chest X-ray images using deep transfer learning," *Medical Image Analysis*, vol. 65, p. 101794, 2020.
- [22] 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.
- [23] D. Das, K. C. Santosh, and U. Pal, "Truncated inception net: COVID-19 outbreak screening using chest X-rays," *Physical and Engineering Sciences in Medicine*, vol. 43, no. 3, pp. 915–925, 2020.
- [24] M. Toğacıoğlu, B. Ergen, and Z. Çömert, "COVID-19 detection using deep learning models to exploit Social Mimic Optimization and structured chest X-ray images using fuzzy color and stacking approaches," *Computers in Biology and Medicine*, vol. 121, 2020.
- [25] A. Waheed, M. Goyal, D. Gupta, A. Khanna, F. Al-Turjman, and P. R. Pinheiro, "CovidGAN: Data Augmentation Using Auxiliary Classifier GAN for Improved Covid-19 Detection," *IEEE Access*, vol. 8, pp. 91 916–91 923, 2020.
- [26] M. Loey, F. Smarandache, and N. E. M. Khalifa, "Within the lack of chest COVID-19 X-ray dataset: A novel detection model based on GAN and deep transfer learning," *Symmetry*, vol. 12, no. 4, 2020.
- [27] 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 and Fractals*, vol. 140, 2020.
- [28] T. Mahmud, M. A. Rahman, and S. A. Fattah, "CovXNet: A multi-dilation convolutional neural network for automatic COVID-19 and other pneumoniadetection from chest X-ray images with transferable multi-receptive feature optimization," *Computers in Biology and Medicine*, vol. 122, 2020.
- [29] Y. Oh, S. Park, and J. C. Ye, "Deep Learning COVID-19 Features on CXR using Limited Training Data Sets," *IEEE Transactions on Medical Imaging*, pp. 1–1, 2020.
- [30] A. Altan and S. Karasu, "Recognition of COVID-19 disease from X-ray images by hybrid model consisting of 2D curvelet transform, chaotic salp swarm algorithm and deep learning technique," *Chaos, Solitons and Fractals*, vol. 140, 2020.
- [31] R. M. Pereira, D. Bertolini, L. O. Teixeira, C. N. Silla, and Y. M. Costa, "COVID-19 identification in chest X-ray images on flat and hierarchical classification scenarios," *Computer Methods and Programs in Biomedicine*, vol. 194, 2020.
- [32] 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, 2020.
- [33] Ardakani A. A., Kanafi A. R., Acharya U. R., Khadem N., Mohammadi A., "Application of deep learning technique to manage COVID-19 in routine clinical practice using CT images: Results of 10 convolutional neural networks," *Computers in Biology and Medicine*, vol. 121, 2020.
- [34] M. Zhang, Chu, C. Dong, J. Wei, W. Lu and N. Xiong, "Residual Learning Diagnosis Detection: An Advanced Residual Learning Diagnosis Detection System for COVID-19 in Industrial Internet of Things," in *IEEE Transactions on Industrial Informatics*, vol. 17, no. 9, pp. 6510–6518, 2021.
- [35] C. D. Vente *et al.*, "Automated COVID-19 Grading With Convolutional Neural Networks in Computed Tomography Scans: A Systematic Comparison," in *IEEE Transactions on Artificial Intelligence*, vol. 3, no. 2, pp. 129–138, April 2022.
- [36] A. Castiglione, P. Vijayakumar, M. Nappi, S. Sadiq and M. Umer, "COVID-19: Automatic Detection of the Novel Coronavirus Disease From CT Images Using an Optimized Convolutional Neural Network," in *IEEE Transactions on Industrial Informatics*, vol. 17, no. 9, pp. 6480–6488, 2021.
- [37] M. L. Huang Y. C. Liao, "A lightweight CNN-based network on COVID-19 detection using X-ray and CT images," *Comput Biol Med.* Vol. 146, pp. 105604, 2022.
- [38] Esmaceli, V., Mohassel Fegghi, M. (2022). "Diagnosis of Covid-19 Disease by Combining Hand-crafted and Deep-learning Methods on Ultrasound Data," *Journal of Machine Vision and Image Processing*, Accepted paper, 2022.
- [1] L. R., Sultan, and C. M., Sehgal, "A review of early experience in lung ultrasound in the diagnosis and management of COVID-19," *Ultrasound in Medicine & Biology*, vol. 46, no. 9, pp. 2530–2545, 2020.
- [2] I. Khan, Z. Ahmed, A. Sarwar, A. Jamil, and F. Anwer, "The Potential Vaccine Component for COVID-19: A Comprehensive Review of Global Vaccine Development Efforts," *Cureus*, vol. 12, no. 6, 2020.
- [3] H. A. Rothan and S. N. Byrareddy, "The epidemiology and pathogenesis of coronavirus disease (COVID-19) outbreak," *Journal of autoimmunity*, vol. 109, p. 102433, 2020.
- [4] M. Keshavarz, M. Karbalaie Niya, A. Tavakoli, H. Keyvani, and A. Kachooei Mohagheghi Yaghubi, "A review on different types of Real-time PCR methods and its optimization," *Journal of Inflammatory Disease*, vol. 21, no. 3, pp. 90–76, 2017.
- [5] B. S. Tan *et al.*, "Rsna international trends: A global perspective on the covid-19 pandemic and radiology in late 2020," *Radiology*, vol. 299, no. 1, pp. E193–E203, 2021.
- [6] Y. Fang *et al.*, "Sensitivity of chest CT for COVID-19: comparison to RT-PCR," *Radiology*, vol. 296, no. 2, pp. E115–E117, 2020.
- [7] American Collage of Radiology, <https://www.acr.org/>
- [8] Radiological Society of North America <https://www.rsna.org/covid-19>
- [9] M. Yu *et al.*, "Thin-section chest CT imaging of COVID-19 pneumonia: a comparison between patients with mild and severe disease," *Radiology: Cardiothoracic Imaging*, vol. 2, no. 2, p. e200126, 2020.
- [10] J. D. Arias-Londoño, J. A. Gomez-Garcia, L. Moro-Velázquez, and J. I. Godino-Llorente, "Artificial Intelligence applied to chest X-Ray images for the automatic detection of COVID-19. A thoughtful evaluation approach," *IEEE Access*, 2020.
- [11] M. E. H. Chowdhury *et al.*, "Can AI Help in Screening Viral and COVID-19 Pneumonia?," in *IEEE Access*, vol. 8, pp. 132665–132676, 2020.
- [12] A. Narin, C. Kaya, and Z. Pamuk, "Automatic detection of coronavirus disease (covid-19) using x-ray images and deep convolutional neural networks," *arXiv preprint arXiv:2003.10849*, 2020.
- [13] E. E.-D. Hemdan, M. A. Shouman, and M. E. Karar, "Covidx-net: A framework of deep learning classifiers to diagnose covid-19 in x-ray images," *arXiv preprint arXiv:2003.11055*, 2020.
- [14] L. Wang, Z. Q. Lin, and A. Wong, "Covid-net: A tailored deep convolutional neural network design for detection of covid-19 cases from chest radiography images," *Scientific Reports*, vol. 10, no. 19549, 2020.
- [15] J. Zhang, Y. Xie, Y. Li, C. Shen, and Y. Xia, "Covid-19 screening on chest x-ray images using deep learning based anomaly detection," *arXiv preprint arXiv:2003.12338*, 2020.
- [16] M. Z. Islam, M. M. Islam, and A. Asraf, "A combined deep CNN-LSTM network for the detection of novel coronavirus (COVID-19) using X-ray images," *Informatics in Medicine Unlocked*, vol. 20, p. 100412, 2020.
- [17] J. Civit-Masot, F. Luna-Perejón, M. D. Morales, and A. Civit, "Deep learning system for COVID-19 diagnosis aid using X-ray pulmonary images," *Applied Sciences*, vol. 10, no. 13, 2020.
- [18] N. Narayan Das, N. Kumar, M. Kaur, V. Kumar, and D. Singh, "Automated Deep Transfer Learning-Based Approach for Detection of COVID-19 Infection in Chest X-rays," *IRBM*, 2020.
- [19] T. Ozturk, M. Talo, E. A. Yildirim, U. B. Baloglu, O. Yildirim, and U. Rajendra Acharya, "Automated detection of COVID-19 cases using deep neural networks with X-ray images," *Computers in Biology and Medicine*, vol. 121, 2020.
- [20] 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, 2020.
- [21] S. Minaee, R. Kafieh, M. Sonka, S. Yazdani, and G. Jamalipour Soufi, "Deep-COVID: Predicting COVID-19

- Applications. Kacprzyk J, editor Berlin: Springer-Verlag, 2008.
- [45] S. Chiu, "Fuzzy model identification based on cluster estimation." *J. Intell. Fuzzy Syst.* 2 (3), pp. 267-278, 1994.
- [46] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "ImageNet classification with deep convolutional neural networks," *Communications of the ACM*, vol. 60, no. 6, pp. 84-90, 2017.
- [47] K. S. Krishnan, "Vision Transformer based COVID-19 Detection using Chest X-rays[C], in: 2021 6th International Conference on Signal Processing, Computing and Control (ISPCC). pp. 644-648, 2021.
- [48] X. Wang, X. Deng, Q. Fu, Q. Zhou, J. Feng, H. Ma, W. Liu, C. Zheng, "A weaklysupervised framework for COVID-19 classification and lesion localization from chest CT[J]," *IEEE Trans. Med. Imaging* vol. 39 (8) pp. 2615–2625, 2020.
- [49] J. Zhang, Y. Chu, N. Zhao, "Supervised framework for COVID-19 classification and lesion localization from chest CT[J]," *Ethiopian J. Health Dev.* Vol. 34 (4), 2020.
- [50] X. Yu, S. Lu, L. Guo, S. Wang, Y. D. Zhang, "ResGNet-C: A graph convolutional neural network for detection of COVID-19[J]," *Neurocomputing* 452 pp. 592–605, 2021.
- [39] Esmaeili, V., Mohassel Feghhi, M., and Shahdi, O. S. "Early COVID-19 Diagnosis from Lung Ultrasound Images Combining RIULBP-TP and 3D-DenseNet," 9th Iranian Joint Congress on Fuzzy and Intelligent Systems (CFIS), pp. 1-5, 2022.
- [40] J. C. Monteral. (2020). COVID-Chestxray Database. [Online]. Available: <https://github.com/ieee8023/covid-chestxray-dataset>
- [41] C. Cortes and V. Vapnik, "Support-Vector Networks," 1995 Kluwer Academic Boston. Manufactured in The Netherlands, *Machine Learning*, 20, 273-297, 1995.
- [42] S. Nishu, and A. P. Singh., "A Comparative Study Of Data Clustering Techniques" *International Journal of Engineering Research and Technology*, 2.6 (June-2013), ESRSA Publications, 2013.
- [43] Dhanachandra, Kh. Manglem and Y. Jina Chanu, "Image Segmentation using K-means Clustering Algorithm and Subtractive Clustering Algorithm," *National Institute of Technology, Manipur 795 001, India*, Eleventh International Multi-Conference on Information Processing-2015 (IMCIP-2015)
- [44] S.Miyamoto, H.Ichihashi and K.Honda., "Algorithms for fuzzy clustering." *Methods in c-Means Clustering with*

زیر نویس ها

- | | |
|--|---|
| 17- True Negative (TN) | 1- Covid-19 |
| 18- False Negative (FN) | 2- Severe Acute Respiratory Syndrome (SARS) |
| 19- Deep learning | 3- Middle East Respiratory Syndrome (MERS) |
| 20- Long Short Term Memory Network (LSTM) | 4- Acute Respiratory Distress Syndrome (ARDS) |
| 21- Data Augmentation | 5- Angiotensin Converting Enzyme 2 (ACE2) |
| ۲۲- Generative adversarial network (GAN) | 6- Reverse-transcription polymerase chain reaction (RT-PCR) |
| 23- Supervised Learning | 7- Computerized Tomography |
| 24- Unsupervised Learning | 8- Ground-glass opacity (GGO) |
| 25- Support vector machine (SVM) | 9- Multifocal patchy consolidation |
| 26- Subtractive clustering | 10- Interstitial changes with peripheral distribution |
| 27- Vladimir Naumovich Vapnik | 11- Accuracy |
| ۲۸- ImageNet Large Scale visual Recognition Challenge (ILSVRC) | 12- Precision or predictive value |
| ۲۹- Alex Krizhevsky | 13- Sensitivity or recall |
| 30- Overfitting | 14- F1-score |
| 31- Local receptive field | 15- True Positive (TP) |
| 32- Convolutional kernel | 16- False Positive (FP) |