Journal of Soft Computing and Information Technology (JSCIT)
Babol Noshirvani University of Technology, Babol, Iran
Journal Homepage: jscit.nit.ac.ir
Volume 13, Number 3, Autumn 2024, pp. 73-87
Received: 09/13/2023, Revised: 01/11/2025, Accepted: 01/31/2025

Classification of CXR Images into 6 Types of Pulmonary Diseases Using a Mixture of ELM Based Experts and ILQP

Laleh Armi[1], Elham Abbasi[2*], Mohammad Javad Ebadi[3]
1- Department of Computer Science, Yazd University, Yazd, Iran.
2*- Department of Computer Science, Yazd University, Yazd, Iran.
3-Department of Mathematics, Chabahar Maritime University, Chabahar, Iran.
[1]Laleharmi93@gmail.com, [2*] e.abbasi@yazd.ac.ir, [3]ebadi@cmu.ac.ir

Corresponding author's address: Elham Abbasi, Department of Computer Science, Yazd University, Yazd, Iran.

Abstract- The covid-19 is a new virus that causes upper respiratory system and lung infections. Radiographic imaging is used to monitoring various lung diseases and has recently been used to monitoring covid-19 disease, which to detect early and control the outbreak of the disease. Most research in this field has been devoted to articles based on deep learning methods. Due to the high training and testing time of deep learning-based models, in this paper a mixture of ELM based experts with trainable gating network (MEETG) is used. In MEETG, the advantages of ELM are used for designing the structure of ME. The ELM learning process is faster than SVM and MLP and has a better generalizability than them. In continuation, ILQP has been used as texture descriptor for feature extraction and MEETG has been used as a classifier to diagnose six types of lung disease and healthy lung. To evaluate the proposed model, from the RYDLS-20 dataset with unbalanced samples containing chest X-ray images belonging to seven classes including six different viral pneumonia disease lung diseases (Covid-19, SARS, MERS and varicella), bacteria (Streptococcus), fungus (Pneumocystis) and healthy lungs. Our main aim is to achieve the best possible identification for Covid-19 among other types of pneumonia and healthy lungs. Evaluation measures consisting of accuracy, precision, recall, and F-Score have been used to evaluate the proposed model. The experimental results revealed that F-Score for detection of Covid-19 is equal to 0.897 and the average of the total F-Score and the classification accuracy is 0.80 and 97.07%, respectively. The average of total F-Score of the proposed method improves 24%, 43%, 37% and 20% compared with KNN, DT, MLP and ELM, and compared with ensemble learning based method such as ME and bagging is about 19%.

Keywords- Ensemble learning, Mixture of experts, Texture descriptor.

مجله علمی رایانش نرم و فناوری اطلاعات
دانشگاه صنعتی نوشیروانی بابل
صفحه مجله: jscit.nit.ac.ir
جلد ۱۳، شماره ۳، پائیز ۱۴۰۳، صفحه ۷۳-۸۷
دریافت: ۱۴۰۲/۰۶/۲۲، بازنگری: ۱۴۰۳/۱۰/۲۲، پذیرش: ۱۴۰۳/۱۱/۱۲

طبقه‌بندی تصاویر CXR متعلق به شش نوع بیماری ریوی با استفاده از روش اختلاط خبره‌ها مبتنی بر ماشین یادگیری سریع و الگوهای پنج‌تایی محلی بهبودیافته

لاله آرمی[۱]، الهام عباسی *[۲] ، محمد جواد عبادی[۳]
۱- گروه علوم کامپیوتر، دانشگاه یزد، یزد، ایران.
*۲- گروه علوم کامپیوتر، دانشگاه یزد، یزد، ایران.
۳-گروه ریاضی، دانشگاه دریانوردی و علوم دریایی چابهار، چابهار، ایران.
[1]laleharmi93@gmil.com, [2*] e.abbasi@yazd.ac.ir, [3]ebadi@cmu.ac.ir

* نشانی نویسنده مسئول: الهام عباسی، دانشگاه یزد، یزد، ایران.

چکیده- کووید-۱۹ یک ویروس جدید است که باعث عفونت دستگاه تنفسی فوقانی و ریه می‌شود. تصاویر رادیولوژیکی برای نظارت بر بیماری‌های مختلف ریوی بوده و اخیراً برای نظارت بر بیماری کووید-۱۹ مورد استفاده قرارگرفته‌است که با هدف تشخیص زودهنگام و کنترل گسترش همه‌گیری بیماری به‌کار گرفته می‌شود. بیشترین تحقیقات در این حوزه، به مقالات مبتنی بر روش‌های یادگیری عمیق اختصاص داشته است. با توجه به مدت زمان آموزش و پیچیدگی محاسبات زیاد این روش‌ها، در این مقاله از اختلاط خبره‌ها مبتنی بر ماشین یادگیری سریع با شبکه میانجی آموزش‌پذیر (MEETG) استفاده شده است. در MEETG از مزایای ماشین یادگیری سریع برای طراحی ساختار اختلاط خبره‌ها استفاده شده‌است. فرآیند یادگیری ماشین یادگیری سریع بسیار سریع‌تر از ماشین بردار پشتیبان و پرسپترون چند لایه می‌باشد و قابلیت تعمیم بهتری را نسبت به آن‌ها دارد. در ادامه، از الگوهای پنج‌تایی محلی بهبودیافته به‌عنوان توصیف‌کننده بافت برای استخراج ویژگی و از MEETG به عنوان طبقه‌بندی‌کننده برای تشخیص شش نوع بیماری ریوی و افراد سالم استفاده شده‌است.

برای ارزیابی مدل پیشنهادی، از پایگاه‌داده RYDLS-20 با نمونه‌های نامتعادل که حاوی تصاویر اشعه ایکس قفسه سینه متعلق به هفت کلاس شامل شش بیماری مختلف ریوی ذات‌الریه ناشی از ویروس‌ها (کووید-۱۹، سارس، مرس و واریسلا)، باکتری‌ها و قارچ‌ها و همچنین ریه‌های سالم استفاده شده است. هدف اصلی، دستیابی به بهترین میزان تشخیص ممکن برای کووید-۱۹ در بین انواع دیگر ذات‌الریه و ریه‌های سالم است. معیارهای دقت طبقه‌بندی، صحت، بازخوانی و معیار-F برای ارزیابی مدل پیشنهادی استفاده شده‌است. نتایج تجربی نشان داد که معیار-F برای تشخیص کووید-۱۹ برابر با ۰.۸۹۷ و همچنین میانگین کل معیار-F و دقت به ترتیب برابر با ۰.۸۰و ٪۹۷.۰۷ می‌باشد. میزان بهبود میانگین کل معیار-F روش پیشنهادی در مقایسه با k- نزدیک‌ترین همسایه، درخت تصمیم، پرسپترون چند لایه و ماشین یادگیری سریع حدود ۲۴٪، ۴۳٪ ، ۳۷٪ و ۲۰٪ و در مقایسه با روش‌های مبتنی بر یادگیری مرکب نظیر اختلاط خبره‌ها و کیسه‌ای حدود ۰.۱۹٪ است.

واژه‌های کلیدی: یادگیری مرکب، اختلاط خبره‌ها، توصیف‌گر بافتی.

۱- مقدمه

کروناویروس‌ها خانواده بزرگی از ویروس‌ها هستند که در ویروس سرماخوردگی مشترک ایجاد می‌شوند و باعث بیماری‌های شدیدتر سارس ، مرس و کووید-۱۹ می‌شوند. یکی از این کروناویروس‌ها که اخیراً زندگی جهانیان را تحت تاثیر قرار داده‌است، سندروم حاد تنفسی یا همان کووید-۱۹ است. شیوع این ویروس در دسامبر ۲۰۱۹ از شهر ووهان چین شروع و در عرض چند ماه تبدیل به یک همه‌گیری جهانی شد و باعث مرگ بسیاری از انسان‌ها در کشورهای مختلف گردیده است [۱, ۲].

به دلیل گسترش شدید بیماری، تشخیص دقیق و سریع برای مبارزه موثر با کووید-۱۹ضروری است و اقدامات جدی برای این بیماری در سراسر جهان انجام می‌شود. در حال حاضر، تشخیص رسمی بیماری کووید-۱۹ نیاز به انجام تست آزمایشگاهی RT-PCR از نمونه‌های بینی و گلو دارد [۳] که وابسته به تجهیزات تخصصی است و حداقل ۲۴ ساعت طول می‌کشد تا نتیجه آن آماده شود. تست RT-PCR گاهی عفونت را تشخیص نمی‌دهد و نتایج منفی کاذب آن نسبتاً بالا است و برای تایید تشخیص ممکن است نیاز به انجام RT-PCR دوم یا تست دیگری باشد. از دیگر آزمایش‌هایی که برای تشخیص بیماری کووید-۱۹ انجام می‌شود، توموگرافی کامپیوتری (CT) و اشعه ایکس قفسه سینه (CXR) برای تصویربرداری ریه است که سلامت ریه‌ها به دقت بررسی می‌شوند. انجمن رادیولوژی آمریکا عکس‌برداری و اسکن قفسه سینه بیمار را بهترین راه برای تشخیص ابتلا به این ویروس معرفی نموده است [۴]. مزیت تصویربرداری این است که حساسیت خوبی دارد، و می‌تواند میزان عفونت در ریه را تجسم کند. تشخیص انواع مختلف عفونت ریه به ویژه هنگامی که عفونت شدید ریه وجود دارد، چالش برانگیز است [۵]. محققان از روش‌های هوش مصنوعی برای توسعه یک سیستم تشخیص هوشمند برای سرعت بخشیدن به تشخیص زودهنگام کووید- ۱۹ استفاده کرده‌اند [۵-۹]. در این مقاله سعی شده است روشی ارائه گردد که ویژگی‌های مناسبی از تصاویر ریه استخراج نموده و انواع مختلف عفونت ریه را تشخیص و طبقه‌بندی نماید.

با تجزیه و تحلیل تصاویر CXR ، می‌توان مشاهده کرد که بافت یکی از اصلی‌ترین ویژگی‌های بصری موجود در تصاویر است. همان‌گونه که اشاره شد، روش‌های مبتنی بر یادگیری عمیق برای آموزش نیاز به مجموعه‌داده‌های عظیمی دارند و آموزش آن‌ها زمان‌بر است. برای حل مشکلاتی نظیر زمان آموزش مدل‌های مبتنی بر یادگیری عمیق و ضعف مدل‌های یادگیری عمیق نسبت به تغییر فضایی در داده‌های ورودی و همچنین نیاز به تجهیزات سخت‌افزاری، در این مقاله از ویژگی‌های بافت تصویر برای استخراج ویژگی‌ها و از روش مبتنی بر اختلاط خبره‌ها برای طبقه‌بندی کووید-۱۹ استفاده شده است که می‌تواند به دستیابی به بهترین عملکرد طبقه‌بندی برای این کلاس‌های خاص کمک کند.

طبقه‌بندی بافت یک موضوع تحقیقاتی فعال در بینایی ماشین است و اطلاعات مفیدی در مورد محتوای تصاویر تولید می‌نماید که در بسیاری از کاربردها مانند سیستم‌های بازرسی بصری، ردیابی اشیاء، تجزیه و تحلیل تصویر پزشکی، تقسیم‌بندی تصویر و غیره نقش مهمی ایفا می‌کند [۱۰]. در این مقاله، از توصیف‌گر الگوهای پنج‌تایی محلی بهبودیافته [۱۱] جهت استخراج ویژگی استفاده شده است. این توصیف‌گر بافتی علاوه بر این که در برابر تغییرات شدت نور، چرخش و مقیاس مقاوم است، نسبت به نویز نیز مقاوم بوده و هم چنین از دقت و کارایی بالایی برخوردار است [۱۱]. در این مقاله، همچنین برای طبقه‌بندی از روش اختلاط خبره‌های مبتنی بر ماشین یادگیری سریع [۱۲] استفاده شده است. از جمله مزایای این روش می‌توان به سرعت فرآیند یادگیری اشاره نمود زیرا تنها به یک تکرار نیاز دارد و از تکرار متعدد جلوگیری می‌کند. طبق [۱۳]، ماشین یادگیری سریع هزاران بار سریع‌تر از پرسپترون چند لایه(MLP)و ماشین بردار پشتیبان (SVM) است و بر مشکل بیش‌برازش و قرار گرفتن در کمینه می‌تواند غلبه نماید. لازم به ذکر است از آنجا که شبکه عصبی عمیق از پس انتشار برای آموزش وزن‌های سیناپسی خود استفاده می‌کند، نیاز به زمان بیشتری نسبت به ماشین یادگیری سریع (ELM)دارد [۱۴].

نوآوری‌های مقاله به‌طور خلاصه شامل:

- استفاده از توصیف‌گر الگوهای پنج‌تایی محلی بهبودیافته (ILQP) جهت استخراج ویژگی
- به‌کارگیری یک روش مبتنی بر یادگیری مرکب به‌نام اختلاط خبره‌های مبتنی بر ماشین یادگیری سریع (MEETG)
- کاهش پارامترهای روش پیشنهادی نسبت به اختلاط خبره‌های استاندارد
- افزایش کارایی نسبت به طبقه‌بندی‌کننده‌های منفرد نظیر k- نزدیک‌ترین همسایه (KNN)، درخت تصمیم (DT)، MLP و ELM

- افزایش کارایی نسبت به روش‌های مرکب نظیر ME و bagging

بخش‌های مقاله به‌صورت زیر سازماندهی شده است. در بخش ۲ به مرور کارهای پیشین پرداخته شده است. پیش‌نیازهای لازم برای معرفی روش پیشنهادی در بخش ۳ آورده شده است. بخش ۴ به معرفی روش پیشنهادی پرداخته است. آزمایش‌هایی و نتایج در بخش ۵ مشاهده می‌شود و نتیجه‌گیری در بخش ۶ بیان شده است.

۲- کارهای پیشین

در مطالعات انجام شده بسیاری از محققان مدل‌هایی را بر اساس مفاهیم یادگیری عمیق و شبکه‌های عصبی پیچشی برای تشخیص کووید-۱۹ از تصاویر سی‌تی‌اسکن و اشعه ایکس ارائه کرده‌اند [۱۵-۲۴ و ۳۹-۴۰]. در جدول ۱ خلاصه‌ای از پژوهش‌های انجام شده آورده شده است.

به عنوان مثال، نارین و همکاران در مطالعاتشان در [۱۵] بر اساس مفهوم شبکه پیچشی بر روی سه مجموعه‌داده به تشخیص بیماران مبتلا به کروناویروس با استفاده از رادیوگرافی اشعه ایکس قفسه سینه پرداخته‌اند. در این روش با استفاده از مدل ResNet50 بالاترین دقت طبقه‌بندی بدست آمده‌است [۱۵].

اوزکایا و همکاران [۱۶] روش ماشین بردار پشتیبان پیچشی را برای طبقه‌بندی کووید-۱۹ از تصاویر اسکن قفسه سینه پیشنهاد داده‌اند. در این روش از ۳ بلوک با پنجره‌هایی با ابعاد مختلف استفاده شده‌است، هر بلوک از ترکیب چندین لایه‌ی پیچشی و لایه ادغام برای بخش استخراج ویژگی و در لایه‌ی انتهایی این روش از SVM استفاده کرده‌اند.

شریفرازی و همکاران در [۱۷] یک معماری جدید 2D-CNN برای تشخیص کووید-۱۹با استفاده از تصاویر اشعه ایکس ارائه داده‌اند. این روش، تلفیقی از شبکه عصبی پیچشی، SVM و فیلتر سوبل می‌باشد. در 2D-CNN از تعدادی لایه پیچشی، لایه حداکثر تجمع و لایه‌های تمام متصل استفاده شده است. نتایج مطالعات آن‌ها نشان می‌دهد که استفاده از فیلتر سوبل می‌تواند عملکرد شبکه عصبی پیچشی را بهبود ببخشد و دقت طبقه‌بندی ۹۹.۰۲٪ حاصل گردد. جاین و همکاران در تحقیقات خود سه مدل شبکه‌های عصبی پیچشی Xception net، Inception-V3 و ResNeXt [۱۸] را مقایسه نموده و عملکرد آن‌ها را بررسی کرده‌اند. در تجزیه و تحلیل نتایج، مدل Xception بالاترین دقت ۹۷.۹۷٪ را برای تشخیص تصاویر اشعه ایکس قفسه سینه برای تشخیص بیماری کووید-۱۹ ارائه داده است [۱۸]. خان و همکاران [۱۹]، CoroNet که یک شبکه عصبی پیچشی است را برای تشخیص کووید-۱۹ از تصاویر اشعه ایکس قفسه سینه طراحی کردند. مدل CoroNet بر اساس Extreme Inception است و شامل ۷۱ لایه است که بر روی مجموعه‌داده ImageNet آموزش دیده‌است [۱۹]. نتایج ارائه شده برای سه کلاس و چهار کلاس به ترتیب ۹۵٪ و ۸۹.۶٪ می‌باشد [۱۹].

جدول ۱: خلاصه‌ای از پژوهش‌های توصیف‌شده در این بخش

مرجع	نوع تصویر	مجموعه‌داده	الگوریتم به‌کارگرفته‌شده
[۱۵]	CT	NCP identification on a dataset composedof x-ray images from 50 healthy patients and 50 COVID-19 patients	ResNet50, Inception-V3 and Inception-ResNetV2
[۱۶]	CT	SARS-CoV-2 CT scan dataset	Convolutional Support Vector Machines
[۱۷]	X-ray	Omid Hospital in Tehran	2D-CNN-SVM -Sobel
[۱۸]	X-ray	Kaggle repository	Inception-V3, Xception, and ResNeXt
[۱۹]	CXR	ImageNet	CoroNet
[۲۰]	CXR	Kaggle CXR public database	COVID-19 Super pixel SqueezNet
[۲۱]	CXR	Public dataset	Inception-V3
[۲۲]	A compreh ensive review	A comprehensive review	A comprehensive review
[۲۴]	CT, CXR	Created by authors	GLCM, LBGLCM, GLRLM, SFTA, sAE, PCA, SVM
[۵]	CXR	covid-chestxray-dataset	Energy, Inverse difference moment, Homogeneity, Standard deviation,Contrast Smoothness, Skewness, RMS
[۲۵]	CT, CXR	dataset-1 (CT), dataset-2 (X-ray) dataset-3 (CT)	HOG, GLCM, SIFT, LBP, k-NN, SVM, Bag of Tree, K-ELM
[۲۶]	CT	created manually	DWT, GLRLM, LDP, GLSZM, SVM
[۲۷]	CXR	RYDLS-20	LBP, EQP, LDN, LETRIST, BSIF, LPQ, oBIFs, Inception-V3, MLP
[۳۹]	X-ray images	Four publicly accessible sources	Deep convolutional neural network (DCNN)
[۴۰]	CXR	collecting data from multiple repositories	Three pre-trained CNN and a fuzzy rank-based ensemble method
[۴۱]	X-rays	Kaggle repository	LBP+GLCM+SCM+GABOR+HIST+PERC, OPF، Fuzzy-OPF ،SVM ،Bayes، KNN و LDA
[۴۲]	A compreh ensive review	A comprehensive review	A comprehensive review

در [۲۰] پراکاش و همکارانش یک روش مبتنی بر یادگیری عمیق برای تقسیم‌بندی و تشخیص مناطق عفونی کووید-۱۹ پیشنهاد کرده‌اند. آن‌ها یک روش یادگیری عمیق برای تشخیص کووید-۱۹ و تقسیم‌بندی مناطق آلوده از تصاویر اشعه ایکس قفسه سینه پیشنهاد کرده‌اند. در این روش یک نوع مدل پیچشی SqueezeNet را که دارای یک لایه جمع‌آوری فوق پیکسل برای تقسیم‌بندی ناحیه آلوده است ساخته‌اند.روش پیشنهادی برای طبقه‌بندی نمونه‌ها به دو کلاس و سه کلاس می‌باشد. در این چارچوب، Grad-CAM روی نقشه‌های ویژگی تصویر از لایه پیچشی نهایی برای ساختن نقشه فعال‌سازی اعمال می‌شود و این نقشه حرارتی به عنوان ورودی به لایه ادغام سوپر پیکسل برای تقسیم‌بندی داده می‌شود [۲۰]. در [۲۱] یک ساختار سلسله مراتبی مبتنی بر Inception-V3 برای تشخیص کووید-۱۹ با دقت ۹۸.۷۶٪ ارائه شده است. در [۲۲] مرور جامعی از روش‌های یادگیری ماشین و یادگیری عمیق برای تشخیص کووید-۱۹ ارائه شده است.

در یادگیری عمیق با مدل‌های پیچیده، نیاز به داده‌های آموزشی زیادی می‌باشد و عدم توانایی تغییر فضایی در داده‌های ورودی وجود دارد. پیاده سازی نیاز به تجهیزات سخت افزاری بالا مانند GPU قدرتمند دارد [۲۳]. در [۳۹] یک مدل ابری مبتنی بر اینترنت اشیا برای شناسایی بیماران کووید-۱۹ بر اساس اسکن اشعه ایکس قفسه سینه پیشنهاد شده است. در [۴۰] از سه شبکه عصبی پیچشی از پیش آموزش داده شده و روش مرکب مبتنی بر رتبه فازی برای ترکیب نتایج استفاده شده است. در این پژوهش دقت ۹۸.۰۵٪ با معیار-F ۹۷.۷۶٪ گزارش شده است. در [۴۲] بررسی جامعی از حدود ۲۰۰ مقاله شامل روش‌های یادگیری ماشین و یادگیری عمیق برای تشخیص کووید-۱۹ انجام شده است.

در ادامه، محققانی بدون بکارگیری یادگیری عمیق به تشخیص بیماری کووید-۱۹ پرداخته‌اند. به عنوان مثال در [۲۴] برای طبقه‌بندی ویروس کرونا روشی را مبتنی بر ویژگی‌های بافتی مستخرج از CXR و CT ارائه داده‌اند. در این روش با استفاده از چهار توصیف‌گر (ماتریس هم‌رویدادی سطح خاکستری، تجزیه و تحلیل بافت فرکتال بر اساس تقسیم‌بندی، ماتریس هم‌رویداد سطح خاکستری دوتایی محلی و سطح خاکستری ماتریس طول اجرا) ویژگی‌ها استخراج شده و با ترکیب خروجی توصیف‌کننده‌ها، ۷۸ ویژگی به دست آمده است. در ادامه از الگوریتم‌های کاهش ابعاد برای مرحله کاهش ویژگی‌ها استفاده نموده‌اند. آن‌ها با استفاده از دو الگوریتم کاهش ابعاد، ۷۸ ویژگی استخراج شده را به ۲۰ ویژگی کاهش داده‌اند. در نهایت، داده‌ها با SVM طبقه‌بندی می‌شوند. صحت روش با استفاده از ویژگی‌های کاهش یافته با تحلیل مولفه اصلی ۹۴.۲۳٪ گزارش شده است [۲۴].

در مطالعات انجام شده در [۵] از ویژگی‌های بافت و ویژگی مورفولوژیکی حاصل از تصاویر CXR جهت تشخیص عفونت ریه ناشی از کووید-۱۹استفاده شده‌است. در این روش، ویژگی‌های مرتبه دوم شامل همبستگی، انرژی، وارون اختلاف گشتاور، همگنی، میانگین، انحراف استاندارد، واریانس، کنتراست، آنتروپی، صافی، کج شدن و مربع میانگین ریشه از ماتریس هم‌رویداد سطح خاکستری برای مرحله استخراج ویژگی‌های بافت استفاده شده است. همچنین، برای مرحله مورفولوژیکی، ۱۴ ویژگی استخراج شده است. در ادامه ، آن‌ها از پنج طبقه‌بندی‌کننده KNN، XGB-L، XGB-Tree، Naïve Bayes و CART برای طبقه‌بندی چهار کلاس کووید-۱۹، پنومونی باکتریایی، ویروسی و نرمال استفاده کرده‌اند [۵]. در [۲۵]، روشی برای تشخیص کووید-۱۹ از تصاویر CT و CXR ارائه شده است که شامل پیش‌پردازش، استخراج ویژگی، کاهش ابعاد و طبقه‌بندی است. این رویکرد بر روی ۳ مجموعه‌داده مختلف آزمایش شده است. در مرحله پیش‌پردازش، اندازه تصاویر یکسان شده و در مرحله استخراج ویژگی، از الگوی محلی دودویی و هیستوگرام گرادیان‌های جهت‌دار (HOG) استفاده کرده‌اند. همچنین، از روش تحلیل مولفه اصلی برای کاهش ابعاد استفاده شده‌است. در مرحله طبقه‌بندی، برای آموزش فرآیند طبقه‌بندی از روش‌های ماشین بردار پشتیبان، نزدیک‌ترین همسایه، ماشین یادگیری سریع مبتنی بر کرنل و کیسه‌ای استفاده نموده‌اند [۲۵]. بهترین دقت طبقه‌بندی گزارش شده در این مقاله بر روی مجموعه‌داده ۱، مجموعه‌داده ۲ و مجموعه‌داده۳ به ترتیب ۸۹.۴۱٪، ۹۹.۰۲٪ و۹۸.۱۱٪ است. این نتایج با استفاده از نزدیک‌ترین همسایه برای مجموعه اول و سوم و برای مجموعه‌داده دوم با استفاده از ماشین بردار پشتیبان گزارش شده‌است [۲۵]. در [۲۶] برای طبقه‌بندی کووید-۱۹ از تبدیل موجک گسسته، ماتریس هم‌رویدادی سطح خاکستری، ماتریس طول سطح خاکستری، الگو جهت محلی و ماتریس منطقه اندازه خاکستری به‌منظور استخراج ویژگی و برای طبقه‌بندی از ماشین بردار پشتیبان استفاده شده است. بهترین دقت طبقه‌بندی گزارش شده با استفاده از توصیف‌گر GLSZM برابر با ۹۹.۶۸٪ است.

در مرجع [۲۷] روش ارائه شده شامل چهار مرحله می‌باشد. در مرحله اول برای استخراج ویژگی‌ها از هشت توصیف‌گر بافتی استفاده شده‌است. در مرحله دوم، روش همجوشی اولیه بکار گرفته شده‌است، که در مجموع به استخراج هشتاد و چهار مجموعه

ویژگی منجر شده‌است. نمونه‌گیری مجدد داده‌ها در مرحله سوم انجام شده و در مرحله آخر، طبقه‌بندی و تولید نتایج برای سناریوهای چند طبقه و سلسله مراتبی صورت گرفته‌است. در آزمایش‌هایی انجام شده در [۲۷] با به‌کارگیری طبقه‌بندی‌کننده MLP با استفاده از مجموعه ویژگی LBP و نمونه مجدد با ENN، میانگین کل معیار-F برابر با ۰.۶۵حاصل شده است [۲۷].

در [۴۱] از شش توصیف‌گر و ترکیب آن‌ها برای استخراج ویژگی‌ها استفاده شده‌است. بهترین نتایج حاصل از توصیف‌گرها و شش طبقه‌بندی‌کننده شامل OPF، Fuzzy-OPF، SVM، Bayes، KNN و LDA به‌ترتیب برابر ۹۲.۶۲٪، ۹۱.۲۵٪، ۹۵.۴۷٪، ۷۵.۱۷٪، ۹۳.۰۵٪ و ۹۰.۸۹٪ گزارش شده است.

۳- پیش‌نیازها

در این بخش مروری بر الگوریتم‌های ماشین یادگیری سریع و اختلاط خبره‌ها انجام شده است.

۳-۱- ماشین یادگیر سریع

ماشین یادگیری سریع یک الگوریتم یادگیری می‌باشد که برای آموزش شبکه‌های عصبی جلوسو[1] با یک لایه پنهان پیشنهاد شده‌است [۲۸]. این الگوریتم به‌منظور غلبه بر مشکلات و محدودیت‌های الگوریتم یادگیری پس‌انتشار خطا توسط هوانگ و همکاران ارائه شده‌است [۲۸]. در ELM پارامترهای نورون‌های لایه پنهان نیازی به تنظیم شدن ندارند. این پارامترها می‌توانند به صورت تصادفی مقداردهی شوند و هیچ‌گاه به روزرسانی نمی‌شوند [۲۸]. هم‌چنین فرآیند یادگیری ELM فقط به یک تکرار نیاز دارد و از تکرارهای متعدد جلوگیری می‌کند. در مقایسه با الگوریتم‌های شبکه عصبی معمولی، الگوریتم‌های ELM قادر به دستیابی به سرعت آموزش سریع‌تر هستند و می‌توانند بر مشکل بیش‌برازش غلبه کنند [۱۳, ۲۸].

فرض کنید N نمونه (x_i, y_i) وجود دارد به‌طوری‌که $x_i = [x_{i1}, x_{i2}, \cdots, x_{id}]^T$ و $y_i = [y_{i1}, y_{i2}, \cdots, y_{im}]^T$ به‌ترتیب بردار ورودی و خروجی iامین نمونه را نشان می‌دهد. نماد d بعد ورودی و m تعداد کلاس را نشان می‌دهد. شبکه ELM با L نورون لایه پنهان و تابع فعال‌ساز $G(w_j, b_j, x_i)$ متناظر نورون j در لایه پنهان را درنظر بگیرید. مدل ریاضی ELM به شرح زیر است [۱۳]:

$$\sum_{j=1}^{L} \beta_j G(w_j, b_i, x_i) = y_i, i = 1, \dots, N \quad (۱)$$

$w_j = [w_{j1}, w_{j2}, \cdots, w_{jd}]$ و $b_j = [b_{j1}, b_{j2}, \cdots, b_{jd}]$ به‌ترتیب وزن‌ها و بایاس بین لایه ورودی و jامین نورون لایه پنهان می‌باشند که به‌صورت تصادفی تنظیم می‌شوند و β_j وزن بین jامین نورون لایه پنهان و لایه خروجی است. حال اگر معادله (۱) به صورت خلاصه نوشته شود، معادله (۲) حاصل خواهد شد [۱۳].

$$H\beta = Y \quad (۲)$$

$$H = \begin{bmatrix} G(w_1, b_1, x_1) & \cdots & G(w_L, b_L, x_1) \\ \vdots & \ddots & \vdots \\ G(w_1, b_1, x_{\mathrm{N}}) & \cdots & G(w_L, b_L, x_N) \end{bmatrix}_{N \times L} \quad (۳)$$

$$\beta = \begin{bmatrix} \beta_{11} & \cdots & \beta_{1m} \\ \vdots & \ddots & \vdots \\ \beta_{j1} & \cdots & \beta_{jm} \\ \vdots & \ddots & \vdots \\ \beta_{L1} & \cdots & \beta_{Lm} \end{bmatrix}_{L \times m}, Y = \begin{bmatrix} y_1 \\ \vdots \\ y_N \end{bmatrix}_{N \times m} \quad (۴)$$

با توجه به رابطه (۲)، H ماتریس خروجی لایه پنهان، β وزن بین لایه پنهان و خروجی و Y خروجی دلخواه است که در معادله‌های (۳) و (۴) نشان داده شده‌است. با توجه به رابطه‌ی (۳) ستون iام ماتریس H برابر با خروجی iامین نورون لایه پنهان به‌ازای ورودی $x_1, x_2, \cdots, x_N$ است. برای محاسبه ماتریس وزن خروجی β، می‌توان از روش حداقل مربعات برای حل معادله (۵) استفاده کرد [۱۳].

$$\beta = H^{\dagger} \cdot Y \quad (۵)$$

که $H^{\dagger}$ معکوس مور-پنروز[2] ماتریس H می‌باشد. روش‌های زیادی برای یافتن معکوس ماتریس مور-پنروز وجود دارد. از این روش‌ها می‌توان به روش حذفی گوس، روش ضرب متعامد، روش متعامدسازی، روش مبتنی بر تکرار و روش تجزیه مقدار منفرد[3] اشاره کرد [۱۳, ۲۹]. از آن جایی که در روش متعامدسازی و مبتنی بر تکرار از جستجو و تکرار استفاده می‌شود، از آن پرهیز می‌شود [۱۳]. رابطه (۶) خروجی ELM به‌ازای نمونه x_{test} را نشان می‌دهد [۱۳].

$$f(x_{test}) = \sum_{j=1}^{L} \beta_j G(w_j, b_i j, x_{test}) \quad (۶)$$

برای یک مسئله طبقه‌بندی چند کلاسه تابع تصمیم ELM به صورت زیر می‌باشد:

$$O = \operatorname{argmax} f(x_{test}) \quad (۷)$$

۳-۲- اختلاط خبره‌ها

ترکیب طبقه‌بندها رویکردی است جهت بهبود عملکرد طبقه‌بندی خصوصاً برای مسائل پیچیده‌ای از قبیل مسائلی که محدودیت

تعداد الگو، مجموعه ویژگی با بعد بالا و کلاس‌های هم‌پوشان دارند. در روش‌های ترکیب طبقه‌بندها، ثابت شده است که قاعده تقسیم و غلبه[۴] در حل بسیاری از مسائل پیچیده مؤثر بوده است. یکی از مشهورترین ساختارهای پویا در ترکیب طبقه‌بندها که توسط ژاکوب و جردن ارائه شده است، اختلاط خبره‌ها (ME) می‌باشد [۳۰]. روش اختلاط خبره‌ها بر اساس قاعده تقسیم و غلبه پایه‌گذاری شده است. ساختار این روش متشکل از چندین خبره و یک شبکه میانجی[۵] است. این روش از یک روش پویا برای ترکیب نتایج استفاده می‌کند. به عبارتی شبکه میانجی فضای ورودی را هوشمندانه بین خبره‌ها تقسیم می‌کند و با توجه به میزان خبرگی یک وزن به نظر آن خبره اختصاص می‌دهد. در این روش هم‌زمان با یادگیری خبره‌ها، شبکه میانجی نیز آموزش می‌بینند که چگونه با در نظر گرفتن تخصص هر یک از خبره‌ها (طبقه‌بندها) با توجه به نمونه ورودی، وزن را به خروجی خبره‌ها اختصاص دهد. در ME معمولاً از پرسپترون چند لایه به عنوان خبره‌های پایه و شبکه میانجی استفاده می‌شود. اگر N تعداد خبره‌هایی باشد که با $j = 1,2,\dots,N$ مشخص شده‌است، خروجی شبکه میانجی میزان مشارکت خبره‌ها را در تولید خروجی تعیین می‌کند که نرمال‌شده آن در معادله (۸) نشان داده شده‌است.

$$g_i = \frac{\exp(O_{g_i})}{\sum_{j=1}^{N}(O_{g_j})} \qquad (۸)$$

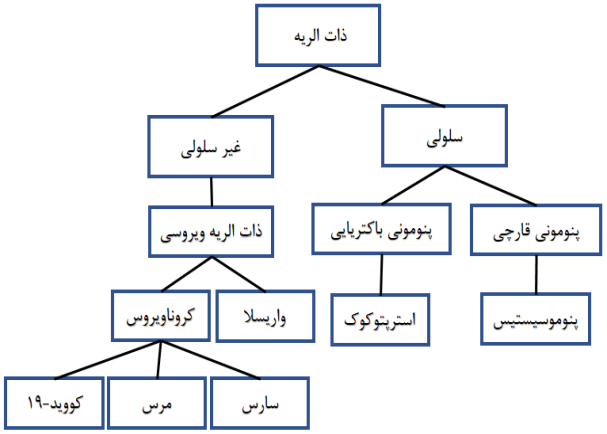
که در آن O_{g_i}، iامین خروجی شبکه میانجی است. معادله (۸) یک نگاشت نمایی نرمال شده است که g_i یک مقدار بین صفر و یک و مجموع g_i ها برابر یک می‌باشد. بزرگ بودن g_i برای یک خبره به معنی تواتمند بودن آن خبره برای تولید خروجی مطلوب می‌باشد. شبکه میانجی، فضای ورودی را به‌صورت هوشمندانه بین خبره‌ها تقسیم می‌کند و در نهایت برای ترکیب خروجی‌های خبره‌ها، وزنی را مطابق با عملکرد خبره‌ها به هر یک از خروجی خبره‌ها اختصاص می‌دهد و خروجی نهایی ME به صورت جمع وزن‌گذاری‌شده خروجی شبکه میانجی و خروجی خبره توسط رابطه (۹) محاسبه می‌شود [۳۰].

$$O_{ens} = \sum_{i=1}^{N} O_i . g_i \qquad (۹)$$

همان‌طور که بیان شد در ME معمولاً از MLP به عنوان خبره پایه و شبکه میانجی استفاده می‌شود. در مرحله آموزش ME، روش گرادیان نزولی اعمال می‌شود که شامل محدودیت‌هایی مانند مرحله آموزش وقت‌گیر، احتمال گیرافتادن در حداقل‌های محلی و همچنین پارامترهای زیادی که نیاز به تنظیم دارند می‌باشد [۳۱].

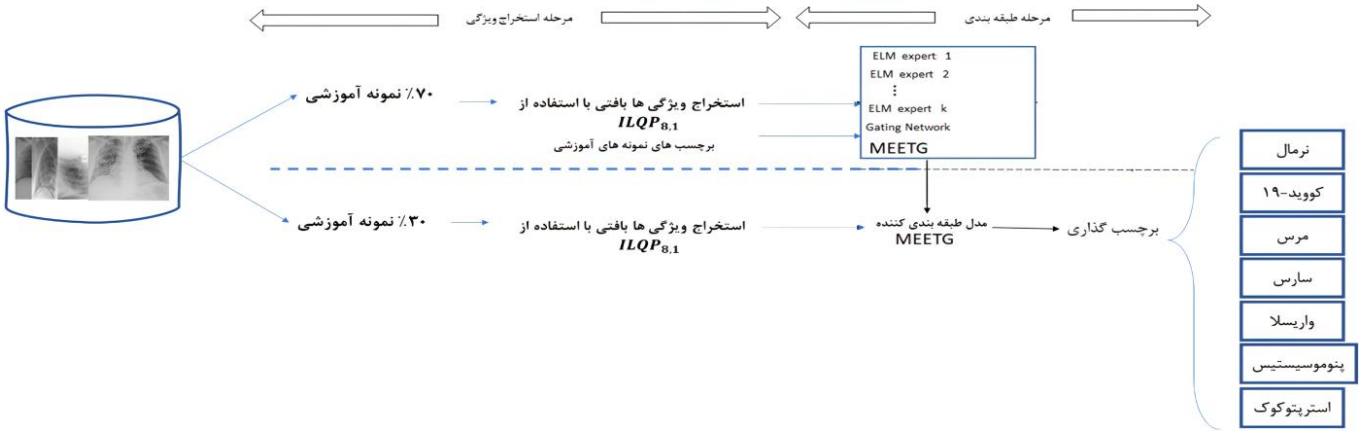
۴- روش پیشنهادی

در این مطالعه، هدف شناسایی انواع مختلف ذات‌الریه و شناسایی کووید-۱۹ در بین دیگر بیماری‌های ذات‌الریه و ریه‌های سالم است. در شکل ۱ ساختار طبقه‌ای سلسله مراتبی ذات الریه نشان داده شده‌است. در این مقاله، به طبقه‌بندی تصاویر اشعه ایکس از قفسه سینه با استفاده از توصیف‌گر الگوهای پنج‌تایی محلی بهبودیافته و با استفاده از روش اختلاط خبره مبتنی بر ELM با شبکه میانجی آموزش‌پذیر جهت طبقه‌بندی پرداخته شده‌است. شکل ۲ یک نمای کلی از روش پیشنهادی را نشان می‌دهد.



شکل ۱: ساختار طبقه ای سلسله مراتبی ذات الریه [۲۷].

در این راستا ابتدا مجموعه‌داده بارگذاری می‌شود. بعد از بارگذاری و خواندن تصاویر CXR، ویژگی‌های بافتی از تصاویر استخراج می‌شود. استخراج ویژگی یکی از مهم‌ترین قسمت‌های سیستم‌های پردازش و تشخیص است. بنابراین انتخاب مناسب عملگر و توصیف‌گر برای استخراج الگوها و ویژگی‌های با قدرت تمایز دهندگی بالا از اهمیت بالایی برخوردار است که می‌تواند دقت نهایی سیستم را افزایش دهد. علاوه بر آن توصیف‌کننده‌هایی که برای تجزیه و تحلیل و استخراج ویژگی‌ها استفاده می‌شوند باید پیچیدگی محاسباتی کم و همچنین نسبت به تغییرات ثابت باشد. در شرایط واقعی، دو چالش عمده در تجزیه و تحلیل و طبقه‌بندی تصاویر وجود دارد که آثار مخرب زیادی دارد. این دو پدیده مهم عبارتند از چرخش و نویز تصویر [۱۰, ۱۱, ۳۲]. از آنجا که چرخش تصویر ممکن است در آزمایشگاه پزشکی به دلیل عدم تنظیم دستگاه‌ها یا شرایط ثبت رخ دهد، در عمل می‌تواند دقت نتایج را به شدت کاهش دهد [۳۲]. بنابراین، انتخاب یک توصیف‌گر خوب مقاوم در برابر نویز و چرخش می‌تواند کارایی را افزایش دهد.



شکل ۲: روش پیشنهادی برای شناسایی و طبقه‌بندی.

۴-۱- الگوی پنج‌تایی بهبودیافته

الگوی پنج‌تایی محلی بهبودیافته[۶] از جمله نسخه‌های توسعه یافته الگوهای دودویی محلی می‌باشد که توسط آرمی و فکری ارشاد ارائه شده است [۱۱]. برای ایجاد الگوی پنج‌تایی محلی بهبودیافته ابتدا برای هر نقطه از تصویر یک همسایگی دایروی تعریف می‌شود. نقاطی از همسایه‌هایی که مختصات آن‌ها دقیقاً روی مرکز پیکسل قرار نمی‌گیرند، با $\left(-R\sin\left(\frac{2\pi p}{P}\right), R\,cos\left(\frac{2\pi p}{P}\right)\right)$ درونیابی می‌شوند. R شعاع همسایگی، P تعداد همسایگی و p همسایه‌ها هستند که $p\epsilon\{0,1,\dots,P-1\}$ است. این کار به منظور حساس نبودن عملگر نسبت به چرخش تصویر می‌باشد. سپس برای هر همسایه g_p، شدت روشنایی با شدت روشنایی پیکسل مرکزی g_c مقایسه می‌شود.

$$\mathbf{s}(g_c.g_p.\tau_1.\tau_2) = \begin{cases} 2 & g_p \geq g_c+\tau_2 \\ 1 & g_c+\tau_1 \leq g_p < g_c+\tau_2 \\ 0 & g_c-\tau_1 \leq g_p < g_c+\tau_1 \\ -1 & g_c-\tau_2 \leq g_p < g_c-\tau_1 \\ -2 & 0therwise \end{cases} \quad (۱۰)$$

باتوجه به رابطه (۱۰)، الگوهایی بین ۲ و ۲- ایجاد می‌شوند. بنابراین به‌ازای هر همسایگی در این مرحله یک کد پنج‌تایی حاصل خواهد شد. دو حد آستانه پویا τ_1 و τ_2 برای ایجاد کد پنج‌تایی به کار می‌رود [۱۱].

$$\begin{aligned} \text{LocalMAD} &= \text{median}(|G-\text{median}(G)|), \\ G &= \{g_p|p=0,1,\dots,P-1\} \end{aligned} \quad (۱۱)$$

$$\begin{aligned} \text{MAD} &= \text{median}(|\text{lmad}-\text{median}(\text{lmad})|), \\ \text{lmad} &= \{\text{LocalMAD}_k|k=1,2,\dots,M\times N\} \end{aligned} \quad (۱۲)$$

$$LSV = {}^1\!/_P \sum_{p=0}^{P-1}(|g_c-g_p|) \quad (۱۳)$$

$$\text{GSV} = {}^1\!/_{M\times N}\sum_{i=1}^{N}\sum_{j=1}^{M}\text{LSV} \quad (۱۴)$$

با توجه به رابطه‌ها، M و N اندازه تصویر می‌باشد. برای انتخاب حد آستانه اول از انحراف معیار مطلق از میانه[۷] با توجه به معادله (۱۲) و برای انتخاب آستانه دوم از مقدار معنادار کلی[۸] با توجه به معادله (۱۴) استفاده می‌شود. بعد از ایجاد الگوی پنج‌تایی، این الگو باتوجه به رابطه (۱۵) به چهار الگوی دودویی محلی (الگوی مثبت قوی، الگوی مثبت، الگوی منفی و الگوی منفی قوی) تقسیم می‌شود [۱۱].

$$ILQP_{ch} = \begin{cases} ILQP_{strongly\ positive\ pattern} = \begin{cases} 1 & if\ x=2 \\ 0 & otherwise \end{cases} \\ ILQP_{positive\ pattern} = \begin{cases} 1 & if\ x=2\ and\ x=1 \\ 0 & otherwise \end{cases} \\ ILQP_{negative\ pattern} = \begin{cases} 1 & if\ x=-2\ and\ x=-1 \\ 0 & otherwise \end{cases} \\ ILQP_{strongly\ negative\ pattern} = \begin{cases} 1 & if\ x=-2 \\ 0 & otherwise \end{cases} \end{cases} \quad (۱۵)$$

در این رویکرد، برای هر یک از این الگوهای دوتایی، میزان یکنواختی بر اساس معادله (۱۷) برچسب بین صفر و $P+1$ به آن‌ها اختصاص داده می‌شود.

$$U(ILQP_{P,R,ch}) = |(g_{p-1}^{ch}) - (g_0^{ch})| + \sum_{p=0}^{P-1} |(g_p)^{ch} - (g_{p+1}^{ch})| \quad (۱۶)$$

$$ILQP_{P,R,ch}^{riu} = \begin{cases} \sum_{p=0}^{P-1} (g_p^{ch}) & if\ U(ILQP_{P,R,ch}) \le \frac{P}{4} \\ P+1, & otherwise \end{cases} \quad (۱۷)$$

با توجه به معادله‌های (۱۶) و (۱۷)، P و g_p^{ch} به ترتیب تعداد همسایه‌ها و مقدار pامین همسایه را در الگوی استخراج شده دوتایی نشان می‌دهند. شاخص ch با هر یک از الگوهای منفی قوی، منفی، مثبت و مثبت قوی مطابقت دارد. سپس، احتمال وقوع هر برچسب در کل تصویر به عنوان یک ویژگی در نظر گرفته می‌شود. بنابراین، برای هر یک از چهار الگوی باینری تعریف کننده، یک بردار ویژگی $P+2$ استخراج می‌شود. بردار ویژگی $F_{ILQP_{ch}}$ را می‌توان به صورت زیر نوشت:

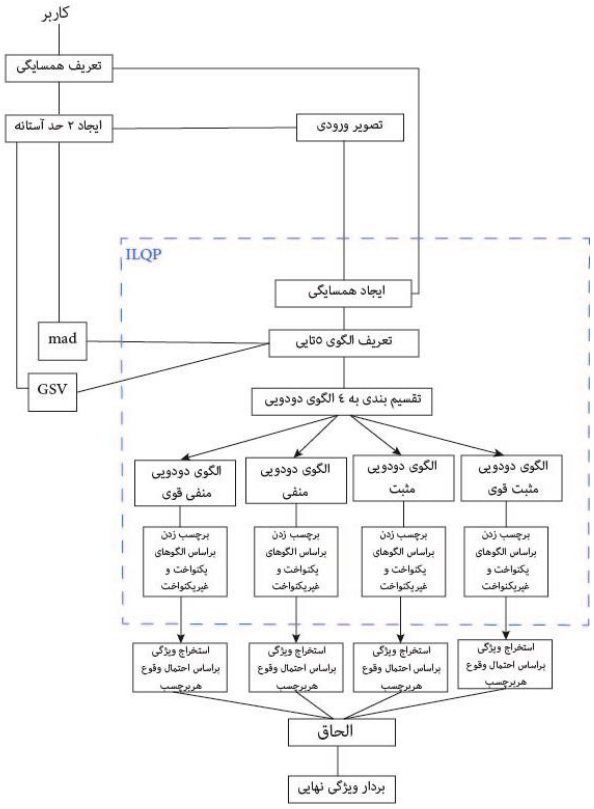
$$\mathrm{F_{ILQP_{ch}}} = \langle \mathrm{F_0}, \mathrm{F_1}, \cdots, \mathrm{F_{(P+1)}} \rangle, \quad (۱۸)$$

جایی که، F_0 احتمال وقوع برچسب صفر را در کل تصویر پس از پیاده‌سازی $ILQP_{P,R,ch}^{riu}$ نشان می‌دهد [۱۱]. در نهایت، پس از استخراج ویژگی‌ها از هر چهار الگوی مختلف دوتایی، آنها به هم متصل می‌شوند و در نتیجه، بردار ویژگی با بعد $4 \times (P+2)$ مطابق معادله (۱۹) استخراج می‌شود. با توجه به آنچه گفته شد، روند کلی کار در شکل ۳ نشان داده شده‌است.

$$\mathrm{FinalFeatureVector_{ILQP}} = \langle \mathrm{ILQP^{riu}_{P,R,stronglypositive}}, \mathrm{ILQP^{riu}_{P,R,positive}}, \mathrm{ILQP^{riu}_{P,R,negative}}, \mathrm{ILQP^{riu}_{P,R,stronglynegative}} \rangle \quad (۱۹)$$

۴-۲- اختلاط خبره‌ها مبتنی بر ماشین یادگیری سریع با شبکه میانجی آموزش پذیر

در [۱۲, ۳۳] روش اختلاط خبره مبتنی بر ELM با شبکه میانجی آموزش‌پذیر[۹] که به اختصار MEETG نامیده می‌شود پیشنهاد شده‌است. روش MEETG یک روش یادگیری مرکب است که بر اساس ترکیبی از خبره‌ها برای بهبود هزینه محاسبه و تسریع فرایند یادگیری ME عمل می‌نماید. یادگیری مرکب رویکردی است که توانایی بالایی در بهبود دقت طبقه‌بندی کلی دارد. روش MEETG از مزایای ME و ELM استفاده می‌کند [۱۲, ۳۳]. همان‌طور که گفته شد، ME یکی از متداول‌ترین روش‌های مبتنی بر یادگیری مرکب است که می‌تواند دقت مسائل پیچیده را بر اساس اصل تقسیم و غلبه افزایش دهد. اگرچه ME دارای نقاط قوت است، اما دارای محدودیت‌هایی است. یکی از معایب رایج آن



شکل ۳: بلوک دیاگرام کلی روش ILQP جهت آنالیز بافت [۱۱].

پیچیدگی محاسبات بالا است. در ME، الگوریتم‌های مبتنی بر گرادیان نزولی مانند پس‌انتشار خطا برای آموزش خبره‌ها و شبکه میانجی استفاده می‌شود. تحقیقات نشان داده است که روش پس‌انتشار خطا دارای محدودیت‌های متعددی مانند حساسیت به کمینه‌های محلی [۱۲, ۳۶-۳۳]، نیاز به تنظیم پارامترهای یادگیری، همگرایی آهسته و یادگیری تکراری برای بهبود عملکرد شبکه عصبی می‌باشد.

نویسندگان در [۱۲, ۳۳] به منظور غلبه بر مشکلات فوق از ELM به عنوان خبره و شبکه میانجی در طراحی اختلاط خبره‌ها استفاده نموده‌اند. همچنین مساله گوناگونی در روش پیشنهادی نیز در نظر گرفته شده‌است. یکی از روش‌های ایجاد گوناگونی استفاده از پارامترهای متفاوت برای طبقه‌بندی‌کننده‌های یکسان می‌باشد [۳۱]. در روش پیشنهادی از ELM به‌عنوان خبره‌های پایه استفاده شده است و وزن‌های بین لایه ورودی و لایه پنهان در این شبکه‌ها به‌صورت تصادفی تنظیم می‌گردد که این مساله نقش بسزایی در ایجاد گوناگونی دارد.

بلوک نمودار MEETG در شکل ۴ نشان‌داده شده است. همان‌طور که در شکل ۴ مشاهده می‌شود نمونه‌های ورودی $X_{N_{train} \times d}$ با ابعاد d بعدی به‌طور هم‌زمان به خبره‌ها و شبکه میانجی ارسال می‌شود. در ELMها، وزن بین لایه ورودی و لایه‌ی پنهان به‌صورت

تصادفی انتخاب شده‌اند. تعداد نورون‌های لایه پنهان به صورت آزمون و خطا برای هر مجموعه انتخاب می‌شوند. m تعداد نورون لایه خروجی هر یک از خبره‌ها، متناظر با تعداد کلاس‌ها است و تعداد نورون‌های لایه‌ی خروجی در شبکه میانجی برابر با K تعداد خبره‌ها است. ماتریس خروجی لایه پنهان خبره‌ها و شبکه میانجی با استفاده از رابطه (۳) محاسبه می‌شود. سپس وزن بین لایه پنهان و لایه خروجی هر یک از خبره‌ها طبق رابطه (۵) محاسبه می‌شود. بردار h به عنوان یک بردار خروجی مطلوب شبکه میانجی به صورت زیر است [۳۱].

$$h = \left[\frac{exp\|y-O^{Expert1}\|^2}{\sum_{i=1}^{k} exp\|y-O^{Experti}\|^2}, \cdots, \frac{exp\|y-O^{Expertk}\|^2}{\sum_{i=1}^{k} exp\|y-O^{Experti}\|^2}\right] \quad (۲۰)$$

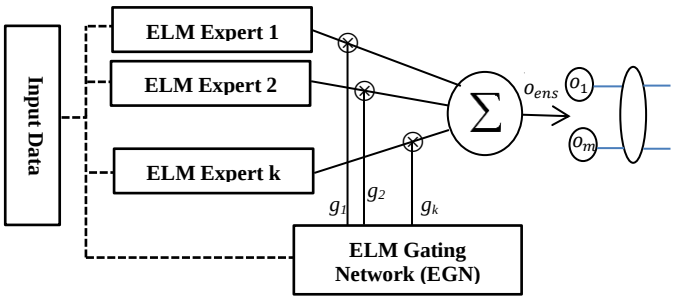
باتوجه به معادله (۲۰)، y خروجی واقعی و O^{Expert} خروجی خبره iام می باشد. ماتریس H موردنظر شبکه میانجی برای N مجموعه آموزشی در رابطه (۲۱) نشان داده شده است [۳۱].

$$H = \begin{bmatrix} \frac{\exp\|y_1 - O_1^{Expert\ 1}\|^2}{\sum_{i=1}^{k}\exp\|y_1 - O_1^{Expert\ i}\|^2} & \cdots & \frac{\exp\|y_1 - O_1^{Expert\ k}\|^2}{\sum_{i=1}^{k}\exp\|y_1 - O_1^{Expert\ i}\|^2} \\ \vdots & \ddots & \vdots \\ \frac{\exp\|y_{N_{train}} - O_{N_{train}}^{Expert\ 1}\|^2}{\sum_{i=1}^{k}\exp\left\|y_{N_{train}} - O_{N_{train}}^{Expert\ i}\right\|^2} & \cdots & \frac{\exp\|y_{N_{train}} - O_{N_{train}}^{Expert\ k}\|^2}{\sum_{i=1}^{k}\exp\left\|y_{N_{train}} - O_{N_{train}}^{Expert\ i}\right\|^2} \end{bmatrix} \quad (۲۱)$$

همان‌طور که بیان شد، ELM به عنوان شبکه میانجی نیز استفاده شده و وزن بین لایه‌ی پنهان و لایه‌ی خروجی باتوجه به ماتریس H بدست آمده از رابطه (۲۰)، مطابق با رابطه (۵) تنظیم می‌شود [۳۲ ,۱۲].

$$C = \text{argmax}_{j=1}^{m} O_{ens} \quad (۲۲)$$

بردار خروجی روش پیشنهادی برای نمونه دلخواه x و با برچسب به صورت $O_{ens} = [O_1, O_2, \cdots, O_m]$ باتوجه به رابطه‌های (۶، ۸ و ۹) محاسبه می‌شود. در انتها برچسب نهایی نمونه ورودی x طبق رابطه‌ی (۲۲) مشخص می‌شود.



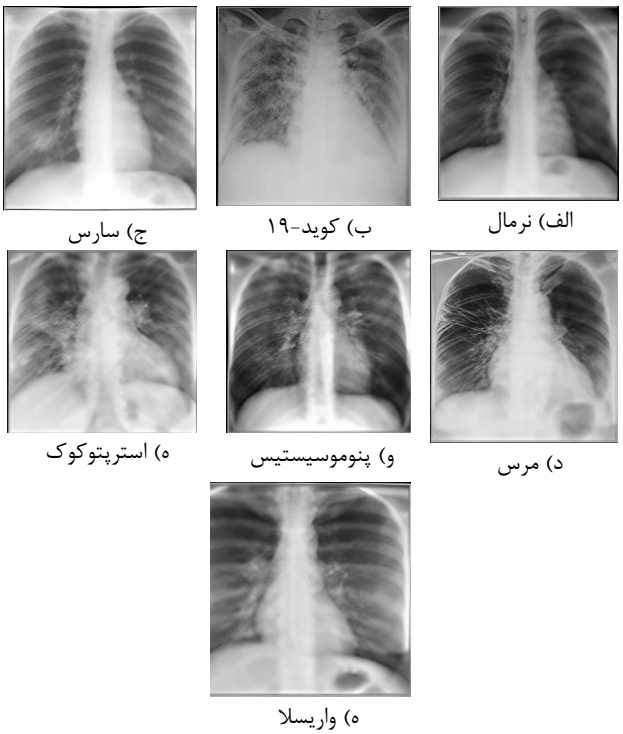
شکل ۴: بلوک دیاگرام MEETG [۳۲ ,۱۲].

۵- آزمایش‌ها و نتایج

در این بخش، مجموعه‌داده استفاده شده، پارامترها و معیارهای مورد استفاده و نتایج تجربی در این مقاله شرح داده خواهد شد. تمام آزمایش‌هایی با استفاده از MATLAB R2018a، با استفاده از رایانه GHZ Intel Core (TM) i5 Qrad ۲.۴ با Windows 10 Enterprise با حافظه اصلی ۱۲ گیگابایت انجام شده است.

۵-۱- مجموعه‌داده و پارامتر

برای ارزیابی روش پیشنهادی، از مجموعه‌داده‌ای به نام RYDLS-20 برگرفته شده از مقاله [۲۷] و از سایت " Pneumonia Classification Paper - Google Drive" استفاده شده است. این مجموعه‌داده حاوی تصاویر CXR از ذات الریه و همچنین تصاویر CXR از ریه‌های سالم است. شکل ۵ نمونه‌ای از تصاویر مجموعه داده‌ی RYDLS-20 را نشان می‌دهد. تعداد کل تصاویر در این مجموعه ۱۱۴۴ می‌باشد.



شکل ۵: نمونه تصاویر RYDLS-20.

همان‌طور که در جدول ۲ نشان داده‌شده است، این مجموعه داده نامتعادل می‌باشد که در نیمی از برچسب‌ها بین ۱۰-۱۲ نمونه وجود دارد. در این مقاله برای این‌که نتایج و مقایسه عادلانه‌ای انجام شود، باتوجه به آزمایش‌هایی انجام شده در دیگر مقاله‌ها نمونه‌ها به صورت ۳۰/۷۰ بین آموزش و آزمایش تقسیم شده‌اند و ۱۰ درصد از نمونه‌های آموزش به‌عنوان مجموعه اعتبارسنجی برای تنظیم پارامترها استفاده شده است. در جدول ۳ پارامترهای

استفاده شده در این مقاله و مقادیر آن‌ها نشان داده شده‌است.

جدول ۲: توزیع نمونه‌های RYDLS-20 در ۷ کلاس.

برچسب کلاس	تعداد نمونه‌ها	تعداد نمونه آموزشی	تعداد نمونه آزمایش
Normal	۱۰۰۰	۷۰۰	۳۰۰
COVID-19	۹۰	۶۳	۲۷
MERS	۱۰	۷	۳
SARS	۱۱	۸	۳
Varicella	۱۲	۷	۳
Streptococcus	۱۲	۹	۳
Pneumocystis	۱۱	۸	۳

جدول۳ : تنظیم پارامترهای توصیف‌گر و طبقه بند.

روش و الگوریتم	پارامترها
ILQP	تعداد همسایگی(p) = ۸ شعاع همسایگی (R)= ۱
MEETG	تعداد خبره‌ها = {۳، ۵ و ۷} تعداد نورون‌های لایه پنهان= [۵۰-۳۸] تابع فعال‌ساز= سیگموئید

۵-۲- نتایج تجربی

در این قسمت آزمایش‌هایی مختلفی بر اساس تعداد مختلف خبره‌ها و هم چنین با تعداد مختلف نورون‌های لایه پنهان انجام شده است. نتایج حاصل در شکل ۶ نشان داده شده است. برای ارزیابی روش پیشنهادی از ۷۰ درصد نمونه‌ها برای آموزش و ۳۰ درصد برای آزمایش استفاده شده است و میانگین حاصل از ۱۰۰ بار تکرار آزمایش گزارش شده است.



شکل ۶: نمودارهای تحلیل حساسیت بر روی مجموعه‌داده RYDLS-20.

باتوجه به نتایج گزارش شده درشکل ۶ دقت طبقه‌بندی با استفاده از سه خبره بهتر بوده است. هم چنین با تعداد نورون‌ها لایه پنهان بین ۴۴ تا ۴۸ نیز دقت بهتری حاصل شده است. از آن‌جایی‌که مجموعه داده بکار رفته نامتعادل است و تعداد نمونه‌های هر کلاس مختلف است، بنابراین معیار دقت، معیار مناسبی نبوده و از معیارهای دیگری برای مقایسه و ارائه نتایج استفاده شده است که در ادامه به آن‌ها اشاره می‌شود. زمان اجرای طبقه‌بندی انجام‌شده برابر با ۰.۰۳ ثانیه است.

۵-۳- معیارهای ارزیابی

ماتریس آشفتگی[۱۰]، به ماتریسی گفته می‌شود که در آن عملکرد الگوریتم یادگیری قابل مشاهده است. معمولاً چنین نمایشی برای الگوریتم‌های یادگیری باناظر استفاده می‌شود. به عبارتی، یکی از روش‌های بیان کارایی هر طبقه‌بندی‌کننده ماتریس آشفتگی می‌باشد. این ماتریس یک ماتریس مربعی $N \times N$ می‌باشد که N تعداد کلاس است. باتوجه به ماتریس آشفتگی، علاوه بر دقت‌طبقه‌بندی، سه معیار صحت[۱۱]، بازخوانی[۱۲] و معیار-F برای ارزیابی کارایی بکار گرفته شده‌است.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (۲۳)$$

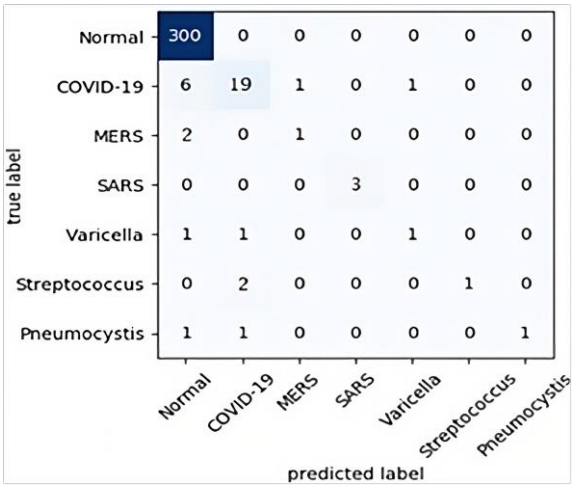
$$Precision = \frac{TP}{TP + FP} \quad (۲۴)$$

$$Recall = \frac{TP}{TP + FN} \quad (۲۵)$$

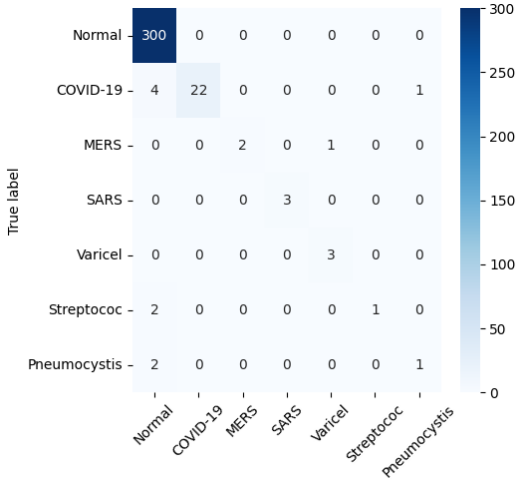
$$\mathrm{F-score} = \frac{2\mathrm{TP}}{2\mathrm{TP} + \mathrm{FP} + \mathrm{FN}} \quad (۲۶)$$

با توجه به رابطه‌های (۲۶-۲۳)، FP،TP و FN به ترتیب تعداد مثبت‌های واقعی، تعداد مثبت‌های کاذب و تعداد نمونه‌های به اشتباه منفی شناسایی شده را نشان می‌دهد. معیار بازخوانی بیان کننده نسبت تعداد داده‌های درست طبقه‌بندی شده در یک کلاس خاص، به تعداد کل داده‌هایی که باید در همان کلاس خاص دسته‌بندی شوند. معیار صحت نسبت تعداد پیش بینی‌های صحیح انجام شده برای نمونه های یک کلاس خاص، به تعداد کل پیش‌بینی‌ها برای نمونه‌های همان کلاس خاص را ارزیابی می‌کند. معیار-F را می‌توان به عنوان میانگین وزنی بازخوانی و صحت تفسیر کرد. در شکل ۷ ماتریس آشفتگی روش ارائه شده در [۲۷] نشان داده شده‌است که برای گزارش بهترین نتیجه برای ۷ کلاس از طبقه‌بندی‌کننده MLP و از ویژگی‌های LBP و از نمونه‌گیری مجدد استفاده شده‌است. شکل ۸ ماتریس آشفتگی روش پیشنهادی که از ILQP برای استخراج ویژگی‌ها و از روش MEETG برای طبقه‌بندی استفاده شده را نشان می‌دهد. در این

روش بهترین نتایج MEETG با استفاده از سه خبره و ۴۶ نورون لایه پنهان و استفاده از تابع‌فعالساز سیگموئید است.



شکل ۷: ماتریس آشفتگی با استفاده از LBP+RENN+MLP

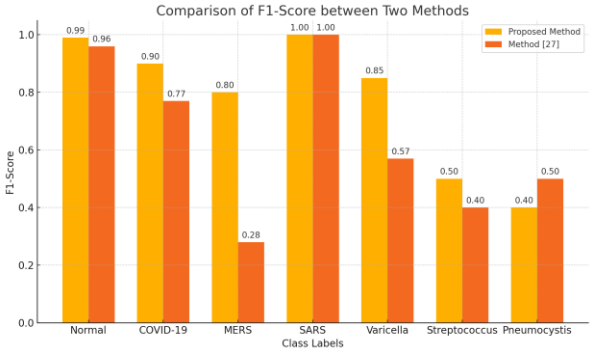


شکل ۸: ماتریس آشفتگی روش پیشنهادی برای داده‌های تست نسبت ۳۰ درصدی.

همان‌گونه که از شکل‌های ۷ و ۸ مشاهده می‌شود، می‌توان دریافت که روش پیشنهادی در مقایسه با روش ارائه شده در [۲۷] نمونه‌های بیشتری را به درستی تشخیص داده‌است. با مقایسه ماتریس‌های آشفتگی مشاهده می‌شود که میزان صحت و فراخوانی تشخیص کووید-۱۹ روش پیشنهادی نسبت به روش [۲۷] به ترتیب ۰.۱۸ و ۰.۱۱ افزایش داشته است. همچنین صحت روش [۲۷] برای شناسایی تصاویر از ریه نرمال، برابر با ۰.۹۶ بوده درحالی صحت روش پیشنهادی برابر با ۰.۹۸ است. در جدول ۴ معیارهای صحت، بازخوانی و معیار-F با توجه به ماتریس آشفتگی روش پیشنهادی برای هر کلاس نمایش داده شده است.

جدول ۴: معیارهای ارزیابی روش پیشنهادی بر روی مجموعه‌داده RYDLS-20 و داده‌های تست نسبت ۳۰ درصدی.

برچسب کلاس	بازخوانی	صحت	معیار-F
Normal	۱	۰.۹۷	۰.۹۹
COVID-19	۰.۸۱	۱	۰.۹۰
MERS	۰.۶۷	۱	۰.۸۰
SARS	۱	۱	۱
Varicella	۱	۰.۷۵	۰.۸۵
Streptococcus	۰.۳۳	۱	۰.۵۰
Pneumocystis	۰.۳۳	۰.۵۰	۰.۴۰
میانگین	۰.۷۴	۰.۸۹	۰.۷۸
دقت طبقه‌بندی	۰.۹۷		



شکل ۹: مقایسه روش پیشنهادی و نتایج معیار-F گزارش شده در [۲۷] برای هر کلاس بر روی مجموعه‌داده RYDLS-20 برای داده‌های تست نسبت ۳۰ درصدی.

با توجه به شکل ۹، مشاهده می‌شود که نتایج بر روی کلاس‌های کووید-۱۹، مرس و واریسلا افزایش یافته است. در جدول ۵، نتایج میانگین معیار-F روش پیشنهادی با دیگر طبقه‌بندها مورد مقایسه قرار گرفته است. همان‌گونه که مشاهده می‌شود، استفاده از طبقه‌بند MEETG موجب بهترشدن نتایج شده است.

با توجه به جدول ۵، با استفاده از طبقه‌بند MEETG میانگین معیار-F نسبت به طبقه‌بندهای مبتنی بر یادگیری مرکب از جمله اختلاط خبره‌ها و روش کیسه‌ای ۰.۱۹ بهتر شده و نسبت به طبقه‌بندهای نزدیک‌ترین همسایه، پرسپترون و ماشین یادگیری سریع به ترتیب ۰.۲۴، ۰.۳۷ و ۰.۲۰ بهبود داشته است.

جدول۵: مقایسه نتایج میانگین کل معیار-F روش پیشنهادی با دیگر طبقه‌بندها بر روی مجموعه‌داده RYDLS-20 برای داده‌های تست نسبت ۳۰ درصدی.

روش	میانگین کل معیار-F
$ILQP_{8,1} + k-NN$	۰.۵۴
$ILQP_{8,1} + DT$	۰.۳۵
$ILQP_{8,1} + MLP$	۰.۴۱
$ILQP_{8,1} + ELM$	۰.۵۸
$ILQP_{8,1} + ME$	۰.۶۱
$ILQP_{8,1} + bagging$	۰.۶۱
(روش پیشنهادی) $ILQP_{8.1} + MEETG$	**۰.۷۸**

از جدول ۶ مشاهده می‌شود که روش پیشنهادی نسبت به دیگر روش‌های ارائه شده بهتر عمل کرده، همچنین می‌توان مشاهده نمود که در [۲۷] از ترکیب چندین توصیف‌گر برای استخراج ویژگی‌ها از تصاویر استفاده شده‌است در حالی‌که در این پژوهش از یک توصیف‌گر استفاده شده است. شایان ذکر است که توصیف‌گر ILQP نسخه بهبودیافته روش EQP بوده است. با توجه به تعداد همسایگی‌های استفاده شده در این مقاله و در [۲۷] که از ۸ همسایگی و با شعاع ۱ استفاده نموده، ابعاد بردار ویژگی روش پیشنهادی برابر با ۴۰ است این در حالی می‌باشد که تعداد ابعاد روش EQP و LBP هریک برابر با ۲۵۶ است. از طرفی طبقه‌بند پایه روش MEETG، ELM بوده و با توجه به مطالب گفته شده در بخش‌های قبل سرعت یادگیری ELM نسبت به MLP هزاران بار سریع‌تر بوده و همچنین می‌تواند بر کمینه محلی و بیش‌برازش غلبه کند. در روش پیشنهادی از روش‌هایی مانند نمونه‌گیری مجدد نیز استفاده نشده است. بنابراین می‌توان نتیجه گرفت که زمان اجرای روش پیشنهادی بسیار سریع‌تر از روش [۲۷] است.

جدول۶: مقایسه نتایج میانگین معیار-F روش پیشنهادی با روش [۲۷] برای داده‌های تست نسبت ۳۰ درصدی.

ویژگی	نمونه گیری مجدد	طبقه‌بند	میانگین کل معیار-F
(LBP+RENN+MLP)+ (LBP+AllKNN+ MLP) [۲۷]			۰.۶۴۹۱
BSIF + EQP + LPQ [۲۷]	RENN	MLP	۰.۵۳۸۶
BSIF + EQP + LPQ [۲۷]	ENN	MLP	۰.۴۷۶۴
EQP +LPQ [۲۷]	TomekLink	3-NN	۰.۴۷۲۲
ILQP	----	**MEETG**	**۰.۷۸**

در آزمایش دیگر نشان داده شده‌است که روش پیشنهادی نسبت به رخدادهایی همچون کم‌برازش و بیش‌برازش مقاومت بالایی دارد. به عبارت دیگر، روش پیشنهادی با وجود تعداد داده آموزشی کم توانسته است دقت خوبی را فراهم کند (کم‌برازش) و هم چنین با وجود آموزش با درصد زیاد این نمونه‌ها نیز، دقت طبقه‌بندی افت نکرده است (بیش‌برازش) که نتایج در جدول ۷ قابل مشاهده است. در این آزمایش از ۳۰ درصد تا ۸۰ درصد نمونه‌ها برای آزمایش استفاده شده‌است و نتایج معیار-F برای هر کلاس گزارش شد. نتایج گزارش شده با در نظر گرفتن ۴۶ نورون لایه پنهان و سه خبره می‌باشد. به طور کلی، تعداد کل پارامترهای روش پیشنهادی ۵۹۸۰ است که در مقایسه با روش‌های عمیق دارای بیش از یک میلیون پارامتر، به‌طور قابل‌توجهی کمتر است. این کاهش تعداد پارامترها نه‌تنها منجر به کاهش زمان آموزش و نیاز به حافظه کمتر می‌شود، بلکه امکان استفاده از این روش در سیستم‌های کم‌منابع را نیز فراهم می‌کند. با این حال، با وجود این کاهش پیچیدگی، روش پیشنهادی دقت بالایی را ارائه داده است. این نتایج نشان‌دهنده تعادل مناسبی بین دقت و کارایی در روش پیشنهادی است.

جدول۷: معیار-F روش پیشنهادی به ازای هر کلاس بر اساس درصد نمونه آموزشی

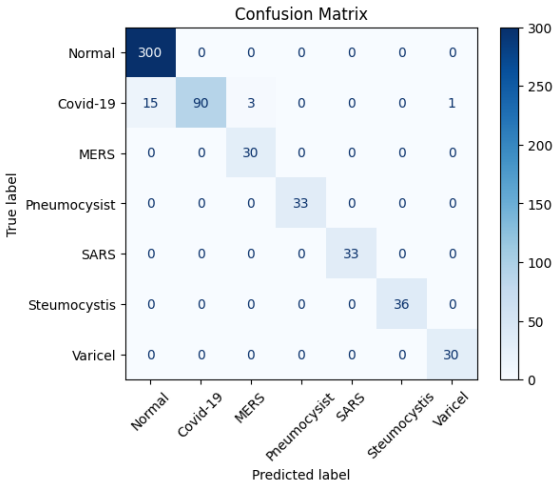
کلاس	۳۰٪	۴۰٪	۵۰٪	۶۰٪	۷۰٪	۸۰٪
Normal	۰.۹۸	۰.۹۸	۰.۹۸	۰.۹۸	۰.۹۹	۰.۹۹
COVID-19	۰.۸۸	۰.۹۰	۰.۸۷	۰.۹۱	۰.۹۰	۰.۹۰
MERS	۰.۸۰	۰.۶۰	۰.۶۶	۰.۸۰	۰.۸۰	۰.۸۰
SARS	۰.۶۶	۰.۸۳	۰.۸	۰.۷۵	۱	۱
Varicella	۰.۴۶	۰.۶۱	۰.۴۴	۰.۶۶	۰.۸۶	۰.۸۶
Streptococcus	۰	۰.۲۲	۰.۵۴	۰.۲۸	۰.۵۰	۰.۵۰
Pneumocystis	۰.۲۵	۰.۲۸	۰.۲۵	۰.۳۳	۰.۴۰	۰.۶۰

برای کاهش اثرات ناشی از عدم تعادل داده‌ها، تکنیک افزونگی داده‌ها برای کلاس‌های دارای تعداد نمونه کمتر (کلاس‌های ۲ به بعد) اعمال شد. در این روش، تغییراتی از جمله چرخش تصاویر در زوایای مختلف (مانند ۳۰، ۹۰، ۱۸۰، و ۲۷۰ درجه)، وارونگی افقی و عمودی و تغییرات روشنایی و کنتراست بر روی داده‌های کلاس‌های با تعداد نمونه کمتر اعمال شد تا حجم داده‌ها افزایش یابد و تعادل میان کلاس‌ها برقرار شود.

بر اساس دقت مدل در پیش‌بینی کلاس‌های کمتر تکرار شده مانند COVID-19 ، MERS و Pneumocystis بهبود چشمگیری

داشته است. برای مثال، مدل توانسته است ۹۰ نمونه از کلاس COVID-19، ۳۰ نمونه ازMERS ، و ۳۳ نمونه از Pneumocystis را به درستی پیش‌بینی کند. عملکرد مدل در پیش‌بینی کلاس Normal نیز با حفظ تعداد پیش‌بینی‌های درست (۳۰۰ نمونه صحیح)، نشان‌دهنده پایداری مدل در مواجهه با داده‌های افزوده شده است.

نتایج ارائه‌شده در ماتریس آشفتگی شکل ۱۰ نشان‌دهنده بهبود چشمگیر پیش‌بینی‌های مدل برای نمونه‌های کم‌تعداد است. این امر اثربخشی رویکرد افزونگی داده‌ها را در بهبود دقت و پایداری مدل تأیید می‌کند و نشان می‌دهد که این تکنیک می‌تواند به‌عنوان راهکاری موثر برای رفع چالش‌های ناشی از عدم تعادل داده‌ها مورد استفاده قرار گیرد. به عبارت دیگر این نتایج حاکی از آن است که اعمال افزونگی داده‌ها نه‌تنها موجب بهبود دقت مدل در کلاس‌های دارای تعداد نمونه کمتر شده است، بلکه تاثیر منفی بر دقت مدل در کلاس‌های پرتکرار نداشته است.



شکل ۱۰ ماتریس آشفتگی مدل پیشنهادی پس از اعمال افزونگی داده‌ها براساس داده‌های تست نسبت ۳۰ درصدی.

۶- نتیجه‌گیری

در این مطالعه، روشی مبتنی بر یادگیری مرکب، برای کاربرد ایجاد تمایز بین بافت ریه افراد سالم و افراد مبتلا به بیماری کووید -۱۹ و دیگر بیماری ریوی با دقت بالا، پیشنهاد شده است. با توجه به این‌که زمان آموزش مدل‌های مبتنی بر یادگیری عمیق زیاد است و همچنین برای آموزش به مجموعه‌داده‌های عظیم و به تجهیزات سخت افزاری نیاز دارد، برای حل این مشکلات به طور مؤثر، از ویژگی‌های بافت تصویر برای استخراج ویژگی‌ها و از روش مبتنی بر یادگیری مرکب برای طبقه‌بندی کووید-۱۹و پنج بیماری دیگر و افراد سالم استفاده شده است که توانسته به دستیابی به بهترین دقت در زمینه طبقه‌بندی برای این ۷ کلاس کمک کند. در این مقاله، از ILQP به عنوان توصیف‌کننده بافت برای استخراج ویژگی از تصاویر CXR استفاده نموده و MEETG به‌عنوان روش طبقه‌بندی استفاده شده‌است. باتوجه به نتایج گزارش شده در این مطالعه، می‌توان ملاحظه نمود که روش پیشنهادی از میانگین معیار-F بالاتری نسبت به [۲۷] برخوردار بوده است. همچنین نشان داده شده است که روش پیشنهادی نسبت به بیش‌برازش و کم‌برازش نیز مقاوم است. در روش [۲۷] برای شناسایی کووید-۱۹ با استفاده از ترکیب ویژگی‌های BSIF، EQP و LPQ و طبقه‌بند MLP، معیار-F برابر ۰.۸۹ حاصل شده‌است. با به‌کارگیری روش پیشنهادی برای شناسایی کووید-۱۹ با ۶۰ ٪ نمونه‌های آموزشی معیار-F برابر با ۰.۹۱ و با ۷۰ درصد نمونه‌های آموزش برابر با ۰.۸۹ بدست آمده است. با توجه به این‌که در روش [۲۷] از ترکیب چند توصیف‌گر استفاده شده می‌توان دریافت که بار محاسباتی روش پیشنهادی نسبت به روش [۲۷] به مراتب کمتر و همچنین دقت طبقه‌بندی و میانگین کل معیار-F بالاتر بوده است. لازم به ذکر است که توصیف‌گر ILQP بهبودیافته توصیف‌گر EQP است [۱۰] و زمان اجرا طبقه‌بند مورد استفاده نسبت به MLP کمتر می‌باشد [۳۲]. در این مقاله، با استفاده از طبقه‌بند MEETG و با استفاده از توصیف‌گر بافتی $ILQP_{8,1}$ دقت طبقه‌بندی برابر ۹۷.۰۴٪ و میانگین کل معیار-F برابر ۰.۷۸ برای طبقه‌بندی ۷ کلاس حاصل شده است. مدل پیشنهادی می‌تواند به‌عنوان جایگزینی برای کیت‌های مختلف آزمایش کووید-۱۹ باشد، زیرا دستگاه سی‌تی اسکن در اکثر موسسات پزشکی موجود است و همچنین مدل پیشنهادی می‌تواند روند آزمایش کووید را بهبود بخشد. در خصوص پیشنهاد برای تحقیقات آینده، درصورتی که بتوان تعداد نمونه‌های بیشتر در هر کلاس اضافه نمود به منظور کمتر نمودن اثر نامتعادل بودن مجموعه داده می‌توان به بهبود نتایج و دقیق‌تربودن تشخیص نزدیک‌تر شد. همچنین پیشنهاد می‌شود که با شعاع‌های دیگر این توصیف‌گر مورد ارزیابی قرار بگیرد.

مراجع

[1] World Health Organization, “WHO Disease outbreak news: Novel Coronavirus – Republic of Korea (ex-China),” January 21, 2020.

[2] N. Chen, M. Zhou, X. Dong and et al. “Epidemiological and clinical characteristics of 99 cases of 2019 novel coronavirus pneumonia in Wuhan, China: a descriptive study,” The lancet, Vol.395, No.10223, pp. 507-513, 2020.

[3] H. A. Rothan and S. N. Byrareddy, “The epidemiology and pathogenesis of coronavirus disease (COVID-19) outbreak” Journal of autoimmunity, Vol.109, 102433, 2020.

[4] T. Ai, Z. Yang, H. Hou, C. Zhan and et al. “Correlation of chest CT and RT-PCR testing for coronavirus disease 2019

(COVID-19) in China: a report of 1014 cases," Radiology, Vol.296, No.2, E32-E40, 2020.

[5] L. Hussain, T. Nguyen, H. Li, A. A. Abbasi, and et al. "Machine-learning classification of texture features of portable chest X-ray accurately classifies COVID-19 lung infection," BioMedical Engineering OnLine, Vol.19, No.1, pp. 1-18, 2020.

[6] S. Varela-Santos and P. Melin, "A new approach for classifying coronavirus COVID-19 based on its manifestation on chest X-rays using texture features and neural networks," Information sciences, Vol. 545, pp. 403-414, 2021.

[7] D. Al-Karawi, S. Al-Zaidi, N. Polus and S. Jassim, "AI based chest x-ray (cxr) scan texture analysis algorithm for digital test of covid-19 patients," medRxiv, 2020.

[8] M. Murugappan, A. K. Bourisly, P. T. Krishnan and et al. "Artificial Intelligence Based COVID-19 Detection using Medical Imaging Methods: A Review," Computational Modelling and Imaging for SARS-CoV-2 and COVID-19, CRC Press, pp. 1-22, 2021.

[9] R Vaishya, M. Javaid, I. H. Khan and A. Haleem, "Artificial Intelligence (AI) applications for COVID-19 pandemic," Diabetes & Metabolic Syndrome: Clinical Research & Reviews, Vol.14, No.4, pp. 337-339, 2020.

[10] L. Armi and S. Fekri-Ershad, "Texture image analysis and texture classification methods-A review," International Online Journal of Image Processing and Pattern Recognition, arXiv preprint arXiv:1904.06554 , Vol.2, No.1, pp. 1-29, 2019.

[11] L. Armi and S. Fekri-Ershad, "Texture image Classification based on improved local Quinary patterns," Multimedia Tools and Applications, Vol.78, No.14, pp. 18995-19018, 2019.

[12] L. Armi, E. Abbasi and J. Zarepour-Ahmadabadi, "Mixture of ELM based experts with trainable gating network," arXiv preprint arXiv:2105.11706, 2021.

[13] G. B. Huang, Q. Y. Zhu and C. K. Siew, "Extreme learning machine: theory and applications," Neurocomputing, Vol.70, No.1-3, pp. 489-501, 2006.

[14] S. A. Khan and H. T. Chang, "Comparative analysis on Facebook post interaction using DNN, ELM and LSTM," PloS one, Vol.14, No.11, e0224452, 2019.

[15] A. Narin, C. Kaya and Z. Pamuk, "Automatic detection of coronavirus disease (covid-19) using x-ray images and deep convolutional neural networks," Pattern Analysis and Applications, arXivpreprintarXiv:2003.10849, 2021.

[16] U. Özkaya, Ş. Öztürk, S. Budak, F. Melgani and K. Polat, "Classification of COVID-19 in Chest CT Images using Convolutional Support Vector Machines," arXiv preprint arXiv:2011.05746, 2020.

[17] D. Sharifrazi, R. Alizadehsani, M. Roshanzamir and et al. "Fusion of convolution neural network, support vector machine and Sobel filter for accurate detection of COVID-19 patients using X-ray images," Biomedical Signal Processing and Control, Vol.68, 102622, 2021.

[18] R. Jain, M. Gupta, S. Taneja and D. J. Hemanth, "Deep learning-based detection and analysis of COVID-19 on chest X-ray images," Applied Intelligence, Vol.51, No.3, pp. 1690-1700, 2021.

[19] A. I. Khan, J. L. Shah and 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, 105581, 2020.

[20] N. B. Prakash, M. Murugappan, G. R. Hemalakshmi and et al. "Deep transfer learning for COVID-19 detection and infection localization with superpixel based segmentation," Sustainable Cities and Society, Vol.75, 103252, 2021.

[21] A. Abbasi, E. Abbasi, M. Khouri, and M. Alehosseini, "Implementing a Hierarchically Classification of COVID-19 and Pneumonia Diseases Using Deep Learning, 1st international congress of artificial intelligence in medical sciences," 2023.

[22] P. Aggarwal, N. Kumar Mishra, B. Fatimah, P. Singh, A. Gupta, and S. Dutt Joshi, "COVID-19 image classification using deep learning: Advances, challenges and opportunities, " Computers in Biology and Medicine, Vol.144, 2022.

[23] S. Pang and X. Yang, "Deep convolutional extreme learning machine and its application in handwritten digit classification," Computational intelligence and neuroscience, 2016.

[24] Ş. Öztürk, U. Özkaya and M. Barstuğan, "Classification of Coronavirus (COVID-19) from X-ray and CT images using shrunken features," International Journal of Imaging Systems and Technology, Vol.31, No.1, pp. 5-15, 2021.

[25] 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, 107323, 2021.

[26] M. Barstugan, U. Ozkaya and S. Ozturk, "Coronavirus (covid-19) classification using ct images by machine learning method," arXiv preprint arXiv:2003.09424, 2020.

[27] R. M. Pereira, D. Bertolini, L. O. Teixeira, C. N. Silla Jr and Y. M. Costa, "COVID-19 identification in chest X-ray images on flat and hierarchical classification scenarios," Computer Methods and Programs in Biomedicine, Vol.194, 105532, 2020.

[28] G. B. Huang, Q. Y. Zhu and C. K. Siew, "Extreme learning machine: a new learning scheme of feedforward neural networks," In 2004 IEEE international joint conference on neural networks (IEEE Cat. No. 04CH37541) 2, pp. 985-990, 2004.

[29] G. B. Huang, H. Zhou, X. Ding and R. Zhang, "Extreme learning machine for regression and multiclass classification," IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics), Vol.42, No.2, pp. 513-529, 2011.

[30] R. A. Jacobs, M. I. Jordan, S. J. Nowlan and G. E. Hinton, "Adaptive mixtures of local experts," Neural computation, Vol.3, No.1, pp. 79-87, 1991.

[31] S. Masoudnia and R. Ebrahimpour, "Mixture of experts: a literature survey," Artificial Intelligence Review, Vol.42, No.2, pp. 275-293, 2014.

[32] Sh. Fekri-Ershad, "Pap smear classification using combination of global significant value, texture statistical features and time series features," Multimedia Tools and Applications, Vol.78, No.22, pp. 31121-31136, 2019.

[33] L. Armi, E. Abbasi and J. Zarepour-Ahmadabadi, "Texture images classification using improved local quinary pattern and mixture of ELM-based experts," Neural Computing & Applications, pp. 1-24, 2021.

[34] J. H. Cho, D. J. Lee and M. G. Chun, "Parameter optimization of extreme learning machine using bacterial foraging algorithm," Journal of Korean Institute of Intelligent Systems, Vol.17, No.6, pp. 807-812, 2007.

[35] H. G. Zhang, S. Zhang and Y. X. Yin, "A novel improved ELM algorithm for a real industrial application," Mathematical Problems in Engineering, pp. 1-7, 2014.

[36] S. Toraman, T. B. Alakus and I. Turkoglu, "Convolutional capsnet: A novel artificial neural network approach to detect COVID-19 disease from X-ray images using capsule networks," Chaos, Solitons & Fractals, vol.140, 110122, 2020.

[37] L. M. AbouEl-Magd, A. Darwish, V. Snasel and A. E. Hassanien, "A pre-trained convolutional neural network with optimized capsule networks for chest X-rays COVID-19 diagnosis," Cluster Computing, vol.26, pp.1389-1403, 2023.

[38] U. Özkaya, Ş. Öztürk, S. Budak, F. Melgani, K. Polat, "Classification of COVID-19 in Chest CT Images using Convolutional Support Vector Machines," European Journal of Clinical Microbiology & Infectious Diseases, vol.39, pp.1379-1389, 2020.

[39] M. E. Elaraby, A. A. Ewees, A. M. Anter, "A robust IoT-based cloud model for COVID-19 prediction using advanced machine learning technique," Biomedical Signal Processing and Control, Vol.87, 105542, 2024.

[40] P. Sahoo, S. Saha, S. K. Sharma, S. Mondal, S. Gowda, "A Multi-stage framework for COVID-19 detection and severity assessment from chest radiography images using advanced fuzzy ensemble technique," Expert Systems With Applications, Vol.238, 121724, 2024.

[41] E. P. Medeiros, M. R. Machado, E. D. G. de Freitas, D. S. da Silva, R. W. R. de Souza, "Applications of machine learning algorithms to support COVID-19 diagnosis using X-rays data information," Expert Systems With Applications, Vol.238, 122029, 2024.

[42] S. Das, I. Ayus, D. Gupta, "A comprehensive review of COVID-19 detection with machine learning and deep learning techniquesHealth and Technology, Vol.13, pp. 679–692, 2023.

پاورقی‌ها:

[1] Feedforward

[2] Moore-Penrose

[3] Singular value decomposition (SVD)

[4] Divide and conquer

[5] Gating network

[6] Improved local quinary pattern (ILQP)

[7] Median absolute deviation(MAD)

[8] Global significant value (GSV)

[9] Mixture of ELM based experts with trainable gating network

[10] confusion matrix

[11] Precision

[12] Recall