DOI: 10.22034/yafteh.28.2.93

Yafteh
Volume 28, Issue 2, 2026

Original Article

A COVID-19 Diagnostic Approach Based on Cough Sound Analysis Using Deep Learning with Convolutional Neural Networks and Long Short-Term Memory Networks

Shadi Dalvand[1], Hamidreza Ghaffari[1 *]

1. Department of Computer Engineering, Fe.C., Islamic Azad University, Ferdows, Iran

***Corresponding author:** Department of Computer Engineering, Fe.C., Islamic Azad University, Ferdows, Iran
Email: hamidghaffary53@iau.ac.ir

How to Cite this Article:
Dalvand SH, GHaffari H. A COVID-19 Diagnostic Approach Based on Cough Sound Analysis Using Deep Learning with Convolutional Neural Networks and Long Short-Term Memory Networks. Yafteh. 2026;28(2):93-109.

Received: November 29, 2025
Revised: March 19, 2026
Accepted: March 27, 2026

Keywords:
COVID-19
Cough sound analysis
Deep learning
Lung infection
Signal processing
Swarm intelligence

Abstract

Background: Conventional COVID-19 diagnostic assays, such as reverse transcription polymerase chain reaction (RT-PCR), may be time-consuming, costly, and susceptible to environmental and operational factors. These limitations are particularly challenging in resource-constrained settings. Artificial intelligence-based analysis of cough sounds has emerged as a promising noninvasive approach for COVID-19 screening.

Materials and Methods: This study proposes a novel COVID-19 detection method based on cough sound analysis. First, cough signals are converted into spectrogram images. Next, spatial features are extracted using an enhanced Convolutional Neural Network (CNN), the hyperparameters of which are optimized using the Coati Optimization Algorithm. The Arithmetic Optimization Algorithm is then employed to select the most informative features. Finally, a Long Short-Term Memory (LSTM) network classifies the samples into COVID-19-infected and healthy groups.

Results: On the CHRSD dataset, the proposed method achieved an accuracy of 95.72%, a sensitivity of 93.41%, and a precision of 91.75%. On the Cambridge dataset, it achieved an accuracy of 98.26%, a sensitivity of 97.73%, and a precision of 97.92%. On the COUGHVID dataset, the method obtained an accuracy of 98.83%, a sensitivity of 97.29%, and a precision of 97.68%.

Conclusion: The proposed method outperformed conventional CNN, Deep Neural Network, and LSTM models in COVID-19 detection based on cough sounds. Its noninvasive nature and computational efficiency indicate its potential for deployment in smartphone-based screening applications. However, the method should be considered a supportive screening tool and requires further clinical validation before use as a replacement for standard diagnostic tests, such as RT-PCR.

Copyright © 2026 The Author(s); Published by Lorestan University of Medical Sciences.

This is an open-access article, distributed under the terms of the Creative Commons Attribution-NonCommercial 4.0 International License (http://creativecommons.org/licenses /by-nc/4.0/), which permits others to copy and redistribute material just in non-commercial usages, provided the original work is properly cited.

[Downloaded from yafteh.lums.ac.ir on 2026-11-06]

یافتـــه
دوره ۲۸، شماره ۲، تابستان ۱۴۰۵

DOI: 10.22034/yafteh.28.2.93

مقاله پژوهشی

یک رویکرد تشخیص بیماری کووید ۱۹ بر اساس تحلیل صدای سرفه با یادگیری عمیق مبتنی بر شبکه عصبی Convolutional Neural Networks و Long short-term memory

شادی دالوند[۱]، حمیدرضا غفاری[۱*]

۱- گروه مهندسی نرم‌افزار، دانشگاه آزاد اسلامی، (خراسان جنوبی)، واحد فردوس، ایران

***نویسنده مسئول:** حمیدرضا غفاری، دانشگاه آزاداسلامی ،(خراسان جنوبی)،واحد فردوس ،دانشکده فنی و مهندسی ،گروه مهندسی کامپیوتر. ایمیل: hamidghaffary53@iau.ac.ir

استناد: دالوند، شادی؛ غفاری، حمیدرضا. یک رویکرد تشخیص بیماری کووید ۱۹ بر اساس تحلیل صدای سرفه با یادگیری عمیق مبتنی بر شبکه عصبی Convolutional Neural Networks و Long short-term memory . یافته. دوره ۲۸، شماره ۲، تابستان ۱۴۰۵.

تاریخ دریافت: ۱۴۰۴/۰۹/۰۸
تاریخ ویرایش: ۱۴۰۴/۱۲/۲۷
تاریخ پذیرش: ۱۴۰۵/۰۱/۰۵

واژگان کلیدی:
عفونت‌های ریه
کووید ۱۹
پردازش سیگنال
یادگیری عمیق
هوش گروهی

چکیده

مقدمه: تشخیص ویروس کووید-۱۹ با سنجش‌های موجود مانند RT-PCR کند و حساس به شرایط هستند که مشکلاتی را به ویژه در محیط‌های با منابع کم ایجاد می‌کنند. یک روش برای تحلیل صدای سرفه بیماران بکارگیری هوش مصنوعی و یادگیری عمیق برای تشخیص بیماری کووید-۱۹ است.

مواد و روش‌ها: در این مقاله یک روش تشخیص بیماری کووید ۱۹ بر اساس تجزیه و تحلیل صدای سرفه بیماران ارایه شده است. در فاز اول سیگنالهای سرفه به تصاویر طیف‌نگار تبدیل می‌شود. در مرحله بعدی ویژگی‌های مکانی با شبکه عصبی کانولوشن بهبود یافته با الگوریتم بهینه‌سازی کوآتی استخراج می‌شود و نقش الگوریتم بهینه‌سازی کوآتی بهینه‌سازی فراپارامترهای CNN است. در مرحله بعدی الگوریتم بهینه‌سازی محاسبات ریاضی برای انتخاب ویژگی استفاده می‌شود و در نهایت از LSTM برای طبقه‌بندی نمونه‌ها به بدخیم و خوش خیم استفاده می‌شود.

یافته‌ها: آزمایشات نشان می‌دهد در مجموعه داده CHRSD روش پیشنهادی به دقت، حساسیت و صحت ۹۵/۷۲٪، ۹۳/۴۱ ٪ و ۹۱/۷۵٪ رسیده است. در مجموعه داده Cambridge دقت، حساسیت و صحت روش پیشنهادی ۹۸/۲۶٪، ۹۷/۷۳ ٪ و ۹۷/۹۲٪ است و مجموعه داده COUGHVID دقت، حساسیت و صحت روش پیشنهادی ۹۸/۸۳٪، ۹۷/۲۹٪ و ۹۷/۶۸٪ است.

بحث و نتیجه‌گیری: نتایج نشان می دهد دقت روش پیشنهادی در تشخیص بیماری کووید ۱۹ از CNNs, DNNs, LSTMs بیشتر است. مزیت مهم روش پیشنهادی عدم نیاز به آزمایشات هزینه بر مانند PCR است. یک مزیت مهم روش پیشنهادی، امکان پیاده سازی آن به عنوان یک برنامه تحت گوشی های هوشمند برای تشخیص بیماری کووید ۱۹ است.

Copyright © 2026 The Author(s); Published by Lorestan University of Medical Sciences.

This is an open-access article, distributed under the terms of the Creative Commons Attribution-NonCommercial 4.0 International License (http://creativecommons.org/licenses /by-nc/4.0/), which permits others to copy and redistribute material just in non-commercial usages, provided the original work is properly cited.

[Downloaded from yafteh.lums.ac.ir on 2026-11-06]

مقدمه

بیماری‌های عفونی باعث بیماری گسترده، مرگ و میر بالا و اختلال اقتصادی قابل توجه می‌شوند و همچنین در طول تاریخ بشر به طور مداوم خطرات قابل توجهی را برای سلامت عمومی ایجاد کرده‌اند (۱). ویروس Severe Acute Respiratory Syndrome Coronavirus 2(SARS-CoV 2) که اخیراً شناسایی شده است، بیماری ویروسی معروف به نام COVID-19 را ایجاد می‌کند. سارس و سرماخوردگی معمولی مشابه کووید-۱۹ هستند (۲). سازمان بهداشت جهانی اعلام می‌کند که علائم متوسط کووید-۱۹ ممکن است شامل سرفه، تب و مشکلات تنفسی مشابه سرماخوردگی باشد. مشابه موارد شدیدتر سارس، کووید-۱۹ نیز باعث ذات‌الریه و یا مشکلات تنفسی جدی می‌شود. در شرایط بسیار نادر، این بیماری می‌تواند کشنده باشد. در ۳۱ دسامبر ۲۰۱۹، اولین موارد ابتلا به کووید-۱۹ در ابتدا به عنوان ذات‌الریه شناسایی شدند، اما متعاقباً به عنوان COVID-19 شناسایی شدند (۳). این ویروس بسیار مسری بوده و در مجاورت فرد مبتلا به سرعت گسترش می‌یابد. به طور دقیق‌تر، همانطور که توسط سازمان بهداشت جهانی بیان شده است، از فرد مبتلا منتقل می‌شود. پس از ۳ ماه از ثبت دیدگاه‌ها در چین، در ۱۱ مارس ۲۰۲۰، سازمان بهداشت جهانی آن را شیوع جهانی اعلام کرد (٤).

چارچوب‌های بهداشتی در سراسر جهان به دلیل کووید-۱۹ تحت فشار زیادی هستند و حتی کشورهای ثروتمند نیز برای غربالگری افراد کافی برای جلوگیری از رشد موفقیت‌آمیز آن تلاش می‌کنند (٥). در حال حاضر، رویکرد اصلی برای تشخیص کووید-۱۹ شامل استفاده از آزمایش Reverse transcription polymerase chain reaction (RT-PCR) است (٦). با این وجود، این روش تشخیصی چالش‌های قابل توجهی را ایجاد می‌کند، که در درجه اول به دلیل هزینه بالا و ماهیت تهاجمی آن است. علاوه بر این، تهاجمی بودن آزمایش RT-PCR ، که شامل جمع‌آوری نمونه از دستگاه تنفسی است، می‌تواند باعث ناراحتی و تردید بیمار شود (۷). این محدودیت‌ها، نیاز فوری به استراتژی‌های تشخیصی جایگزین، مقرون به صرفه‌تر و کمتر تهاجمی را که امکان غربالگری گسترده‌تر و راحت‌تر کووید-۱۹ را فراهم می‌کنند، برجسته می‌کند. مطالعات اخیر همچنین توجه را به چالش‌های منفی کاذب و مثبت کاذب در نتایج RT-PCR جلب کرده‌اند و بر احتمال تشخیص اشتباه و پیامدهای آن برای مراقبت از بیمار تأکید دارند (۸).

پیچیدگی‌های جمع‌آوری نمونه، از جمله نیاز به پرسنل آموزش‌دیده و تجهیزات تخصصی و در نهایت، بار مالی قابل توجه مرتبط با آزمایش RT-PCR از جمله چالش‌های آن برای تشخیص کووید-۱۹ است. این محدودیت‌ها در مجموع بر نیاز مبرم به روش‌های تشخیصی جایگزین که بتوانند به طور مؤثر این چالش‌ها را برطرف کنند، تأکید می‌کنند (۹). با این حال، در دهه گذشته تغییر قابل توجهی رخ داده است، که بیشتر به دلیل رشد کاربردهای هوش مصنوعی در صنعت مراقبت‌های بهداشتی است. چندین الگوریتم یادگیری ماشین و یادگیری عمیق در این زمینه برای تشخیص زودهنگام موقعیت‌ها با استفاده از رویه‌های مناسب‌تر و مقرون‌به‌صرفه‌تر ایجاد شده‌اند که بیشتر آنها بر پایه تجزیه و تحلیل تصویر سی‌تی اسکن است (۱۰، ۱۱). هزینه تهیه تصاویر سی‌تی اسکن از ریه قابل توجه است و در در بیشتر مناطق روستایی یا دورافتاده تهیه تصاویر سی‌تی اسکن ریه به دلیل عدم وجود تجهیزات غیر ممکن است (۱۲). زمینه یک بیماری همه‌گیر جهانی، جستجوی راه‌حل‌های نوآورانه را تسریع کرده و پیشرفت‌های چشمگیری را در مراقبت‌های بهداشتی به همراه داشته است (۱۳). یکی از این پیشرفت‌های پیشگامانه، تشخیص مبتنی بر سرفه برای کووید-۱۹ است.

دانشمندان و متخصصان مراقبت‌های بهداشتی با بهره‌گیری از توانایی هوش مصنوعی و الگوریتم‌های پیچیده، تلاشی مهم را برای شناسایی الگوهای متمایز سرفه که به طور پیچیده‌ای با ویروس مرتبط هستند، انجام می‌دهند (١٤). با وجود پیشرفت در استفاده از صداهای سرفه برای تشخیص کووید-۱۹، چندین شکاف همچنان وجود دارد. رویکردهای موجود اغلب به مدل‌های سنتی یادگیری ماشین متکی هستند که ممکن است به دلیل قابلیت‌های محدود استخراج ویژگی، در تشخیص صداهای سرفه کووید-۱۹ از سایر بیماری‌های تنفسی، فاقد استحکام باشند (١٥).

برخی مطالعات از مدل‌های آماری استفاده می‌کنند، ادغام تکنیک‌های پیش‌پردازش پیشرفته و استخراج ویژگی همچنان مورد بررسی قرار نگرفته است و دقت و قابلیت اطمینان کلی چارچوب‌های تشخیص کووید-۱۹ را محدود می‌کند (١٦). از طرفی عدم تعادل در مجموعه‌های آموزشی مرتبط با صدای افراد سالم و بیمار نیز باعث افزایش خطای تشخیص بیماران از افراد سالم می‌شود (١٧). عدم انتخاب ویژگی مناسب و هوشمندانه نیز باعث می‌شود تا دقت روشهای یادگیری عمیق و یادگیری ماشین برای تجزیه و تحلیل صدای سرفه کاهش داده شود و توانایی روشهای یادگیری ماشین و یادگیری عمیق برای تشخیص بیماران کووید ۱۹ را کاهش دهد (١٨). به طور کلی شناسایی سرفه، که یکی از علائم برجسته کووید-۱۹ است، این

[Downloaded from yafteh.lums.ac.ir on 2026-11-06]

امر نیاز به بررسی تکنیک‌های مختلف برای تشخیص و تمایز سرفه انسان از سایر الگوهای صوتی را برجسته می‌کند (۱۹). برای تشخیص بیماری کووید ۱۹ و سایر عفونتهای ریه روشهای مختلفی بر اساس صدای سرفه یا تنفس بیماران وجود دارد. بیشتر رویکردهای تشخیص پاندمی بر اساس یادگیری عمیق است لذا در ادامه تعدادی از کارهای مرتبط خارجی در این حوزه مرور می‌شود. در پژوهشی تحلیل صدای سرفه مبتنی بر یادگیری عمیق برای تشخیص بیماری‌های عفونی و تنفسی را پیشنهاد دادند (۲۰). ارزیابی‌ها نشان داد روش CNN-SVM نسبت به روش CNN و یادگیری انتقالی دقت بیشتری دارد. تشخیص کووید-۱۹ با استفاد از سیگنال‌های صوتی سرفه و الگوریتم بهینه‌سازی ایمنی جمعی ویروس کرونا نیز در (۲۱) ارایه شده است.

مدل پیشنهادی شاخص خطای پیش بینی را نسبت به مدل‌های PSO، WOA و LSTM بهبود می‌بخشد. د تشخیص کووید-۱۹ بر اساس سیگنال‌های صوتی تنفس با استفاده از یادگیری ماشین گروهی در (۲۲) پیشنهاد شده است. روش پیشنهادی آنها در تشخیص بیماری کووید ۱۹ به دقت ۹۷/۵۰٪ دست می‌یابد. تقویت سیگنال سرفه با استفاده از نمایش تبدیل کسینوسی گسسته اصلاح‌شده را در (۲۳) پیشنهاد دادند. هدف این مطالعه، رفع چالش سیگنال‌های ناکافی سرفه در مجموعه داده‌ها است. در برخی از پژوهش‌ها با تولید مصنوعی سیگنال‌های سرفه با استفاده از شبکه‌ی هماوردی مولد تلاش می‌شود تا مجموعه داده غنی‌تر شود. در این پژوهشها عملکرد مدل پیش‌بینی تحقق‌یافته ۱۷٪ بهبود در دقت طبقه‌بندی را داشته است (۲٤).

پیش‌بینی پیامد بالینی در عفونت‌های تنفسی کودکان با استفاده از انتخاب ویژگی ترکیبی و یادگیری ماشین بهینه‌شده با الگوریتم ژنتیک در (۲۵)، ارایه شده است. معیارهای عملکرد مدل پیشنهادی در مقایسه با کارهای موجود، به دقت کلی۹۵/۰۲٪ دست یافته و می‌تواند در تجزیه و تحلیل مراقبت‌های بهداشتی به کار رود. مروری جامع بر تکنیک‌های یادگیری انتقالی و گروهی فازی که در مقالات مربوط به استراتژی‌های تشخیص کووید-۱۹ در (۲٦)، شرح داده شده است. مدل‌های یادگیری عمیق مبتنی بر صدای سرفه برای تشخیص کووید-۱۹ با استفاده از ویژگی‌های آماری و طیف زمان-فرکانس در (۲۷)، بکار گرفته شده است. ارزیابی‌ها نشان داد رویکرد آنها در مجموعه داده‌های کمبریج به دقت ۹۳/٤٦٪ رسیده است. برای تشخیص کووید-۱۹ با استفاده از سیگنال صدای سرفه یک روش مبتنی بر جنگل تصادفی در (۲۸)، ارایه شده است. چارچوب پیشنهادی ممکن است برای برنامه‌های تشخیص کووید-۱۹ مبتنی بر تلفن‌های هوشمند مفید باشد. یک مدل یادگیری عمیق چند شاخه‌ای برای تشخیص کووید-۱۹ از طریق صداهای سرفه در (۲۹)، ارایه دادند. نتایج آزمایش نشان می‌دهد که سیستم پیشنهادی به دقت حدود ۹۰/٤٪رسیده است. یک چارچوب یادگیری عمیق مبتنی بر نمونه اشعه ایکس قفسه سینه و سرفه برای تشخیص دقیق کووید۱۹ در (۳۰)، ارایه دادند. دقت برای تشخیص بیماری بر اساس تصاویر و سرفه در روش آنها به ترتیب برابر ۹۸/۷۰٪ و ۸۲/۷٪ است. در برخی از پژوهش‌ها، با استخراج ویژگی‌های طیفی از سیگنال گفتار، روشی برای تشخیص بیماری‌های تنفسی ارائه شده است(٤٥).

نتایج نشان داد نشان داد ویژگی‌های فرکانسی می‌توانند اطلاعات مفیدی درباره وضعیت دستگاه تنفسی ارائه دهند. در برخی از مطالعات کاربرد مدل‌های یادگیری عمیق را در تشخیص بیماری‌های ریوی بر اساس داده‌های صوتی بررسی (٤٦) شده است و نویسندگان نشان دادند که شبکه‌های عمیق در استخراج الگوهای پیچیده صوتی عملکرد مناسبی دارند. در مطالعه‌ای دیگر، محمدی و شریفی (٤٧) از شبکه‌های عصبی کانولوشنی برای تحلیل سیگنال‌های زیستی تنفسی استفاده کردند و نتایج آن‌ها بیانگر توانایی این شبکه‌ها در استخراج خودکار ویژگی‌ها از داده‌های پیچیده زیستی بود.

در برخی پژوهش‌ها تمرکز بر استخراج ویژگی و بهبود طبقه‌بندی سیگنال‌های صوتی و تصاویر پزشکی بوده است. برای نمونه، شفیع خانی و همکاران(٤٨) با استفاده از الگوریتم‌های یادگیری ماشین، رویکردی برای تشخیص کووید ۱۹ ارائه کردند و نشان دادند که ترکیب ویژگی‌های مناسب با طبقه‌بندهای هوشمند می‌تواند به بهبود عملکرد تشخیص کمک کند. در برخی پژوهش‌ها تمرکز بر استخراج ویژگی و بهبود طبقه‌بندی سیگنال‌های صوتی پزشکی بوده است. برای نمونه، عرب زاده و همکاران (٤۹) روشی برای استخراج ویژگی از سیگنال‌های صوتی به‌منظور تشخیص اختلالات تنفسی ارائه کردند. کریمی و محمدی (۵۰) با استفاده از شبکه‌های عصبی کانولوشن، ساختاری پیشنهاد دادند که اطلاعات تصاویر اسکن شده از ریه افراد را دریافت کرده و پس از پردازش، وضعیت فرد را در ۳ دسته کووید-۱۹، سالم و پنومونی در خروجی نشان می‌دهد. در پژوهش دیگری، میرزائی و همکاران (۵۱) برای تحلیل سیگنال‌های زیستی ویژگی‌ها سیگنال‌ها را به عنوان ورودی به روش‌های طبقه بندی خطی و غیرخطی مانند LDA ، ماشین بردار پشتیبانی خطی، نزدیک‌ترین همسایه و شبکه های عصبی داده دادند. کارساز و همکاران (۵۲) شبکه‌های عصبی کانولوشن مبتنی بر یادگیری عمیق جهت غربالگری تصاویر سی‌تی‌اسکن قفسه سینه بیماران مبتلا به کووید-۱۹ را بررسی کردند. علاوه بر این، حکاک و همکاران(۵۳) نشان دادند که استفاده از روش‌های انتخاب ویژگی می‌تواند باعث بهبود

[Downloaded from yafteh.lums.ac.ir on 2026-11-06]

عملکرد مدل‌های طبقه‌بندی نظیر شبکه‌های عصبی کانولوشن در تحلیل تصاویر پزشکی شود. موسوی (٥٤) نیز با استفاده از رویکردهای یادگیری عمیق پیشرفته مانند U-Net ، ResNet، DenseNet fiبه تشخیص بیماری کووید ۱۹ پرداختند. در جدول(۱)، خلاصه‌ای از کارهای مرتبط در زمینه خارجی و داخلی مرور شده است:

جدول ۱: خلاصه‌ای از کارهای مرتبط در زمینه خارجی و داخلی

محدودیت	نقاط قوت	روش مورد استفاده	نوع داده	مرجع
وابستگی به کیفیت داده	استخراج خودکار ویژگی‌ها	CNN + استخراج ویژگی طیفی	صدای سرفه	(۲۰)
پیچیدگی محاسباتی	بهبود عملکرد طبقه‌بندی	الگوریتم بهینه‌سازی فراابتکاری + ML	صدای سرفه	(۲۱)
نیاز به داده زیاد	دقت بالا در تشخیص	Ensemble Learning	صدای تنفس	(۲۲)
تمرکز کم بر طبقه‌بندی	بهبود کیفیت سیگنال	تقویت سیگنال صوتی	صدای سرفه	(۲۳)
امکان تولید داده غیرواقعی	حل مشکل کمبود داده	GAN برای افزایش داده	صدای سرفه	(۲٤)
حساسیت به تنظیم پارامتر	افزایش دقت پیش‌بینی	انتخاب ویژگی + الگوریتم ژنتیک	داده‌های پزشکی	(۲٥)
عدم بررسی جامع همه روشهای یادگیری انتقالی	بررسی روشهای پیشرفته	مرور تکنیک‌های یادگیری انتقالی و گروهی فازی	داده‌های پزشکی	(۲٦)
نیاز به منابع محاسباتی	استخراج الگوهای پیچیده	Deep Learning + ویژگی زمان-فرکانس	صدای سرفه	(۲۷)
دقت کمتر نسبت به DL	مناسب برای سیستم‌های سبک	Random Forest	صدای سرفه	(۲۸)
پیچیدگی مدل	استفاده از چند نوع ویژگی	شبکه عمیق چندشاخه‌ای	صدای سرفه	(۲۹)
نیاز به چند نوع داده	افزایش دقت تشخیص	مدل ترکیبی چندرسانه‌ای	سرفه + تصویر X-ray	(۳۰)
عدم استفاده از مدل‌های عمیق	تحلیل فرکانسی دقیق سیگنال	استخراج ویژگی طیفی + ML	سیگنال گفتار	(٤٥)
حجم داده محدود	توانایی استخراج ویژگی خودکار	یادگیری عمیق	داده صوتی پزشکی	(٤٦)
عدم تحلیل وابستگی زمانی	استخراج ویژگی قوی از داده زیستی	CNN	سیگنال‌های تنفسی	(٤۷)
استفاده از ویژگی‌های محدود	کاربرد در تشخیص بیماری	الگوریتم‌های ML	داده پزشکی مرتبط با کووید	(٤۸)
دقت محدود در داده‌های پیچیده	سادگی پیاده‌سازی	استخراج ویژگی صوتی	سیگنال صوتی تنفسی	(٤۹)
نیاز به داده آموزشی زیاد	تشخیص سه نوع بیماری	شبکه عصبی کانولوشن	تصاویر سی‌تی اسکن	(٥۰)
پیچیدگی محاسباتی	تحلیل جامع	روشهای یادگیری ماشین	سیگنال زیستی	(٥۱)
عدم تمرکز بر سیگنال سرفه	تحلیل چندمنبعی داده‌ها	شبکه‌های عصبی کانولوشن	داده‌های پزشکی	(٥۲)
وابستگی به نوع ویژگی	بهبود دقت طبقه‌بندی	شبکه‌های عصبی کانولوشن	تصاویر پزشکی	(٥۳)
عدم استفاده از معماری ترکیبی	استخراج الگوهای پیچیده	یادگیری عمیق پیشرفته	تصاویر پزشکی	(٥٤)

با وجود پیشرفت‌های حاصل‌شده در مطالعات پیشین، اغلب پژوهش‌های داخلی با خارجی یا بر تحلیل کلی سیگنال‌های صوتی پزشکی تمرکز داشته‌اند یا از یک مدل یادگیری ماشین منفرد استفاده کرده‌اند. در بسیاری از این مطالعات، چالش‌هایی نظیر عدم توازن داده‌ها، انتخاب ویژگی‌های بهینه و بهره‌گیری از معماری‌های ترکیبی یادگیری عمیق به‌طور کامل مورد توجه قرار نگرفته است. از این رو، در پژوهش حاضر تلاش شده است با ارائه چارچوب پیشنهادی GCLSI که شامل ترکیب روش‌های افزایش داده مبتنی بر شبکه عصبی مولد متخاصم یا(Generative adversarial network (GAN ، استخراج ویژگی با شبکه‌های کانولوشنی، انتخاب ویژگی با الگوریتم بهینه‌سازی و طبقه‌بندی با شبکه‌های بازگشتی عمیق است، عملکرد تشخیص بیماری کووید-۱۹ از صدای سرفه بهبود یابد.

هدف از این مقاله ارایه یک رویکرد جدید در تشخیص بیماران مبتلا به کووید ۱۹ بدون اتکا به روشهای سی‌تی اسکن و آزمایش RT-PCR است تا هزینه را کاهش و زمان تشخیص را نیز کاهش دهد. سهم نویسندگان و نوآوری در متعادلسازی مجموعه داده با روش تئوری بازی و مبتنی بر روش شبکه عصبی مولد متخاصم برای ایجاد نمونه‌های سرفه بدخیم جدید و ناشناخته و افزایش تعداد نمونه‌های مجموعه داده است. ارایه یک نسخه الگوریتم بهینه‌سازی کوآتی یا Coati Optimization Algorithm (COA) (۳۱). شبکه عصبی کانولوشن برای استخراج ویژگی‌های صدای سرفه بیماران مبتلا به پاندمی عفونتهای ریه(فاز استخراج ویژگی صدا) نوآوری دیگر مقاله است. تشخیص ویژگی‌های اساسی صدای سرفه بیماران مبتلا به پاندمی عفونتهای ریه با ارایه یک نسخه باینری از الگوریتم بهینه‌سازی ریاضی یا Arithmetic Optimization Algorithm (AOA) (۳۲) (فاز انتخاب ویژگی صدا) و طبقه‌بندی نمونه‌ها با LSTM به دو دسته خوش خیم و بدخیم از نوآوری‌های دیگر است. در روش پیشنهادی، ابتدا شبکه عصبی کانولوشن برای

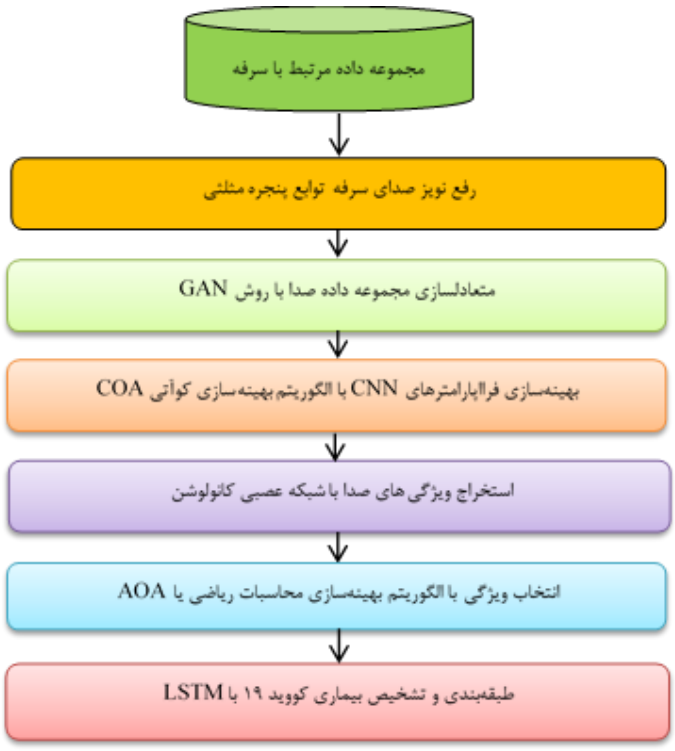
[Downloaded from yafteh.lums.ac.ir on 2026-11-06]

استخراج ویژگی‌های مکانی از نمایش سیگنال صوتی سرفه مورد استفاده قرار می‌گیرد. خروجی لایه‌های کانولوشنی پس از عملیات pooling و flatten به مجموعه‌ای از بردارهای ویژگی تبدیل می‌شود که اطلاعات الگوهای محلی سیگنال را در خود نگه می‌دارند. سپس این بردارهای ویژگی در قالب یک توالی زمانی سازمان‌دهی شده و پس از مرحله انتخاب ویژگی، به عنوان ورودی به شبکه LSTM منتقل می‌شوند. شبکه LSTM با استفاده از ساختار حافظه‌دار خود قادر است وابستگی‌های زمانی و الگوهای پویای موجود در توالی ویژگی‌های استخراج‌شده را مدل‌سازی کند.

بدین ترتیب، شبکه CNN وظیفه استخراج ویژگی‌های سطح بالا از سیگنال صوتی را بر عهده دارد و LSTM روابط زمانی بین این ویژگی‌ها را تحلیل می‌کند. این ترکیب موجب می‌شود اطلاعات مکانی و زمانی سیگنال به صورت همزمان مورد استفاده قرار گرفته و دقت تشخیص در مدل پیشنهادی افزایش یابد. این مقاله برای تشخیص بیماری‌های عفونی ریه و کووید ۱۹ در ۵ بخش ارایه شده است. کارهای مرتبط در زمینه تشخیص بیماری عفونی ریه در بخش ۲، ارایه می‌شود. روش پیشنهادی برای تشخیص بیماری کووید ۱۹ در بخش ۳ ارایه می‌شود. بخش ٤، تجزیه و تحلیل روش پیشنهادی برای تشخیص نوع بیماری کووید ۱۹ و مقایسه نتایج با روشهای مشابه ارایه می‌شود. در بخش ٥، نتیجه‌گیری کارهای آینده ارایه شده است.

مواد و روش‌ها

در سیستم پیشنهادی برای تشخیص کووید ۱۹، ویژگی‌های صدا استخراج و انتخاب می‌شود و برای آموزش LSTM استفاده می‌شود. نقش LSTM دریافت ویژگی‌های صدای سرفه برای تشخیص بیماری کووید ۱۹ است. مراحل پیشنهادی که GCLSI نام دارد و مخفف روشهای GAN، CNN، LSTM و هوش گروهی است در شکل(۱)، نمایش داده شده است.



شکل۱. مراحل روش پیشنهادی برای تشخیص پاندمی‌های کووید ۱۹

با توجه به چارچوب مراحل ارایه شده می‌توان فازهای ذیل را در نظر گرفت:

- گام ۱: دریافت مجموعه داده سرفه: در این مرحله، مجموعه داده مربوط به صدای سرفه افراد به عنوان ورودی اولیه سیستم در نظر گرفته می‌شود.
- گام ۲: پیش‌پردازش و بهبود کیفیت داده‌ها: به منظور افزایش کیفیت سیگنال‌های صوتی، عملیات پیش‌پردازش شامل حذف نویز و پاکسازی داده‌ها بر روی مجموعه داده اعمال می‌شود.
- گام ۳: متعادلسازی مجموعه داده با استفاده از GAN: در این مرحله از شبکه‌های مولد تخاصمی (GAN) برای تولید نمونه‌های مصنوعی از کلاس بدخیم استفاده می‌شود تا

[Downloaded from yafteh.lums.ac.ir on 2026-11-06]

عدم توازن موجود در داده‌ها برطرف گردد و مجموعه داده متعادلسازی شود.

- گام ٤: استخراج ویژگی با شبکه عصبی کانولوشنی (CNN): برای استخراج ویژگی‌های مؤثر از سیگنال‌های صدای سرفه، از شبکه عصبی کانولوشنی استفاده می‌شود تا الگوهای مهم مرتبط با بیماری شناسایی شوند.
- گام ٥: بهینه‌سازی فراپارامترهای CNN با الگوریتم COA: به منظور بهبود عملکرد شبکه CNN، فراپارامترهای این شبکه با استفاده از الگوریتم بهینه‌سازی COA تنظیم و بهینه‌سازی می‌شوند.
- گام ٦: انتخاب ویژگی با الگوریتم AOA: پس از استخراج ویژگی‌ها، از الگوریتم بهینه‌سازی ریاضی (AOA) برای انتخاب مؤثرترین ویژگی‌ها و کاهش ابعاد داده استفاده می‌شود.
- گام ۷: تشخیص بیماری با شبکه LSTM: در نهایت، ویژگی‌های منتخب به عنوان ورودی به شبکه LSTM داده می‌شوند و با آموزش این شبکه، تشخیص ابتلا به بیماری کووید-۱۹ انجام می‌شود.

دلیل انتخاب الگوریتم‌های مورد استفاده در چارچوب پیشنهادی GCLSI در تشخیص بیماری کووید ۱۹ بر اساس سیگنال صوتی به شرح زیر است:

- شبکه‌های مولد رقابتی (GAN): با توجه به محدودیت و نابرابری داده‌ها در مجموعه‌داده‌های کووید-۱۹، از GAN برای تولید داده‌های مصنوعی باکیفیت و متعادل‌سازی کلاس‌ها استفاده شد تا مدل از سوگیری نسبت به کلاس اکثریت جلوگیری کند.
- شبکه‌های عصبی کانولوشن (CNN): این شبکه‌ها به دلیل توانایی بی‌نظیر در استخراج ویژگی‌های سطح بالا و الگوهای بصری از طیف‌نگارها (Spectrograms) و ویژگی‌های صوتی مانند MFCC انتخاب شدند.
- حافظه طولانی کوتاه‌مدت (LSTM): از آنجا که صدای سرفه یک سیگنال زمانی است، LSTM برای مدل‌سازی وابستگی‌های زمانی و توالی‌های صوتی انتخاب شد تا تغییرات دینامیک در طول زمان را به دقت ثبت کند.
- الگوریتم بهینه‌سازی کوآتی: انتخاب الگوریتم‌های بهینه‌سازی کوآتی به منظور یافتن خودکار بهترین ابرپارامترها (Hyperparameters) و جلوگیری از فرآیند زمان‌بر آزمون و خطا بود. این الگوریتم به دلیل تعادل مناسب میان Exploration و Exploitation در یافتن بهینه محلی و جهانی، کارایی مدل را به حداکثر رساندند.
- الگوریتم بهینه‌سازی محاسبات ریاضی: الگوریتم مورد نظر سبک، دقیق و کارآمد برای جستجوی فضای چند بعدی از جمله انتخاب ویژگی است و باعث کاهش ابعاد ورودی LSTM و افزایش سرعت آن در تصمیم‌گیری می‌شود.

پیش پردازش

برای هر فایل ضبط صدا در مجموعه داده سرفه، زمان سیگنال صوتی ناهموار است و برای تعیین مدت زمان متفاوت برای هر فایل، از عبارت $L=(N(Y)./f(\mathrm{s})$ استفاده می‌شود، که در آن $N(\mathrm{Y})$ طول نمونه و $f(\mathrm{s})$ فرکانس نمونه‌برداری برای هر نمونه صوتی است که ٤٨ کیلوهرتز است. بر اساس عبارت ریاضی برای محاسبه L ثانیه، حداقل و حداکثر طول فایل‌های صوتی به ترتیب ٤ و ۲۹ ثانیه است. برای اطمینان از اینکه تمام ویژگی‌های مربوطه در طول تجزیه و تحلیل ثبت می‌شوند، یک روش ساده نرمال‌سازی را با مقیاس‌بندی گفتار بر اساس مقدار اوج آن با حداکثر مقدار دامنه ۱ اعمال می‌شود(٤۳).

متعادلسازی مجموعه داده

در بیشتر موارد تعداد نمونه‌های بدخیم کووید ۱۹ از نمونه‌های خوش خیم کمتر است و از این جهت مجموعه داده نامتعادل است و اگر یک روش روی این مجموعه داده آموزش داده شود آنگه دقت آن کاهش خواهد یافت. شبکه مولد تخاصمی GAN نوعی مدل‌سازی مولد است که از تکنیک‌های یادگیری عمیق در شبکه‌های عصبی کانولوشن استفاده می‌کند و برای متعادلسازی مجموعه داده‌ها ایده‌آل است (٤٤).

حذف نویز در سیگنالهای صوتی سرفه

در روش پیشنهادی فایل‌های صدای تنفسی با یک فیلتر برای حذف نویز، به ویژه اطلاعات فرکانس پایین، با استفاده از یک فیلتر میان‌گذر بر روی صدای تنفسی اعمال می‌شود. در مرحله بعدی صداها به فرمت زمان–فرکانس تبدیل می‌شوند و برای این منظور از طیف‌نگار Mel استفاده می‌شود. طیف‌نگارها نقش حیاتی در تحلیل صدا دارند، زیرا بینش‌های مهمی در مورد فرکانس توزیع انرژی در طول زمان ارائه می‌دهند. طیف‌نگار توزیع انرژی را در باندهای فرکانسی مختلف را مشخص می‌کند. از نظر ریاضی، فرکانس مقیاس مل (f_{Mel}) یک فرکانس معین (f_{Hz}) با استفاده از معادله (۱) محاسبه می‌شود. این تبدیل به طیف مل اجازه می‌دهد تا ویژگی‌های صوتی را به طور مؤثرتری ثبت کند و بر اطلاعات ادراکی مرتبط در سیگنال صوتی تأکید کند (۳۳).

$$f_{\mathrm{Mel}} = 2595\log_{10}\left(1+\frac{f_{\mathrm{Hz}}}{700}\right)$$

ایجاد طیف Mel شامل اعمال بانک فیلتر Mel بر روی حوزه فرکانس سیگنال است، همانطور که در معادله(۲) ارایه شده

[Downloaded from yafteh.lums.ac.ir on 2026-11-06]

است. فیلتر Mel از توابع پنجره مثلثی (H_k) تشکیل شده است. این فیلترها سیگنال را به باندهای فرکانسی مختلف تقسیم می‌کنند و گزینش‌پذیری فرکانسی گوش انسان را شبیه‌سازی می‌کنند.

$$H_k(m)=\begin{cases}0 & \text{for } m<f(k-1)\\ \dfrac{m-f(k-1)}{f(k)-f(k-1)} & \text{for } f(k-1)\le m\le f(k)\\ \dfrac{f(k+1)-m}{f(k+1)-f(k)} & \text{for } f(k)<m\le f(k+1)\\ 0 & \text{for } m>f(k+1)\end{cases}$$

که در آن $H_k(m)$ تابع پنجره مثلثی، m تعداد فیلترها و k از ۰ تا m-1 متغیر است.

استخراج ویژگی از سیگنال‌های صوتی سرفه

با تبدیل سیگنالهای صوتی به تصاویر طیف‌نگار می‌توان از یک شبکه عصبی CNN برای استخراج ویژگی‌ها استفاده نمود. این بخش یک روش بهینه‌سازی را شرح می‌دهد که از الگوریتم بهینه‌سازی کوآتی برای یافتن مناسب‌ترین پارامترها برای معماری شبکه عصبی کانولوشن استفاده می‌کند. هدف اصلی، تعیین بهینه‌ترین پارامترها برای CNN است تا کارایی آن در استخراج مدل افزایش یابد. از جمله پارامترهای تاثیر گذار در بهبود عملکرد CNN می‌توان به Kernel Size، Stride و Filter number اشاره نمود. هر راه‌حل در الگوریتم COA مجموعه‌ای از سه گانه Kernel Size، Stride و Filter number است. برای ارزیابی راه‌حلهای خطای خروجی CNN به عنوان تابع هدف در نظر گرفته می‌شود که کمینه آن مطلوب است. الگوریتم COA بر اساس رفتار شکار و فرار کوآتی‌ها مدلسازی شده است. غذای اصلی کوآتی‌ها، ایگوانا می‌باشد. در الگوریتم COA هر راه‌حل یک کواتی است و بهینه‌ترین راه‌حل نیز یک ایگوانا است. در فاز اول، تعدادی راه‌حل اولیه به عنوان جمعیت اولیه COA تصادفی تولید می‌شود و مطابق معادله(۳)، در ماتریس جمعیت P قرار داده می‌شود.

$$X=\begin{bmatrix}X_1\\ \vdots\\ X_i\\ \vdots\\ X_N\end{bmatrix}_{N\times Dim}=\begin{bmatrix}x_{1,1} & \cdots & x_{1,j} & \cdots & x_{1,Dim}\\ \vdots & \ddots & \vdots & \ddots & \vdots\\ x_{i,1} & \cdots & x_{i,j} & \cdots & x_{i,Dim}\\ \vdots & \ddots & \vdots & \ddots & \vdots\\ x_{N,1} & \cdots & x_{N,j} & \cdots & x_{N,Dim}\end{bmatrix}_{N\times Dim}$$

کوآتی‌های بالای درخت، ایگوانا را تعقیب کرده و ایگونا برای نجات، خود را به زمین پرتاب می‌کند تا فرار کنند. جمعیتی از کوآتی‌ها که روی زمین قرار دارند، با مشاهده ایگوانا روی زمین، سعی می‌کنند آن را دنبال کنند. در الگوریتم COA، موقعیت کواتی‌های که از درخت بالا می‌روند به صورت معادله(٤)، به روزرسانی می‌شوند.

$$X_i^{P1}:\ x_{i,j}^{P1}=x_{i,j}+r\cdot\left(\text{Iguana}_j-I.x_{i,j}\right),\ i=1,2,\dots,\left\lfloor\frac{N}{2}\right\rfloor \text{ and } j=1,2,\dots,m$$

ایگوانا با مشاهده کوآتی‌های که روی درخت آمده‌اند خود را تصادفی مطابق معادله(٥)، روی زمین می‌اندازد و در ادامه کوآتی‌های که روی زمین قرار دارند مطابق معادله(٦)، ایگوانا را تعقیب می‌کنند.

$$\text{Iguana}^G:\ \text{Iguana}_j^G=lb_j+r\cdot\left(ub_j-lb_j\right),\ j=1,\ 2,\dots,\text{m}$$

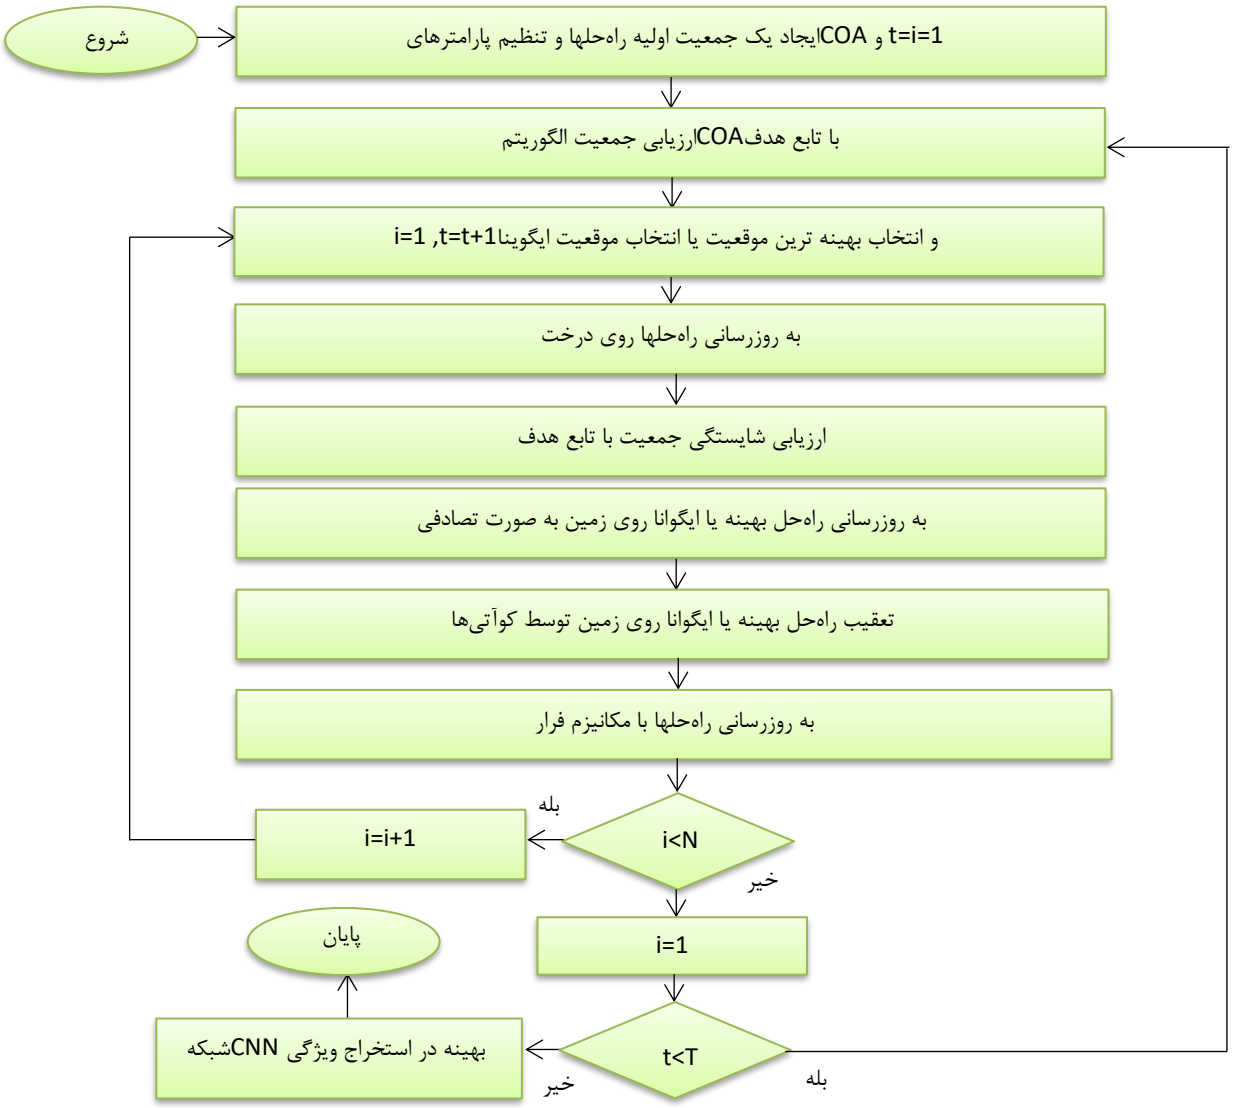
$$X_i^{P1}:x_{i,j}^{P_1}=\begin{cases}x_{i,j}+r\cdot\left(\text{Iguana}_j^G-I\cdot x_{i,j}\right), & F_{\text{Iguana}^G}<F_i\\ x_{i,j}+r\cdot\left(x_{i,j}-\text{Iguana}_j^G\right), & \text{else}\end{cases}$$
$$\text{for } i=\left\lfloor\frac{N}{2}\right\rfloor+1,\left\lfloor\frac{N}{2}\right\rfloor+2,\ \dots,N \text{ and } j=1,\ 2,\ \dots,\ m$$

Iguana_j^G موقعیت ایگوانا در بعد j است و مقدار تابع هدف F_{Iguana^G} ارزیابی موقعیت بهینه را فرموله می‌دهد. I یک عدد تصادفی است برابر ۱ یا ۲ که شدت تعقیب را نشان می‌دهد. کوآتی‌ها با اینکه شکارچی می‌باشند، خود نیز می‌تواندشکار شوند لذا الگوریتم COA فاز فرار را نیز فرموله کرده است. فاز فرار به عنوان جستجوی بهره برداری است. اجراء می‌شود. هنگامی که یک شکارچی به یک کوآتی حمله می‌کند، حیوان از موقعیت خود فرار می‌کند. برای اجرای فاز فرار از معادلات (۷) و (۸) استفاده می‌شود(٣٤):

$$L_j^{\text{local}}=\frac{lL_j}{t},U_j^{\text{local}}=\frac{U_j}{t},\text{where iter}=1,2,\ \dots,T\text{max}.$$
$$\wedge i=1,\dots,N,\ j=1,\dots,\ m.X_i^{P2}:\ x_{i,j}^{P2}=x_{i,j}+(1-2r)\cdot\left(L_j^{\text{local}}+r\cdot\left(U_j^{\text{local}}-U_j^{\text{local}}\right)\right)$$

X_i^{P2} موقعیت به روزرسانی شده کوآتی بر اساس مکانیزم فرار است. L_j^{local} و U_j^{local} محدوده بالا و پایین بعد j است. iter شمارنده فعلی الگوریتم COA و Tmax حداکثر تعداد تکرار بیشینه الگوریتم COA است. فلوچارت روش پیشنهادی برای بهینه‌سازی فراپارامترهای مدل CNN با COA در شکل(۲)، نمایش داده شده است.

[Downloaded from yafteh.lums.ac.ir on 2026-11-06]



شکل۲: فلوچارت روش پیشنهادی در استخراج ویژگی صدای سرفه

طبق فلوچارت یک جمعیت اولیه از فراپارامترهای CNN به عنوان جمعیت اولیه الگوریتم COA تصادفی ایجاد می‌شود در مرحله بعد جمعیت ارزیابی می‌شود و بهینه‌ترین فراپارامترها در هر تکرار الگوریتم COA محاسبه می‌شود. با اجرای الگوریتم COA و مکانیزم جستجوی روی درخت، روی زمین و فرار از شکار، فراپارامترها به روزرسانی می‌شوند. در تکرار آخر بهینه‌ترین فراپارامترها به عنوان پارامترهای CNN تنظیم می‌شود.

انتخاب ویژگی در صدای سرفه

هر بردار ویژگی یک راه‌حل الگوریتم AOA است. در الگوریتم AOA از عملگرهای +، −، * و برای به روزرسانی راه‌حلها استفاده می‌شود. تابع هزینه برای ارزیابی بردارهای ویژگی مطابق معادله(۹)، فرموله می‌شود.

$$Cost(X_i) = \mathrm{a}.Error + b.\frac{\|X_i\|}{\|dim\|}$$

X_i به عنوان یک بردار ویژگی و یک عضو الگوریتم AOA است. $Error$ خطای تشخیص بیماری به ازای بردار ویژگی X_i است. a و b دو عدد تصادفی بین صفر و یک است و مجموع آنها برابر یک تنظیم می‌شود. در الگوریتم AOA عملگرهای جمع، تفریق به عنوان جستجوی بهره‌برداری یا جستجوی محلی در نظر گرفته می‌شود. برای جستجوی محلی از معادله(۱۰)، استفاده می‌شود و مقدار M طبق معادله(۱۱)، محاسبه می‌شود:

$$x_i(iter+1) = \begin{cases} X^* - M \times ((U-L)\times\mu + L) & rand(0,1) > 0.5 \\ X^* + M \times ((U-L)\times\mu + L) & rand(0,1) \le 0.5 \end{cases}$$

$$M(iter) = 1 - iter^{\frac{1}{\alpha}}/Tmax^{\frac{1}{\alpha}}$$

[Downloaded from yafteh.lums.ac.ir on 2026-11-06]

در این معادله، Tmax حداکثر تکرار الگوریتم AOA است. X^* بهینه‌ترین راه‌حل است و μ ثابت عددی است. برای جستجوی سراسری در الگوریتم AOA از معادله(۱۲)، استفاده می‌شود.

$$x_i(iter+1) = \begin{cases} X^* \div (M+\varepsilon) \times ((U-L)\times\mu + L) & rand > 0.5 \\ X^* \times M \times ((U-L)\times\mu + L) & rand \le 0.5 \end{cases}$$

U و L محدود بالا و پایین بعد j–ام یک راه‌حل در الگوریتم AOA است. برای تعیین نوع جستجوی سراسری یا محلی از پارامتر MA استفاده می‌شود. اگر عدد تصادفی بین صفر و یک از MA بیشتر باشد آنگاه جستجو بر اساس عملگر + و − می‌شود و در غیر اینصورت جستجو بر اساس عملگرهای * و % انجام می‌گردد.

طبقه بندی بیماران با LSTM

در مدل پیشنهادی، سیگنال صدای سرفه ابتدا به نمایش زمان–فرکانس (اسپکتروگرام) تبدیل شده و به شبکه CNN داده می‌شود تا ویژگی‌های مکانی–فرکانسی استخراج شوند. سپس این ویژگی‌ها پس از انتخاب ویژگی با استفاده از الگوریتم AOA، به صورت توالی بردارهای ویژگی سازمان‌دهی شده و به عنوان ورودی شبکه LSTM استفاده می‌شوند تا وابستگی‌های زمانی موجود در سیگنال صوتی تحلیل و در نهایت تشخیص بیماری انجام شود.

در چارچوب پیشنهادی، سیگنال صدای سرفه ابتدا به نمایش زمان–فرکانس تبدیل شده و به عنوان ورودی به شبکه CNNداده می‌شود تا ویژگی‌های مکانی–فرکانسی مؤثر استخراج شوند. سپس ویژگی‌های استخراج‌شده در مرحله بعد با استفاده از الگوریتم بهینه‌سازی AOA مورد ارزیابی و انتخاب قرار می‌گیرند تا مجموعه‌ای از ویژگی‌های بهینه حاصل شود. این ویژگی‌های منتخب به صورت توالی از بردارهای ویژگی سازمان‌دهی شده و به عنوان ورودی به شبکه LSTM داده می‌شوند. شبکه LSTM با بهره‌گیری از ساختار حافظه‌دار خود قادر است وابستگی‌های زمانی میان ویژگی‌های صوتی را مدل‌سازی کرده و الگوهای پویای موجود در سیگنال سرفه را تحلیل کند. در نهایت، بر اساس این تحلیل، فرآیند طبقه‌بندی نمونه‌ها و تشخیص وضعیت بیماران انجام می‌شود.

LSTM در یادگیری وابستگی‌ها با ویژگی‌های بلندمدت، مؤثرتر از شبکه‌های عصبی بازگشتی است. هر سلول LSTM شامل چهار واحد است به گونه‌ای یک سلول شامل دروازه ورودی، دروازه فراموشی، دروازه خروجی و وضعیت سلول است. دروازه فراموشی تعیین می‌کند که کدام اطلاعات موجود در حافظه سلول قبلی اجازه انتقال به سلول جدید را دارند. وظیفه دروازه ورودی به‌روزرسانی وضعیت سلول و تعیین نسبت اطلاعات داده جدید تحویل داده شده به حافظه است. دروازه خروجی روش‌های به‌روزرسانی حافظه و میزان اطلاعات تغذیه شده به لایه بعدی را تعیین می‌کند. معادلات(۱۳)، (۱٤)، (۱۵)، (۱٦) و (۱۷) برای مدلسازی شبکه LSTM برای پیش بینی نوع بیماری بکار گرفته می‌شوند.

$$GI_t = \mathrm{Sig}(W_i IS_t + U_i h_{t-1} + \beta_i)$$
$$\hat{G}C_t = \tanh(W_c IS_t + U_c h_{t-1} + \beta_c)$$
$$FG_t = \mathrm{Sig}(W_f x_t + U_f h_{t-1} + \beta_f)$$
$$GC_t = GI_t \times \hat{G}C_t + FG_t \times GC_{t-1}$$
$$OG_t = \mathrm{Sig}(W_o IS_t + U_o h_{t-1} + \beta_o)$$

در این معادلات، GI_t گیت ورودی در زمان t است. Sig تابع سیگموید است. U_i، U_c، U_f و U_o وزن‌های ورودی است. W_i، W_c، W_f و W_o وزن‌های بازگشتی است. β_i، β_c، β_f، β_o بایاس شبکه است.

بحث و نتیجه گیری

در این بخش روش پیشنهادی برای تشخیص بیماری‌های ریه در پایتون پیاده‌سازی می‌شود. برای پیاده‌سازی‌ها مقدار a و b در تابع هزینه انتخاب ویژگی دو عدد تصادفی در بازه [0,1] است و مجموع آنها برابر یک است. در الگوریتم COA مقدار I یک عدد تصادفی است که می‌تواند ۱ یا ۲ باشد. برای ارزیابی روش پیشنهادی در تشخیص پاندمی کووید ۱۹، شاخص‌های طبقه‌بندی نظیر دقت، حساسیت و صحت استفاده می‌شود که در معادله(۱۸)، (۱۹)، (۲۰) فرموله شده‌اند. مقدار هر یک از این شاخص‌ها بین صفر و ۱۰۰٪ است:

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \times 100\%$$
$$Sensitivity = \frac{TP}{TP+FN} \times 100\%$$
$$Precision = \frac{TP}{TP+FP} \times 100\%$$

نمونه‌های صحیح مثبت(TP)، نمونه‌های غلط مثبت(FP)، نمونه‌های صحیح منفی(TN)، نمونه‌های غلط منفی(FN) در ارزیابی‌های این شاخص‌ها بکار رفته است. برای ارزیابی و تشخیص بیماران کووید ۱۹، از چندین مجموعه داده سرفه استفاده می‌شود. مجموعه صدای سرفه CHRSD(۳۵)، شامل صداهای تنفسی بیماران است. مجموعه داده Cambridge (۳۹) با استفاده از یک برنامه اندروید/وب جمع‌آوری شد و شامل سرفه، صدا و صداهای تنفسی شرکت‌کنندگان و همچنین اطلاعات مربوط به سابقه پزشکی و علائم آنها است. مجموعه داده دیگر مورد استفاده در این مطالعه، مجموعه داده عمومی COUGHVID شامل صدای سرفه ضبط شده توسط افراد از

[Downloaded from yafteh.lums.ac.ir on 2026-11-06]

گروه‌های سنی، جنسیت‌ها و موقعیت‌های جغرافیایی مختلف است. جمع‌آوری داده‌ها از طریق یک پلتفرم آنلاین انجام شد که در آن شرکت‌کنندگان سرفه‌های خود را ثبت کرده و اطلاعاتی در مورد سن، جنسیت و وضعیت سلامتی خود ارائه دادند (۴۰). در جدول(۲)، وضعیت سه مجموعه داده بکار رفته قبل از متعادلسازی نمایش داده شده است.

جدول ۲: وضعیت سه مجموعه داده بکار رفته

نام مجموعه‌داده	تعداد کل نمونه‌ها	نمونه‌های کووید مثبت	نمونه‌های غیرکووید	وضعیت تعادل
COUGHVID	حدود ۲۷،۰۰۰ نمونه صوتی	حدود ۱،۲۰۰–۱،۵۰۰	بقیه (~۲۵،۰۰۰)	به‌شدت نامتوازن
Cambridge	حدود ۱،۰۰۰–۱،۲۰۰ نمونه	حدود ۳۰۰–۳۵۰	حدود ۷۰۰–۸۰۰	نسبتاً متوازن‌تر از COUGHVID
CHRSD	حدود ۴۰۰–۵۰۰ نمونه	حدود ۱۵۰–۱۸۰	حدود ۲۵۰–۳۰۰	نمونه‌ها کم و نویز زیاد

در این مطالعه از مجموعه‌داده‌های عمومیCambridge ، COUGHVIDو CHRSD استفاده شده است و هر یک از این مجموعه‌داده‌ها به‌صورت مستقل مورد استفاده قرار گرفتند. برای ارزیابی عملکرد مدل از روش اعتبارسنجی متقابل 10-fold cross-validation استفاده شده است. در این فرآیند، در هر تکرار حدود ۸۰٪ از داده‌ها برای آموزش، ۱۰٪ برای اعتبارسنجی (به‌منظور تنظیم پارامترهای مدل) و ۱۰٪ برای آزمون در نظر گرفته شد. این روند در تمامیfold ها تکرار گردید و در نهایت میانگین نتایج حاصل از تمام تکرارها به‌عنوان عملکرد نهایی مدل گزارش شده است.

ابتدا سیگنال‌های صوتی خام برای حذف نویزهای محیطی و سکوت‌های ابتدا و انتهای فایل، فیلتر شدند. سپس تمامی سیگنال‌ها به نرخ نمونه‌برداری یکسان تبدیل و نرمال‌سازی شدند. با توجه به اینکه تعداد نمونه‌های افراد سالم بسیار بیشتر از افراد مبتلا بود (عدم توازن کلاس‌ها)، از شبکه‌های مولد رقابتی (GAN) استفاده شد. GAN با تولید نمونه‌های مصنوعی باکیفیت از کلاس اقلیت (مثبت)، حجم داده‌ها را متعادل کرد تا از سوگیری مدل جلوگیری شود.

سیگنال‌های صوتی به حوزه زمان–فرکانس منتقل شده و به تصاویر طیف‌نگار مِل (Mel-spectrogram) و ویژگی‌های MFCCتبدیل شدند. سپس از یک شبکه عصبی کانولوشن (CNN)به عنوان استخراج‌کننده ویژگی استفاده شده است لایه‌های کانولوشن قادرند الگوهای بصری پیچیده و ویژگی‌های سطح بالای موجود در طیف‌نگارها را که نشان‌دهنده تغییرات آکوستیک ناشی از بیماری در ریه است، شناسایی و استخراج کنند.

پس از استخراج ویژگی‌های متعدد توسطCNN، برای کاهش پیچیدگی محاسباتی و حذف ویژگی‌های زائد، از الگوریتم بهینه‌سازی حسابی (AOA) استفاده شده است. AOA مجموعه‌ای بهینه از موثرترین ویژگی‌ها را انتخاب می‌کند. همچنین برای تنظیم خودکار ابرپارامترهای شبکه (مانند نرخ یادگیری و تعداد نورون‌ها(، الگوریتم بهینه‌سازی کوآتی (COA)به کار گرفته شد تا عملکرد مدل به بیشینه خود برسد. در این پژوهش، ترکیبی از ویژگی‌های آکوستیک و عمیق برای تشخیص کووید-۱۹ از صدای سرفه مورد استفاده قرار گرفت. در بخش آکوستیک، ویژگی‌هایی مانند ضرایب کپسترال فرکانس مِل (MFCC) و طیف‌نگار مِل (Mel-Spectrogram) به‌عنوان نمایش زمان-فرکانس سیگنال استخراج شدند که نمایانگر توزیع انرژی در باندهای مختلف فرکانسی‌اند. علاوه بر این، ویژگی‌های سطح پایین مانند نرخ عبور از صفر(ZCR) ، مرکز ثقل طیفی(Spectral Centroid) ، ریزش طیفی (Spectral Rolloff)، انرژی میانگین مربعی (RMS) و ویژگی‌های کروم (Chroma)برای تحلیل دقیق‌تر ساختار صوتی سرفه محاسبه شدند. خروجی لایه‌های میانی شبکه CNN نیز به‌عنوان ویژگی‌های عمیق به مدل اضافه شد تا الگوهای پیچیده‌تر و نهفته در طیف‌نگارها شناسایی گردد. در نهایت، برای حذف ویژگی‌های زائد و انتخاب مجموعه‌ای بهینه و مؤثر، از الگوریتم بهینه‌سازی حسابی (AOA) استفاده شد تا تنها بهترین ویژگی‌ها به شبکه LSTMجهت طبقه‌بندی نهایی منتقل شوند.

در آزمایشات انجام شده روش پیشنهادی از CNN برای استخراج ویژگی استفاده می‌کند و همزمان نیز فراپارامترهای مدل با COA بهینه‌سازی می‌شوند. برای تشخیص بیماران کووید ۱۹ بر اساس صدا از روش انتخاب ویژگی AOA و طبقه-بندی کننده LSTM استفاده می‌شود. در جدول(۳)، مقادیر دقت، حساسیت و صحت در روش پیشنهادی نمایش داده شده است. آزمایشات نشان می‌دهد روش پیشنهادی در مجموعه داده CHRSD، موفق شده است که به دقت، حساسیت و صحت ۹۵٪/۷۲، ۹۳٪/۴۱ و ۹۱/۷۵٪ برای تشخیص کووید ۱۹ بر اساس صدای سرفه برسد. در مجموعه داده Cambridge دقت، حساسیت و صحت روش پیشنهادی ۹۸/۲۶٪، ۹۷/۷۳٪ و ۹۷٪/۹۲ است.

[Downloaded from yafteh.lums.ac.ir on 2026-11-06]

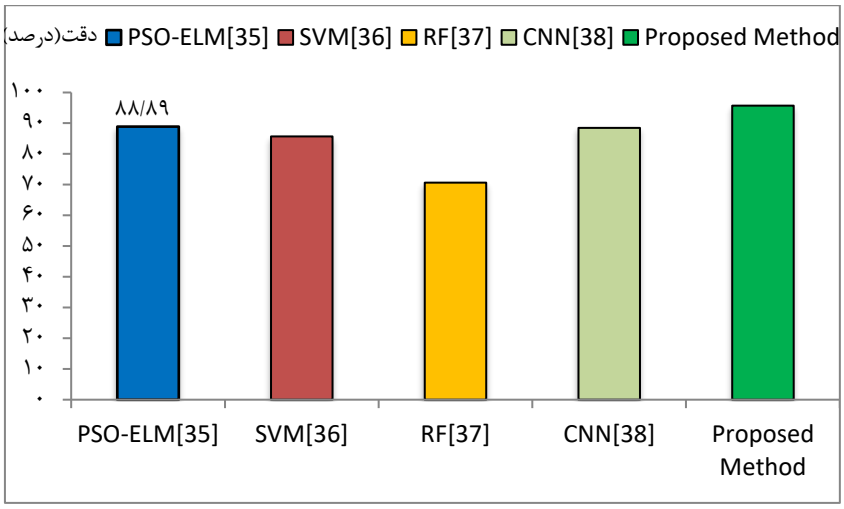
جدول ۳: مقایسه شاخص دقت، حساسیت و صحت روش پیشنهادی در سه مجموعه داده

مجموعه داده	دقت	حساسیت	صحت
CHRSD	٪ ۹۵/۷۲	٪ ۹۳/۴۱	٪ ۹۱/۷۵
Cambridge	٪ ۹۸/۲۶	٪ ۹۷/۷۳	٪ ۹۷/۹۲
COUGHVID	٪ ۹۸/۸۳	٪ ۹۷/۲۹	٪ ۹۷/۶۸

در مجموعه داده COUGHVID دقت، حساسیت و صحت روش پیشنهادی به ترتیب برابر ٪۹۸/۸۳، ٪۹۷/۲۹ و ٪۹۷/۶۸است. تحلیل نتایج جدول نشان می‌دهد که چارچوب پیشنهادی در تشخیص کووید-۱۹ از صدای سرفه عملکرد بسیار مطلوبی در مجموعه‌داده‌های مختلف داشته است. همان‌طور که مشاهده می‌شود، بیشترین مقدار دقت مربوط به مجموعه‌داده COUGHVID با مقدار ۸۳/۹۸ درصد است که نشان‌دهنده توانایی بالای مدل در شناسایی صحیح نمونه‌ها در یک پایگاه داده بزرگ و متنوع می‌باشد. در مجموعه‌داده Cambridge نیز دقت ۲۶/۹۸ درصد و حساسیت ۷۳/۹۷ درصد به دست آمده است که بیانگر توانایی مناسب مدل در شناسایی صحیح افراد مبتلا به کووید-۱۹ است. همچنین مقدار صحت ۹۲/۹۷ درصد در این مجموعه داده نشان می‌دهد که مدل در تشخیص افراد سالم نیز عملکرد قابل قبولی دارد. در مجموعه‌داده CHRSD نیز با وجود شرایط پیچیده‌تر و احتمال وجود نویز محیطی، مدل توانسته است دقت ۷۲/۹۵ درصد را به دست آورد که همچنان نشان‌دهنده عملکرد مناسب روش پیشنهادی است.

برجسته بودن روش پیشنهادی عمدتاً به دلیل استفاده از یک چارچوب ترکیبی هوشمند (GCLSI) است که مزایای چندین روش پیشرفته را به طور همزمان به کار می‌گیرد. در این چارچوب، استفاده از GAN برای متعادل‌سازی داده‌ها باعث کاهش مشکل عدم توازن کلاس‌ها و بهبود یادگیری مدل شده است. همچنین CNN قادر است ویژگی‌های پیچیده و عمیق را از طیف‌نگارهای صوتی استخراج کند، در حالی که LSTM وابستگی‌های زمانی موجود در سیگنال سرفه را به خوبی مدل‌سازی می‌کند. علاوه بر این، استفاده از الگوریتم‌های بهینه‌سازی COA و AOA برای تنظیم پارامترها و انتخاب ویژگی‌های مؤثر باعث کاهش ابعاد داده، حذف ویژگی‌های غیرضروری و افزایش دقت نهایی سیستم شده است. بنابراین ترکیب این روش‌ها در قالب یک چارچوب یکپارچه سبب شده است که مدل پیشنهادی از نظر دقت تشخیص، پایداری عملکرد و توانایی تعمیم به مجموعه‌داده‌های مختلف عملکرد بهتری نسبت به بسیاری از روش‌های منفرد داشته باشد. روش پیشنهادی در شاخص دقت با روشهای PSO-ELM (۳۵)، SVM (۳۶)، RF (۳۷) و CNN (۳۸) در شکل(۳)، مقایسه شده است.

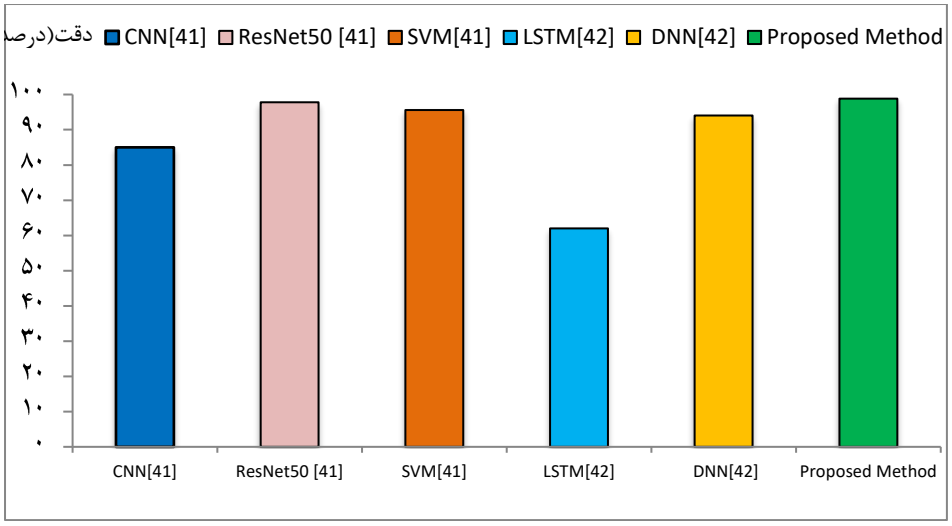
دقت روشهای PSO-ELM، SVM، RF و CNN در تشخیص بیماری کووید ۱۹ بر اساس صدای سرفه برابر ٪۸۸/۸۹، ٪۸۵/۷۰، ٪۷۰/۶۹، ٪۸۸/۴۸، است. روش پیشنهادی به دلیل بکارگیری روش GAN توانایی افزایش داده‌های مصنوعی سرفه را دارد و از طرفی با استفاده از الگوریتم COA موفق شده فراپارامترهای مدل CNN را بهینه‌سازی نماید. روش پیشنهادی به دلیل بکارگیری روش انتخاب ویژگی AOA موفق شده است تا دقت از ٪۸۸/۴۸، به ٪۹۵/۷۲ افزایش دهد. به عبارت بهتر متعادلسازی و انتخاب بهینه پارامترهای CNN و بکارگیری روش هوشمند AOA در روش پیشنهادی باعث افزایش دقت تشخیص کووید ۱۹ در حدود ٪۷/۲۴ می‌شود.



شکل ۳: مقایسه در صد دقت روش پیشنهادی با روشهای تشخیص کووید ۱۹در مجموعه داده CHRSD

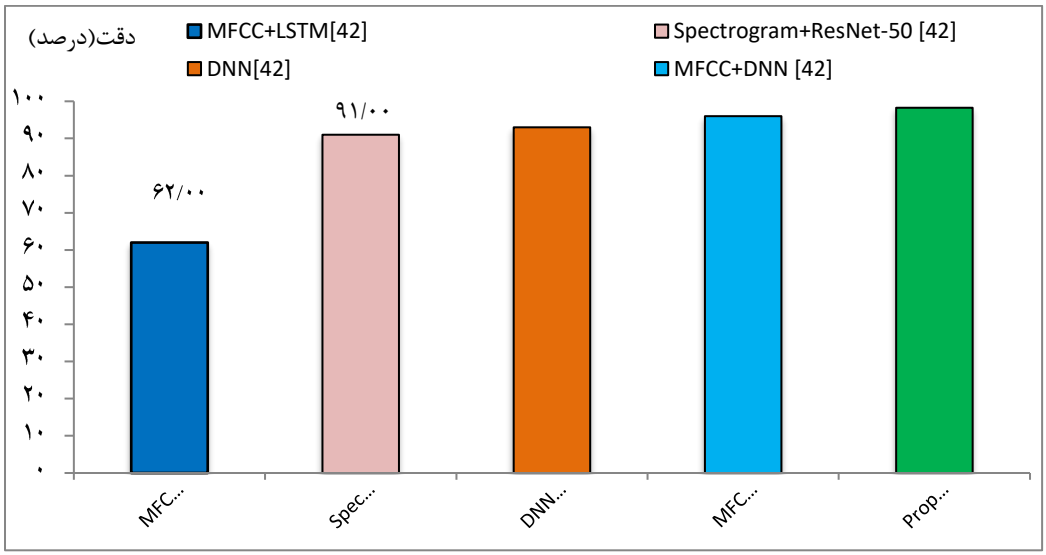
[Downloaded from yafteh.lums.ac.ir on 2026-11-06]

در شکل(٤)، روش پیشنهادی در مجموعه داده COUGHVID دارای دقتی برابر ۹۸/۸۳٪ است و روشهای CNN، ResNet50 ، SVM، LSTM و DNN در این مجموعه داده دارای دقتی برابر ۸۵٪، ۹۷/۸٪، ۹۵/٦٪، ٦۲٪ و ۹٤٪ است. رویکرد پیشنهادی نسبت به روش CNN و LSTM موفق شده است که دقت را ۱۳/۸۳٪ و ۳/۸۳٪ افزایش دهد که دلیل اصلی آن متعادلسازی مجموعه داده با روش GAN، بهینه‌سازی فراپارامترهای CNN با هوش گروهی COA و بکارگیری روش بهینه‌سازی AOA برای بهینه‌سازی ورودی‌های LSTM است. در شکل(٥)، روش پیشنهادی از نظر شاخص دقت در مجموعه داده Cambridge مورد مقایسه قرار گرفته شده است.



شکل ٤: مقایسه دقت روش پیشنهادی با روشهای تشخیص کووید ۱۹در مجموعه داده COUGHVID

در مجموعه داده Cambridge روش پیشنهادی موفق شده است به دقت برابر ۹۸/۲٦٪ برسد و از طرفی دقت آن از روشهای MFCC+LSTM، Spectrogram+ResNet-50، DNN و MFCC+DNN بیشتر بوده است. آزمایشات نشان می‌دهد روش DNN نسبت به سایر روشهای مورد مقایسه عملکرد بهتری دارد و از روش LSTM در تشخیص بیماری کووید ۱۹ موفق‌تر بوده است.



شکل ٥: مقایسه دقت روش پیشنهادی با روشهای تشخیص کووید ۱۹در مجموعه داده Cambridge

نتایج به‌دست‌آمده نشان می‌دهد که عملکرد چارچوب پیشنهادی GCLSI در مجموعه‌داده CHRSD کمی پایین‌تر از نتایج حاصل از مجموعه‌داده‌های Cambridge و COUGHVID است. این تفاوت عملکرد را می‌توان به ویژگی‌های ساختاری و کیفی مجموعه‌داده CHRSD نسبت داد. نخست آنکه تعداد نمونه‌های موجود در این مجموعه‌داده نسبت به دو مجموعه‌داده

[Downloaded from yafteh.lums.ac.ir on 2026-11-06]

دیگر کمتر است و در نتیجه تنوع الگوهای سرفه در مرحله آموزش مدل محدودتر می‌شود. کاهش تنوع داده‌ها می‌تواند توانایی مدل‌های یادگیری عمیق را در یادگیری الگوهای مختلف سرفه مرتبط با بیماری کووید- 19کاهش دهد. علاوه بر این، شرایط ثبت و ضبط سیگنال‌های صوتی در مجموعه‌داده CHRSDممکن است شامل نویز محیطی بیشتر یا تغییرات در شرایط ضبط باشد که می‌تواند بر کیفیت ویژگی‌های استخراج‌شده از سیگنال‌های صوتی تأثیر بگذارد.

وجود نویز و تغییرات محیطی می‌تواند فرآیند استخراج ویژگی توسط شبکه CNN را با چالش مواجه کند و در نتیجه بر عملکرد نهایی مدل طبقه‌بندی اثر بگذارد. در مقابل، مجموعه‌داده‌های Cambridge و COUGHVID دارای نمونه‌های بیشتر و تنوع بالاتری از صداهای سرفه هستند که به مدل اجازه می‌دهد الگوهای نماینده‌تری را یاد بگیرد و عملکرد بهتری در مرحله تشخیص بیماری ارائه دهد.

جداسازی افرادی که به کووید مبتلا هستند می‌تواند انتقال و شیوع بیماری را به حداقل برساند، بنابراین آزمایش‌های مختلفی برای تشخیص ویروس مانند RT-PCR ، عکس‌برداری از قفسه سینه و توموگرافی کامپیوتری پیشنهاد شده است. با این حال، این روش‌ها از نرخ تشخیص پایین یا دوز بالای تابش و همچنین گران بودن رنج می‌برند. در این مقاله، مدل مبتنی بر یادگیری عمیق مبتنی بر شبکه GAN، CNN و LSTM برای تشخیص بیماران مبتلا به کووید ۱۹ بر اساس صدای سرفه آنها ارایه شده است. در رویکرد پیشنهادی از GAN برای متعادلسازی مجموعه داده استفاده شده است و از شبکه عصبی کانولوشن بهبود یافته با الگوریتم بهینه‌سازی کوآتی برای استخراج ویژگی استفاده می‌شود. ورودی‌های طبقه‌بندی کننده LSTM با الگوریتم انتخاب ویژگی بهینه‌سازی محاسبات ریاضی، بهینه می‌شود تا خطای مدل تشخیص کووید ۱۹ کاهش داده شود. به طور خلاصه، این پژوهش چارچوب ترکیبی را برای تشخیص کووید-۱۹ از طریق تحلیل صدای سرفه معرفی کرد که نوآوری آن در ادغام هوشمندانه مولدهای تخاصمی تعمیم‌یافته برای متعادل‌سازی داده‌ها، شبکه‌های عصبی کانولوشن با بهینه‌سازی الگوریتم کوآتی برای استخراج ویژگی‌های صوتی غنی، و شبکه‌های حافظه طولانی کوتاه با استفاده از الگوریتم محاسبات ریاضی برای انتخاب بهینه ورودی‌ها نهفته است.

آزمایشات نشان می‌دهد در مجموعه داده CHRSD روش پیشنهادی در تشخیص بیماری کووید ۱۹ بر اساس صدای سرفه موفق شده است که دقت بیشتری از PSO-ELM، SVM ، RF و CNN ارایه دهد. روش پیشنهادی در مجموعه داده COUGHVID از روشهای یادگیری عمیق CNN، ResNet50 ، LSTM و DNN دقت بیشتری در تشخیص بیماران مبتلا به کووید ۱۹ ارایه داده است. مزیت روش پیشنهادی دقت بیشتر در تشخیص بیماری کووید ۱۹ نسبتا به روشهای مشابه یادگیری عمیق است. یک مزیت دیگر روش پیشنهادی متعادلسازی مجموعه داده و بکارگیری هوش گروهی برای افزایش دقت تشخیص کووید ۱۹ است. روش پیشنهادی همچنین توانایی تشخیص پاندمی و افراد بیمار بر اساس صدا یا تصویر را دارد. اهمیت بالینی این دستاورد در ارائه یک روش تشخیصی غیرتهاجمی، کم‌هزینه و سریع نهفته است که می‌تواند به عنوان یک ابزار غربالگری اولیه مؤثر در کنار سایر روش‌های تشخیصی مورد استفاده قرار گیرد. قابلیت تشخیص بیماری در مراحل اولیه و همچنین پتانسیل به‌کارگیری آن در شرایط پاندمیک، این روش را به گزینه‌ای جذاب برای سیستم‌های بهداشتی در سراسر جهان تبدیل می‌کند.

با وجود موفقیت‌های چشمگیر، لازم است محدودیت‌های این مطالعه نیز در نظر گرفته شود. مجموعه‌داده‌های مورد استفاده، اگرچه گسترده هستند، اما ممکن است تمامی تنوعات صوتی و شرایط بالینی را پوشش ندهند. لذا، ارزیابی چارچوب پیشنهادی بر روی مجموعه‌داده‌های بزرگ‌تر و متنوع‌تر در مقیاس جهانی، گامی ضروری در جهت تعمیم‌پذیری بیشتر نتایج خواهد بود. علاوه بر این، همان‌طور که اشاره شد، توسعه رویکردهای تشخیص ترکیبی که صدا و تصویر (مانند رادیوگرافی قفسه سینه) را به‌صورت همزمان ادغام می‌کنند، می‌تواند دقت و جامعیت تشخیص را به سطح بالاتری برساند. همچنین، کاوش در حوزه یادگیری کوانتومی برای کاربرد در تشخیص بیماری‌های عفونی مانند کووید-۱۹، افق‌های جدیدی را در این زمینه خواهد گشود و پتانسیل پردازش حجم عظیم داده‌های بیومتریک را با سرعت و دقت بی‌سابقه‌ای فراهم خواهد آورد. در نهایت، بررسی امکان به‌کارگیری این چارچوب برای تشخیص سایر بیماری‌های تنفسی با استفاده از صدای سرفه، می‌تواند دامنه کاربردهای آن را گسترش دهد.

تشکر و قدردانی

بدینوسیله نویسندگان این مقاله از کلیه شـــرکت کنندگان در این مطالعه که همکاری صمیمانه را داشته، تقدیر و تشـــکر فراوان داریم.

تعارض منافع

نویسندگان اعلام می‌دارند هیچگونـه تعـارض منـافعی در نگارش این پژوهش ندارند.

[Downloaded from yafteh.lums.ac.ir on 2026-11-06]

حمایت مالی

پژوهشـگران از هـیچ سـازمانی حمایـت مـالی دریافـت نگردید.

مشارکت نویسندگان

بررسی، طراحـــی و ویرایش مقاله: حمید رضا غفاری و جمـع‌آوری داده‌هـای بـالینی و پیش پردازش آنها و نگارش مقاله : شادی دالوند

ملاحظات اخلاقی

به اطلاع میرساند این پژوهش در دانشگاه آزاد اسلامی ، (خراسان جنوبی)، واحد فردوس بررسی و با شناسه اخلاق IR.IAU.BIRJAND.REC.1404.153 مصـــوب گردیـد و در وبگاه سـامانه ملی اخلاق در پژوهش‌های زیسـت پزشـکی نیز قابل مشاهده است.

[Downloaded from yafteh.lums.ac.ir on 2026-11-06]

References

1. Tan CY, Jang ST, Lam SM, An AQ, Venus Lo UK. Teaching and learning challenges due to the COVID-19 pandemic: a systematic review. Educ Res Rev. 2025;100667. DOI: 10.1016/j.edurev.2025.100667
2. Campione-Barr N, Skinner A, Moeller K, Cui L, Kealy C, Cookston J. The role of family relationships on adolescents' development and adjustment during the COVID-19 pandemic: a systematic review. J Res Adolesc. 2025;35(1):e12969. DOI: 10.1111/jora.12969
3. Pöyry E, Reinikainen H, Luoma-Aho V. The role of social media influencers in public health communication: case COVID-19 pandemic. Int J Strateg Commun. 2022;16(3):469-484. DOI: 10.1080/1553118X.2022.2042694
4. Jacobs T, Morden E, Smith M, von Delft A, Kassanjee R, Mudaly V, et al. Severe outcomes among adults with TB during COVID-19. IJTLD Open. 2024;1(7):292-298. DOI: 10.5588/ijtldopen.24.0220
5. Coimbra BM, Zylberstajn C, van Zuiden M, Hoeboer CM, Mello AF, Mello MF, et al. Moral injury and mental health among health-care workers during the COVID-19 pandemic: meta-analysis. Eur J Psychotraumatol. 2023;15(1):2299659. DOI: 10.1080/20008066.2023.2299659
6. Länsivaara A, Lehto K-M, Hyder R, Janhonen ES, Lipponen A, Heikinheimo A, et al. Comparison of different reverse transcriptase-polymerase chain reaction-based methods for wastewater surveillance of SARS-CoV-2: exploratory study. JMIR Public Health Surveill. 2024;10:e53175. DOI: 10.2196/53175
7. Klimaszyk K, Wirstlein P, Bednarek-Rajewska K, Jankowski M, Svarre Nielsen H, Wender Ożegowska E, et al. Endometrial factors and pregnancy loss frequency in recurrent pregnancy loss patients: comparing RT-PCR microbiology, microbial cultures, and immunohistochemistry of endometrium biopsy. J Appl Genet. 2025;66(2):459-468. DOI: 10.1007/s13353-025-00949-5
8. Jääskeläinen AE, Pitkäranta A, Haaramo A, Nokso-Koivisto J, Sanmark E. Saliva samples in SARS-CoV-2 virus detection compared to the nasopharyngeal RT-PCR findings in individuals with suspected COVID-19 infection. J Virol Methods. 2025;115295. DOI: 10.1016/j.jviromet.2025.115295
9. Blake J, Birrell P, Walker AS, Pouwels KB, House T, Tom BDM, et al. Estimating the duration of RT-PCR positivity for SARS-CoV-2 from doubly interval censored data with undetected infections. arXiv [Preprint]. 2025. DOI: 10.48550/arXiv.2502.04824
10. Aboshosha A. AI based medical imagery diagnosis for COVID-19 disease examination and remedy. Sci Rep. 2025;15(1):1607. DOI: 10.1038/s41598-024-84644-1
11. Bhatele KR, Jha A, Tiwari D, Bhatele M, Sharma S, Mithora MR, et al. COVID-19 detection: a systematic review of machine and deep learning-based approaches utilizing chest X-rays and CT scans. Cogn Comput. 2022;16(4):1-38. DOI: 10.1007/s12559-022-10076-6
12. Low WC S, Chuah JH, Tee CATH, Anis S, Shoaib MA, Faisal A, et al. An overview of deep learning techniques on chest X-ray and CT scan identification of COVID-19. *Comput Math Methods Med. 2021;2021:5528144. DOI: 10.1155/2021/5528144
13. Islam R, Abdel-Raheem E, Tarique M. A study of using cough sounds and deep neural networks for the early detection of Covid-19. Biomed Eng Adv. 2022;3:100025. DOI: 10.1016/j.bea.2022.100025
14. Andreu-Perez J, Perez-Espinosa H, Timonet E, Kiani M, Giron-Perez MI, Benitez-Trinidad AB, et al. A generic deep learning based cough analysis system from clinically validated samples for point-of-need Covid-19 test and severity levels. IEEE Trans Serv Comput. 2022;15(3):1220-1232. DOI: 10.1109/TSC.2021.3061402
15. Celik G. CovidCoughNet: a new method based on convolutional neural networks and deep feature extraction using pitch-shifting data augmentation for covid-19 detection from cough, breath, and voice signals. Comput Biol Med. 2023;163:107153. DOI: 10.1016/j.compbiomed.2023.107153
16. Benmalek E, El Mhamdi J, Jilbab A, Jbari A. A cough-based covid-19 detection system using PCA and machine learning classifiers. Appl Comput Sci. 2022;18(4):96-115. DOI: 10.35784/acs-2022-31
17. Xia T, Han J, Qendro L, Dang T, Mascolo C. Uncertainty-aware COVID-19 detection from imbalanced sound data. arXiv [Preprint]. 2021. DOI: 10.48550/arXiv.2104.02005
18. Chen X, Hu M, Zhai G. Cough detection using selected informative features from audio signals. arXiv [Preprint]. 2021. DOI: 10.48550/arXiv.2108.03538
19. Alqahtani A, Zahoor MM, Nasrullah R, Fareed A, Cheema AA, Shahrose A, et al. Computer aided COVID-19 diagnosis in pandemic era using CNN in chest X-ray images. Life (Basel). 2022;12(11):1709. DOI: 10.3390/life12111709
20. Benaliouche H, Hafi H, Bendjenna H, Alshaikh Z. Toward AI-driven cough sound analysis for respiratory disease diagnosis. IEEE Access. 2025;13:92554-92568. DOI: 10.1109/ACCESS.2025.3572202
21. Ayappan G, Anila S. Automatic detection and prediction of COVID-19 in cough audio signals using coronavirus herd immunity optimizer algorithm. Sci Rep. 2025;15(1):2271. DOI: 10.1038/s41598-025-85140-w
22. Singh K, Gaur A, Kumar S, Shastri S, Mansotra V. Deep CP-CXR: a deep learning model for classification of Covid-19 and pneumonia disease using chest X-ray images. Ann Data Sci. 2025;1-24. DOI: 10.1007/s40745-025-00601-3
23. Sultana S, Hossain ABMA, Alam J. COVID-19 detection from optimized features of breathing audio signals using explainable ensemble machine learning. Results Control Optim. 2025;18:100538. DOI: 10.1016/j.rico.2025.100538
24. Lakshmip D, Saraswathi D. Wasserstein generative adversarial network for cough signal augmentation using modified discrete cosine transform representation. Biomed Signal Process Control. 2025;110:108164. DOI: 10.1016/j.bspc.2025.108164
25. Madhalaimuthu S, Radhakrishnan S. Clinical outcome prediction in pediatric respiratory infections using hybrid feature selection and a genetic algorithm-optimized machine learning. Sci Rep. 2025;15(1):36542. DOI: 10.1038/s41598-025-18258-6
26. Mahanty C, Patro G, Rathor S, Rachapudi V, Mohanty J, Muzammil K, et al. A comprehensive review on COVID-19 detection based on cough sounds, symptoms, CXR, and CT images. IEEE Access. 2024;12:75412-75425. DOI: 10.1109/ACCESS.2024.3396728
27. Kim J, Lee J. Cough sound based deep learning models for diagnosis of COVID-19 using statistical features and time-frequency spectrum. Proc Annu Int Conf IEEE Eng Med Biol Soc. 2024;1-4. DOI: 10.1109/EMBC53108.2024.10781593
28. Puja WD, Sultana S, Aowlad Hossain ABM. COVID-19 detection from cough sound signal using random forest

[Downloaded from yafteh.lums.ac.ir on 2026-11-06]

learning of deep spectral features. In: 2024 IEEE International Conference on Signal Processing, Information, Communication and Systems (SPICSCON); 2024. p. 1-4. DOI: 10.1109/SPICSCON64195.2024.10940971
29. Ulukaya S, Sarıca AA, Erdem O, Karaali A. MSCCov19Net: multi-branch deep learning model for COVID-19 detection from cough sounds. Med Biol Eng Comput. 2023;61(7):1619-1629. DOI: 10.1007/s11517-023-02803-4
30. Kumar S, Nagar R, Bhatnagar S, Vaddi R, Gupta SK, Rashid M, et al. Chest X-ray and cough sample-based deep learning framework for accurate diagnosis of COVID-19. Comput Electr Eng. 2022;103:108391. DOI: 10.1016/j.compeleceng.2022.108391
31. Dehghani M, Montazeri Z, Trojovská E, Trojovský P. Coati optimization algorithm: a new bio-inspired metaheuristic algorithm for solving optimization problems. Knowl Based Syst. 2023;259:110011. DOI: 10.1016/j.knosys.2022.110011
32. Abualigah L, Diabat A, Mirjalili S, Abd Elaziz M, Gandomi AH. The arithmetic optimization algorithm. Comput Methods Appl Mech Eng. 2021;376:113609. DOI: 10.1016/j.cma.2020.113609
33. El-Latif EIA, El-Sayad NE, Mohammed KK, Darwish A, Hassanien AE. VGGish transfer learning model for the efficient detection of payload weight of drones using Mel-spectrogram analysis. Neural Comput Appl. 2024;36(21):12883-12899. DOI: 10.1007/s00521-024-09661-7
34. Chen Z, Song D. Modeling landslide susceptibility based on convolutional neural network coupling with metaheuristic optimization algorithms. Int J Digit Earth. 2023;16(1):3384-3416. DOI: 10.1080/17538947.2023.2249863
35. Albadr MAAA, Tiun S, Ayob M, Al-Dhief FT. Particle swarm optimization-based extreme learning machine for COVID-19 detection. Cogn Comput. 2022;16(4):1-16. DOI: 10.1007/s12559-022-10063-x
36. Dash TK, Mishra S, Panda G, Satapathy SC. Detection of COVID-19 from speech signal using bio-inspired cepstral features. Pattern Recognit. 2021;117:107999. DOI: 10.1016/j.patcog.2021.107999
37. Muguli A, Pinto L, Sharma N, Krishnan P, Ghosh PK, Kumar R, et al. DiCOVA challenge: dataset, task, and baseline system for COVID-19 diagnosis using acoustics. arXiv [Preprint]. 2021. DOI: 10.48550/arXiv.2103.09148
38. Lella KK, Pja A. Automatic COVID-19 disease diagnosis using 1D convolutional neural network and augmentation with human respiratory sound based on parameters: cough, breath, and voice. AIMS Public Health. 2021;8(2):240. DOI: 10.3934/publichealth.2021019
39. Brown C, Chauhan J, Grammenos A, Han J, Hasthanasombat A, Spathis D, et al. Exploring automatic diagnosis of COVID-19 from crowdsourced respiratory sound data. In: Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining; 2020 Aug; Virtual Event, CA, USA. p. 3474-3484. DOI: 10.1145/3394486.3412865
40. Ghourabi M, Mourad-Chehade F, Chkeir A. Advancing cough classification: Swin Transformer vs. 2D CNN with STFT and augmentation techniques. Electronics. 2024;13(7):1177. DOI: 10.3390/electronics13071177
41. Husssain S, Ayoub M, Wahid JA, Khan A, Alabrah A, Amran GA. Cough2COVID-19 detection using an enhanced multi layer ensemble deep learning framework and CoughFeatureRanker. Sci Rep. 2024;14(1):25207. DOI: 10.1038/s41598-024-76639-9
42. Kim S, Baek JY, Lee SP. COVID-19 detection model with acoustic features from cough sound and its application. Appl Sci (Basel). 2023;13(4):2378. DOI: 10.3390/app13042378
43. Abayomi-Alli OO, Damaševičius R, Abbasi AA, Maskeliūnas R. Detection of COVID-19 from deep breathing sounds using sound spectrum with image augmentation and deep learning techniques. Electronics. 2022;11(16):2520. DOI: 10.3390/electronics11162520
44. Khalif KMNK, Chaw Seng W, Gegov A, Bakar ASA, Shahrul NA. Integrated generative adversarial networks and deep convolutional neural networks for image data classification: a case study for COVID-19. Information. 2024;15(1):58. DOI: 10.3390/info15010058
45. Hosseini M, Ahmadi R. Diagnosis of respiratory diseases using spectral features of speech signals. Iranian Journal of Electrical and Electronic Engineering. 2022;18(2):145-154. (In Persian). Link
46. Karimi S, Rezaei M. Application of deep learning in the diagnosis of pulmonary diseases based on audio signals. Signal Processing Quarterly. 2023;9(1):23-34. (In Persian). Link
47. Mohammadi A, Sharifi H. Analysis of respiratory biomedical signals using convolutional neural networks. Iranian Journal of Biomedical Engineering. 2022;15(4):301-310. (In Persian). Link
48. Shafiekhani S, Asghardoust Rezaei M, Saberi M, Raei M, Chartab Mohammadi T. Classification of COVID-19 patients based on clinical symptoms and demographic characteristics. Journal of Military Medicine. 2025;26(6):2605-2617. (In Persian). DOI: 10.30491/jmm.2025.1006542.1090
49. Arabzadeh SAA, Jamshidi V, Saeed M, Yazdani R, Jamshidi M. Automated detection of coronavirus disease (COVID-19) by using data-mining techniques: a brief report. Tehran University Medical Journal (TUMJ). 2022;79(10):822-830. (In Persian). Link
50. Karimi G, Mohammadi A. Detection of COVID-19 Disease Using Optimized Convolutional Neural Networks. Journal of Advanced Signal Processing (University of Tabriz). 2022; 6(1): 47-58. DOI: 10.22034/jasp.2022.52486.1197
51. Mirzaei Yaghin R, Shamsi M, Aghaei M. Diagnosis of Neurodegenerative Diseases Based on Time and Frequency Features Using Machine Learning. In: Proceedings of the 20th CSI International Symposium on Artificial Intelligence and Signal Processing (AISP 2024). Tehran: Computer Society of Iran; 2024: 1-7. Link
52. Karsaz A, Akbarian R, Khorrami A. Deep Learning in the Processing of Lung CT-Scan Images of COVID-19 Patients. Asre Bargh (Journal of Khorasan Branch of the Iranian Association of Electrical and Electronics Engineers - IAEEE). 2022; 8(16): 43-55. Link
53. Hakkak H, Mirzazadeh Z, Honarmand M, Zolfaghari A. Investigation of Audio Signal Processing and Feature Extraction Methods for the Diagnosis of Pulmonary Diseases. National Conference on Electrical and Electronics Industry (EEICONF). 2020; 1-19. Link
54. Mousavi S. Application of Deep Learning Models in the Analysis of CT-Scan Images for Early Diagnosis of Lung Cancer. 28th National Conference on Applied Research in Electrical, Computer, and Biomedical Engineering. 2026; 1-9. Link

[Downloaded from yafteh.lums.ac.ir on 2026-11-06]