

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 Dalvand¹ , Hamidreza Ghaffari¹ * 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.

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 ID، حمیدرضا غفاری^{۱*} ID

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

*نویسنده مسئول: حمیدرضا غفاری، دانشگاه آزاد اسلامی، (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.

چکیده	تاریخ دریافت: ۱۴۰۴/۰۹/۰۸
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 ارائه 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 فرایارامترهای 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 می‌دهد دقت روش پیشنهادی در تشخیص بیماری کووید ۱۹ از CNNs, DNNs, LSTMها 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.	تاریخ ویرایش: ۱۴۰۴/۱۲/۲۷
	تاریخ پذیرش: ۱۴۰۵/۰۱/۰۵
	واژگان کلیدی: غفونت‌های ریه کووید ۱۹ پردازش سیگنال یادگیری عمیق هوش گروهی

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 (۴).

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 (۵). در حال حاضر، رویکرد اصلی برای تشخیص کووید-۱۹ شامل استفاده از آزمایش Reverse transcription polymerase chain reaction (RT-PCR) است (۶). 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 مقرون به صرفه‌تر 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 (۱۴). 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 (۱۵).

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 (۱۶). از طرفی عدم تعادل در مجموعه‌های آموزشی مرتبط با صدای افراد سالم و بیمار نیز باعث افزایش خطای تشخیص بیماران از افراد سالم می‌شود (۱۷). 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 (۱۸). به طور کلی شناسایی سرفه، که یکی از علائم برجسته کووید-۱۹ است، این

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) ارائه شده است.

مدل پیشنهادی شاخص خطای پیش بینی را نسبت به مدل‌های WOA، PSO 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 هموردی مولد تلاش می‌شود تا مجموعه داده غنی‌تر شود. در این پژوهش‌ها عملکرد مدل پیش‌بینی تحقق‌یافته ۱۷٪ بهبود در دقت طبقه‌بندی را داشته است (۲۴).

پیش‌بینی پیامد بالینی در عفونت‌های تنفسی کودکان با استفاده از انتخاب ویژگی ترکیبی و یادگیری ماشین بهینه‌شده با الگوریتم ژنتیک در (۲۵)، ارائه شده است. معیارهای عملکرد مدل پیشنهادی در مقایسه با کارهای موجود، به دقت کلی ۹۵/۰۲٪ 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 (۲۶)، 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 کم‌برج به دقت ۹۳/۴۶٪ رسیده است. برای تشخیص کووید-۱۹ با استفاده از سیگنال صدای سرفه یک روش مبتنی بر جنگل تصادفی در (۲۸)، ارائه 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)، ارائه دادند. نتایج آزمایش نشان می‌دهد که سیستم پیشنهادی به دقت حدود ۹۰/۴٪ رسیده است. یک چارچوب یادگیری عمیق مبتنی بر نمونه اشعه ایکس قفسه سینه و سرفه برای تشخیص دقیق کووید-۱۹ در (۳۰)، ارائه 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 (۴۵). 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 (۴۶) شده است و نویسندگان نشان دادند که شبکه‌های عمیق در استخراج الگوهای پیچیده صوتی عملکرد مناسبی دارند. در مطالعه‌ای دیگر، محمدی و شریفی (۴۷) 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 (۴۸) 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 (۴۹) 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 شبکه‌های 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

DenseNet fi به تشخیص بیماری کووید ۱۹ پرداختند. در جدول (۱)، خلاصه‌ای از کارهای مرتبط در زمینه خارجی و داخلی مرور شده است:

عملکرد مدل‌های طبقه‌بندی نظیر شبکه‌های عصبی کانولوشن در تحلیل تصاویر پزشکی شود. موسوی (۵۴) نیز با استفاده از رویکردهای یادگیری عمیق پیشرفته مانند U-Net ، ResNet.

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	(۲۴)
حساسیت به تنظیم پارامتر	افزایش دقت پیش‌بینی	انتخاب ویژگی + الگوریتم ژنتیک	داده‌های پزشکی	(۲۵)
عدم بررسی جامع همه روشهای یادگیری انتقالی	بررسی روشهای پیشرفته	مرور تکنیک‌های یادگیری انتقالی و گروهی فازی	داده‌های پزشکی	(۲۶)
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	(۴۵)
حجم داده محدود	توانایی استخراج ویژگی خودکار	یادگیری عمیق	داده صوتی پزشکی	(۴۶)
عدم تحلیل وابستگی زمانی	استخراج ویژگی قوی از داده زیستی	CNN	سیگنال‌های تنفسی	(۴۷)
استفاده از ویژگی‌های محدود	کاربرد در تشخیص بیماری	الگوریتم‌های ML	داده پزشکی مرتبط با کووید	(۴۸)
دقت محدود در داده‌های پیچیده	سادگی پیاده‌سازی	استخراج ویژگی صوتی	سیگنال صوتی تنفسی	(۴۹)
نیاز به داده آموزشی زیاد	تشخیص سه نوع بیماری	شبکه عصبی کانولوشن	تصاویر سی‌تی اسکن	(۵۰)
پیچیدگی محاسباتی	تحلیل جامع	روشهای یادگیری ماشین	سیگنال زیستی	(۵۱)
عدم تمرکز بر سیگنال سرفه	تحلیل چندمنبعی داده‌ها	شبکه‌های عصبی کانولوشن	داده‌های پزشکی	(۵۲)
وابستگی به نوع ویژگی	بهبود دقت طبقه‌بندی	شبکه‌های عصبی کانولوشن	تصاویر پزشکی	(۵۳)
عدم استفاده از معماری ترکیبی	استخراج الگوهای پیچیده	یادگیری عمیق پیشرفته	تصاویر پزشکی	(۵۴)

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

با وجود پیشرفت‌های حاصل شده 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 کانولوشن، 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


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 ۴، تجزیه و تحلیل روش پیشنهادی برای تشخیص نوع بیماری کووید ۱۹ و مقایسه نتایج با روشهای مشابه ارایه می‌شود. در بخش ۵، 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 گروهي است در شکل (۱)، نمایش داده شده است.

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



شکل ۱. مراحل روش پیشنهادی برای تشخیص پاندمی‌های کووید ۱۹

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 تخصصی (GAN) برای تولید نمونه‌های مصنوعی از کلاس بدخیم استفاده می‌شود تا

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

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 $L = (N(Y) / f(s))$ استفاده می‌شود، که در آن $N(Y)$ طول نمونه و $f(s)$ فرکانس نمونه‌برداری برای هر نمونه صوتی است که ۴۸ کیلوهرتز است. بر اساس عبارت ریاضی برای محاسبه L ثانیه، حداقل و حداکثر طول فایل‌های صوتی به ترتیب ۴ 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 (۴۳).

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 آنگاه دقت آن کاهش خواهد یافت. شبکه مولد تخصصی GAN نوعی مدل‌سازی مولد است که از تکنیک‌های یادگیری عمیق در شبکه‌های عصبی کانولوشن استفاده می‌کند و برای متعادل‌سازی مجموعه داده‌ها ایده‌آل است (۴۴).

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).

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

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

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

- گام ۴: 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 ۵: بهینه‌سازی فرآیندهای CNN با الگوریتم COA: به منظور بهبود عملکرد شبکه CNN، فرآیندهای این شبکه با استفاده از الگوریتم بهینه‌سازی COA تنظیم و بهینه‌سازی می‌شوند.
- گام ۶: 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 مجموعه داده‌های 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

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 کوآتی‌های که از درخت بالا می‌روند به صورت معادله (۴)، به روزرسانی می‌شوند.

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

ایگوانا با مشاهده کوآتی‌های که روی درخت آمده‌اند خود را تصادفی مطابق معادله (۵)، روی زمین می‌اندازد و در ادامه کوآتی‌های که روی زمین قرار دارند مطابق معادله (۶)، ایگوانا را تعقیب می‌کنند.

$$Iguana^G: Iguana_j^G = lb_j + r \cdot (ub_j - lb_j), j = 1, 2, \dots, m$$

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

$Iguana^G$ 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 می‌توانند شکار 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 (۳۴):

$$L_j^{local} = \frac{ll_j}{t}, U_j^{local} = \frac{uj}{t}, \text{ where } iter = 1, 2, \dots, T_{max}. \\ \lambda i = 1, \dots, N, j = 1, \dots, m. X_i^{P2}: x_{i,j}^{P2} = x_{i,j} + (1 - 2r) \cdot (L_j^{local} + r \cdot (U_j^{local} - L_j^{local}))$$

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 T_{max} حداکثر تعداد تکرار بیشینه الگوریتم COA است. فلوچارت روش پیشنهادی برای بهینه‌سازی فرایامترهای مدل CNN با COA در شکل (۲)، نمایش داده شده است.

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.

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


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 راحل 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 راحل یک کوآتی است و بهینه‌ترین راحل نیز یک ایگوانا است. در فاز اول، تعدادی راحل اولیه به عنوان جمعیت اولیه COA تصادفی تولید می‌شود و مطابق معادله (۳)، در ماتریس جمعیت P قرار داده می‌شود.

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

کوآتی‌های بالای درخت، ایگوانا را تعقیب کرده و ایگوانا



شکل ۲: فلوچارت روش پیشنهادی در استخراج ویژگی صدای سرفه

ویژگی مطابق معادله (۹)، فرموله می‌شود.

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

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:

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

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

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

وظیفه دروازه ورودی به روزرسانی وضعیت سلول و تعیین نسبت اطلاعات داده جدید تحویل داده شده به حافظه است. دروازه خروجی روش‌های به روزرسانی حافظه و میزان اطلاعات تغذیه شده به لایه بعدی را تعیین می‌کند. معادلات (۱۳)، (۱۴)، (۱۵)، (۱۶) و (۱۷) برای مدلسازی شبکه LSTM برای پیش بینی نوع بیماری بکار گرفته می‌شوند.

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

در این معادلات، GI_t گیت ورودی در زمان t است. Sig تابع سیگموئید است. U_i, U_c, U_f, U_o و وزن‌های ورودی است. W_i, W_c, W_f, W_o و وزن‌های بازگشتی است. $\beta_i, \beta_c, \beta_f, \beta_o$ 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:

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

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

در این معادله، T_{max} حداکثر تکرار الگوریتم AOA است. X^* بهینه‌ترین راه حل است و μ ثابت عددی است. برای جستجوی سراسری در الگوریتم AOA از معادله (۱۲)، استفاده می‌شود.

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

U و L محدود بالا و پایین بعد z -ام یک راه حل 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 CNN داده 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.

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

وضعیت تعادل	نمونه‌های غیرکوئید	نمونه‌های کوئید مثبت	تعداد کل نمونه‌ها	نام مجموعه داده
به شدت نامتوازن	بقیه (~۲۵,۰۰۰)	حدود ۱,۵۰۰-۱,۲۰۰	حدود ۲۷,۰۰۰ نمونه صوتی	COUGHVID
نسبتاً متوازن‌تر از COUGHVID	حدود ۸۰۰-۷۰۰	حدود ۳۵۰-۳۰۰	حدود ۱,۲۰۰-۱,۰۰۰ نمونه	Cambridge
نمونه‌ها کم و نویز زیاد	حدود ۳۰۰-۲۵۰	حدود ۱۸۰-۱۵۰	حدود ۵۰۰-۴۰۰ نمونه	CHRSRD

در این مطالعه از مجموعه داده‌های عمومی Cambridge، COUGHVID و CHRSRD استفاده شده است و هر یک از این مجموعه داده‌ها به صورت 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 (به منظور تنظیم پارامترهای مدل) و ۱۰٪ برای آزمون در نظر گرفته شد. این روند در تمامی fold ها تکرار گردید و در نهایت میانگین نتایج حاصل از تمام تکرارها به عنوان 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 مل (Mel-spectrogram) و ویژگی‌های MFCC تبدیل 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 توسط CNN، 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 نرون‌ها)، 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 کوئید-۱۹ از صدای سرفه مورد استفاده قرار گرفت. در بخش آکوستیک، ویژگی‌هایی مانند ضرایب کپسترال فرکانس مل (MFCC) و طیف‌نگار مل (Mel-Spectrogram) به عنوان 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 به عنوان 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 LSTM جهت طبقه‌بندی نهایی منتقل شوند.

در آزمایشات انجام شده روش پیشنهادی از CNN برای استخراج ویژگی استفاده می‌کند و همزمان نیز فرآپارامترهای مدل با COA بهینه‌سازی می‌شوند. برای تشخیص بیماران کوئید ۱۹ بر اساس صدا از روش انتخاب ویژگی AOA و طبقه‌بندی 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 CHRSRD، موفق شده است که به دقت، حساسیت و صحت ۷۲٪/۹۵٪/۹۱٪ و ۷۵٪/۹۱٪ برای تشخیص کوئید ۱۹ بر اساس صدای سرفه برسد. در مجموعه داده Cambridge دقت، حساسیت و صحت روش پیشنهادی ۷۳٪/۹۸٪/۹۷٪ و ۹۲٪/۹۷٪ است.

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


مجموعه داده			
مجموعه داده	دقت	حساسیت	صحت
CHRS D	٪ 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 ۹۷/۶۸٪ است. تحلیل نتایج جدول نشان می‌دهد که چارچوب پیشنهادی در تشخیص کووید-۱۹ از صدای سرفه عملکرد بسیار مطلوبی در مجموعه داده‌های مختلف داشته است. همان‌طور که مشاهده می‌شود، بیشترین مقدار دقت مربوط به مجموعه داده 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 مجموعه داده 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 مجموعه داده CHRS D 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 مجموعه داده‌های 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 ۱۹ در مجموعه داده CHRS D

آن متعادل سازی مجموعه داده با روش GAN، بهینه سازی فرایامترهای CNN با هوش گروهی COA و بکارگیری روش بهینه سازی AOA برای بهینه سازی ورودی های LSTM است. در شکل (۵)، روش پیشنهادی از نظر شاخص دقت در مجموعه داده Cambridge مورد مقایسه قرار گرفته شده است.


در شکل (۴)، 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٪، ۹۵/۶٪، ۶۲٪ و ۹۴٪ است. رویکرد پیشنهادی نسبت به روش CNN و LSTM موفق شده است که دقت را ۱۳/۸۳٪ و ۲/۸۳٪ افزایش دهد که دلیل اصلی



شکل ۴: مقایسه دقت روش پیشنهادی با روشهای تشخیص کووید ۱۹ در مجموعه داده COUGHVID

روش DNN نسبت به سایر روشهای مورد مقایسه عملکرد بهتری دارد و از روش LSTM در تشخیص بیماری کووید ۱۹ موفق تر بوده است.

در مجموعه داده Cambridge روش پیشنهادی موفق شده است به دقت برابر ۹۸/۲۶٪، برسد و از طرفی دقت آن از روشهای DNN، Spectrogram+ResNet-50، MFCC+LSTM و MFCC+DNN بیشتر بوده است. آزمایشات نشان می دهد



شکل ۵: مقایسه دقت روش پیشنهادی با روشهای تشخیص کووید ۱۹ در مجموعه داده Cambridge

است. این تفاوت عملکرد را می توان به ویژگی های ساختاری و کیفی مجموعه داده CHRSD نسبت داد. نخست آنکه تعداد نمونه های موجود در این مجموعه داده نسبت به دو مجموعه داده

نتایج به دست آمده نشان می دهد که عملکرد چارچوب پیشنهادی GCLSI در مجموعه داده CHRSD کمی پایین تر از نتایج حاصل از مجموعه داده های Cambridge و COUGHVID

LSTM و DNN دقت بیشتری در تشخیص بیماران مبتلا به کووید ۱۹ ارائه داده است. مزیت روش پیشنهادی دقت بیشتر در تشخیص بیماری کووید ۱۹ نسبتاً به روشهای مشابه یادگیری عمیق است. یک مزیت دیگر روش پیشنهادی متعادل سازی 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، کم هزینه و سریع نهفته است که می تواند به عنوان یک ابزار غربالگری اولیه مؤثر در کنار سایر روش های تشخیصی مورد استفاده قرار گیرد. قابلیت تشخیص بیماری در مراحل اولیه و همچنین پتانسیل به کارگیری آن در شرایط پاندمیک، این روش را به گزینه ای جذاب برای سیستم های بهداشتی در سراسر جهان تبدیل می کند.

با وجود موفقیت های چشمگیر، لازم است محدودیت های این مطالعه نیز در نظر گرفته شود. مجموعه داده های مورد استفاده، اگرچه گسترده هستند، اما ممکن است تمامی تنوعات صوتی و شرایط بالینی را پوشش ندهند. لذا، ارزیابی چارچوب پیشنهادی بر روی مجموعه داده های بزرگتر و متنوع تر در مقیاس جهانی، گامی ضروری در جهت تعمیم پذیری بیشتر نتایج خواهد بود. علاوه بر این، همان طور که اشاره شد، توسعه رویکردهای تشخیص ترکیبی که صدا و تصویر (مانند رادیوگرافی قفسه سینه) را به صورت همزمان ادغام می کنند، می تواند دقت و جامعیت تشخیص را به سطح بالاتری برساند. همچنین، کاوش در حوزه یادگیری کوانتومی برای کاربرد در تشخیص بیماری های عفونی مانند کووید-۱۹، افق های جدیدی را در این زمینه خواهد گشود و پتانسیل پردازش حجم عظیم داده های بیومتریکی را با سرعت و دقت بی سابقه ای فراهم خواهد آورد. در نهایت، بررسی امکان به کارگیری این چارچوب برای تشخیص سایر بیماری های تنفسی با استفاده از صدای سرفه، می تواند دامنه کاربردهای آن را گسترش دهد.

تشکر و قدردانی

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

تعارض منافع

نویسندگان اعلام می دارند هیچگونه تعارض منافعی در نگارش این پژوهش ندارند.

دیگر کمتر است و در نتیجه تنوع الگوهای سرفه در مرحله آموزش مدل محدودتر می شود. کاهش تنوع داده ها می تواند توانایی مدل های یادگیری عمیق را در یادگیری الگوهای مختلف سرفه مرتبط با بیماری کووید-19 کاهش دهد. علاوه بر این، شرایط ثبت و ضبط سیگنال های صوتی در مجموعه داده CHRSD ممکن است شامل نویز محیطی بیشتر یا تغییرات در شرایط ضبط باشد که می تواند بر کیفیت ویژگی های استخراج شده از سیگنال های صوتی تأثیر بگذارد.

وجود نویز و تغییرات محیطی می تواند فرآیند استخراج ویژگی توسط شبکه CNN را با چالش مواجه کند و در نتیجه بر عملکرد نهایی مدل طبقه بندی اثر بگذارد. در مقابل، مجموعه داده های Cambridge و COUGHVID دارای نمونه های بیشتر و تنوع بالاتری از صداهای سرفه هستند که به مدل اجازه می دهد الگوهای نماینده تری را یاد بگیرد و عملکرد بهتری در مرحله تشخیص بیماری ارائه دهد.

جداسازی افرادی که به کووید مبتلا هستند می تواند انتقال و شیوع بیماری را به حداقل برساند، بنابراین آزمایش های مختلفی برای تشخیص ویروس مانند RT-PCR، عکس برداری از قفسه سینه و توموگرافی کامپیوتری پیشنهاد شده است. با این حال، این روش ها از نرخ تشخیص پایین یا دوز بالای تابش و همچنین گران بودن رنج می برند. 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 ارائه شده است. در رویکرد پیشنهادی از GAN برای متعادل سازی مجموعه داده استفاده شده است و از شبکه عصبی کانولوشن بهبود یافته با الگوریتم بهینه سازی کوآتی برای استخراج ویژگی استفاده می شود. ورودی های طبقه بندی کننده LSTM با الگوریتم انتخاب ویژگی بهینه سازی محاسبات ریاضی، بهینه می شود 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 تخصصی تعمیم یافته برای متعادل سازی داده ها، شبکه های عصبی کانولوشن با بهینه سازی الگوریتم کوآتی برای استخراج ویژگی های صوتی غنی، و شبکه های حافظه طولانی کوتاه با استفاده از الگوریتم محاسبات ریاضی برای انتخاب بهینه ورودی ها نهفته است.

آزمایشات نشان می دهد 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 ارائه دهد. روش پیشنهادی در مجموعه داده COUGHVID از روش های یادگیری عمیق CNN، ResNet50،

حمایت مالی

پژوهش - گران از ه - بیچ س - سازمانی حمایت - ت م - مالی
دریافت نگردید.

مشارکت نویسندگان

بررسی، طراحی و ویرایش مقاله: حمید رضا غفاری و
جمع‌آوری داده‌های ب - الینی 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 مصوب گردید و در
وبگاه سامانه ملی اخلاق در پژوهش‌های زیست پزشکی نیز
قابل مشاهده است.

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](https://doi.org/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](https://doi.org/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](https://doi.org/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. *IJTL D Open.* 2024;1(7):292-298. DOI: [10.5588/ijtdopen.24.0220](https://doi.org/10.5588/ijtdopen.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: [10.1080/2008066.2023.2299659](https://doi.org/10.1080/2008066.2023.2299659)
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](https://doi.org/10.2196/53175)
7. Klimaszuk 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](https://doi.org/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](https://doi.org/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](https://doi.org/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](https://doi.org/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](https://doi.org/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](https://doi.org/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](https://doi.org/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](https://doi.org/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](https://doi.org/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](https://doi.org/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](https://doi.org/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](https://doi.org/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](https://doi.org/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](https://doi.org/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](https://doi.org/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](https://doi.org/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](https://doi.org/10.1016/j.rico.2025.100538)
24. Lakshmi 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](https://doi.org/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](https://doi.org/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](https://doi.org/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](https://doi.org/10.1109/EMBC53108.2024.10781593)
28. Puja WD, Sultana S, Aowlad Hossain ABM. COVID-19 detection from cough sound signal using random forest

- 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](https://doi.org/10.1109/SPICSCON64195.2024.10940971)
29. Ulukaya S, Sarica 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](https://doi.org/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](https://doi.org/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](https://doi.org/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](https://doi.org/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](https://doi.org/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](https://doi.org/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](https://doi.org/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](https://doi.org/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](https://doi.org/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](https://doi.org/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](https://doi.org/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](https://doi.org/10.3390/electronics13071177)
 41. Hussain 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](https://doi.org/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](https://doi.org/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](https://doi.org/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](https://doi.org/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, Raci 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](https://doi.org/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](https://doi.org/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](#)