

## هوش مصنوعی در علوم میان رشته ای

نام و نام خانوادگی: احمد رضا قاسمی و علیرضا فولاد

مشخصات نویسندگان: احمد رضا قاسمی و علیرضا فولاد

[dr.alirezafoolad@gmail.com](mailto:dr.alirezafoolad@gmail.com)

[ahmdrdaq02@gmail.com](mailto:ahmdrdaq02@gmail.com)

فصل اول: هوش مصنوعی به مثابه موتور محرک همگرایی در علوم میان‌رشته‌ای: چشماندازها و چالش‌ها برای مهندسی کامپیوتر

### چکیده

هوش مصنوعی (AI) دیگر صرفاً یک حوزه تخصصی در مهندسی کامپیوتر نیست، بلکه به یک زبان مشترک و یک زیرساخت محاسباتی برای حل مسائل پیچیده در تمامی رشته‌های علمی تبدیل شده است. این مقاله بر نقش محوری مهندسان کامپیوتر در هدایت این همگرایی میان‌رشته‌ای تأکید دارد. با بررسی کاربردهای پیشرفته یادگیری عمیق (Deep Learning)، یادگیری تقویتی (Reinforcement Learning) و مدل‌سازی محاسباتی در علوم زیستی، اجتماعی و مهندسی سنتی، به تبیین چالش‌های فنی مرتبط با مقیاس‌پذیری، تفسیرپذیری (Interpretability) و اخلاق داده‌ها می‌پردازیم.

### 1-مقدمه: فراتر از مرزهای سنتی

علم مدرن با مسائلی روبروست که به سادگی در چارچوب یک رشته واحد قابل حل نیستند. این معضلات نیازمند ادغام داده‌ها، مدل‌ها و روش‌شناسی‌های مختلف هستند. هوش مصنوعی، با توانایی‌اش در استخراج الگوهای پیچیده از داده‌های حجیم و چندوجهی، به عنوان کاتالیزور اصلی این همگرایی عمل می‌کند.

برای متخصصان مهندسی کامپیوتر، این بدان معناست که مسئولیت توسعه ابزارهای هوش مصنوعی (AI) صرفاً به بهینه‌سازی عملکرد الگوریتم‌ها محدود نمی‌شود، بلکه شامل طراحی معماری‌هایی است که بتوانند با مفاهیم بنیادی رشته‌های دیگر—مانند قوانین فیزیک، ساختار ژنتیکی، یا دینامیک اقتصادی—تعامل سازنده داشته باشند.

## ۲. کاربردهای پیشرفته در حوزه‌های میانرشته‌ای

توانایی هوش مصنوعی در مدلسازی سیستم‌های غیرخطی و پویا، آن را در خط مقدم اکتشافات میان رشته ای قرار داده است:

### ۱.۲. زیستشناسی محاسباتی و کشف دارو

- تاشوی پروتئین (Protein Folding): مدل‌هایی نظیر آلفافولد (AlphaFold) که از شبکه‌های عصبی ترنسفورمر الهام گرفته‌اند نمونه‌ای بارزی از ادغام بیوانفورماتیک و یادگیری عمیق هستند. مهندسان کامپیوتر مسئول بهینه‌سازی این مدل‌ها برای سرعت بخشیدن به پیش‌بینی ساختارهای جدید و کاهش نیاز به آزمایش‌های آزمایشگاهی پرهزینه هستند.
- ژنومیک: استفاده از شبکه‌های مولد تخصصی (GANs) برای شبیه‌سازی توالی‌های ژنتیکی و شناسایی جهش‌های مرتبط با بیماری.

### ۲.۲. علوم زمین و محیط زیست

- مدلسازی اقلیمی: ترکیب شبکه‌های عصبی گراف (GNNs) با مدل‌های فیزیکی برای پیش‌بینی‌های دقیق‌تر در مقیاس‌های محلی و جهانی، به‌ویژه در مورد پدیده‌های شدید آب‌وهوایی.
- مدیریت منابع: به‌کارگیری یادگیری تقویتی برای بهینه‌سازی شبکه‌های توزیع انرژی (شبکه‌های هوشمند - Smart Grids) با در نظر گرفتن عدم قطعیت منابع تجدیدپذیر.

### ۲.۳. علوم انسانی دیجیتال (Digital Humanities)

تحلیل متون تاریخی: استفاده از مدل‌های زبان بزرگ (LLMs) برای استخراج ساختارهای زبانی، تحلیل احساسات در متون باستانی، و بازسازی روابط اجتماعی از منابع آرشیوی. این حوزه نیازمند مهندسان کامپیوتر مسلط بر پردازش زبان طبیعی (NLP) و دارای درک عمیق از متون تاریخی است.

### ۳. چالش‌های فنی برای جامعه مهندسی کامپیوتر

هم افزایی میان رشته ای چالش‌های فنی جدیدی را برای محققان کامپیوتر به ارمغان می‌آورد که نیازمند تمرکز تحقیقاتی است:

### ۳.۳ توضیح‌پذیری هوش مصنوعی (XAI) - تفسیرپذیری و اعتماد

در حوزه‌های حیاتی مانند پزشکی یا مهندسی سازه، مدل‌های جعبه‌سیاه (Black-Box Models) قابل قبول نیستند. اساتید مهندسی کامپیوتر باید بر توسعه روش‌هایی متمرکز شوند که نه تنها پیش‌بینی کنند، بلکه چرایی و چگونگی رسیدن به آن نتیجه را نیز توضیح دهند. این امر مستلزم تلاقی بین تئوری محاسبات و دانش دامنه (Domain Knowledge) است.

### ۲.۳. مقیاس‌پذیری محاسباتی و سخت افزار

مدل‌های پیچیده میان‌رشته‌ای، به‌ویژه مدل‌های چندوجهی (Multimodal)، نیازمند توان محاسباتی بسیار بالا هستند. تحقیق در زمینه محاسبات کوانتومی و معماری‌های سخت‌افزاری تخصصی مانند شتاب‌دهنده‌های نوری برای تحقق پروژه‌های آتی میان‌رشته‌ای ضروری است.

### ۳.۳. داده‌های نامتقارن و نابرابری

در بسیاری از حوزه‌های میان‌رشته‌ای، داده‌های موجود در رشته‌های مختلف، از نظر کیفیت، فرمت و توزیع، با یکدیگر ناهمگون هستند.

مدیریت و ادغام این داده‌های ناهمگن (Heterogeneous Data Fusion) و تضمین عدم تعصب (Bias) در مدل‌های هوش مصنوعی که بر روی داده‌های با توزیع نامتوازن آموزش دیده‌اند، یک مسئله‌ی مهم اخلاقی و فنی است.

### ۴. نتیجه‌گیری و افق آینده

هوش مصنوعی به عنوان ستون فقرات علوم میان‌رشته‌ای، نیازمند تعهد مجدد مهندسان کامپیوتر به یک رویکرد فرا رشته‌ای است. موفقیت در این عرصه مستلزم پرورش نسل جدیدی از متخصصان است که در اصول بنیادی علوم کامپیوتر مهارت دارند، اما مجهز به درک عملی عمیقی از چالش‌های حوزه‌هایی مانند زیست‌شناسی، فیزیک یا علوم اجتماعی هستند. آینده پژوهش‌های علمی در گرو توانایی ما در ساختن پلهای محاسباتی مستحکم بین این رشته‌هاست.

## فصل دوم: شبکه عصبی کانولوشن کم عمق برای غربالگری شیوع کووید ۱۹ با استفاده از عکسبرداری اشعه x قفسه سینه چکیده:

در میان داده‌های تصویربرداری رادیولوژی، عکسبرداری با اشعه ایکس قفسه سینه (CXR) به‌طور گسترده‌ای برای مشاهده و تشخیص کووید-۱۹ مورد استفاده قرار گرفته است. برای غربالگری انبوه، استفاده از CXR به عنوان یک ابزار کارآمد مبتنی بر هوش مصنوعی، برای تشخیص موارد مثبت کووید-۱۹ از موارد غیرکووید ضروری است. به این منظور، یک شبکه عصبی کانولوشنی سبک‌وزن (CNN) با معماری کم‌عمق متناسب ارائه داده‌ایم که با استفاده از CXR، موارد مثبت کووید-۱۹ را بدون منفی کاذب، به‌طور خودکار تشخیص می‌دهد. این معماری کم‌عمق در مقایسه با سایر مدل‌های یادگیری عمیق، با پارامترهای کمتری طراحی شده است.

معماری پیشنهادی با استفاده از ۳۲۱ مورد مثبت تأییدشده‌ی کووید-۱۹ (از طریق CXR) اعتبارسنجی شد. علاوه بر این، مجموعه‌ای دیگر متشکل از ۵۸۵۶ مورد غیرکووید-۱۹ (منبع عمومی: کاگل) در نظر گرفته شد که شامل موارد ذات‌الریه عادی، ویروسی و باکتریایی بود. در آزمایش‌های ما، برای جلوگیری از جهت‌گیری احتمالی، از روش اعتبارسنجی پنج‌برابری (۵-fold cross-validation) استفاده شد و هر دو سناریوی داده‌های متعادل و نامتعادل مورد بررسی قرار گرفتند.

مدل پیشنهادی بالاترین دقت ممکن (۹۹.۶۹٪) را با حساسیت ۱۰۰٪ (۱۰۰٪) به دست آورد که ناحیه زیر منحنی (AUC) آن ۰.۹۹۹۵ بود. علاوه بر این، نرخ مثبت کاذب (FPR) گزارش شده برای ۵۸۵۶ مورد منفی کووید-۱۹ تنها ۰.۰۰۱۵ بود. نتایج ما نشان می‌دهد که CNN پیشنهادی می‌تواند برای غربالگری انبوه مورد استفاده قرار گیرد. با استفاده از مجموعه داده‌ای دقیقاً مشابه، عملکرد مدل فعلی از سایر مدل‌های یادگیری عمیق و کارهای مرتبط پیشین، بهتر بود.

کلمات کلیدی: کووید-۱۹، اشعه ایکس قفسه سینه، یادگیری عمیق، شبکه عصبی کانولوشن، غربالگری انبوه

#### مقدمه

در دسامبر سال ۲۰۱۹، یک بیماری ویروسی جدید ناشی از ویروس کرونا با نام کووید-۱۹ (COVID-19) در شهر ووهان چین شناسایی شد [۱]. برخلاف سرماخوردگی و آنفولانزا، کووید-۱۹ بسیار مسری‌تر است و برای سیستم ایمنی بدن انسان کاملاً ناشناخته محسوب می‌شود. به بیان دقیق‌تر، سندرم تنفسی حاد شدید (SARS) و سندرم تنفسی خاورمیانه (MERS) دو بیماری شناخته شده ناشی از ویروس کرونا هستند که به ترتیب نرخ مرگ‌ومیر حدود ۱۰٪ و ۳۷٪ دارند [۲،۳]. تا اول ژوئن ۲۰۲۰، این بیماری بیش از ۶۰۵۷'۸۵۳ نفر را در سراسر جهان مبتلا کرده و موجب بیش از ۳۷۱'۱۶۶ مورد مرگ شده است [۸]. نرخ شیوع کووید-۱۹ نمایی و سریع‌تر از سایر بیماری‌های تنفسی است. امروزه، محققان برای پیش‌بینی پیامدهای احتمالی این بیماری، اغلب به داده‌های کمی محدود هستند و از ابزارهای مبتنی بر هوش مصنوعی (AI) برای تحلیل این داده‌ها استفاده می‌کنند.

در ژانویه ۲۰۲۰، هوانگ و همکاران با استفاده از داده‌های ۴۱ بیمار، برخی از جنبه‌های بالینی و پاراکلینیکی کووید-۱۹ را گزارش کردند. مقاله آنها اشاره کرده است که ناهنجاری‌های ریوی مانند کدورت شیشه‌شکسته (Ground-Glass Opacity - GGO) با استفاده از سی‌تی اسکن قفسه سینه قابل مشاهده است [۴]. سی‌تی اسکن به‌طور گسترده‌ای برای شناسایی الگوهای غیرمعمول در موارد تأیید شده کووید-۱۹ استفاده می‌شود [۵-۷]. به‌طور دقیق، لی و شیا ۵۱ تصویر سی‌تی اسکن را بررسی کردند و موفق به شناسایی کووید-۱۹ در ۹۶٪ موارد شدند [۷]. ژو و همکاران ۶۲ مورد کووید-۱۹ و ذات‌الریه را آزمایش کردند و الگوهای متنوعی شبیه به درگیری پارانشیم ریه و بیماری‌های بینابینی را گزارش دادند [۹]. همچنین، ژنگ و همکاران اظهار داشتند که یافته‌های معمول و غیرمعمول سی‌تی اسکن می‌تواند به رادیولوژیست‌ها در تصمیم‌گیری و آشنایی با تظاهرات بیماری کمک کند [۱۰].



به روشی مشابه، از رادیوگرافی قفسه سینه (CXR) نیز به‌طور گسترده‌ای برای تشخیص موارد مثبت کووید-۱۹ استفاده شده است [۱۱، ۱۳، ۲۲، ۲۴]. سون و همکاران رابطه بین یافته‌های CXR و سی‌تی اسکن را در ۹ مورد مثبت بررسی کردند [۱۱]. علاوه بر این، پژوهشگران دیگری بر استفاده از مدل‌های یادگیری عمیق (DL) مناسب مانند COVID-Net [24] و ResNet-50 [25] تمرکز کرده‌اند. COVID-Net تنها بر روی ۳۱ مورد مثبت آزمایش شد، در حالی که ResNet-50 روی ۲۵ مورد مثبت ارزیابی گردید. به همین ترتیب، ژانگ و همکاران از یک مدل یادگیری عمیق کلاسیک برای تشخیص موارد مثبت کووید-۱۹ استفاده کردند که در آن از ۱۰۰ نمونه بهره بردند [۲۲]. تا به امروز، بالاترین دقت گزارش شده برای تشخیص موارد مثبت کووید-۱۹ با استفاده از این روش‌ها ۹۶٪ بوده است [۲۲].

داس و همکاران سیستمی مبتنی بر شبکه برای شناسایی موارد کووید-۱۹ ارائه دادند. آنها ۶ مجموعه داده مختلف را آزمایش کرده و دقت ۹۹/۹۶٪ را در تشخیص موارد مثبت و سالم گزارش کردند. علاوه بر این، دقت ۹۹/۹۲٪ را در تشخیص موارد مثبت از یک مجموعه ترکیبی از نمونه‌های سالم و ذات‌الریه به دست آوردند [۱۵]. اسنوی و چاویکی یک روش مبتنی بر یادگیری عمیق برای تشخیص کووید-۱۹ ارائه دادند. آنها با معماری‌های مختلف شبکه عصبی کانولوشنی (CNN) روی ۶۰۸۷ تصویر CXR و سی‌تی آزمایش کردند و با استفاده از Inception-ResNetV2 به دقت ۹۲/۱۸٪ و با DenseNet-201 به دقت ۸۸/۰۹٪ دست یافتند [۱۶].


پیرا و همکاران از طبقه‌بندی چندکلاسه و سلسله‌مراتبی برای شناسایی کووید-۱۹ از CXR استفاده کردند. آنها آزمایش‌های خود را روی مجموعه داده RYDLS-20 انجام دادند و امتیازات F1 معادل ۰/۶۵ و ۰/۸۹ را برای رویکردهای چندکلاسه و سلسله‌مراتبی گزارش کردند [۱۷]. منگل و همکاران یک روش یادگیری عمیق به نام CovidAID برای تشخیص موارد کووید-۱۹ از CXR ارائه دادند. آنها با استفاده از بیش از ۶۰۰۰ تصویر CXR (شامل ۱۵۵ مورد مثبت) آزمایش کردند و به دقت ۹۰/۵٪ رسیدند [۱۸]. آصف و همکاران برای تشخیص ذات‌الریه ناشی از کووید-۱۹ از CXR، از یک روش مبتنی بر InceptionNetV3 مجهز به یادگیری انتقالی استفاده کردند. آنها داده‌ها را از منابع مختلف جمع‌آوری کرده (مجموعاً بیش از ۲۰۰۰ تصویر) و دقت اعتبارسنجی ۹۳٪ را گزارش دادند [۱۹].

با توجه به اینکه سیستم‌های تصویربرداری با اشعه ایکس در مقایسه با سی تی اسکن، رایج‌تر و مقرون به صرفه‌تر هستند، در این مقاله یک شبکه عصبی کانولوشنی کم عمق (CNN) برای تشخیص موارد مثبت کووید-۱۹ از موارد غیر کووید، با استفاده از تصاویر CXR پیشنهاد شده است.

#### مواد و روشها جمعآوری دادهها

ابزارهای مبتنی بر هوش مصنوعی (AI) برای آموزش دیدن کامل و پوشش همه‌ی آلودگی‌های احتمالی، به حجم کافی از داده نیاز دارند [۲۵]. با این حال، برخلاف سایر بیماری‌های تنفسی، تاکنون داده‌های تصویربرداری زیادی از موارد مثبت کووید-۱۹ در دسترس نیست.

داده‌های تصویربرداری رادیولوژی در بررسی بروز کووید-۱۹ استفاده شده‌اند. در این میان، سیستم‌های تصویربرداری اشعه ایکس قفسه سینه (CXR) نسبت به سیستم‌های سی تی اسکن رایج‌تر و مقرون به صرفه‌تر هستند. به عنوان نمونه، در اسپانیا (۲۰ مارس ۲۰۲۰)، رادیوگرافی قفسه سینه به عنوان روش اولیه تصویربرداری برای تشخیص عفونت کووید-۱۹ به کار گرفته شد. عکسبرداری از قفسه سینه معمولاً برای بیماران مشکوک یا تأیید شده، بر اساس پروتکل‌های بالینی خاص انجام می‌شود.



شکل ۱- نمونه های CXR: موارد مثبت کووید ۱۹ و موارد غیر کووید ۱۹ (ذات الریه)

#### شبکه عصبی کانولوشن کم عمق

شبکه‌های عصبی کانولوشن (CNNs) کلاسی از شبکه‌های عصبی هستند که بر اساس اصل یادگیری عمیق کار می‌کنند. معماری CNN اولیه شامل لایه‌های یکدرمیان کانولوشن و فشرده‌سازی است که در طبقه آخر پس از آنها یک یا چند لایه کاملاً متصل وجود دارد.

لایه کانولوشن جز اصلی این معماری است که وجود مجموعه‌ای از ویژگی‌ها را از ورودی تشخیص می‌دهد. این لایه شدت‌های مجموعه‌ای از هسددتهای کانولوشن را می‌توان به صورت زیر محاسبه کرد:

$f_c^k(m, n) = \sum_d \sum_{r,s} J_d(r, s) \times i_c^k(v, w)$  جایی که  $J_d(r, s)$  نمونه‌ای از بردار ورودی  $J_d$  است که در  $i_c^k(v, w)$  شاخص  $k$ ام هسته لایه  $c$ ام ضرب می‌شود. نگاشت خروجی هسته  $k$ ام به صورت زیر اندازه‌گیری می‌شود:

$$F_c^k = [f_c^k(1, 1), \dots, f_c^k(m, n), \dots, f_c^k(M, N)]$$

لایه فشرده‌سازی بین دو لایه کانولوشن مرتب شده است که در حالی که ارتباط آنها را دست نخورده نگه می‌دارد، اندازه بردارها را کاهش می‌دهد. این لایه اطلاعات مربوط به منطقه دامنه پذیرنده را جمع می‌کند و بازخورد آن منطقه با استفاده از  $Y_c^k = 0_p(F_c^k)$  به عنوان خروجی می‌دهد، جایی که  $Y_c^k$  نقشه و ویژگی ترکیبی لایه  $c$ ام را برای هسته  $k$ ام و  $p_0$  نوع عملیات فشرده‌سازی را تعیین می‌کند.

لایه متراکم ورودی مراحل قبلی را می‌پذیرد و در سطح جهانی خروجی تمام لایه‌های قبلی را ارزیابی می‌کند. از این رو، ترکیبی غیرخطی از ویژگی‌های مشخص شده که برای هدف طبقه‌بندی استفاده می‌شود، ایجاد می‌کند.

در این مقاله، یک معماری CNN کم عمق ارائه شده است که در مقایسه با معماری‌های عمیق، فقط از چهار لایه تشکیل شده است. انگیزه اصلی این امر طراحی معماری سدبک با حداقل تعداد پارامترها (وزنها) بود تا از زمان محاسباتی زیادی متحمل نشود. در نتیجه، معماری CNN کم عمق پیشنهادی (یا سدبک وزن) نه تنها از نظر محاسباتی کارآمد است بلکه قادر است از بیش برآزش احتمالی جلوگیری کند. بی‌شتر اوقات، معماری‌های عمیق به دلیل استفاده زیاد از پارامترها، و البته مدت زمان آموزش طولانی تر، آماده بیش برآزش هستند. بنابراین معماری CNN کم عمق پیشنهادی برای غربالگری انبوه جمعیت بخصوص در مناطق محدود منابع مناسب تر است.


شبکه از یک لایه کانولوشن منفرد تشکیل شده است و پس از آن یک لایه حداکثر فشرده‌سازی و یک لایه متراکم 256 بعدی وجود دارد. این شبکه در نهایت یک لایه متراکم 2 بعدی (خروجی) به همراه داشت. در ابتدا، تصاویر تا  $50 \times 50$  پیکسل

کوچک شده و به شبکه منتقل میشدند. لایه کانولوشن و اولین متراکم لایه عملکرد فعال سازی خطی اصلاح شده را دارد:  $f$

$$\sigma(z)_j = \frac{e^{z_j}}{\sum_{k=1}^K e^{z_k}}$$

که  $x = \max(0, x)$  ورودی یک نورون است. لایه متراکم نهایی یک تابع فعال سازی نرم افزاری دارد:


که در آن  $z_i$  عنصری از بردار ورودی  $z$  با اندازه  $K$  است. این شبکه به صورت نمودار در شکل ۲ ارائه شده است. تعداد پارامترهای تولید شده در جدول ۱ ارائه شده است.



شکل ۲- معماری CNN پیشنهادی

با استفاده از معماری CNN کم عمق پیشنهادی نقشه های تولید شده برای CXRهای موارد مثبت کووید ۱۹ و ذات الریه در شکل ۳ نشان داده شده است.





شکل ۳: تجسم نقشه ویژگی: یک مورد مثبت کووید ۱۹ و نقشه های مشخصه b-d مربوط به آن و مورد ذات الریه مثبت و نقشه های مشخصه f, g مربوط به آن آزمایشات  
برای اعتبارسنجی معماری پیشنهادی، اعتبارسنجی ۵ برابری برای همه آزمونها در نظر گرفته شد. این کار تحلیل آماری کامل از مدل را فراهم میکند. در هر دسته، معیارهای ارزیابی زیر را محاسبه کردیم: دقت، صحت، حساسیت (یادآوری)، وضوح، امتیاز 1F و سطح زیر منحنی ROC (AUC). آنها به صورت زیر محاسبه شدند:

$$\text{Accuracy (دقت)} = \frac{T_p + T_N}{T_p + T_N + F_p + F_N}$$

$$\text{Precision} = \frac{T_p}{T_p + F_p}$$

$$\text{Sensitivity (Recall)} = \frac{T_p}{T_p + F_N}$$

$$\text{Specificity} = \frac{T_N}{T_N + F_p}$$

$$F1 \text{ score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (1)$$

که در آن  $T_N$ ،  $F_p$ ،  $T_p$  و  $F_N$  به ترتیب به مثبت واقعی، منفی واقعی، مثبت کاذب و منفی کاذب اشاره دارند.

نتایج در مجموعه داده متعادل

از آنجا که ابزارهای یادگیری ماشین به طور سنتی به مجموعه داده های متعادل نیاز دارند، ابتدا تعداد برابری از موارد مثبت و منفی کووید-۱۹ را از دو مجموعه داده عمومی ترکیب کردیم:

۱. COVID-Chestxray-Dataset

۲. Chest X-Ray Pneumonia

(برای جزئیات کامل به بخش «مجموعه داده» مراجعه کنید). به طور خلاصه، در این مرحله برای آزمایش ها از ۳۲۱ تصویر مثبت کووید-۱۹ و ۳۲۱ تصویر غیرکووید (منفی) استفاده شد.

از آنجا که معماری کم عمق CNN پیشنهادی به تنظیم چندین پارامتر کلیدی وابسته است، مجموعه آزمایش های اولیه با هدف ارزیابی قابلیت آموزش مدل انجام گرفت. برای این منظور، پارامترهای اساسی زیر در نظر گرفته شد و سپس به طور جداگانه مورد بحث و تحلیل قرار می گیرند:

۱. اندازه تصویر: اندازه تصاویر CXR در مجموعه داده های اصلی متفاوت بود؛ بنابراین همه تصاویر به یک اندازه ثابت تغییر مقیاس داده شدند. در آزمایش ها، ابعاد از  $20 \times 20$  تا  $150 \times 150$  پیکسل متغیر بود. با مدل پیشنهادی، استفاده از اندازه  $25 \times 25$

پیکسل در مقایسه با اندازه‌های  $50 \times 50$  (دقت  $99/07\%$ ) و  $150 \times 150$  (دقت  $99/38\%$ )، نتیجه بهتری را ارائه داد (دقت  $99/53\%$ ). نتیجه اندازه  $20 \times 20$  مشابه نتیجه  $150 \times 150$  بود.

۲. تعداد فیلترها در لایه کانولوشن: در لایه کانولوشن، تعداد فیلترهای مختلفی شامل ۵، ۱۰، ۲۰ و ۳۰ مورد آزمایش شد. از میان این مقادیر، بهترین نتیجه آزمایشی زمانی حاصل شد که ۱۰ فیلتر مورد استفاده قرار گرفت.

۳. اندازه فیلتر: اندازه فیلتر کانولوشن نیز به صورت گام به گام از ۲ تا ۵ (یعنی  $2 \times 2$ ،  $3 \times 3$ ،  $4 \times 4$  و  $5 \times 5$ ) ارزیابی شد. در بین همه اندازه‌ها، بهترین نتیجه از فیلتر  $2 \times 2$  با دقت  $99/38\%$  به دست آمد.

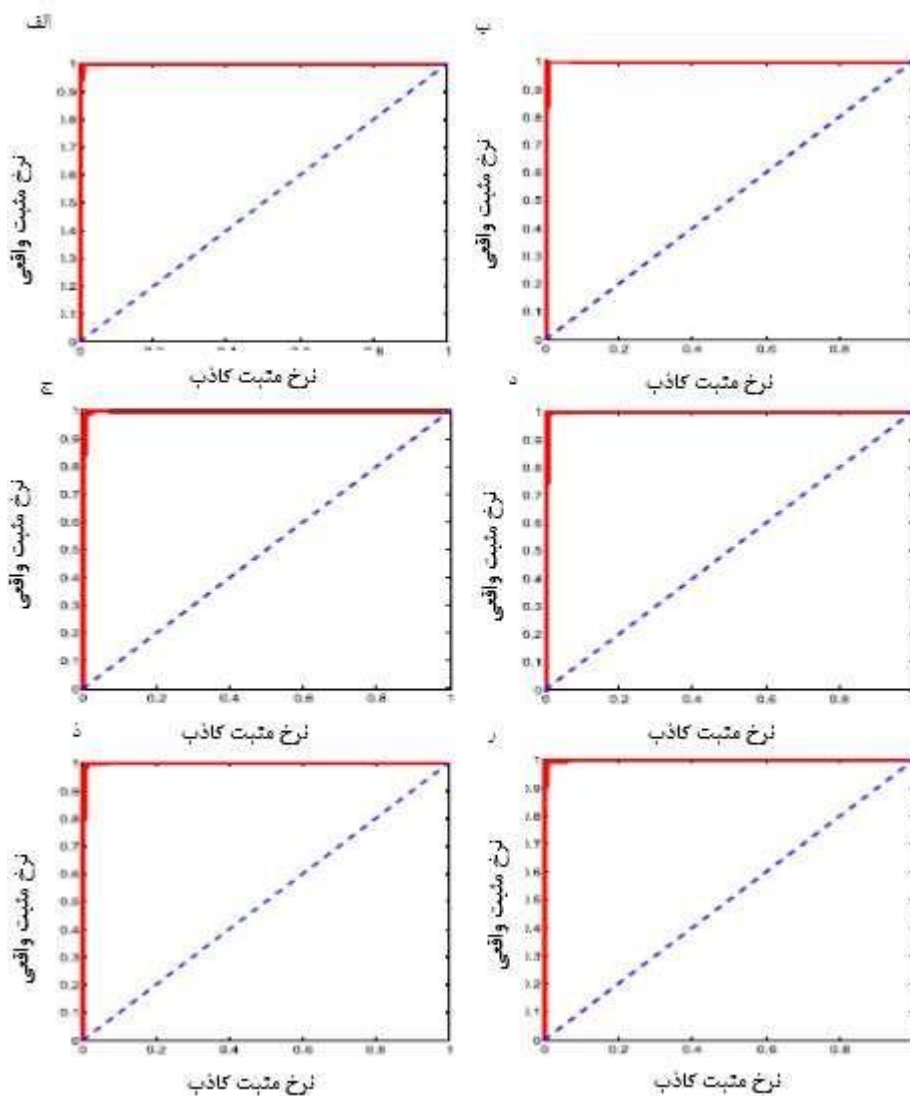
۴. اندازه پنجره فشرده‌ساز (Pooling size): مشابه اندازه فیلتر، اندازه پنجره‌های فشرده‌ساز نیز از ۲ تا ۴ (یعنی  $2 \times 2$ ،  $3 \times 3$  و  $4 \times 4$ ) متغیر در نظر گرفته شد. نتایج آزمایش‌ها نشان داد که با افزایش اندازه پنجره فشرده‌ساز، عملکرد مدل کاهش می‌یابد. بنابراین، اندازه پنجره فشرده‌ساز روی  $2 \times 2$  تثبیت شد که دقت  $98/38\%$  را ارائه داد.

جدول ۲- ماتریسهای درهم‌ریختگی اندازه دسته‌های مختلف

اندازه دسته: ۲۰			اندازه دسته: ۲۵ (بهترین نتیجه)		
	COVID-19	Non-COVID-19		COVID-19	Non-COVID-19
COVID-19	321	0	COVID-19	321	0
Non-COVID-19	3	318	Non-COVID-19	2	319
اندازه دسته: ۵۰			اندازه دسته: ۷۵		
	COVID-19	Non-COVID-19		COVID-19	Non-COVID-19
COVID-19	319	2	COVID-19	320	1
Non-COVID-19	3	318	Non-COVID-19	4	317
اندازه دسته: ۱۰۰			اندازه دسته: ۱۲۵		
	COVID-19	Non-COVID-19		COVID-19	Non-COVID-19
COVID-19	320	1	COVID-19	320	1
Non-COVID-19	3	318	Non-COVID-19	3	318

اندازه دسته: در طول دوره آموزش، اندازه دسته‌های مختلف استفاده می‌شود، از ۲۵ تا ۱۲۵ نمونه با اختلاف ۲۵ شروع می‌شود. از بین همه این اندازه‌ها، بهترین نتایج از ۲۵ نمونه {دقت =  $69/99\%$ } بدست آمده است. چون بهترین نتایج برای ۲۵ نمونه به دست آمد، اندازه دسته با ۲۰ نمونه را نیز آزمایش کردیم تا دقت‌های مشابه را بررسی کنیم. در هر دو دسته ۲۰ و ۲۵ نمونه، همه ۳۲۱ مورد مثبت کووید ۱۹ به درستی شناسایی شد. با این حال، در مورد ۲۰ نمونه، ۳۱۸ مورد غیر کووید ۱۹

مورد به درست ی شناسایی شده است در حال ی که در مورد 25 نمونه، ۳۱۹ مورد غیر کووید ۱۹ به درستی شناسایی شده است. نتایج دقیق آزمون آزمایشی برای اندازه دسته های مختلف در جدول 2 ارائه شده است. نتایج بیشتر با توجه به چندین معیار عملکردی، مانند حساسیت، وضوح، دقت، امتیاز 1F و AUC که در جدول ۳ شرح داده شده است، تحلیل شد. برای درک بهتر، منحنیهای ROC مربوطه در شکل 4 ارائه شده است.





شکل ۴ - منحنی ROC اندازه دسته‌های مختلف: الف) اندازه دسته 20؛ ب) اندازه دسته 25؛ ج) اندازه دسته 50؛ د) اندازه دسته 75؛ ذ) اندازه دسته 100؛ ر) اندازه دسته 125. اندازه دسته 50 از همه بهتر است.

جدول ۳- معیارهای عملکردی اندازه دسته‌های مختلف

معیارها	اندازه دسته					
	20	25	50	75	100	125
حساسیت	1	1	0.9938	0.9969	0.9969	0.9969
وضوح	0.9907	0.9938	0.9907	0.9875	0.9907	0.9907
صحت	0.9907	0.9938	0.9907	0.9877	0.9907	0.9907
نرخ مثبت کاذب	0.0093	0.0062	0.0093	0.0125	0.0093	0.0093
نرخ منفی کاذب	0	0	0.0062	0.0031	0.0031	0.0031
دقت (%)	99.53	99.69	99.22	99.22	99.38	99.38
امتیاز F1	0.9953	0.9969	0.9922	0.9922	0.9938	0.9938
AUC	0.9997	0.9995	0.9993	0.9991	0.9993	0.9996

در کل، برای معماری CNN کم عمق پیشنهادی، پارامترها برای اهداف آزمون آینده تنظیم شدند.

تا اکنون، مشاهده کردیم که بهترین امتیازات عملکردی زمانی بدست می‌آیند که معماری از 10 فیلتر با اندازه 2x2 در لایه کانولوشن، اندازه دسته 25 نمونه تصویر 25x25 CXR پیکسل و اندازه پنجره 2x2 لایه فشرده ساز استفاده کند. با اسد تفاده از این پارامترها، نتایج آزمایش‌ها در جدول ۳ ارائه شده اسدت. برای درک بهتر، منحنیهای ROC مربوطه در شکل 4 ارائه شده اسدت. مدل پیشنهادی بالاترین دقت ممکن 99/69 % را با AUC 0/9995 ارائه می‌دهد. توجه به این نکته مهم اسدت که مدل پیشنهادی نرخ منفی کاذب 0 را دریافت کرده اسدت.

اکنون میتوان نتایج را برای مقایسه با سایر مدل‌های یادگیری عمیق موجود بررسی کرد. برای مقایسه، مجموعه دقیقاً همین مجموعه داده‌های آزمایش‌شده در سددایر معماریهای معروف یادگیری عمیق (DL) مانند [27] MobileNet، 3InceptionV و [29] 50ResNet اعمال شدد. امتیازات عملکرد آنها همراه با تعداد پارامترهای تولید شدد در جدول 4 ارائه شده اسدت. علاوه بر این، منحنی ROC مربوطه در شکل 5 ارائه شده اسدت. از بین این سه معماری، MobileNet بهترین عملکرد را دارد و پس از آن 3InceptionV و 50ResNet قرار دارند. MobileNet به طور کلی دقت 99/69 % به دسدت آورد در حالی که



ICAICS

<https://icaics.ir>

[info@icaics.ir](mailto:info@icaics.ir)

اولین کنفرانس بین‌المللی هوش مصنوعی  
و علوم کامپیوتری نو ظهور: از الگوریتم تا آینده‌نگری

First International Conference on Artificial Intelligence  
and Emerging Computer Science: From Algorithm to Foresight


March 17, 2026-GEORGIA

۲۶ اسفند ماه ۱۴۰۴ - گرجستان

50ResNet به طور کلی دقت 95/02% را به دسددت آورد. در مورد 3InceptionV و 50ResNet، که محدود به دقت نیست ، مدل پیشنهادی با تفاوت چشمگیر از نظر سیر معیارها، مانند حسدداسدددیت، نرخ منفی کاذب ، دقت و AUC، از اینها بهتر عمل کرد. حتی اگر، تفاوت بین CNN کم عمق پیشنهادی و MobileNet کم بود، مهم است که به تعدادی از پارامترهای استفاده شده نگاه ی بیندازید. با توجه به مسدددثله پیچیدگی محاسدددباتی، مدل پیشدددذنهادی به ۳۱۰۸۱۰ عدد پارامتر نیاز داشدددت که 99/8۳% کمتر از 3InceptionV، 95/8۱% کمتر از MobileNet و 99/۳7% کمتر از 50ResNet بود.

جدول ۴- مقایسه عملکرد با سایر مدل‌های یادگیری عمیق برای مجموعه داده متعادل

معیارها	InceptionV3	MobileNet	ResNet50	CNN پیشنهادی
حساسیت	1.0000	1.0000	0.9252	1.0000
وضوح	0.9751	0.9938	0.9751	0.9938
صحت	0.9757	0.9938	0.9738	0.9938
نرخ مثبت کاذب	0.0249	0.0062	0.0249	0.0062
نرخ منفی کاذب	0.0000	0.0000	0.0748	0.0000
دقت (%)	98.75	99.69	95.02	99.69
امتیاز F1	0.9877	0.9969	0.9489	0.9969
AUC	0.9877	0.9969	0.9355	0.9995
	26,522,146	7,423,938	49,278,594	310,810



شکل 5- منحنی معماری های الف (ROC ب) InceptionV3 ج) MobileNet د) ResNet50  
نتایج در مجموعه داده نامتعادل



ICAICS

<https://icaics.ir>

[info@icaics.ir](mailto:info@icaics.ir)

اولین کنفرانس بین المللی هوش مصنوعی  
و علوم کامپیوتری نوظهور: از الگوریتم تا آینده نگر

First International Conference on Artificial Intelligence  
and Emerging Computer Science: From Algorithm to Foresight


March 17, 2026-GEORGIA

۲۶ اسفند ماه ۱۴۰۴ - گرجستان

چون اندازه مجموعه داده ها با گذشت زمان (از ژانویه ۲۰۲۰) متفاوت است، کارهایی که در پیشرفته ترین مقالات گزارش شده ،مجموعه داده های مختلف را در یک سناریوی نامتعادل استفاده میکنند. دقیقاً با همین روند، در این بخش ، مجموعه دیگری از آزمون های آزمایشی را با استفاده از مجموعه کامل داده های کگل (<https://www.kaggle.com/paultimothymooney/chest-xray-pneumonia>) انجام دادیم که در مجموع ۵۸۵۶ عدد CXR استفاده شد (۱۵۸۳، عادی و ۴۲۷۳، ذات الریه). در نتیجه، اندازه دسته غیر کووید ۱۹ ۱۷۲۴/۳۰ % بزرگتر از اندازه گروه مثبت کووید ۱۹ بود.

مجموعه داده نامتعادل به طور معمول سناریوی دنیای واقعی را به تصویر میکشد. شبیه حالت قبل، ماتریس درهم ریختگی در جدول ۵ ارائه شده است. نتایج با توجه به چندین معیار عملکرد، مانند حساسیت، وضوح، دقت، امتیاز 1F و AUC که در جدول شرح داده شده است. بیشتر تحلیل شد (برای سایر معماریهای ثابت نیز بررسی شد). برای درک بهتر، منحنی های ROC مربوطه در شکل ۶ ارائه شده است.





شکل 6 - منحنی ROC الف (3InceptionV، ب (MobileNet، ج (50ResNet، د) شبکه پیشنهادی  
جدول 5- ماتریس‌های درهم‌ریختگی مجموعه داده‌های نامتعادل

	COVID-19	Non-COVID-19
COVID-19	311	10
Non-COVID-19	9	5847

در چنین مجموعه داده‌ای نامتعادل، به دقت 99/69٪ دست یافتیم. در این سناریو، نرخ منفی کاذب فقط 0015.0 بدست آمد که به شناسایی ثابت موارد مثبت کووید ۱۹ در میان ذات الریه و CXR سالم اشاره دارد. علاوه بر این، نرخ منفی کاذب 0.0۳۱۲ بدست آمد که نشان‌دهنده توانایی شبکه در مدیریت کلاس منفی نامتعادل است. این اغلب سناریویی است که در دنیای واقعی هنگام غربالگری گسترده در شرایط فعلی ضروری است. در بین معماریهای دیگر، 3InceptionV بهترین نتیجه را با 99/0۱٪

به دست آورد. با این حال، مقدار حساسیت 88۱6.0 بود که کمتر بود. در مورد شبکه های دیگر، عدم تعادل داده ها یک مشکل اساسی بود که در جدول 6 مشهود است.

جدول 6- معیارهای عملکردی داده های نامتعادل

معیارها	InceptionV3	MobileNet	ResNet50	پیشنهادی CNN
حساسیت	0.8816	0.0000	0.0000	<b>0.9688</b>
وضوح	0.9961	1.0000	1.0000	<b>0.9985</b>
صحت	0.9248	0.0000	0.0000	<b>0.9719</b>
نرخ مثبت کاذب	0.0039	0.0000	0.0000	<b>0.0015</b>
نرخ منفی کاذب	0.1184	1.0000	1.0000	<b>0.0312</b>
دقت (%)	99.01	94.80	94.80	<b>99.69</b>
امتیاز F1	0.9027	0.0000	0.0000	<b>0.9704</b>
AUC	0.9870	0.5000	0.5000	<b>0.9969</b>

Bold entries denote best result


نتایج آزمایشات مجموعه داده های گسترده در یک مجموعه داده های گسترده از <https://github.com/ieee8023/covid-chestxray-dataset> انجام شد، جایی که CXRهای 439 مورد کووید ۱۹ از این مجموعه داده دست آمد. تعداد مشابهی از CXR هدایات الیه غیرکووید ۱۹ از <https://www.kaggle.com/paultimothymooney/chest-xray-pneumonia> برای کنار هم قرار دادن کلاس منفی استفاده شد. درهم ریختگی های بین کلاس برای این مجموعه داده در جدول 7 ارائه شده است. معیارهای عملکردی فوق الذکر نیز برای این تنظیم محاسبه شده اند که در جدول 8 ذکر شده است. منحنی ROC این مجموعه در شکل 7 ارائه شده است. ذکر شده است که نتایج در افزایش مجموعه داده انحراف زیادی ندارند. علاوه بر این، موارد جدید اضافه شده در داده ها از نظر کیفیت متفاوت بودند. این امر به مناسب بودن سیستم سناریوهای دنیای واقعی اشاره دارد، جایی که اندازه داده ها با گذشت زمان تغییر میکند.

جدول 7- ماتریس های درهم ریختگی مجموعه داده گسترده

	COVID-19	Non-COVID-19
COVID-19	437	2
Non-COVID-19	4	435

جدول 8- معیارهای عملکردی داده های گسترده

معیارها	CNN پیشنهادی
حساسیت	0.9954
وضوح	0.9909
صحت	0.9909
نرخ مثبت کاذب	0.0091
نرخ منفی کاذب	0.0046
دقت (%)	99.32
امتیاز F1	0.9932
AUC	0.9997



شکل 7- منحنی ROC مجموعه داده گسترده

## بحث و گفتگو

برای غربالگری COVID - 19، چون حساسیت احتمال این که مدل در تشخیص بیماران مثبت کووید ۱۹ اشتباه نکند، اندازه گیری می کند، در مراحل اولیه همه گیری در اعتبار سنجی مدل نقش مهمی دارد. در نتیجه، به جلوگیری از گسترش بیشتر کووید ۱۹ کمک میکند. استدلال مشابه در محاسبه نرخ منفی کاذب است. علاوه بر این، دقت بیانگر احتمال تشخیص موارد مثبت کووید ۱۹ است. چون احتمال اینکه یک مدل در طبقه بندی بیماران مثبت کووید ۱۹ به عنوان عادی (با در نظر گرفتن هشدارهای دروغین) اشتباه کند، مفید است و در مراحل بعدی همه گیری، وقتی منابع پزشکی محدود به بیماران کووید ۱۹ می باشد، مهم است. دقت برای اندازه گیری عملکرد کلی مدل محاسبه شد. از طرف دیگر، AUC میزان پایداری سیستم را نشان میدهد: درجه اندازه گیری میزان تفکیک پذیری (بین دو دسته: کووید ۱۹ و غیرکووید ۱۹).

در مورد مجموعه داده متعادل، مدل پیشنهادی با استفاده از پروتکل اعتبار سنجی 5 برابری، میانگین امتیاز حساسیت 0.1 را به دست آورد. این بدان معنی است که نرخ منفی کاذب 0 بوده است. مدل پیشنهادی با دقت متوسط 0/9938 گزارش شده است. چون کار به ویژه روی شناسایی موارد مثبت کووید ۱9 متمرکز بود، بحث به حساسیت، نرخ مثبت کاذب و دقت محدود میشود. به همین ترتیب، معیارهای دیگر (همانطور که در جدول ۳ ارائه شده است) برای آزمایش بیشتر استحکام مدل مهم هستند. برای مجموعه داده نامتعادل، امتیاز حساسیت 9688.0 بدست آمد. نرخ منفی کاذب با توجه به نامتعادل بودن و تشابه بین طبقاتی در مجموعه داده بسیار کم بود. در این حالت، دقت 99.69٪ با مقدار 0.9996AUC بدست آمد. سایر معیارهای مهم مجموعه داده های نامتعادل در جدول 6 همراه با منحنی ROC در شکل 6 ارائه شده است.

#### نتیجه گیری و کارهای آینده

به طور کلی، در این مقاله، یک معماری کم عمق متنا سب با CNN کم وزن را برای تشخیص موارد مثبت کووید ۱۹ با استفاده از CXR ها در برابر موارد غیر کووید ۱۹ پیشنهاد شده است. این آزمایشات بر روی مجموعه داده CXR های کووید ۱۹ مثبت، ذاتالریه - مثبت و سالم انجام شد. برای تأیید دقت، از پروتکل اعتبار سنجی 5 برابر در هر دو سناریوی مجموعه داده متعادل و نامتعادل استفاده شد که در آن ۳۲۱ مورد مثبت کووید ۱۹ استفاده شده است. با استفاده از (الف) ابزارهای محبوب DL، مانند MobileNet، InceptionV3 و 50ResNet، معماری متناسددب CNN پیشنهادی را مقایسه کرده ایم. و (ب) کارهای پیشرفته تشخیص COVID - 19 با استفاده از CXR ها، در نظر گرفته شود. مدل پیشنهادی بهتر از همه بوده و از نظر محاسباتی کارآمد است زیرا به تعداد پارامترهای کمتری نیاز دارد. چون معماری CNN کم عمق پیشنهادی منفی کاذب ندارد، میتوان از آن برای غربالگری موارد مثبت کووید ۱۹ در اشعه X قفسه سینه استفاده کرد. در آینده، معماری شبکه با هدف به حداقل رساندن موارد مثبت کاذب، بررسی میشود. همچنین قصد داریم داده ها را اضافه کنیم که به ما کمک میکند تا از مشکلی که در حال حاضر با آن روبرو هستیم، یعنی کمبود داده کافی، جلوگیری کنیم.

#### References

1. Novel coronavirus – China. 2020. <http://www.who.int/csr/don/12-january-2020-novel-coronaviruschina/en/>. Accessed 25 March 2020.



2. Summary of probable SARS cases with onset of illness from 1 November 2002 to 31 July 2003. 2003. [https://www.who.int/csr/sars/country/table2004\\_04\\_21/en/](https://www.who.int/csr/sars/country/table2004_04_21/en/). Accessed 25 March 2020.
3. Middle East respiratory syndrome coronavirus (MERS-CoV). 2019. <http://www.who.int/emergencies/mers-cov/en/>. Accessed 25 March 2020.
4. Huang C, et al. Clinical features of patients infected with 2019 novel coronavirus in Wuhan, China. Lancet. 2020;395(10223):497–506. [https://doi.org/10.1016/S0140-6736\(20\)30183-5](https://doi.org/10.1016/S0140-6736(20)30183-5). Epub 2020 Jan 24.
5. Fang Y, Zhang H, Xie J, Lin M, Ying L, Pang P, Ji W. Sensitivity of chest CT for COVID-19: comparison to RT-PCR in radiology. 2020. <https://doi.org/10.1148/radiol.2020200432>.
6. NG M et al. Imaging profile of the COVID-19 infection: radiologic findings and literature review in radiology. Cardiothoracic Imaging 2(1). 2020. <https://doi.org/10.1148/ryct.2020200034>.
7. Li Y, Xia L. Coronavirus disease 2019 (COVID-19): role of chest CT in diagnosis and management. Am J Roentgenol: 1–7. 2020. <https://doi.org/10.2214/AJR.20.22954>.
8. WHO Coronavirus disease (COVID-2019) situation reports. 2020. <https://www.who.int/emergencies/diseases/novel-coronavirus-2019/situation-reports>, report #133.
9. Zhou S, Wang Y, Zhu T, Xia L. CT features of coronavirus disease 2019 (COVID-19) pneumonia in 62 patients in Wuhan, China. Am J Roentgenol: 1–8. <https://doi.org/10.2214/AJR.20.22975>.
10. Ye Z, Zhang Y, Wang Y, Huang Z, Song B. Chest CT manifestations of new coronavirus disease 2019 (COVID-19): a pictorial review. European Radiology. 2020.
11. Yoon S, et al. Chest radiographic and CT findings of the 2019 novel coronavirus disease (COVID19): analysis of nine patients treated in Korea. Korean Journal of Radiology. 2020;21(4):494–500.
12. Abbas A, Abdelsamea MM, Gaber MM. Classification of COVID-19 in chest X-ray images using DeTraC deep convolutional neural network. arXiv:2003.13815. 2020.
13. Sethy PK, Behera SK. Detection of coronavirus disease (COVID-19) based on deep features. Preprints 2020, 2020030300. 2020.
14. Li X, Li C, Zhu D. COVID-Mobilexpert: On-device COVID-19 screening using snapshots of chest X-ray. arXiv:2004.0304243:915–.0202 .529
15. Das D, Santosh KC, Pal U. Truncated inception net: COVID-19 outbreak screening using chest X-rays. Physical and Engineering Sciences in Medicine: 1–.0202 .11
16. El asnaoui K, Chawki Y. Using X-ray images and deep learning for automated detection of coronavirus disease. Journal of Biomolecular Structure and Dynamics: 1–.0202 .22
17. Pereira RM, Bertolini D, Teixeira LO, Silla CN Jr, Costa YM. COVID-19 identification in chest X-ray images on flat and hierarchical classification scenarios. Comput Methods Prog Biomed: 105532. .0202
18. Mangal A, Kalia S, Rajgopal H, Rangarajan K, Namboodiri V, Banerjee S, Arora C. CovidAID: COVID-19 detection using chest X-ray. ar Xiv:2004.09803. 2020.
19. Asif S, Wenhui Y, Jin H, Tao Y, Jinhai S. Classification of COVID-19 from chest X-ray images using deep convolutional neural networks. medRxiv. 2020.
20. Luz E, Silva PL, Silva R, Moreira G. Towards an efficient deep learning model for COVID-19 patterns detection in X-ray images. arXiv:2004.05717. 2020.

21. Szegedy C, Vanhoucke V, Ioffe S, Shlens J, Wojna Z. Rethinking the inception architecture for computer vision. In: Proceedings of the IEEE conference on computer vision and pattern recognition; 2016. p. 2818–2826.
22. Zhang J, Xie Y, Li Y, Shen C, Xia Y. COVID-19 screening on chest X-ray images using deep learning based anomaly detection. In arXiv. 2020.
23. Gan F, Luo C, Liu X, Wang H, Peng L. Fast terahertz coded aperture imaging based on convolutional neural network. Appl Sci. 2020;10:2661.
24. Wang L, Lin ZQ, Wong A. COVID-net: a tailored deep convolutional neural network design for detection of COVID-19 cases from chest radiography images. In arXiv. 2020.
25. Santosh KC. AI-driven tools for coronavirus outbreak: need of active learning and cross-population train/test models on multitudinal/multimodal data. J Med Syst. 2020;44:93.
26. Krizhevsky A, Sutskever I, Hinton GE. Imagenet classification with deep convolutional neural networks. In: Advances in neural information processing systems; 2012. p. 1097–1105.
27. Chen H, Su C. An enhanced hybrid MobileNet. In: 2018 9th international conference on awareness science and technology (iCAST), Fukuoka; 2018. p. 308–312.
28. Apostolopoulos ID, Mpesiana TA. Covid-19: automatic detection from x-ray images utilizing transfer learning with convolutional neural networks. Physical and Engineering Sciences in Medicine: .0202 .1
29. Akiba T, Suzuki S, Fukuda K. Extremely large minibatch sgd: training resnet-50 on imagenet in 15 minutes. arXiv:1711.04325.