

## Lung Image Retrieval Based on Supervised Hashing, MRMR Feature Selection and Deep Convolutional Neural Network

Fatemeh Mahmoodi<sup>1</sup> MSc., Farsad Zamani Boroujeni<sup>2\*</sup> Assistant Professor

1- Department of Computer Engineering, Isfahan (Khorasgan) Branch, Islamic Azad University, Isfahan, Iran.

2\*- Department of Computer Engineering, Isfahan (Khorasgan) Branch, Islamic Azad University, Isfahan, Iran.

<sup>1</sup>Fmahmoodi90@yahoo.com, <sup>2\*</sup>F.zamani@khuif.ac.ir

Corresponding author's address: Farsad Zamani Boroujeni, Faculty of Computer Engineering, Islamic Azad University Isfahan (Khorasgan) Branch, Isfahan, Iran

**Abstract-** On the one hand, the development of modern medicine has made it possible to store medical images, and on the other hand, due to the daily increase in the storage of such data, it has also made their management and recovery difficult. Considering that medical images are used as a powerful tool in the early diagnosis of most diseases, providing a powerful system that can retrieve images with similar content from the growing volume of medical images is very effective in control and treatment. In this article, a medical image retrieval system based on Siamese neural network consisting of two convolutional sub-networks with 13 layers is presented. To reach the optimal subset of deep features extracted by Siamese, the Minimum Redundancy-Maximum Relevant (mRMR) technique has been used, and after binary hashing of the features, similar images are retrieved using Hamming distance. Although the proposed model is capable of retrieving a variety of gray scale medical images, two types of lung images have been used to evaluate it, including CT scan images of Covid-19 patients in the CT-COV database and X-ray images of pneumonia patients in the Pneumonia database. The results indicate that the proposed method in the Covid database has been able to achieve an average precision of 93.83% and 92.73% in 5 and 10 retrieved images respectively, and an average precision of 100% in the pneumonia database, which is compared to previous methods have been able to improve the retrieval of lung images.

**Keywords-** Supervised Hashing, Convolutional Neural Network, Deep Learning, Lung Image Retrieval, Minimal-Redundancy-Maximal-Relevance (MRMR)

## بازیابی تصاویر پزشکی ریه با استفاده از درهم سازی با ناظر، انتخاب ویژگی mRMR و شبکه‌های عصبی کانولوشنی عمیق

فاطمه محمودی<sup>۱</sup> کارشناسی ارشد، فرساد زمانی بروجنی استادیار<sup>۲\*</sup>

۱- گروه کامپیوتر، واحد اصفهان (خوراسگان)، دانشگاه آزاد اسلامی، اصفهان، ایران.

\*۲- گروه کامپیوتر، واحد اصفهان (خوراسگان)، دانشگاه آزاد اسلامی، اصفهان، ایران.

<sup>1</sup>fahmoodi90@yahoo.com, <sup>2</sup>\*f.zamani@khuif.ac.ir

\* نشانی نویسنده مسئول: فرساد زمانی بروجنی، اصفهان، خیابان ارغوانیه، دانشگاه آزاد اسلامی واحد اصفهان (خوراسگان)، دانشکده فنی و مهندسی.

چکیده- توسعه پزشکی نوین از یک طرف امکان ذخیره‌سازی تصاویر پزشکی را فراهم کرده است و از طرف دیگر بدلیل افزایش روزانه ذخیره‌سازی این قبیل داده، مدیریت و بازیابی آن‌ها را نیز با مشکل مواجه ساخته است. با توجه به آنکه تصاویر پزشکی به عنوان ابزاری قدرتمند در تشخیص زودرس اغلب بیماری‌ها مورد استفاده هستند، ارائه سیستمی توانمند که بتواند از حجم رو به رشد تصاویر پزشکی، تصاویری با محتوای مشابه را بازیابی نماید، در کنترل و درمان بسیار موثر است. در این مقاله یک سیستم بازیابی تصاویر پزشکی مبتنی بر شبکه عصبی سیامی متشکل از دو زیر شبکه کانولوشن با ۱۳ لایه ارائه شده است. برای رسیدن به زیر مجموعه بهینه از ویژگی‌های عمیق استخراج شده توسط سیامی، از تکنیک حداقل افزونگی - حداکثر همبستگی (mRMR) استفاده شده است و پس از درهم‌سازی باینری ویژگی‌ها، بازیابی تصاویر مشابه با استفاده از فاصله Hamming انجام می‌شود. اگر چه مدل مطرح قابلیت بازیابی انواع تصاویر پزشکی سطح خاکستری را دارد، اما برای ارزیابی آن، از دو نوع تصاویر ریه، شامل تصاویر سی تی اسکن بیماران کووید-۱۹ در پایگاه داده CT-COV و تصاویر اشعه X بیماران ذات‌الریه در پایگاه Pneumonia استفاده شده است. نتایج حاکی از آن است که روش پیشنهاد شده در پایگاه کووید به ترتیب در ۵ و ۱۰ تصویر بازیابی توانسته است به میانگین دقت ۹۳.۸۳٪ و ۹۲.۷۳٪ و در پایگاه داده ذات‌الریه به میانگین دقت ۱۰۰٪ دست یابد که در مقایسه با روش‌های پیشین توانسته است بازیابی تصاویر ریه را بهبود بخشد.

واژه‌های کلیدی: درهم سازی، شبکه عصبی سیامی، انتخاب ویژگی با حداقل افزونگی - حداکثر همبستگی، بازیابی تصاویر ریه.

### ۱- مقدمه

داده‌های چندرسانه‌ای در دسترس هستند. یافتن اطلاعات مورد نظر از این مجموعه گسترده پایگاه داده بسیار مهم است. داده‌های پزشکی نیز از این امر مستثنی نیستند و روزانه بدلیل وجود سیستم‌های نوین ذخیره‌سازی امکان ذخیره‌سازی داده‌های پزشکی از جمله انواع مختلف تصاویر تهیه شده با دستگاه‌های اشعه X<sup>۱</sup>، سی تی اسکن<sup>۲</sup> و غیره فراهم شده است [۱]. در حوزه پزشکی و سلامت بدلیل کاربردهای حیاتی داده‌های پزشکی برای درمان و تشخیص بیماری‌های مختلف، یافتن اطلاعات مورد نظر در یک بازه زمانی

در طی سال‌های اخیر، محققان توجه زیادی به سیستم‌های بازیابی تصویر مبتنی بر محتوا (CBIR)<sup>۱</sup> داشته‌اند و سعی در ارائه مدل‌هایی داشته‌اند که بتواند با موفقیت بازیابی تصاویر را از پایگاه داده‌های چندرسانه‌ای در مقیاس بزرگ انجام دهد. به طور معمول، روزانه چندین گیگابایت محتوای چندرسانه‌ای توسط دوربین‌های دیجیتال، تلفن همراه و رایانه در حال تولید است و به صورت پایگاه

• بررسی روش در دو نوع تصاویر ریه شامل ستی اسکن ریه بیماران کووید-۱۹ و اشعه ایکس بیماران ذات‌الریه برای ارائه راهکاری تعمیم پذیر.

در ادامه این مقاله، در بخش ۲ معماری‌های عمیق معرفی می‌شوند و مطالعات این حوزه بررسی می‌شوند. در بخش ۳ روش پیشنهادی معرفی می‌شود و در بخش ۴ نتایج ارزیابی روش ارائه می‌شوند و در بخش پایانی نتیجه‌گیری ارائه خواهد شد.

## ۲- تاریخچه

### ۲-۱- بازیابی مبتنی بر محتوا

سیستم‌های بازیابی مبتنی بر محتوا همانطور که در شکل (۱) ارائه شده است، در دو گام اساسی برخط<sup>۲</sup> و برون خط<sup>۱</sup> از دو مرحله موثر استخراج ویژگی و بررسی تشابه تشکیل شده‌اند. در این سیستم‌ها در فاز برون خط استخراج ویژگی از تصاویر انجام می‌شود و در فاز برخط فرآیند بازیابی تصاویر انجام می‌شود [۴].

در فاز اول پایگاه داده‌ای شامل بردارهای ویژگی<sup>۱</sup> استخراج شده از تصاویر تشکیل می‌گردد؛ در فاز دوم میزان شباهت بردار ویژگی تصویر پرس و جو با استفاده از معیارهای فاصله مثل فاصله اقلیدسی، با بردارهای ویژگی در پایگاه داده، محاسبه می‌شود؛ سپس تصاویری که در پایگاه داده دارای بیشترین شباهت و حداقل فاصله ممکن از تصویر پرس‌وجو هستند، به صورت نزولی مرتب‌سازی شده و به کاربر ارائه می‌شوند.

در این قبیل سیستم، اگر در فاز اول مدل قادر به استخراج ویژگی‌های مناسب از تصاویر نباشد و قادر به ایجاد یک نمایش مناسب از محتوای بصری تصویر نباشد، تصاویر بازیابی شده از نظر بصری هیچگونه شباهتی با تصویر پرس‌وجو نخواهد داشت. در نتیجه تصاویر ارائه شده مطابق با درخواست کاربر نخواهد بود؛ این مسئله در سیستم‌های بازیابی تصاویر پزشکی بسیار مشکل‌ساز خواهد بود.

استخراج ویژگی با هدف به دست آوردن ویژگی‌هایی که نشان دهنده یک تصویر است، انجام می‌شود. در این مرحله ویژگی‌ها در دو حالت سراسری<sup>۱</sup> و محلی<sup>۱۱</sup> استخراج می‌شوند. ویژگی سراسری برای تصویر  $Q$  یک بردار منفرد است که می‌تواند به صورت  $\vec{V}_Q = (v_1, v_2, \dots, v_d)$  نمایش داده شود که در آن  $d$  ابعاد بردار ویژگی سراسری است [۵]. در مقابل، ویژگی محلی مجموعه‌ای از بردارها است که می‌تواند به صورت  $S_Q = \{\vec{V}_1, \vec{V}_2, \dots, \vec{V}_n\}$  نمایش داده شود، بطوری که  $(1 \leq i \leq n)$   $\vec{V}_i = (v_{i1}, v_{i2}, \dots, v_{id})$  است [۵].

کوتاه بسیار حائز اهمیت می‌باشد؛ چرا که این مسئله با زندگی بیماران و درمان پذیری و یا برگشت ناپذیری بیماری آن‌ها مرتبط است.

سیستم‌های بازیابی تصویر مبتنی بر محتوا از جمله مدل‌هایی هستند که می‌توانند در کنترل این چالش موثر واقع شوند [۱]. سیستم‌های بازیابی تصاویر، با دریافت یک تصویر پرس‌وجو<sup>۱</sup> بدنال یافتن نزدیکترین و مشابه‌ترین تصاویر به تصویر پرس‌وجو هستند. در سیستم‌های بازیابی تصویر غالباً، ویژگی‌های سطح پایین تصویر مثل رنگ و بافت و شکل استخراج شده و بازیابی تصاویر مشابه، با کمک این قبیل ویژگی‌ها انجام می‌شود [۲].

موفقیت یک سیستم بازیابی مبتنی بر محتوا کاملاً وابسته به کیفیت ویژگی‌های استخراج شده است؛ به این معنی که اگر سیستم قادر به ایجاد یک نمایش مناسب از محتوای بصری تصویر نباشد، تصاویر مشابه کاملاً متفاوت در نظر گرفته می‌شود، در نتیجه تصاویر به دست آمده مطابق با انتظارات کاربر نخواهد بود [۲].

از طرف دیگر استخراج انواع متنوع ویژگی برای رسیدن به اطلاعات کافی از تصاویر، باعث می‌گردد که ابعاد ویژگی‌های تصاویر در پایگاه داده افزایش یافته و بار محاسباتی و حافظه مصرفی سیستم نیز افزایش یابد. این امر گاه‌ها منجر به کاهش صحت مدل در بازیابی تصاویر مشابه نیز می‌گردد. یکی از راه‌حلی‌هایی که برای رفع این مشکل در سال‌های اخیر به شدت مورد توجه بوده است، استفاده از شبکه‌های عصبی عمیق کانولوشن<sup>۵</sup> برای استخراج ویژگی از تصاویر است؛ این شبکه‌ها قادر هستند دانش کافی و مختصری از تصاویر را استخراج نمایند [۳].

در این مطالعه نیز در راستای کنترل محدودیت‌های روش‌های استخراج ویژگی سنتی، یک سیستم بازیابی تصاویر پزشکی ریه ارائه شده است که بواسطه شبکه‌های عصبی عمیق، فرآیند استخراج ویژگی را انجام داده و با تکنیک انتخاب ویژگی mRMR<sup>۲</sup> سعی در رسیدن به بهترین ویژگی‌ها دارد. در این روش از معماری جدیدی تحت عنوان شبکه‌های سیامی که یک معماری جفتی متشکل از دو شبکه کانولوشن است، برای استخراج ویژگی از تصاویر استفاده شده است.

نقاط کلیدی این روش به شرح زیر است:


- استفاده از شبکه عصبی عمیق سیامی متشکل از دو زیر شبکه عمیق کانولوشن ۱۳ لایه‌ای برای استخراج ویژگی از تصاویر.
- استفاده از تکنیک انتخاب ویژگی حداقل افزونگی - حداکثر همبستگی برای انتخاب زیر مجموعه بهینه از ویژگی‌ها.
- استفاده از تکنیک درهم‌سازی باینری برای تبدیل ویژگی‌ها بر بردارهای باینری.

در کاربردهایی که شامل یافتن رابطه بین دو چیز قابل مقایسه است استفاده می‌شوند. برخی از کاربردهای رایج برای شبکه‌های سیامی شامل شناسایی چهره، تأیید امضا [۹] یا شناسایی تفسیر<sup>۱۳</sup> است. دو زیر شبکه عصبی استفاده شده در شبکه سیامی می‌توانند از خانواده شبکه‌های عصبی پیشخور<sup>۱۴</sup> و شبکه‌های عصبی عمیق باشند، که در طول آموزش از یک تابع خطا استفاده می‌کنند. آن‌ها به دنبال یکدیگر کار می‌کنند و خروجی خود را در پایان، معمولاً از طریق فاصله کسینوسی مقایسه می‌کنند. خروجی ایجاد شده توسط شبکه عصبی سیامی می‌تواند شباهت معنایی بین دو بردار ورودی در نظر گرفته شود [۱۰].

شبکه عصبی سیامی اولین بار توسط برملی و همکاران<sup>۱۵</sup> در سال ۱۹۹۴ [۱۱] برای تشخیص امضاهای جعلی معرفی شد. قبل از آن، بلدی و همکاران<sup>۱۶</sup> در سال ۱۹۹۳ [۱۲] با یک نام متفاوت یک شبکه عصبی سیامی مشابه را معرفی کردند که قادر به تشخیص اثر انگشت بود [۱۰]. شبکه‌های سیامی در حوزه‌های فوق عملکرد بسیار خوبی دارند زیرا وزن مشترک آن‌ها به این معنی است که پارامترهای کمتری برای یادگیری در طول آموزش نیاز دارند و آن‌ها می‌توانند با مقدار نسبتاً کمی داده آموزش دیده و نتایج خوبی را به دست آورند [۱۳].

شبکه‌های سیامی به ویژه در مواردی که تعداد زیادی کلاس با تعداد کم مشاهدات از هر یک وجود دارد، بسیار مفید هستند. در چنین مواردی، شبکه‌های عصبی کانولوشن عمیق برای طبقه‌بندی تصاویر در این کلاس‌ها با مشکل مواجه می‌شوند. اما در مقابل، شبکه سیامی می‌تواند تعیین کند، که آیا دو تصویر در یک کلاس هستند یا خیر [۱۴].

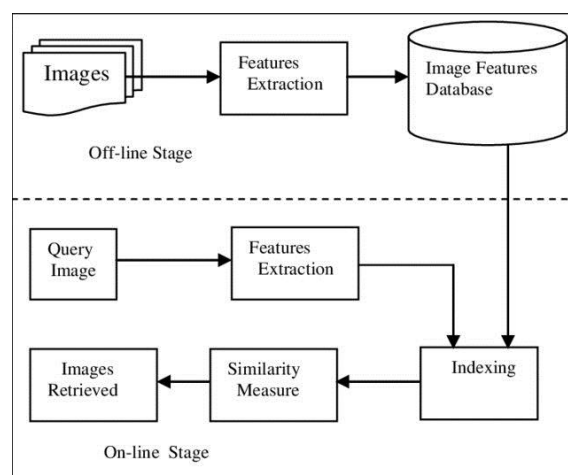
زیر شبکه‌های، شبکه عصبی سیامی می‌توانند هر یک از انواع مختلف شبکه‌های عصبی همچون پرسپترون چندلایه<sup>۱۷</sup>، شبکه‌های عمیق بازگشتی<sup>۱۸</sup>، شبکه‌های کانولوشن<sup>۱۹</sup> و غیره باشند [۱۵، ۱۶]. در این مطالعه برای استخراج ویژگی از تصاویر ریه بیماران از یک شبکه سیامی متشکل از دو زیر شبکه کانولوشن استفاده شده است.



شکل ۲: معماری یک شبکه سیامی [۱۰]

در مرحله بررسی تشابه، غالباً از معیارهای فواصل برداری در فضای برداری (فضای اقلیدسی) استفاده می‌شود [۵، ۶]. در این سیستم‌ها شباهت برای انعکاس نزدیکی بین دو تصویر، محاسبه می‌شود. توابع فاصله عدم تشابه بین دو تصویر را محاسبه می‌کنند، و تصاویری که حداقل فاصله را از تصویر پرس‌وجو دارند به کاربر ارائه می‌دهند [۵، ۶]. فاصله اقلیدسی یکی از رایج‌ترین معیارهای محاسبه فاصله بین دو بردار است که در مدل فضای بردار استفاده می‌شود.

در حال حاضر روش‌های بازیابی مبتنی بر محتوای بصری به عنوان ابزار مهمی در پزشکی برای کمک به پزشکان در تشخیص و درمان بیماری‌های مختلف عمل می‌کنند. این سیستم‌ها به پزشکان کمک می‌کنند تا تصاویر مشابه و سوابق مورد نظر را برای درک بیماری خاص یک بیمار یا وضعیت آسیب به وی جستجو کنند؛ همچنین به بیمار در مورد گزارش پزشکی وی کمک می‌کند. این سیستم‌ها همچنین به رادیولوژیست کمک می‌کنند تا تشخیص خاص را با دقت بیشتری ارائه دهند. بازیابی مبتنی بر محتوای بصری علاوه بر تشخیص، در امر آموزش و تحقیق نیز کمک می‌کند [۷].



شکل ۱: بازیابی مبتنی بر محتوا [۸]

## ۲-۲- شبکه‌های عصبی سیامی و کانولوشن

هر زمان که دو بردار با هم مقایسه شوند، با توجه به هدف نهایی مقایسه، بسیاری از رویکردهای محاسبه تشابه می‌توانند استفاده شوند. اما اگر این مقایسه به نمونه‌های پیچیده‌تری اعمال شود، ویژگی‌هایی که ابعاد و انواع مختلفی دارند که ممکن است قبل از پردازش به فشرده‌سازی نیاز داشته باشند، این معیارها نامناسب هستند. در این موارد، یک شبکه عصبی مصنوعی سیامی (شکل ۲) ممکن است بهترین انتخاب باشد.

شبکه سیامی نوعی شبکه عمیق محسوب می‌شود که از دو یا چند زیر شبکه<sup>۱۲</sup> یکسان استفاده می‌کند که معماری یکسانی دارند و از پارامترها و وزن‌های یکسانی برخوردارند. شبکه‌های سیامی معمولاً

دودویی محلی (LBP)<sup>۲۳</sup> استفاده شده و برای ویژگی‌های سراسری از رنگ و لبه استفاده شده است. این روش بر روی پایگاه داده جمع‌آوری شده به دقت ۹۲٪ رسیده است.

در [۱۹] از شبکه‌های عصبی کانولوشن و شبکه‌های عصبی سیامی برای بازیابی تصاویر پزشکی استفاده کرده‌اند. در این روش پس از آموزش شبکه سیامی، بردارهای  $k$  بیتی ویژگی تصاویر تشکیل می‌شود و سپس کدهای هش باینری از ویژگی‌ها مستخرج محاسبه می‌شود. جهت بازیابی تصاویر مشابه به تصویر پرس‌وجو با استفاده از معیار فاصله Hamming مقایسه‌ای بین کدهای هش باینری انجام می‌شود. این روش اگر چه دارای عملکرد نسبتاً مناسبی است اما نتایج آن به شدت وابسته به تعداد بیت‌های کد باینری نهایی تصاویر است، که باعث می‌شود نتایج میانگین دقت آن بین ۷۹ تا ۸۰ درصد باشد.

در [۲۰] یک سیستم بازیابی تصویر پزشکی دو مرحله‌ای ارائه شده است. در این روش ضرایب تبدیل موجک گسسته (DWT)<sup>۲۴</sup> از هر تصویر ورودی استخراج می‌شود. سپس، کدهای BTC<sup>۲۵</sup> از ضرایب موجک استخراج می‌شوند. در مرحله پرس و جو، BTCها از ضرایب موجک تصویر پرس و جو استخراج می‌شوند. و از ۸ نوع معیار فاصله برای بررسی تشابه استفاده می‌شود. آن‌ها روش خود را بر روی دو پایگاه داده VIAELCAP شامل تصویر سی تی اسکن مغزی و KVASIR شامل تصاویر روده ارزیابی نموده‌اند. نتایج نشان داد که روش آن‌ها به دقت ۹۳.۹٪ بر روی تصاویر مغز و ۵۹.۳٪ روی تصاویر روده رسیده است.


در [۲۱] یک روش بازیابی با استفاده از شبکه‌های عصبی عمیق برای بازیابی تصاویر اشعه x قفسه سینه ارائه شده است. در این روش با استفاده از شبکه کانولوشن ویژگی‌های تصاویر استخراج می‌شود و سپس با استفاده از بردارهای ویژگی، گراف تصاویر تشکیل شده و با استفاده از مفهوم اجتماع در شبکه، جوامع تصاویر تشکیل می‌گردد. سپس برای بازیابی، تصویر پرس‌وجو با اعضای هر یک از جوامع مقایسه می‌شود و اعضای نزدیکترین اجتماع به عنوان تصاویر مشابه بازیابی می‌شوند. روش آن‌ها بر روی پایگاه داده Stanford-UHR به دقت ۸۵٪ رسیده است.

در [۲۲] یک روش بازیابی برای تصاویر اشعه x قفسه سینه با استفاده از تکنیک کیف کلمات بصری ارائه شده است. در این روش تصاویر به بخش‌های کوچک تقسیم‌بندی می‌شود و از هر بخش از تصویر با استفاده از توصیفگر SIFT<sup>۲۶</sup>، ویژگی استخراج می‌گردد و پس از اعمال خوشه‌بندی و تشکیل هیستوگرام تصاویر، مرحله

شبکه‌های کانولوشن از جمله شبکه‌های عصبی عمیق هستند که در دسته شبکه‌های پیشخور قرار می‌گیرند. این شبکه‌ها بطور تخصصی در طبقه‌بندی داده‌های دو بعدی و سه بعدی همچون تصاویر و ویدئو استفاده می‌شوند.

این شبکه‌ها همانطور که در شکل (۳) نشان داده شده است دارای یک معماری و ساختار سلسله مراتبی هستند. معماری شبکه‌های کانولوشن به طور کلی، از لایه‌های کانولوشن و تجمع یا کاهش<sup>۲۰</sup> و تمام متصل<sup>۲۱</sup> تشکیل شده است که در ماژول‌هایی گروه‌بندی می‌شوند. ماژول‌های تشکیل شده چندین مرتبه در معماری شبکه تکرار می‌شوند تا یک مدل عمیق ایجاد کنند.

در این شبکه‌ها یک تصویر، پس از گذر لایه‌های کانولوشن و کاهش بعد به بردار ویژگی تبدیل می‌شود. سپس بردار ویژگی تشکیل شده از لایه‌های فوق به عنوان ورودی به لایه‌های کاملاً متصل ارائه می‌شود. آخرین لایه کاملاً متصل، برچسب کلاس تصویر ورودی را پیش‌بینی کرده و ارائه می‌دهد.



شکل ۳: معماری یک شبکه کانولوشن [۱۵]

## ۲-۳- کارهای مرتبط

در زمینه بازیابی مبتنی بر محتوای تصاویر پزشکی مطالعات مختلفی انجام شده است. در [۱۷] یک روش بازیابی برای تشخیص سرطان ریه ارائه شده است. این روش شامل سه مرحله، بخش‌بندی تصویر ریه به نواحی خاص، (۲) استخراج ویژگی بافت از نواحی ریه و (۳) خوشه‌بندی سلسله مراتبی و خوشه‌بندی افزایی است که منجر به بهبود سرعت و دقت می‌شود. در این روش بردار ویژگی تصویر پرس‌وجو با مراکز خوشه‌ها مقایسه می‌شود و تصاویر نزدیکترین خوشه بازیابی می‌شود. آن‌ها بر روی پایگاه داده جمع‌آوری شده به دقت ۶۷٪ رسیده‌اند.

در [۱۸] یک روش بازیابی ترکیبی در تصاویر پزشکی ارائه دادند. در این روش با توجه به اهمیت مرحله محاسبه تشابه بین تصویر پرس‌وجو و تصاویر پایگاه داده از یک روش تطبیق چند سطحی استفاده نموده‌اند. در این روش برای تشکیل بردار ویژگی‌های تصاویر از ویژگی‌های محلی و سراسری استفاده شده است. در ویژگی‌های محلی از ویژگی‌های مقاوم سریع (SURF)<sup>۲۲</sup> و الگوی

مجموعه بهینه از ویژگی‌ها استفاده می‌شود و در نهایت با استفاده از فاصله اقلیدسی تصاویر مشابه بازیابی می‌شود. این روش بر روی دو پایگاه داده CE-MRI و OASIS به دقت ۹۸.۳۳٪ و ۸۸.۲۵٪ رسیده است.

در [۲۸] یک مدل شبکه عصبی کانولوشن عمیق موازی (PDCNN)<sup>۳۴</sup> برای بازیابی مبتنی بر محتوا پیشنهاد شده است. مدل پیشنهادی شامل ویژگی‌های محتوایی سطح پایین، ویژگی‌های معنایی سطح بالا و ویژگی‌های فشرده برای مقابله با مشکل مجموعه داده‌های نامتعادل و کاهش زمان آموزش است. ویژگی‌های سطح بالا و فشرده برای حل مشکل مجموعه داده‌های نامتعادل با استفاده از الگوریتم‌های الگوی باینری محلی، هیستوگرام گرادیان‌های جهت دار و رادون<sup>۳۵</sup> استخراج شده است. موازی‌سازی داده‌ها برای کاهش زمان آموزش شبکه در چندین هسته CPU<sup>۳۶</sup> بر روی یک کامپیوتر منفرد انجام شده است. نتایج تجربی نشان می‌دهد که این روش به دقت ۸۷٪ رسیده است.

در [۲۹] یک چارچوب بازیابی خودکار تصویر پزشکی مبتنی بر اجتماع عمیق<sup>۳۷</sup> برای استخراج تصاویر مشابه از یک پایگاه داده اشعه ایکس بزرگ پیشنهاد شده است. این چارچوب یک رویکرد تولید ویژگی تصویر، مبتنی بر یادگیری عمیق و یک تکنیک تشخیص اجتماع<sup>۳۸</sup> برای استخراج تصاویر مشابه را ادغام می‌کند. روش پیشنهادی در دو مجموعه داده اشعه ایکس قفسه سینه در مقیاس بزرگ ارزیابی شده است. رویکرد فوق قادر به استخراج تصاویر با برجسب‌های بیماری مشابه با دقت ۸۵ درصد است.

در [۳۰] مدلی به نام X-MIR برای بازیابی تصاویر اشعه ایکس ارائه دادند. در این روش از تصاویر ریه بیماران کووید-۱۹ و مجموعه داده‌های ضایعات پوستی ISIC 2017 استفاده شده است. نتایج تجربی نشان می‌دهد که نقشه‌های برجسته<sup>۳۹</sup> به آشکار کردن ویژگی‌های تصویر مورد استفاده توسط مدل‌ها برای تعیین شباهت تصویر کمک می‌کنند. آن‌ها سه الگوریتم برجستگی مختلف را شامل مبتنی بر انسداد<sup>۴۰</sup>، مبتنی بر توجه<sup>۴۱</sup>، مبتنی بر فعال‌سازی<sup>۴۲</sup> استفاده نمودند. آنها در بهترین حالت به دقت ۸۹.۹ درصد در بازیابی ۵ تصویر در پایگاه کووید-۱۹ دست یافتند.

در [۳۱] رویکرد دو مرحله‌ای شامل استخراج ویژگی از طریق بازسازی تصویر متخاصم<sup>۴۳</sup> و تطبیق شاخص و مرحله بازیابی، برای بازیابی تصاویر پزشکی، ارائه شده است. در ابتدا، شبکه بازسازی تصویر متخاصم (AIR-Net)<sup>۴۴</sup> برای رمزگذاری تصویر پزشکی ورودی به مجموعه‌ای از ویژگی‌ها و سپس بازسازی تصویر پزشکی ورودی از ویژگی‌های کدگذاری شده، استفاده شده است. در ادامه این ویژگی‌های رمزگذاری شده در ماژول تطبیق و بازیابی برای

بازیابی با استفاده از فاصله اقلیدسی انجام می‌شود. روش آن‌ها در پایگاه داده NIH به دقتی بین ۶۰ تا ۷۰٪ رسیده است.

در [۲۳] روش بازیابی مبتنی بر محتوا جهت تشخیص بیماری‌های ریه با استفاده از شبکه‌های عصبی عمیق کانولوشن ارائه شده است. در این روش از شبکه کانولوشن برای استخراج ویژگی استفاده شده است و سپس بازیابی تصاویر مشابه با تصویر پرس‌وجو با استفاده از فاصله اقلیدسی انجام شده است. این روش بر روی پایگاه داده جمع‌آوری شده با ۲۴۶ بیمار به دقت ۸۱.۷٪ رسیده است.

در [۲۴] نیز یک روش بازیابی تصاویر اشعه x قفسه سینه مبتنی بر شبکه کانولوشن پیش آموزش دیده معرفی شده است. در این روش با استفاده از شبکه‌های کانولوشن پیش آموزش دیده DenseNet121 و ویژگی‌های تصاویر استخراج می‌شوند و سپس با استفاده از تکنیک رای گیری اکثریت k تصویر مشابه با تصویر پرس‌وجو بازیابی می‌شود. روش آن‌ها بر روی دو پایگاه داده MIMIC-CXR و CheXpert به مقدار AUC<sup>۳۷</sup> برابر با ۰.۸۹ رسیده‌اند.

در [۲۵] یک روش ترکیبی برای بازیابی تصاویر پزشکی ارائه دادند. در این روش از دو ویژگی محلی، الگوی باینری محلی و الگوی مشتق محلی برای استخراج ویژگی استفاده شده است که دو دسته ویژگی فوق به صورت وزن دار با یکدیگر ترکیب شده و بردار نهایی تصاویر را تشکیل می‌دهد. در این روش برای ترکیب ویژگی‌ها از الگوریتم بهینه‌سازی میمون عنکبوتی<sup>۳۸</sup> استفاده شده است.

در [۲۶] یک روش بازیابی برای تصاویر ستی اسکن با استفاده از الگوریتم ماشین بردار پشتیبان و الگوریتم بهینه سازی گرگ خاکستری ارائه دادند. ویژگی‌های بافتی با استفاده از ماتریس هم رخداد GLCM<sup>۳۹</sup> استخراج می‌گردد که شامل همبستگی، کنتراست، انرژی و غیره هستند. در تکنیک فوق در ابتدا کلاسی را که تصویر پرس و جو به آن تعلق دارد با ماشین بردار پشتیبان استخراج می‌کند و سپس بازیابی از کلاس مورد نظر انجام می‌شود. الگوریتم بهینه سازی گرگ خاکستری در این روش برای یافتن پارامترهای بهینه ماشین بردار پشتیبان بکار می‌رود. این روش به دقت ۹۷.۳٪ بر روی پایگاه جمع‌آوری شده از تصاویر اشعه x ریه، مغز، کبد و غیره دست یافته است.

در [۲۷] نیز یک روش جهت بازیابی تصاویر پزشکی با استفاده از شبکه‌های عصبی عمیق خودرمزگذار تنک<sup>۴۰</sup> ارائه دادند. در این روش از تصاویر ویژگی‌های HOG<sup>۴۱</sup> و LTP<sup>۴۲</sup> استخراج می‌شوند. سپس از تکنیک انتخاب ویژگی Inf-FS<sup>۴۳</sup> جهت انتخاب زیر



یادگیری را طی می کند و پس از تکمیل فرآیند یادگیری و تنظیم دقیق وزن های شبکه، از آخرین لایه تمام متصل، ویژگی های متعلق به هر تصویر استخراج می شود. در شکل (۵) معماری دو زیر شبکه کانولوشن پیشنهادی، مشهود است. در شبکه سیامی، معماری دو شبکه با یکدیگر یکسان است.

در مرحله پیش پردازش و آماده سازی تصاویر، ابتدا اندازه تصاویر یکسان سازی می شود، این گام برای پایگاه هایی که اندازه تصاویر موجود در آن ها با یکدیگر متفاوت است ضروری است. به عنوان مثال در این مقاله، پایگاه کووید-۱۹ دارای تصاویر با اندازه های متنوع است و غالب تصاویر آن دارای ابعاد ۳۳۵×۵۸۰ هستند از اینرو در این گام کلیه تصاویر آن به ابعاد فوق تغییر اندازه داده شدند؛ در مقابل در پایگاه داده ذات الریه تصاویر دارای ابعاد ثابت ۱۰۲۴×۱۰۲۴ هستند. سپس کلیه تصاویر مقیاس خاکستری شدند. این مورد نیز برای پایگاه هایی مورد نیاز است که حاشیه نویسی پزشکان در تصاویر به صورت رنگی انجام شده است.

همانطور که در شکل (۵) مشهود است، دو زیر شبکه کانولوشن در شبکه سیامی، متشکل از ۴ لایه کانولوشن، ۳ لایه کاهش بعد از نوع تجمع حداکثر و یک لایه تمام متصل است. در این معماری بر خروجی لایه های کانولوشن، تابع غیر خطی RELU<sup>۴۵</sup> اعمال شده است. آخرین لایه در معماری شبکه سیامی تعریف شده، لایه تمام متصل با ۵۱۲ بعد می باشد. این لایه برای هر تصویر از پایگاه داده یک بردار از ویژگی ها با ۵۱۲ بعد تولید می کند.

برای آموزش شبکه سیامی، تصاویر پایگاه داده به جفت تصاویر مشابه و غیر مشابه با توجه به کلاس تصاویر تقسیم می شوند و برای یادگیری به دو زیر شبکه ارائه می شوند. در این شبکه تابع خطای یادگیری باید به نحوی بهینه سازی شود که مقدار خطا برای جفت تصاویر مشابه ارائه شده به دو زیر شبکه دارای حداقل مقدار ممکن و برای جفت تصاویر متفاوت بیشترین مقدار ممکن را داشته باشد. اگر فرض شود I<sub>1</sub>, I<sub>2</sub> دو جفت تصویر از پایگاه داده باشد و b<sub>1</sub>, b<sub>2</sub> دو خروجی شبکه سیامی برای دو تصویر مذکور باشند؛ تابع خطا برای دو تصویر فوق از رابطه (۱) محاسبه می شود.

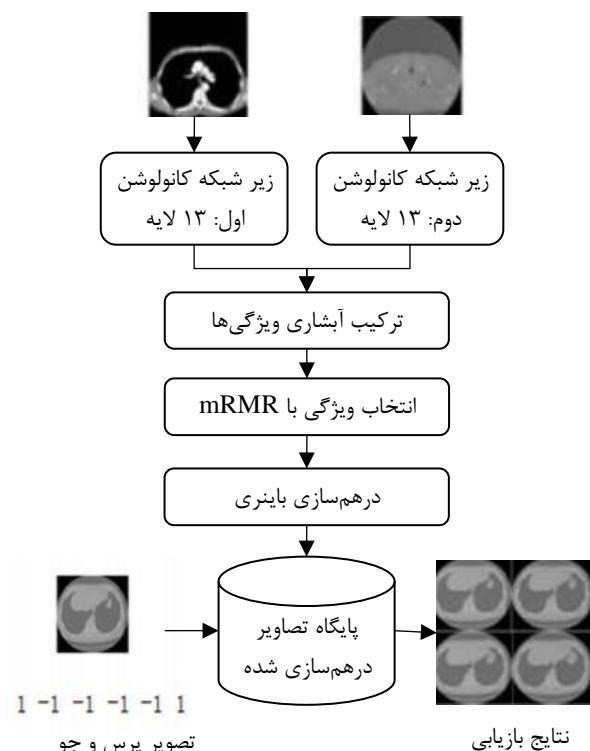
$$L(b_1, b_2, y) = \frac{1}{2}(1 - y)D(b_1, b_2) + \frac{1}{2} y \max(m - D(b_1, b_2), 0), \text{ where } m > 0 \quad (1)$$

در رابطه بالا اگر دو تصویر مشابه باشند مقدار y برابر با صفر در نظر گرفته می شود و غیر این صورت برابر با ۱ در نظر گرفته می شود. همچنین D تابع فاصله اقلیدسی بین دو بردار خروجی است. فاصله اقلیدسی از رابطه (۲) محاسبه می شود. در رابطه بالا m بیانگر آستانه حاشیه است. برای n جفت تصویر در پایگاه داده، رابطه (۱) به رابطه (۳) تغییر می یابد.

بازیابی تصویر پزشکی استفاده می شوند. عملکرد چارچوب پیشنهادی در پایگاه های تصویر پزشکی مانند OASIS, ILD, VIA/ELCAP-CT بررسی شده است؛ که نشان می دهد که رویکرد آن ها از سایر روش های موجود برای بازیابی تصویر پزشکی بهتر عمل می کند.

### ۳- راه کار پیشنهادی

در شرایط کنونی و حجم رو به رشد تصاویر پزشکی ارائه یک مدل بازیابی مبتنی بر محتوا که قابلیت تشخیص و بازیابی بالایی داشته باشد در تشخیص زودهنگام بسیاری از بیماری ها موثر خواهد بود. مدل بازیابی تصویر پزشکی مطرح شده همانطور که در شکل (۴) مشهود است، مشابه با دیگر روش های بازیابی از دو فاز استخراج ویژگی و تشابه تشکیل شده است. در این روش از شبکه عصبی سیامی مبتنی بر کانولوشن برای استخراج ویژگی از تصاویر سی تی اسکن ریه استفاده شده است.



شکل ۴: دیاگرام مدل بازیابی تصویر پزشکی پیشنهادی

### ۳-۱- استخراج ویژگی با استفاده از شبکه سیامی

در ابتدای فرآیند بازیابی، استخراج ویژگی توسط دو زیر شبکه کانولوشن ۱۳ لایه ای در شبکه سیامی انجام می شود. بطور دقیق برای استخراج ویژگی توسط شبکه سیامی که متشکل از دو شبکه کانولوشنی است؛ تصاویر به شبکه ارائه می شود و شبکه فرآیند

در شکل (۵) نمودار تابع خطای شبکه سیامی در فرآیند یادگیری و در شکل (۶) بخشی از ماتریس ویژگی‌های خروجی شبکه ارائه شده است. مقداری خطای شبکه پس از پایان فرآیند یادگیری در ۱۰۰ گردش در حدود ۰.۱ می‌باشد که بیانگر کامل شدن فرآیند یادگیری بطور موثر است.

پس از استخراج ویژگی‌ها توسط شبکه سیامی، گام بعد، انتخاب زیر مجموعه‌ای بهینه از ویژگی‌ها برای فرآیند بازیابی است. در این مرحله از یک تکنیک انتخاب ویژگی فیلتر و الگوریتم حداقل افزونگی و حداکثر همبستگی استفاده شده است.

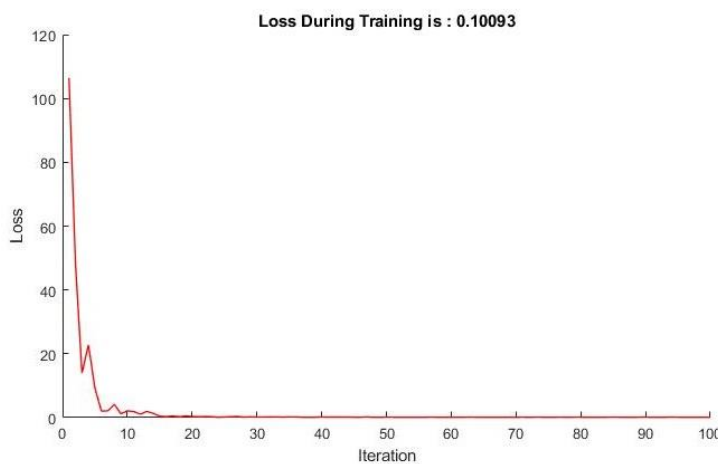
$$euclidian = \sqrt{\sum_{i=1}^n (q_i - p_i)^2} \quad (2)$$

در رابطه بالا n ابعاد داده است و p و q دو بردار از تصاویر پایگاه داده هستند.

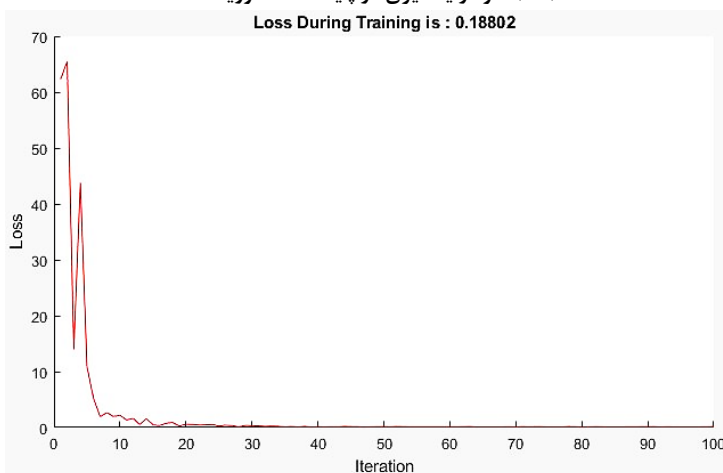
$$L(b_1, b_2, \gamma) = \sum_{i=1}^n L(b_{i1}, b_{i2}, \gamma), \text{ where } i \in \{1, \dots, n\} \quad (3)$$

در رابطه بالا n تعداد جفت تصاویر تصادفی انتخاب شده برای ارائه به زیر شبکه‌های کانولوشن شبکه سیامی است. b1, b2 نیز دو خروجی شبکه متعلق به دو تصویر ورودی است.

پس از پایان مرحله آموزش شبکه سیامی، به ازاء هر تصویر در پایگاه داده برداری با طول ۵۱۲ از آخرین لایه تمام متصل تولید می‌شود.



(الف) نمودار یادگیری در پایگاه داده کوپید-۱۹



(ب) نمودار یادگیری در پایگاه داده ذات‌الریه

Name	Type	Activation
Input1 335×580×1	Image input	335×580×1
Conv1 32 5×5×1 with Stride [1,1]	Convolution	331×576×32
Relu1	RELU	331×576×32
Maxpool1 2×2 with Stride [2,2]	Max Pooling	165×288×32
Conv2 32 5×5×32 with Stride [1,1]	Convolution	161×284×32
Relu2	RELU	161×284×32
Maxpool2 2×2 with Stride [2,2]	Max Pooling	80×142×32
Conv3 64 5×5×32 with Stride [1,1]	Convolution	76×138×64
Relu3	RELU	76×138×64
Maxpool3 2×2 with Stride [2,2]	Max Pooling	38×69×64
Conv4 128 5×5×64 with Stride [1,1]	Convolution	34×65×128
Relu4	RELU	34×65×128
Fc1 512 Fully Connected Layer	Fully Connected	1×1×512

شکل ۵: معماری و لایه‌های تشکیل دهنده ۲ زیر شبکه کانولوشن در شبکه سیامی و نمودار یادگیری شبکه در دو پایگاه داده



	1	2	3	4	5	6	7	8	9	10	11	12
1	0.0375	0.0116	0.0127	0.0045	0.0239	-0.0073	0.0188	-0.0187	-0.0630	0.0057	-0.0164	0.0297
2	0.0366	0.0029	0.0138	0.0157	0.0179	-0.0049	0.0112	-0.0124	-0.0623	0.0047	-0.0150	0.0254
3	0.0348	-4.0301e...	0.0168	0.0118	0.0273	0.0018	0.0060	-0.0174	-0.0646	0.0052	-0.0131	0.0287
4	0.0342	5.7701e-...	0.0126	-0.0011	0.0253	-0.0059	0.0155	-0.0125	-0.0742	0.0057	-0.0105	0.0223
5	0.0403	0.0018	0.0093	0.0055	0.0266	-7.271...	0.0147	-0.0111	-0.0724	0.0051	-0.0116	0.0223
6	0.0330	0.0044	0.0087	0.0053	0.0269	-0.0027	0.0111	-0.0145	-0.0741	0.0087	-0.0134	0.0212
7	0.0319	-0.0030	0.0053	0.0118	0.0289	-0.0114	0.0145	-0.0253	-0.0671	0.0068	-0.0126	0.0217
8	0.0363	8.8474e-...	0.0102	0.0058	0.0212	-0.0072	0.0092	-0.0131	-0.0630	0.0062	-0.0173	0.0243
9	0.0310	0.0041	0.0125	0.0068	0.0155	-0.0067	0.0108	-0.0077	-0.0675	0.0071	-0.0219	0.0238
10	0.0370	0.0018	0.0092	0.0027	0.0189	-0.0065	0.0054	-0.0201	-0.0663	0.0029	-0.0154	0.0244
11	0.0353	-5.6471e...	0.0075	0.0063	0.0176	-0.0077	0.0099	-0.0176	-0.0663	0.0050	-0.0202	0.0190

شکل ۶: تعدادی از بردارهای ویژگی استخراج شده از تصاویر توسط شبکه سیامی

	1	2	3	4	5	6	7	8	9	10	11	12	13
1	-1	-1	-1	-1	1	1	-1	-1	-1	1	-1	-1	-1
2	-1	-1	1	1	1	1	1	1	-1	1	-1	-1	-1
3	-1	-1	-1	1	1	1	-1	-1	-1	1	-1	-1	1
4	-1	-1	-1	1	1	1	-1	-1	-1	1	-1	-1	-1
5	-1	-1	-1	-1	1	1	-1	-1	-1	1	-1	-1	-1
6	-1	-1	-1	-1	1	1	-1	1	-1	1	-1	-1	-1
7	-1	-1	1	1	1	1	1	-1	-1	1	-1	-1	-1
8	-1	-1	1	1	1	1	-1	-1	-1	1	-1	-1	1
9	-1	-1	1	-1	1	1	-1	-1	-1	1	-1	-1	-1
10	-1	-1	1	-1	1	1	-1	-1	-1	1	-1	-1	-1
11	-1	-1	1	1	1	1	1	-1	-1	1	-1	-1	-1
12	-1	-1	1	-1	1	1	-1	-1	-1	1	-1	-1	-1
13	-1	-1	-1	-1	1	1	-1	1	-1	1	-1	-1	-1

شکل ۷: بخشی از بردار ویژگی‌های بعد از تکنیک درهم‌سازی

بیانگر حداکثر وابستگی است و  $I$  تابع اطلاعات متقابل است [۳۲]. ویژگی‌های انتخاب شده براساس حداکثر همبستگی<sup>۳۷</sup> می‌توانند افزونگی زیادی داشته باشند، یعنی وابستگی در بین این ویژگی‌ها می‌تواند زیاد باشد. وقتی دو ویژگی به شدت به یکدیگر وابسته باشند، در صورت حذف یکی از آن‌ها، قدرت تمایز طبقاتی تغییر چندانی نمی‌کند. بنابراین، شرایط حداقل افزونگی<sup>۳۸</sup> ارائه شده در رابطه (۵) را می‌توان برای انتخاب ویژگی‌های منحصر به فرد اضافه کرد [۳۲].

$$\min R(S), \quad R = \frac{1}{|S|^2} \sum_{x_i, x_j \in S} I(x_i; x_j) \quad (5)$$

در رابطه بالا  $I(x_i; x_j)$  اطلاعات متقابل بین دو ویژگی است. معیار نهایی ترکیبی از دو محدودیت فوق "حداقل افزونگی-حداکثر همبستگی" است که از رابطه (۶) حاصل می‌شود. پس از اعمال تکنیک انتخاب ویژگی mRMR ابعاد داده‌ها از ۵۱۲ بعد به  $k$  بعد


### ۳-۲- انتخاب ویژگی به روش حداقل افزونگی - حداکثر همبستگی

در مدل بازیابی پیشنهادی برای انجام فرآیند بازیابی با بهترین پاسخ در کوتاه‌ترین زمان، از تکنیک انتخاب ویژگی حداقل افزونگی-حداکثر همبستگی برای انتخاب زیر مجموعه بهینه از ویژگی‌ها استفاده شده است. الگوریتم انتخاب ویژگی حداقل افزونگی-حداکثر همبستگی در سال ۲۰۰۵ توسط پنگ و همکاران<sup>۳۹</sup> مطرح گردید [۳۲]. در این الگوریتم برای محاسبه حداکثر همبستگی بین ویژگی‌ها با استفاده از میانگین اطلاعات متقابل از رابطه (۴) استفاده می‌شود.


$$\max D(S, c), \quad D = \frac{1}{|S|} \sum_{x_i \in S} I(x_i; c) \quad (4)$$

در رابطه بالا  $c$  کلاس داده‌ها و  $x$  ویژگی‌های موجود در پایگاه داده و  $S$  نماد مجموعه ویژگی‌ها است که دارای  $m$  ویژگی است.  $\max D$

where  $AP(q) = \frac{\sum_{k=1}^N precision(k) \times rel(k)}{\text{number of relevant image}}$



الف) تصویر بازیابی شده در پایگاه کووید-۱۹



ب) تصویر بازیابی شده در پایگاه Pneumonia

شکل ۸: تصاویر بازیابی شده توسط مدل در دو پایگاه مختلف

در رابطه (۱۰)،  $rel(k)$  برابر با ۱ خواهد بود اگر تصویر بازیابی شده مرتبط با پرس‌وجو باشد و در غیر این صورت ۰ خواهد شد. در محاسبه این معیار از متوسط دقت<sup>۴۹</sup> استفاده می‌شود. متوسط دقت ترکیبی از دو معیار دقت و جایگاه تصویر بازیابی شده است. برای محاسبه متوسط دقت، به ازاء هر پرس‌وجو موقعیت تصویر بازیابی شده نیز در نظر گرفته می‌شود. به عبارت ساده متوسط دقت برای یک تصویر پرس‌وجو از تقسیم مقادیر حاصل شده بر تعداد تصاویر

بهینه کاهش می‌یابد [۳۲]. در رابطه زیر  $D$  و  $R$  از رابطه (۴) و (۵) حاصل می‌شوند.

$$\max \Phi(D, R), \quad \Phi = D - R \quad (۶)$$

### ۳-۳- درهم‌سازی باینری و بازیابی

برای درهم‌سازی ویژگی‌های مستخرج از رابطه (۷) استفاده می‌شود. فرآیند درهم‌سازی باینری باعث می‌شود فرآیند بازیابی با سرعت بیشتری انجام شود. در شکل (۷) بردارهای ویژگی پس از اعمال درهم‌سازی باینری نشان داده شده است

$$Binary_{hashcode} = \begin{cases} 1 & x \geq 0 \\ -1 & otherwise \end{cases} \quad (۷)$$

در آخرین مرحله از روش پیشنهادی، برای بازیابی تصاویر مشابه با تصویر پرس‌وجو از فاصله همینگ ارائه شده در رابطه (۸) استفاده می‌شود.

$$Distance_{Hamming}(x, y) = \sum_{i=1}^n |x_i \neq y_i| \quad (۸)$$

در رابطه بالا  $x$  و  $y$  دو بردار درهم‌سازی باینری متعلق به تصویر پرس‌وجو و یک تصویر پایگاه داده می‌باشد و  $n$  ابعاد دو بردار ویژگی است. پس از محاسبه فاصله همینگ بین کلیه بردارهای ویژگی پایگاه داده و تصویر پرس‌وجو، لیست تولید شده براساس مقدار فاصله‌ها بطور صعودی مرتب می‌شود و با توجه به  $k$  مشخص شده برای مدل،  $k$  تصویر برتر که دارای حداقل فاصله ممکن با تصویر پرس‌وجو هستند به عنوان آخرین تصاویر بازیابی شده به کاربر ارائه می‌شوند.

در شکل (۸) بخش (الف) یک تصویر پرس‌وجو و ۱۲ تصویر بازیابی شده مشابه با آن در پایگاه تصاویر سیتی اسکن کووید-۱۹ و در بخش (ب) نیز یک تصویر پرس‌وجو و ۱۰ تصویر بازیابی شده مشابه با آن در پایگاه تصاویر اشعه X پایگاه Pneumonia نشان داده شده است. در شکل (۸) در هر دو پایگاه داده تصاویر بازیابی شده، در کلاس تصویر پرس‌وجو قرار دارند. به عبارت دیگر مدل در بازیابی تصویر مشابه با یک پرس‌وجوی مطالعه موردی توانسته است به دقت ۱۰۰٪ دست یابد.

### ۴- ارزیابی و نتایج

برای ارزیابی عملکرد مدل بازیابی ارائه شده از معیارهای دقت، میانگین متوسط دقت، فراخوانی و میانگین  $f$  استفاده شده است که از طریق روابط (۹) تا (۱۲) محاسبه می‌شوند.

$$precision = \frac{\text{relevant images} \cap \text{retrieved images}}{\text{retrieved images}} \quad (۹)$$

$$MAP = \frac{\sum_{q=1}^Q AP(q)}{Q} ; \quad (۱۰)$$

در تعداد ۲۰ ویژگی نیز مشاهده می‌شود. در نتیجه این دو مقدار نمی‌توانند تعداد مناسب ویژگی برای مدل پیشنهادی باشند چرا که با افزایش تعداد تصاویر پرس‌وجو تعداد تصاویری که قادر به ارائه پیشگویی برای آن‌ها نیستند افزایش می‌یابد. در بین ابعاد مورد بررسی تعداد ۳۰ و ۴۰ ویژگی بهترین نتایج را ارائه می‌دهند. دقت در تعداد ۴۰ ویژگی در مقایسه با ۳۰ ویژگی بیشتر می‌باشد. این نتایج حاکی از آن است که تعداد ۴۰ ویژگی به عنوان k ویژگی برتر در مدل ارائه شده مناسب است.

جدول ۲: بررسی تاثیرات تعداد ویژگی منتخب بر عملکرد مدل

Query_Id	10-Fea		20-Fea		30-Fea		40-Fea	
	Precision	Ap	Precision	Ap	Precision	Ap	Precision	Ap
288	100	100	100	100	100	100	80	95
134	100	100	80	100	60	86.66	60	86.66
230	100	100	100	100	100	100	100	100
156	100	100	100	100	100	100	100	100
331	100	100	100	100	80	80.41	80	88.75
224	100	100	100	100	100	100	100	100
14	100	100	100	100	100	100	100	100
166	100	100	80	95	80	88.75	100	100
141	100	100	100	100	100	100	100	100
350	0	0	0	0	60	100	80	67.91

Query_Id	50-Fea		100-Fea		150-Fea		200-Fea	
	Precision	Ap	Precision	Ap	Precision	Ap	Precision	Ap
288	80	88.75	60	86.66	40	32.5	60	80.55
134	80	80.41	80	67.91	80	80.41	60	86.66
230	60	86.66	80	100	60	58.88	80	80.41
156	100	100	40	83.33	60	63.88	40	70
331	80	80.41	60	80.55	60	100	80	100
224	80	100	100	100	60	100	100	100
14	100	100	80	88.75	80	80.41	80	80.41
166	100	100	80	80.41	40	100	60	91.66
141	100	100	80	100	100	100	60	100
350	40	32.5	40	41.66	80	100	60	63.88

#### ۴-۲- نتایج بدست آمده برای تعداد تصاویر بازیابی شده

در این آزمایش تعداد تصاویر بازیابی شده برای هر تصویر پرس‌وجو بین ۵۰ تا ۱۰۰ تصویر در نظر گرفته شده است و نتایج آن در جدول (۳) بخش‌های (الف) تا (د) و شکل‌های (۱۰) و (۱۱) بیان شده است. در مدل‌های بازیابی هر چه تعداد تصاویر بازیابی شده افزایش یابد مقدار فراخوان نیز با توجه به رابطه آن، افزایش می‌یابد. از طرف دیگر افزایش تعداد تصاویر بازیابی شده می‌تواند تاثیر عکس بر معیار

بازیابی شده مرتبط، حاصل می‌شود. این معیار حساس به رتبه‌بندی<sup>۵۰</sup> است.

$$Recall = \frac{relevant\ images \cap retrieved\ images}{releant\ images} \quad (11)$$

$$F_{score} = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (12)$$

در روابط فوق منظور از تصاویر مرتبط یا *relevant images* مجموعه تصاویری است که با تصویر پرس‌وجو در یک کلاس مشترک قرار دارند. برای ارزیابی روش‌ها از دو نوع تصویر سی‌تی اسکن و اشعه X ریه در دو پایگاه داده کووید-۱۹ با نام CT-COV [۳۳] و پایگاه ذات‌الریه به نام Pneumonia [۳۴] استفاده شده است.

پایگاه داده کووید-۱۹، شامل ۳۴۹ تصویر سی‌تی اسکن ریه بیماران کووید-۱۹ و ۴۶۳ تصویر از ریه سالم می‌باشد. این پایگاه داده از تصاویر ۲۱۶ بیمار تشکیل شده است.

پایگاه داده Pneumonia، شامل ۳۰۵۰ تصویر اشعه ایکس ریه است که از این تعداد ۱۵۲۵ تصویر در کلاس ذات‌الریه و ۱۵۲۵ تصویر در کلاس نرمال یا سالم است. در جدول (۱) پارامترهای ارزیابی و پیاده‌سازی بیان شده است.

جدول ۱: پارامترهای شبیه سازی، تنظیم و مقداردهی

پارامتر	مقدار
شبیه‌ساز	متلب نسخه ۲۰۲۰، سیستمی با پردازنده ۷ هسته‌ای و رم ۸
تعداد گردش	۱۰۰
سایز دسته کوچک داده <sup>۵۱</sup>	۱۰
آستانه حاشیه <sup>۵۲</sup>	۰.۳
نرخ یادگیری	۰.۰۰۰۰۶
میرایی گرادیان <sup>۵۳</sup>	۰.۹
میرایی مربع گرادیان <sup>۵۴</sup>	۰.۹۹

#### ۴-۱- نتایج بدست آمده برای تعداد ویژگی منتخب

تعداد ویژگی‌های منتخب توسط الگوریتم انتخاب ویژگی حداقلی افزونگی- حداکثر همبستگی بر نتایج مدل ارزیابی موثر هستند و یافتن تعداد بهینه ویژگی در این روش می‌تواند منجر به موفقیت مدل شود. در این آزمون تعداد ویژگی بین ۱۰ تا ۲۰۰ در نظر گرفته شده است و نتایج آن در جدول (۲) و میانگین نتایج در شکل (۹) گزارش شده است. در این آزمون تعداد ۱۰ تصویر پرس‌وجو به تصادف انتخاب شده است و برای هر تصویر ۵ تصویر مشابه بازیابی شده است.

همانطور که در جدول (۲) مشاهده می‌شود در تعداد ۱۰ ویژگی برتر، مدل برای ۹ تصویر پرس‌وجو دقت ۱۰۰ درصد نشان می‌دهد و برای ۱ تصویر توانایی ارائه تصاویر مشابه را نداشته است. این مورد

دقت داشته باشد؛ چرا که احتمال خطای مدل در بازیابی تصاویر مشابه با افزایش تعداد تصاویر بازیابی شده افزایش می‌یابد.

بررسی تاثیر تعداد تصاویر بازیابی شده نشان می‌دهد که بهترین مقدار دقت در مدل ارائه شده در شرایطی حاصل می‌شود که تعداد ۵ تصویر برای هر تصویر پرس‌وجو از پایگاه داده بازیابی شود.

در شکل (۱۰) مقدار دقت و میانگین متوسط دقت با افزایش تعداد تصاویر بازیابی شده کاهش یافته است. اما در شکل (۱۱) با افزایش تعداد تصاویر بازیابی شده فراخوان مدل افزایش یافته است. به این دلیل که هر چه تعداد تصاویر بازیابی شده افزایش یابد، صورت کسر فراخوان به مقدار مخرج کسر نزدیکتر می‌شود و در نتیجه مقدار فراخوان افزایش می‌یابد. مقدار میانگین  $f$  نیز بدلیل آنکه از دو مقدار دقت و فراخوان حاصل می‌شود با افزایش تعداد تصاویر بازیابی شده مقدار آن نیز افزایش یافته است.

جدول ۳ (ب): تاثیر تعداد تصاویر بازیابی شده بر نتایج مدل

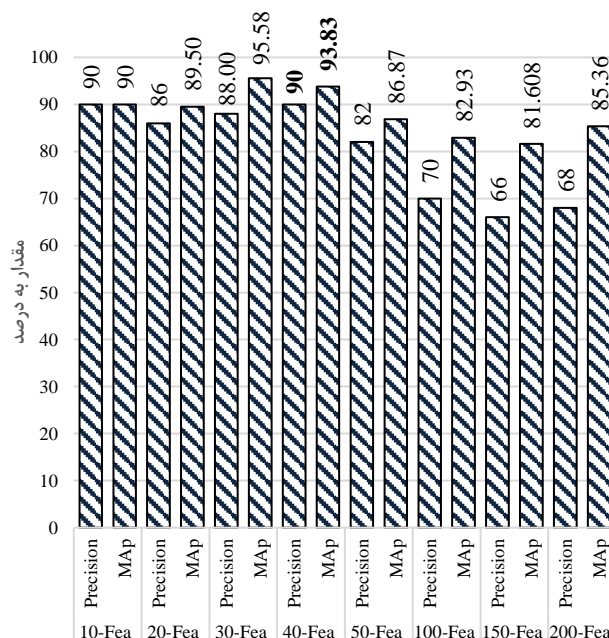
Query_Id	15 – Retrieve Image				20 – Retrieve Image			
	Precision	Recall	Fs	Ap	Precision	Recall	Fs	Ap
220	66.667	2.86	5.48	100	55	3.15	5.96	95.9
139	80	3.43	6.58	81.86	85	4.87	9.21	82.26
73	86.66	3.73	7.15	86.64	90	5.15	9.75	87.24
288	93.33	4.0115	7.69	91.17	95	5.44	1.29	92.02
166	73.33	3.15	6.04	100	75	4.29	8.13	92.76
106	60	2.5788	4.95	100	70	4.01	7.58	88.02
232	73.33	3.1519	6.04	66.5	80	4.58	8.67	69.68
202	93.33	4.0115	7.69	89.39	95	5.44	10.29	90.71
331	93.33	4.0115	7.69	89.39	95	5.44	10.29	90.71
141	53.33	2.29	4.39	100	40	2.29	4.33	100

جدول ۳ (ج): تاثیر تعداد تصاویر بازیابی شده بر نتایج مدل

Query_Id	30– Retrieve Image				40 – Retrieve Image			
	Precision	Recall	Fs	Ap	Precision	Recall	Fs	Ap
220	70	6.017	11.08	80.83	77.5	8.88	15.93	78.78
139	90	7.73	14.24	84.42	70	8.02	14.39	84.63
73	73.33	6.3	11.6	87.9458	67.5	7.73	13.88	83.83
288	63.33	5.44	10.02	92.02	57.5	6.59	11.82	85.72
166	83.33	7.16	13.19	87.71	87.5	10.02	17.99	87.17
106	80	6.87	12.66	83.081	82.5	9.45	16.96	87.99
232	73.33	6.3	11.60	73.5	65	7.44	13.36	71.97
202	76.66	6.59	12.13	91.55	57.5	6.59	11.82	91.55
331	80	6.87	12.64	91.73	60	6.87	12.33	91.73
141	60	5.15	9.49	73.51	70	8.02	14.39	70.82

جدول ۳ (د): تاثیر تعداد تصاویر بازیابی شده بر نتایج مدل

Query_Id	50 – Retrieve Image				100 – Retrieve Image			
	Precision	Recall	Fs	Ap	Precision	Recall	Fs	Ap
220	76	10.88	19.04	78.91	60	17.19	26.72	70.17
139	56	8.02	14.03	84.61	65	18.62	28.95	68.65
73	74	10.6	18.54	80.45	75	21.49	33.4	80.63
288	66	9.45	16.54	78.68	54	15.47	24.05	76.02
166	90	12.89	22.55	87.57	54	15.47	24.05	83.13
106	66	9.45	16.54	82.99	68	19.48	30.28	71.6
232	72	10.31	18.04	71.18	67	19.19	29.84	74.51
202	46	6.59	11.52	91.55	72	20.63	32.07	71.3
331	56	8.02	14.03	86.43	73	20.91	32.51	75.59
141	76	10.88	19.04	71.53	49	14.04	21.82	73.09



شکل ۹: بررسی تاثیر تعداد ویژگی بر نتایج بازیابی

جدول ۳ (الف): تاثیر تعداد تصاویر بازیابی شده بر نتایج مدل

Query_Id	5 – Retrieve Image				10 – Retrieve Image			
	Precision	Recall	Fs	Ap	Precision	Recall	Fs	Ap
220	100	1.43	2.82	100	100	2.86	5.71	100
139	80	1.1461	2.26	100	70	2	3.89	85.59
73	80	1.1461	2.26	100	80	2.29	4.45	88.02
288	80	1.1461	2.26	95	90	2.57	5.01	90.6
166	100	1.43	2.82	100	100	2.86	5.71	100
106	100	1.43	2.82	100	90	2.57	5.01	100
232	80	1.1461	2.25	67.91	60	1.71	3.34	64.53
202	80	1.1461	2.25	88.75	90	2.57	5.01	87.82
331	80	1.1461	2.25	88.75	90	2.57	5.01	87.82
141	100	1.43	2.82	100	80	2.29	4.45	100

نداشته است. در واقع استخراج ویژگی‌های عمیق با استفاده از شبکه عصبی سیامی مبتنی بر دو شبکه عمیق کانولوشن می‌تواند مدل را در مقابل تعداد بالای تصاویر پرس‌وجو مقاوم نماید. نتایج این آزمایش در شکل‌های (۱۲) و (۱۳) نشان می‌دهد که در شرایطی که مدل ۵۰ تصویر پرس‌وجو را دریافت نموده است توانسته به دقت ۸۳.۲۰٪ و در ۵ تصویر پرس‌وجو به دقت ۹۲٪ دست یابد که نتایج قابل قبولی می‌باشد. در واقع نتایج نشان می‌دهد که استفاده از ویژگی‌های عمیق می‌تواند در موفقیت مدل بازیابی برای انواع مختلف تصویر موثر واقع گردد؛ و با در نظر گرفتن تصاویر متفاوت دقت مدل کاهش چندانی ندارد.


نتایج این آزمایش حاکی از آن است که مدل پیشنهادی در تصاویر پزشکی که در جزئیات با هم متفاوت می‌باشند و هر تصویر نکات ریز خاص خود را دارد عملکرد موفق‌تری دارد. در این نتایج اگرچه در تعداد ۵۰ تصویر پرس‌وجو ارائه شده به مدل دقت کاهش یافته است اما مدل کماکان قادر به ارائه نتایج قابل قبولی است. در واقع استفاده از شبکه عصبی سیامی توانسته است در موفقیت مدل در بازیابی تصاویر مختلف موثر واقع گردد.

جدول ۴ (الف): بررسی تاثیر تعداد تصاویر پرس‌وجو بر نتایج مدل


Query	5 Query				Query	10 Query			
	P	Recall	Fs	Ap		P	Recall	Fs	Ap
230	100	1.43	2.82	100	288	80	1.1461	2.26	95
156	100	1.43	2.82	100	134	60	0.85	1.69	86.66
288	80	1.1461	2.26	95	230	100	1.43	2.82	100
331	80	1.1461	2.25	88.75	156	100	1.43	2.82	100
224	100	1.43	2.82	100	331	80	1.1461	2.25	88.75
<b>5-Proposed Result</b>					224	100	1.43	2.82	100
<b>P Recall Fs MAP</b>					14	100	1.43	2.82	100
<b>92.00 1.32 2.59 96.75</b>					166	100	1.43	2.82	100
<b>141</b>					100	1.43	2.82	100	
<b>350</b>					80	1.007	1.99	67.91	
<b>10-Proposed Result</b>									
<b>P Recall Fs MAP</b>									
<b>90.00 1.27 2.51 93.83</b>									

جدول ۴ (ب): بررسی تاثیر تعداد تصاویر پرس‌وجو بر نتایج مدل

Query	20 Query				Query	30 Query			
	P	Recall	Fs	AP		P	Recall	Fs	AP
288	80	1.1461	2.26	95	288	80	1.1461	2.26	95
134	60	0.85	1.69	86.66	134	60	0.85	1.69	86.66
230	100	1.43	2.82	100	230	100	1.43	2.82	100
156	100	1.43	2.82	100	156	100	1.43	2.82	100
331	80	1.1461	2.25	88.75	331	80	1.1461	2.25	88.75



شکل ۱۰: بررسی تاثیر تعداد تصاویر بازیابی شده در دقت مدل



شکل ۱۱: بررسی تاثیر تعداد تصاویر بازیابی شده در فراخوان مدل

### ۳-۴ نتایج بدست آمده برای تعداد تصاویر پرس‌وجو

برای بررسی میزان تاثیر تعداد تصاویر پرس‌وجو بین ۵ تا ۵۰ تصویر پرس‌وجو به تصادفی از پایگاه داده انتخاب شدند و برای هر یک تعداد ۵ تصویر بازیابی گردید. نتایج این آزمایش در جدول (۴) در بخش‌های (الف)، (ب) و (ج) و میانگین نتایج فوق جدول در شکل‌های (۱۲) و (۱۳) گزارش شده است.

از آنجایی که مرحله استخراج ویژگی در موفقیت مدل‌های بازیابی پزشکی بسیار حائز اهمیت است و مدل پیشنهاد شده در این تحقیق از یادگیری عمیق برای مرحله استخراج ویژگی استفاده کرده است؛ افزایش تعداد تصاویر پرس‌وجو تاثیر چندانی بر نتایج دقت مدل



Query	40 Query				Query	50 Query			
	P	Recall	Fs	Ap		P	Recall	Fs	Ap
170	40	0.57	1.29	100	170	40	0.57	1.29	100
312	100	1.43	2.82	100	312	100	1.43	2.82	100
113	100	1.43	2.82	100	113	100	1.43	2.82	100
128	100	1.43	2.82	100	128	100	1.43	2.82	100
300	80	1.1461	2.25	88.75	300	80	1.1461	2.25	88.75
5	80	1.1461	2.25	80.41	5	80	1.1461	2.25	80.41
148	100	1.43	2.82	100	148	100	1.43	2.82	100
332	100	1.43	2.82	100	332	100	1.43	2.82	100
243	60	0.85	1.69	70	243	60	0.85	1.69	70
164	100	1.43	2.82	100	164	100	1.43	2.82	100
179	80	1.1461	2.25	100	179	80	1.1461	2.25	100
264	100	1.43	2.82	100	264	100	1.43	2.82	100
194	80	1.1461	2.25	88.75	194	80	1.1461	2.25	88.75
159	60	0.85	1.69	100	159	60	0.85	1.69	100
91	100	1.43	2.82	100	91	100	1.43	2.82	100
11	100	1.43	2.82	100	11	100	1.43	2.82	100
298	60	0.85	1.69	100	298	60	0.85	1.69	100
231	60	0.85	1.69	100	231	60	0.85	1.69	100
153	100	1.43	2.82	100	153	100	1.43	2.82	100
198	80	1.1461	2.25	100	198	80	1.1461	2.25	100
192	100	1.43	2.82	100	192	100	1.43	2.82	100
228	80	1.14	2.25	80.41	228	80	1.14	2.25	80.41
62	60	0.85	1.69	100	62	60	0.85	1.69	100
249	100	1.43	2.82	100	249	100	1.43	2.82	100
195	100	1.43	2.82	100	195	100	1.43	2.82	100
191	80	1.1461	2.25	88.75	191	80	1.1461	2.25	88.75
200	80	1.1461	2.25	100	200	80	1.1461	2.25	100
188	60	0.85	1.69	100	188	60	0.85	1.69	100
28	100	1.43	2.82	100	28	100	1.43	2.82	100
<b>40-Proposed Result</b>					<b>64</b>	40	0.57	1.29	100
<b>P Recall Fs MAp</b>					<b>500</b>	40	0.57	1.29	100
<b>86.00 1.23 2.42 95.88</b>					<b>94</b>	100	1.43	2.82	100
					20	80	1.46	2.25	80.41
					251	40	0.57	1.29	100
					396	80	1	1.99	67.91
					276	100	1.43	2.82	100
					36	100	1.43	2.82	100
					262	80	1.46	2.25	100
					209	60	0.85	1.69	100
<b>50-Proposed Result</b>									
<b>P Recall Fs MAp</b>									
<b>83.20 1.20 2.35 95.67</b>									

Query	20 Query				Query	30 Query			
	P	Recall	Fs	AP		P	Recall	Fs	AP
224	100	1.43	2.82	100	224	100	1.43	2.82	100
14	100	1.43	2.82	100	14	100	1.43	2.82	100
166	100	1.43	2.82	100	166	100	1.43	2.82	100
141	100	1.43	2.82	100	141	100	1.43	2.82	100
350	80	1.007	1.99	67.91	350	80	1.007	1.99	67.91
38	100	1.43	2.82	100	38	100	1.43	2.82	100
170	40	0.57	1.29	100	170	40	0.57	1.29	100
312	100	1.43	2.82	100	312	100	1.43	2.82	100
113	100	1.43	2.82	100	113	100	1.43	2.82	100
128	100	1.43	2.82	100	128	100	1.43	2.82	100
300	80	1.1461	2.25	88.75	300	80	1.1461	2.25	88.75
5	80	1.1461	2.25	80.41	5	80	1.1461	2.25	80.41
148	100	1.43	2.82	100	148	100	1.43	2.82	100
332	100	1.43	2.82	100	332	100	1.43	2.82	100
243	60	0.85	1.69	70	243	60	0.85	1.69	70
<b>20-Proposed Result</b>					<b>164</b>	100	1.43	2.82	100
<b>P Recall Fs MAp</b>					<b>179</b>	80	1.1461	2.25	100
<b>88.00 1.25 2.48 93.87</b>					<b>264</b>	100	1.43	2.82	100
					194	80	1.1461	2.25	88.75
					159	60	0.85	1.69	100
					91	100	1.43	2.82	100
					11	100	1.43	2.82	100
					298	60	0.85	1.69	100
					231	60	0.85	1.69	100
					153	100	1.43	2.82	100
<b>30-Proposed Result</b>									
<b>P Recall Fs MAp</b>									
<b>86.67 1.23 2.44 95.54</b>									

جدول ۴ (ج): بررسی تاثیر تعداد تصاویر پرس و جو بر نتایج مدل

Query	40 Query				Query	50 Query			
	P	Recall	Fs	Ap		P	Recall	Fs	Ap
288	80	1.1461	2.26	95	288	80	1.1461	2.26	95
134	60	0.85	1.69	86.66	134	60	0.85	1.69	86.66
230	100	1.43	2.82	100	230	100	1.43	2.82	100
156	100	1.43	2.82	100	156	100	1.43	2.82	100
331	80	1.1461	2.25	88.75	331	80	1.1461	2.25	88.75
224	100	1.43	2.82	100	224	100	1.43	2.82	100
14	100	1.43	2.82	100	14	100	1.43	2.82	100
166	100	1.43	2.82	100	166	100	1.43	2.82	100
141	100	1.43	2.82	100	141	100	1.43	2.82	100
350	80	1.007	1.99	67.91	350	80	1.007	1.99	67.91
38	100	1.43	2.82	100	38	100	1.43	2.82	100




تا (۸) و میانگین جدول‌ها، در شکل‌های (۱۴) تا (۱۷) بیان شده است.

نتایج در جدول (۵) و (۶) نشان می‌دهد که روش پیشنهادی در مقایسه با روش‌های پیشین در بازیابی تصاویر مشابه موفق‌تر بوده است. یکی از نقاط ضعف روش‌های کای و هو این است که در بسیاری از تصاویر پرس‌وجو در پایگاه کووید-۱۹ قادر به ارائه تصاویر بازیابی مشابه نیست و نتایج ۰ ارائه می‌دهد. در مقابل روش ارائه شده اگرچه تا حدودی نتایج آن در برخی از تصاویر پرس‌وجو در مقایسه با روش کای و همکاران و هو و همکاران پایین‌تر می‌باشد اما عملکرد قابل اطمینان‌تری دارد و برای کلیه تصاویر پایگاه داده کووید-۱۹ قادر به ارائه پاسخ است.


از شکل (۱۴) می‌توان دریافت در میانگین ۵ تصویر بازیابی شده مدل ارائه شده توانسته است عملکرد موفق‌تری در مقایسه با روش‌های پیشین داشته باشد. در واقع این نتایج نشان می‌دهد که کاهش بعد بواسطه شبکه‌های عصبی سیامی همانطور که در روش کای و همکاران انجام شده است، نمی‌تواند عملکرد موفق‌تری در تصاویر پرس‌وجو مختلف ارائه دهد و این امکان وجود دارد که مدل در برخی تصاویر کاملاً ناکارآمد شود. در مقابل در روش پیشنهادی از مرحله انتخاب ویژگی برای کاهش ابعاد استفاده شده است که این نتایج نشان می‌دهد استخراج ویژگی با ابعاد بالاتر از شبکه سیامی و سپس اعمال یک تکنیک انتخاب ویژگی کارآمد می‌تواند موفقیت مدل را تضمین کند.

علاوه بر این تعریف ساختار متفاوت در معماری‌های زیر شبکه‌های کانولوشن در شبکه سیامی نیز در موفقیت نتایج فوق موثر هستند، کاهش تعداد لایه تمام متصل و در عوض افزایش تعداد لایه کانولوشن و تجمع حداکثر در روش پیشنهادی باعث شده ویژگی‌های دقیق‌تری از تصاویر استخراج شود و در نتیجه مدل در مرحله بازیابی موفق‌تر عمل نماید. از نتایج شکل (۱۵) می‌توان دریافت ترکیب تکنیک استخراج ویژگی مبتنی بر شبکه سیامی و انتخاب ویژگی حداقل افزونگی - حداکثر همبستگی می‌تواند نتایج مناسبی در بازیابی تصاویر پزشکی ارائه دهد. روش پیشنهاد شده در کلیه تصاویر دارای خروجی است و برای هیچ تصویری ناکارآمد نمی‌شود.

در صورتی که روش‌های پایه اگرچه در برخی از تصاویر پرس‌وجو نتایج بهتری ارائه می‌دهند اما روش‌های قابل اطمینانی نیستند و در برخی تصاویر بدون نتیجه بوده و کاملاً ناکارآمد می‌شوند.



شکل ۱۲: نتایج بررسی تعداد تصاویر پرس‌وجو بر دقت مدل



شکل ۱۳: نتایج بررسی تعداد تصاویر پرس‌وجو بر فراخوان مدل

#### ۴-۴-۴- مقایسه نتایج روش‌های پیشین و مدل ارائه شده

در این آزمایش‌ها تعداد تصاویر پرس‌وجو ۱۰ تصویر در نظر گرفته شده است اما تعداد تصاویر بازیابی شده برای هر تصویر به ترتیب ۵ و ۱۰ در نظر گرفته شده است و مقایسه در دو حالت بین مدل ارائه شده و روش‌های کای و همکاران در سال ۲۰۱۹ [۱۹] و هو و همکاران در سال ۲۰۲۲ [۳۰] در دو پایگاه داده کووید-۱۹ و پایگاه داده ذات‌الریه انجام شده است. نتایج این آزمون‌ها در جدول‌های (۵)

جدول ۶: مقایسه نتایج در ۱۰ تصویر بازیابی شده در پایگاه کووید-۱۹

Query_Id	Cai et al. [19]				Hu et al. [30]				Proposed 40f			
	P	R	Fs	Ap	P	R	Fs	Ap	P	R	Fs	Ap
288	100	2.86	5.56	100	80	2.29	4.45	78.69	90	2.57	5.01	90.6
134	100	2.86	5.56	100	60	1.71	3.33	87.34	80	2.29	4.45	78.69
230	100	2.86	5.56	100	100	2.86	5.56	100	80	2.29	4.45	91.59
156	100	2.86	5.56	100	90	2.57	5.01	90.6	90	2.57	5.01	100
331	60	1.71	3.33	87.34	60	1.71	3.33	87.34	90	2.57	5.01	87.82
224	100	2.86	5.56	100	100	2.86	5.56	100	70	2	3.89	100
14	100	2.86	5.56	100	100	2.86	5.56	100	70	2	3.89	100
166	20	0.573	1.11	70	60	1.71	3.33	87.34	100	2.86	5.57	100
141	100	2.86	5.56	100	80	1.14	2.25	88.75	80	2.29	4.45	100
350	0	0	0	0	20	0.573	1.11	70	90	2.26	4.43	78.57

جدول ۵: مقایسه نتایج در ۵ تصویر بازیابی شده در پایگاه کووید-۱۹


Query_Id	Cai et al.[19]				Hu et al. [30]				Proposed 40f			
	P	R	Fs	Ap	P	R	Fs	AP	P	R	Fs	Ap
288	100	1.43	2.82	100	100	1.43	2.82	100	80	1.14	2.26	95
134	100	1.43	2.82	100	100	1.43	2.82	100	60	0.85	1.69	86.66
230	100	1.43	2.82	100	100	1.43	2.82	100	100	1.43	2.82	100
156	100	1.43	2.82	80	100	1.43	2.82	100	100	1.43	2.82	100
331	80	1.14	2.25	88.75	80	1.14	2.26	95	80	1.14	2.25	88.75
224	100	1.43	2.82	100	100	2.86	5.56	100	100	1.43	2.82	100
14	100	1.43	2.82	100	100	1.43	2.82	100	100	1.43	2.82	100
166	80	1.14	2.25	80.41	80	1.14	2.26	95	<b>100</b>	<b>1.43</b>	<b>2.82</b>	<b>100</b>
141	100	1.43	2.82	100	100	1.43	2.82	100	100	1.43	2.82	100
350	0	0	0	0	0	0	0	0	<b>80</b>	<b>1.007</b>	<b>1.99</b>	<b>67.91</b>

جدول ۸: مقایسه نتایج در ۱۰ تصویر بازیابی شده در پایگاه ذات‌الرئیه


Query_Id	Cai et al. [19]				Hu et al. [30]				Proposed 40f			
	P	R	Fs	Ap	P	R	Fs	Ap	P	R	Fs	Ap
488	80	0.524	1.04	100	100	0.65	1.3	100	100	0.65	1.3	100
450	100	0.65	1.3	100	80	0.524	1.04	100	100	0.6	1.3	100
241	100	0.65	1.3	100	80	0.524	1.04	100	100	0.6	1.3	100
41	80	0.524	1.04	100	100	0.65	1.3	100	100	0.6	1.3	100
494	100	0.65	1.3	100	100	0.65	1.3	100	100	0.6	1.3	100
500	100	0.65	1.3	100	80	0.524	1.04	100	100	0.6	1.3	100
280	100	0.65	1.3	100	100	0.65	1.3	100	100	0.6	1.3	100
453	80	0.524	1.04	100	100	0.65	1.3	100	100	0.6	1.3	100
136	60	0.39	0.78	89.34	80	0.524	1.04	100	100	0.6	1.3	100
69	80	0.524	1.04	100	80	0.524	1.04	100	100	0.6	1.3	100

جدول ۷: مقایسه نتایج در ۵ تصویر بازیابی شده در پایگاه ذات‌الرئیه


Query_Id	Cai et al.[19]				Hu et al. [30]				Proposed 40f			
	P	R	Fs	Ap	P	R	Fs	AP	P	R	Fs	Ap
488	80	0.26	0.52	95	100	0.32	0.65	100	100	0.32	0.65	100
450	100	0.32	0.65	100	80	0.26	0.52	95	100	0.32	0.65	100
241	100	0.32	0.65	100	80	0.26	0.52	95	100	0.32	0.65	100
41	80	0.26	0.52	95	100	0.32	0.65	100	100	0.32	0.65	100
494	100	0.32	0.65	100	100	0.32	0.65	100	100	0.32	0.65	100
500	100	0.32	0.65	100	80	0.26	0.52	100	100	0.32	0.65	100
280	100	0.32	0.65	100	100	0.32	0.65	100	100	0.32	0.65	100
453	80	0.26	0.52	100	100	0.32	0.65	100	100	0.32	0.65	100
136	60	0.19	0.39	89.34	80	0.26	0.52	100	100	0.32	0.65	100
69	80	0.26	0.52	100	80	0.26	0.52	100	100	0.32	0.65	100



شکل ۱۵: مقایسه نتایج در ۱۰ تصویر بازیابی شده در پایگاه کووید-۱۹



شکل ۱۴: مقایسه نتایج در ۵ تصویر بازیابی شده در پایگاه کووید-۱۹



شکل ۱۷: مقایسه نتایج در ۱۰ تصویر بازیابی شده در پایگاه ذات‌الریه


### ۱- نتیجه‌گیری و کارهای آتی

مدل‌های بازیابی تصاویر پزشکی در دسته مدل‌های کاربردی قرار می‌گیرند که ضرورت وجود آن‌ها بدلیل مهاجرت پزشکی سنتی به سمت پزشکی نوین و افزایش تصاویر و ابزارهای مختلف تشخیص به شدت افزایش یافته است. سیستم‌های بازیابی تصاویر که به عنوان دستیار پزشکان می‌توانند استفاده شوند در شرایط بحرانی همچون شرایط کنونی که کشورهای مختلف با پاندمی بیماری کووید-۱۹ مواجه هستند می‌تواند در مناطق محروم به تشخیص زودهنگام و کنترل بیماری کمک شایانی کند. در این مقاله، یک مدل بازیابی تصاویر پزشکی مبتنی بر محتوا ارایه گردید. مدل ارائه شده از دو فاز استخراج ویژگی و بررسی تشابه تشکیل شده است؛ که برای استخراج ویژگی از تصاویر سی‌تی ریه از شبکه عصبی سی‌امی مبتنی بر دو زیر شبکه کانولوشن با ۱۳ لایه استفاده می‌کند. این روش شامل یک مرحله انتخاب ویژگی مبتنی بر الگوریتم حداقل افزونگی- حداکثر همبستگی است که زیر مجموعه بهینه از ویژگی‌ها را برای رسیدن به نتایج بهتر در زمان کوتاه‌تر استخراج می‌کند. و در نهایت با اعمال تکنیک درهم‌سازی باینری، بردار باینری ویژگی‌ها را تولید کرده و بازیابی را با فاصله همینگ انجام می‌دهد. نتایج تجربی این روش بر روی دو پایگاه تصاویر ریه شامل تصاویر سی‌تی اسکن کووید-۱۹ و اشعه ایکس بیماران ذات‌الریه نشان داد که مدل بازیابی پیشنهادی دارای درجه اطمینان بالایی در بازیابی تصاویر است و می‌تواند با میانگین دقتی بالغ بر ۹۲٪ بازیابی تصاویر ریه را در پایگاه

در نتایج شکل (۱۵)، ۱۰ تصویر پرس‌وجو بررسی شده است که از این تعداد ۱ تصویر در روش کای و هو بدون پاسخ است، اما با افزایش تعداد تصاویر پرس‌وجو تعداد تصاویری که روش‌های پیشین قادر به ارائه حتی یک تصویر مشابه با آن نیستند، افزایش می‌یابد در نتیجه می‌توان گفت این روش‌ها در دسته روش‌های غیر قابل اطمینان قرار می‌گیرند.

روش پیشنهادی در کلیه تصاویر پرس‌وجو دارای نتیجه حتی کمتر از روش‌های پیشین است اما میانگین عملکرد آن در مقایسه با روش‌های پیشین بهتر می‌باشد. همانطور که در شکل (۱۶) و (۱۷) مشاهده می‌شود در تصاویر ذات‌الریه هر سه مدل در مقایسه با تصاویر کووید-۱۹ نتایج بهتری از خود ارائه دادند. در این پایگاه داده مدل پیشنهادی در تعداد ۱۰ و ۵ تصویر بازیابی شده به میانگین دقت ۱۰۰٪ دست یافته است که در مقایسه با روش پیشین بهتر است. در رتبه دوم مدل هو و همکاران قرار می‌گیرد که توانسته به میانگین دقت ۹۹ و ۱۰۰٪ دست یابد.

نتایج در تصاویر ذات‌الریه نشان می‌دهد که ماهیت تصاویر اشعه X در موفقیت بیشتر مدل موثر بوده است. چرا که مرحله استخراج ویژگی که از اصلی‌ترین مراحل در مدل است در این تصاویر ویژگی‌های دقیق‌تری را از تصاویر استخراج کرده و در نتیجه بازیابی تصاویر به صورت کاملاً موفق انجام شده است.



شکل ۱۶: مقایسه نتایج در ۵ تصویر بازیابی شده در پایگاه ذات‌الریه

[15] W. Rawat and Z. Wang, "Deep convolutional neural networks for image classification: A comprehensive review," *Neural computation*, vol. 29, no. 9, pp. 2352-2449, 2017.

[16] W. Liu, Z. Wang, X. Liu, N. Zeng, Y. Liu, and F. Alsaadi, "A survey of deep neural network architectures and their applications," *Neurocomputing*, vol. 234, pp. 11-26, 2017.

[17] N. Malviya, N. Choudhary, and K. Jain, "Content based medical image retrieval and clustering based segmentation to diagnose lung cancer," *Advances in Computational Sciences and Technology*, vol. 10, no. 6, pp. 1577-1594, 2017.

[18] K. A. Gladis, "Integration of global and local features based on hybrid similarity matching scheme for medical image retrieval system," *International Journal of Biomedical Engineering and Technology*, vol. 31, no. 3, pp. 292-314, 2019.

[19] Y. Cai, Y. Li, C. Qiu, J. Ma, and X. Gao, "Medical image retrieval based on convolutional neural network and supervised hashing," *IEEE Access*, vol. 7, pp. 51877-51885, 2019.

[20] H. Kasban, D. Salama, and Applications, "A robust medical image retrieval system based on wavelet optimization and adaptive block truncation coding," *Multimedia Tools and Applications*, vol. 78, no. 24, pp. 35211-35236, 2019.

[21] N. F. Haq, M. Moradi, and Z. J. Wang, "A Deep Community Based Approach for Large Scale Content Based X-Ray Image Retrieval," *Medical Image Analysis*, vol. 68, pp. 1-16, 2020.

[22] K. France and A. Jaya, "Classification and retrieval of thoracic diseases using patch-based visual words: a study on chest x-rays," *Biomedical Physics & Engineering Express*, vol. 6, no. 2, pp. 1-9, 2020.

[23] H. J. Hwang *et al.*, "Content-Based Image Retrieval of Chest CT with Convolutional Neural Network for Diffuse Interstitial Lung Disease: Performance Assessment in Three Major Idiopathic Interstitial Pneumonias," *Korean Journal of Radiology*, vol. 22, no. 2, pp. 281-290, 2020.

[24] A. Sze-To and H. Tizhoosh, "Searching for Pneumothorax in Half a Million Chest X-Ray Images," in *International Conference on Artificial Intelligence in Medicine*, 2020: Springer, pp. 453-462.

[25] N. Darapureddy, N. Karatapu, and T. K. Battula, "Optimal weighted hybrid pattern for content based medical image retrieval using modified spider monkey optimization," 2020.

[26] B. Renita and S. Christopher, "Novel real time content based medical image retrieval scheme with GWO-SVM," *Multimed Tools Application*, vol. 79, pp. 1-17, 2020.

[27] K. Chethan and R. Bhandarkar, "An Efficient Medical Image Retrieval and Classification using Deep Neural Network," *Indian Journal of Science and Technology*, vol. 13, no. 39, pp. 4127-4141, 2020.

[28] P. HariPriya and R. Porkodi, "Parallel deep convolutional neural network for content based medical image retrieval," *Journal of Ambient Intelligence and Humanized Computing*, vol. 12, no. 1, pp. 781-795, 2021.

[29] N. F. Haq, M. Moradi, and Z. J. Wang, "A deep community based approach for large scale content based X-ray image retrieval," *Medical Image Analysis*, vol. 68, p. 101847, 2021.

[30] B. Hu, B. Vasu, and A. Hoogs, "X-MIR: EXplainable Medical Image Retrieval," in *Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision*, 2022, pp. 440-450.

[31] R. Pinapatruni and S. B. Chigarapalle, "Adversarial image reconstruction learning framework for medical image retrieval," *Signal, Image and Video Processing*, pp. 1-8, 2022.

[32] P. Hanchuan, L. Fuhui, and C. Ding, "Feature selection based on mutual information criteria of max-dependency, max-relevance, and min-redundancy," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 27, no. 8, pp. 1226-1238, 2005. doi: 10.1109/TPAMI.2005.159.

[33] J. Zhao, Y. Zhang, X. He, and P. Xie, "COVID-CT-Dataset: a CT scan dataset about COVID-19," *Machine Learning*, pp. 1-14, 2020.

[34] Z. I. Amanullah Asraf. *COVID19, Pneumonia and Normal Chest X-ray PA Dataset*. [Online]. Available: <https://data.mendeley.com/datasets/jctsfj2sfjn/1>

کووید-۱۹ و ۱۰۰٪ در پایگاه ذات‌الریه انجام دهد. در ادامه این مطالعه می‌توان از تکنیک‌های انتخاب ویژگی مبتنی بر الگوریتم‌های فراابتکاری مثل الگوریتم ازدحام ذرات کوانتومی استفاده نمود و نتایج مدل را بررسی کرد. استفاده از یکی از جدیدترین شبکه‌های عصبی عمیق ارائه شده در سال ۲۰۲۰ با عنوان شبکه عصبی RetrieveNet جهت بازیابی تصاویر می‌تواند در بهبود دقت مدل موثر واقع شود. همچنین انتظار می‌رود استفاده از شبکه‌های عصبی عمیق کانولوشن پیش آموزش دیده برای استخراج ویژگی و ترکیب ویژگی‌های آن‌ها با ویژگی‌های شبکه سیامی می‌تواند باعث شود، مدل نتایج بهتری ارائه دهد.

## مراجع

[1] H. H. Bhatt and A. P. Mankodia, "A Comprehensive Review on Content-Based Image Retrieval System: Features and Challenges," *Data Science Intelligent Applications*, vol. 52, pp. 63-74, 2021.

[2] K. Wanjale, T. Borawake, and S. Chaudhari, "Content based image retrieval for medical images techniques and storage methods-review paper," *IJCA Journal*, vol. 1, no. 19, pp. 105-107, 2010.

[3] T. W. Cai, J. Kim, and D. D. Feng, "Content-based medical image retrieval," in *Biomedical information technology*: Elsevier, 2008, pp. 83-113.

[4] A. Kumar, J. Kim, W. Cai, M. Fulham, and D. Feng, "Content-based medical image retrieval: a survey of applications to multidimensional and multimodality data," *Journal of digital imaging*, vol. 26, no. 6, pp. 1025-1039, 2013.

[5] H. A. Al-Jubouri, "Content-based image retrieval: Survey," *Journal of Engineering Sustainable Development*, vol. 23, no. 03, pp. 42-63, 2019.

[6] C. B. Akgül, D. L. Rubin, S. Napel, C. F. Beaulieu, H. Greenspan, and B. Acar, "Content-based image retrieval in radiology: current status and future directions," *Journal of digital imaging*, vol. 24, no. 2, pp. 208-222, 2011.

[7] P. Das and A. Neelima, "An overview of approaches for content-based medical image retrieval," *International journal of multimedia information retrieval*, vol. 6, no. 4, pp. 271-280, 2017.

[8] M. Alkhawani, M. Elmogy, and H. El Bakry, "Text-based, content-based, and semantic-based image retrievals: a survey," *International Journal of Computer and Information Technology*, vol. 4, no. 01, pp. 58-66, 2015.

[9] J. Bromley *et al.*, "Signature verification using a "siamese" time delay neural network," *International Journal of Pattern Recognition and Artificial Intelligence*, vol. 7, no. 04, pp. 669-688, 1993.

[10] D. Chicco, "Siamese neural networks: An overview," *Artificial Neural Networks*, pp. 73-94, 2021.

[11] J. Bromley, I. Guyon, Y. LeCun, E. Säckinger, and R. Shah, "Signature verification using a "siamese" time delay neural network," *Advances in neural information processing systems*, pp. 737-737, 1994.

[12] P. Baldi and Y. Chauvin, "Neural networks for fingerprint recognition," *neural computation*, vol. 5, no. 3, pp. 402-418, 1993.

[13] A. Mehmood, M. Maqsood, M. Bashir, and Y. Shuyuan, "A Deep Siamese Convolution Neural Network for Multi-Class Classification of Alzheimer Disease," *Brain Sciences*, vol. 10, no. 2, pp. 1-15, 2020.

[14] G. Koch, R. Zemel, and R. Salakhutdinov, "Siamese neural networks for one-shot image recognition," in *ICML deep learning workshop*, 2015, vol. 2: Lille, pp. 1-30.

## باورقی‌ها:

- <sup>1</sup> Content-Based Image Retrieval
- <sup>2</sup> X-ray
- <sup>3</sup> Computed Tomography scan (CT scan)
- <sup>4</sup> Query
- <sup>5</sup> Convolutional Neural Network
- <sup>6</sup> Minimum Redundancy Maximum Relevance
- <sup>7</sup> Online
- <sup>8</sup> Offline
- <sup>9</sup> Feature Vectors
- <sup>10</sup> Global
- <sup>11</sup> Local
- <sup>12</sup> Subnetworks
- <sup>13</sup> Paraphrase Identification
- <sup>14</sup> Feedforward Neural Networks
- <sup>15</sup> Bromley et al.
- <sup>16</sup> Baldi et al.
- <sup>17</sup> Multilayer Perceptron
- <sup>18</sup> Recurrent Neural Networks
- <sup>19</sup> Convolutional Neural Networks
- <sup>20</sup> Subsampling
- <sup>21</sup> Fully Connected
- <sup>22</sup> Speeded Up Robust Features
- <sup>23</sup> Local Binary Pattern
- <sup>24</sup> Discrete Wavelet Transform
- <sup>25</sup> Block Truncation Coding
- <sup>26</sup> Scale-Invariant Feature Transform
- <sup>27</sup> Area Under Curves
- <sup>28</sup> Spider Monkey
- <sup>29</sup> Gray Level Co-occurrence Matrix
- <sup>30</sup> Sparce
- <sup>31</sup> Histogram of oriented gradients
- <sup>32</sup> Local Ternary Patterns
- <sup>33</sup> Infinite Feature Selection
- <sup>34</sup> Parallel Deep Convolutional Neural Network
- <sup>35</sup> Radon
- <sup>36</sup> Central Processing Unit
- <sup>37</sup> Deep Community
- <sup>38</sup> Community
- <sup>39</sup> Saliency Maps
- <sup>40</sup> Occlusion-Based
- <sup>41</sup> Attention-Based
- <sup>42</sup> Activation Based
- <sup>43</sup> Adversarial Image Reconstruction
- <sup>44</sup> Adversarial Image Reconstruction Network
- <sup>45</sup> Rectified Linear Activation Function
- <sup>46</sup> Peng et al.
- <sup>47</sup> Max Relevance
- <sup>48</sup> Min Redundancy
- <sup>49</sup> Average Precision
- <sup>50</sup> Ranking
- <sup>51</sup> Mini Batch Size
- <sup>52</sup> Margin Threshold
- <sup>53</sup> Gradient Decay
- <sup>54</sup> Squared Gradient Decay