

## Breast Cancer Detection in Thermographic Images Using Hybrid Networks

Rezazadeh Tamrin Hanieh<sup>1</sup>, Saniei Elham<sup>2</sup>, Salehi Barough Mehdi<sup>2</sup>

• Received: 6 Jun 2023

• Accepted: 31 Oct 2023

**Introduction:** Breast cancer is the most common cancer in women that causes more deaths than other cancers. Thermography is one of the methods of breast cancer diagnosis. The most important challenge in early detection of these images can be human error or lack of access to a skilled person. The use of artificial intelligence methods in image processing can be effective in early detection and reduction of human error. The main aim of this research was to introduce hybrid networks for intelligent diagnosis of breast cancer from thermographic images.

**Method:** The thermographic images used in this study were collected from the DMR-IR database. First, the main features of the images were extracted by deep convolutional network (CNN). Then, FCNNs and SVM algorithms were used to classify breast cancer from thermographic images.

**Results:** The accuracy rate for CNN\_FC and CNN-SVM algorithms was 94.2% and 0.95%, respectively. In addition, the reliability parameters for these classifiers were calculated as 92.1%, and 97.5%, and the sensitivity for each of these classifiers as 95.5%, and 94.1%, respectively.

**Conclusion:** The proposed model based on the deep hybrid network has good accuracy compared to similar algorithms; therefore, it can help doctors in the early diagnosis of breast cancer through thermographic images and minimize human error.

**Keywords:** Diagnosis, Breast Cancer, Deep Learning, Convolutional Neural Network, Thermography

• **Citation:** Rezazadeh Tamrin H, Saniei E, Salehi Barough M. Cancer Detection in Thermographic Images Using Hybrid Networks. Journal of Health and Biomedical Informatics 2023; 10(3): 260-68. [In Persian] doi: 10.34172/jhbmi.2023.30

1. Master of Nuclear Engineering, Medical Radiation Research Center, Central Tehran Branch Islamic Azad University, Tehran, Iran

2. Ph.D. in Nuclear Engineering, Assistant Professor, Medical Radiation Research Center, Central Tehran Branch Islamic Azad University, Tehran, Iran

\*Corresponding Author: Elham Saniei

Address: Medical Radiation Research Center, Islamic Azad University, Tehran Branch, Imam Hassan Mojtaba Blvd., Poonak Square, Tehran

• Tel: 02144600024 • Email: [elhsaniei@gmail.com](mailto:elhsaniei@gmail.com)

© 2023 The Author(s); Published by Kerman University of Medical Sciences. This is an open-access article distributed under the terms of the Creative Commons Attribution License (<http://creativecommons.org/licenses/by/4.0/>), which permits unrestricted use, distribution, and reproduction in any medium, provided the original work is properly cite

## تشخیص هوشمند سرطان پستان از طریق شبکه‌های ترکیبی عمیق با استفاده از تصاویر ترموگرافی

حانیه رضازاده تمرین<sup>۱</sup>، الهام صنیعی<sup>۲</sup>، مهدی صالحی باروق<sup>۲\*</sup>

• دریافت مقاله: ۱۴۰۲/۳/۱۶ • پذیرش مقاله: ۱۴۰۲/۸/۹

**مقدمه:** سرطان پستان، شایع‌ترین سرطان بدخیم در زنان است و بیشتر از سایر سرطان‌ها باعث مرگ و میر آنان می‌شود. روش ترموگرافی یکی از روش‌های تشخیص سرطان پستان است. مهم‌ترین چالش در تشخیص زود هنگام از روی این تصاویر می‌تواند مربوط به خطای انسانی و یا عدم دسترسی به شخص ماهر باشد. استفاده از روش‌های هوش مصنوعی در پردازش تصاویر در تشخیص زود هنگام و کاهش خطای انسانی می‌تواند مؤثر باشد. هدف کلی این پژوهش معرفی شبکه‌های ترکیبی عمیق برای تشخیص هوشمند سرطان پستان از تصاویر ترموگرافی است.

**روش:** تصاویر ترموگرافی مورد استفاده در این پژوهش از پایگاه داده DMR-IR جمع‌آوری شده است. ابتدا ویژگی‌های اصلی تصاویر توسط شبکه پیچشی عمیق CNN استخراج گردید. سپس در ادامه از دو الگوریتم FCNNs و SVM برای کلاس‌بندی سرطان پستان از تصاویر ترموگرافی استفاده شد.

**نتایج:** نرخ دقت برای الگوریتم‌های CNN\_FC و CNN-SVM، به ترتیب ۹۴/۲٪، ۹۵/۰٪ بود. علاوه بر این، پارامترهای قابلیت اطمینان هم برای این طبقه‌بندی‌کننده‌ها به ترتیب ۹۲/۱٪، ۹۷/۵٪ و حساسیت برای هر یک از این طبقه‌بندی‌کننده‌ها به ترتیب ۹۵/۵٪، ۹۴/۱٪ محاسبه شد.

**نتیجه‌گیری:** مدل پیشنهادی مبتنی بر شبکه ترکیبی عمیق دقت مناسبی نسبت به الگوریتم‌های مشابه دارد؛ بنابراین می‌تواند پزشکان را در تشخیص زود هنگام سرطان پستان از طریق تصاویر ترموگرافی کمک نموده و خطای انسانی را به حداقل برساند.

**کلیدواژه‌ها:** تشخیص، سرطان پستان، یادگیری عمیق، شبکه عصبی کانولوشنی، ترموگرافی

• **ارجاع:** رضازاده تمرین، حانیه، صنیعی الهام، صالحی باروق مهدی. ارائه مدل خدمات بیمارستان هوشمند مبتنی بر اینترنت اشیاء. مجله انفورماتیک سلامت و زیست پزشکی

doi: 10.34172/jhbmi.2023.30. ۲۶۰-۲۶۸ (۳)۱۰، ۱۴۰۲

۱. کارشناسی ارشد مهندسی هسته‌ای، مرکز تحقیقات پرتو پزشکی، دانشگاه آزاد اسلامی واحد تهران مرکز، تهران، ایران

۲. دکتری مهندسی هسته‌ای، استادیار، مرکز تحقیقات پرتو پزشکی، دانشگاه آزاد اسلامی واحد تهران مرکز، تهران، ایران

\* نویسنده مسئول: الهام صنیعی

**آدرس:** تهران، میدان پونک، بلوار امام حسن مجتبی (ع)، دانشگاه آزاد اسلامی واحد تهران مرکز، مرکز تحقیقات پرتو پزشکی

• Email: elhsaniei@gmail.com

• شماره تماس: ۰۲۱۴۴۶۰۰۰۲۴

## مقدمه

سرطان پستان یکی از سرطان‌های شایع است. طبق محاسبات انستیتو ملی سرطان ایالات متحده آمریکا از هر هشت زن یک نفر در زندگی خود به سرطان پستان مبتلا می‌شود. این سرطان در صورتی که به موقع تشخیص داده شود به راحتی قابل درمان است. روش‌های بسیاری برای تصویربرداری سرطان پستان در مرحله تشخیصی وجود دارد. ترموگرافی یکی از این روش‌ها است که به وسیله یک دوربین مادون قرمز به ثبت دمای ناحیه مورد نظر می‌پردازد. این روش کاملاً بی‌خطر بوده و نسبت به سایر روش‌های تصویربرداری سرطان پستان، مقرون به صرفه‌تر است. با این وجود، این تکنیک دارای تعداد زیاد مثبت کاذب (False Positive) و منفی کاذب (False Negative) (حدود ۱۰٪) است و منطقه آسیب دیده را به طور دقیق تعیین نمی‌تواند تشخیص دهد [۱]. برای تشخیص مناطق با گرادیان دمای بالا، تشخیص خودکار مناطق مورد نظر در هر پستان و تجزیه و تحلیل عدم تقارن، تکنیک‌های هوش مصنوعی متفاوتی استفاده می‌شود [۲].

تکنیک‌های یادگیری مختلفی، از جمله شبکه‌های عصبی پرسپترون چند لایه، شبکه‌های عصبی کانولوشن و سیستم‌های خبره شبکه عصبی فازی تاکنون، برای تشخیص سرطان پستان با دقت بالا پیشنهاد شده است [۳]. این تکنیک‌ها با استفاده از مجموعه داده‌ها و ویژگی‌های مختلف، مانند تصاویر هیستوپاتولوژیک، تصاویر ماموگرافی و ترموگرام آزمایش شده‌اند. تکنیک‌های هوش مصنوعی، در حوزه‌های گوناگون از تحقیقات و کاربردهای علمی به چشم می‌خورند. شبکه‌های عصبی پرسپترون چند لایه با قابلیت یادگیری به تحلیل داده‌های ساختاریافته و غیرساختاری در حوزه‌هایی از جمله پردازش تصویر و تشخیص الگو کمک می‌کنند [۴]. شبکه عصبی پیچشی می‌تواند نگاشت غیرخطی بین ورودی و خروجی را به دست آورد و به طور خودکار ویژگی‌های محلی و ویژگی‌های سطح بالا را از طریق ساختارهای شبکه چند لایه و مجموعه ویژگی‌های از پیش تعریف شده را یاد بگیرد [۴]. این تکنولوژی‌ها به طور ویژه در سامانه‌های تشخیص تصویری مثل تشخیص اشیاء، تشخیص چهره و در پزشکی برای تشخیص بیماری‌ها مورد استفاده قرار می‌گیرند. علاوه بر این، ادغام ابزارهای مبتنی بر هوش مصنوعی در عمل بالینی برای بهبود دقت و کارایی غربالگری و درجه‌بندی سرطان سینه نیز مورد بررسی قرار گرفته است. با این حال،

تحقیقات بیشتری برای تأیید این رویکردها در مجموعه داده‌های بزرگ‌تر و اطمینان از ادغام ایمن در عمل بالینی مورد نیاز است. در جدیدترین نسخه‌های سیستم‌های تشخیصی، تکنیک‌های یادگیری عمیق به کمک پزشکان آمده‌اند. Desai و همکاران [۵] رویکرد جدیدی را برای تشخیص سرطان پستان با استفاده از تکنیک‌های یادگیری عمیق پیشنهاد کردند. آن‌ها در این مطالعه اثربخشی شبکه‌های عصبی (Multilayer perceptron) و MLP (Convolutional Neural Networks) را در طبقه‌بندی ماموگرافی به کلاس‌های خوش‌خیم و بدخیم تأیید کردند. برای تشخیص دقیق متاستاز سرطان پستان، یک مدل توسط Awotunde و همکاران [۶] پیشنهاد شده است که از الگوریتم‌های ترکیبی یادگیری ماشین و یادگیری عمیق استفاده می‌کند. این پژوهش تصاویر پاتولوژیک بیماران دارای سرطان پستان که نمونه‌برداری شده بودند به کار برد. آن‌ها به دقت ۹۹/۵٪ در تشخیص متاستاز رسیدند و نشان دادند که رویکرد آن‌ها از سایر تکنیک‌های پیشرفته برتری دارد. Francis و همکاران [۷] مدلی را پیشنهاد دادند که در این مدل ابتدا ویژگی‌های آماری و بافتی ابتدا توسط تبدیل curvete ابتدا استخراج می‌شود. سپس از بردار پشتیبان برای کلاس‌بندی تصاویر ترموگرافی استفاده کردند. الگوریتم پیشنهادی آن‌ها به صحت ۹۰/۹٪ در تشخیص سرطان پستان رسید. هدف اصلی این پژوهش طراحی یک سیستم ترکیبی با استفاده از شبکه عصبی پیچشی و الگوریتم‌های یادگیری ماشین همچون SVM (Support Vector Machines) و Fully FCNNs (Connected Neural Networks) جهت تشخیص زودهنگام سرطان پستان از تصاویر ترموگرافی است.

## روش


در این پژوهش چارچوب پیشنهادی برای تشخیص سرطان پستان از طریق دو معماری متفاوت شبکه ترکیبی عمیق شرح داده شد. در معماری اول شبکه عصبی پیچشی CNN به همراه الگوریتم کلاس‌بندی ماشین بردار پشتیبان SVM برای تشخیص خودکار سرطان پستان استفاده شد و در معماری دوم شبکه عصبی پیچشی به همراه یک شبکه عصبی تماماً متصل FCNNs جهت کلاس‌بندی تصاویر به دو کلاس نرمال و بیمار به کار رفت.

## مجموعه داده‌های تصاویر ترموگرافی

۴۸۰\*۶۴۰ استفاده شده است. در این مطالعه از تصویرترموگرافی ۴۵۰۰ فرد سالم و ۲۸۰۰ فرد سرطانی استفاده شد.

### پیش پردازش تصاویر

در این مرحله همه تصاویر رنگی به خاکستری تبدیل شدند. برای هر فرد از زوایای روبه‌رو، ۴۵، ۹۰ از جهات راست و چپ تصویرگیری شد و نهایتاً برای هر فرد ۵ تصویر ترموگرافی ثبت شد (شکل ۱). برای آموزش و آزمون شبکه CNN از مجموعه ۸۰ درصد برای آموزش و ۲۰ درصد برای آزمون انتخاب شد که رایج‌ترین نسبت در برنامه‌های یادگیری ماشین است. همچنین برای جلوگیری از overfitting از روش cross-fold validation با نسبت ۳ استفاده شد. تصاویر برای کلاس‌بندی در دو پوشه سرطانی و سالم قرار می‌گیرند.



شکل ۱: نمونه‌ای از تصاویر ترموگرافی استفاده شده: از چپ به راست به ترتیب نمای روبه‌رو، راست ۴۵، راست ۹۰، چپ ۴۵، چپ ۹۰

$7 \times 7$  پیکسل می‌باشد. علاوه بر این، عملیات کانولوشن از گزینه padding استفاده می‌کند که پیکسل‌های مرزی را قبل از عملیات کانولوشن گسترش می‌دهد.

۲- لایه‌های کانولوشن انباشته شده توسط یک عملیات نرمال‌سازی دسته‌ای دنبال می‌شوند. از طرفی لازم است هر لایه کانولوشن با یک عملیات واحد خطی اصلاح‌شده دنبال شود. یک لایه max-pooling با اندازه هسته  $2 \times 2$  پیکسل و گام ۲ در ادامه آن وجود دارد.

۳- لایه‌های کانولوشن انباشته بعدی و لایه نرمال‌سازی دسته‌ای از همان قسمت اول استفاده می‌کنند، با این تفاوت که اندازه هسته کانولوشن به ترتیب روی  $5 \times 5$ ،  $3 \times 3$  و  $3 \times 3$  تنظیم شده است.

۴- اولین لایه کاملاً متصل شامل ۱۶ نورون است.


۵- دومین لایه کاملاً متصل که دارای ۲ نورون است، دو دسته از تصاویر را در مجموعه داده‌های ترموگرافی سرطان جدا می‌کند. لایه خروجی یک تابع فعال‌سازی softmax با مقادیر خروجی برابر با صفر و یک خواهد بود.

در این مطالعه از تصاویر ترموگرافی پستان از مجموعه پایگاه داده DMR-IR (Database For Mastology Research) [۷] استفاده شد. این وب سایت دسترسی به یک پایگاه داده عمومی از تصاویر پزشکی، از جمله چندین مجموعه داده مرتبط با سرطان سینه، مانند ماموگرافی و ترموگرافی را فراهم می‌کند. این تصاویر از منابع مختلف از جمله بیمارستان‌ها، کلینیک‌ها و مؤسسات تحقیقاتی جمع‌آوری شده‌اند و طیف وسیعی از گروه‌های سنی و جنسیت را پوشش می‌دهند اطلاعات مرتبط با هر تصویر، مانند سن و جنسیت بیمار، در بیشتر موارد در دسترس هستند و اطلاعات ارزشمندی را برای توسعه الگوریتم‌های تشخیص سرطان پستان فراهم می‌کنند. برای ثبت تصاویر ترموگرافی در این پایگاه داده از دوربین FLIR SC-620 با رزولوشن

### استخراج ویژگی با استفاده از شبکه عصبی پیچشی (CNN)

در این تحقیق، برای استخراج ویژگی‌های تصاویر ترموگرافی در مرحله اول استفاده از شبکه عصبی CNN که توانایی خوبی در استخراج ویژگی تصاویر دارد پیشنهاد می‌شود [۹]. شبکه‌های عصبی پیچشی یکی از مهم‌ترین شبکه‌های عصبی عمیق هستند که تصویر را به عنوان ورودی دریافت و سپس به صورت هم‌زمان چندین ویژگی را پیش‌بینی می‌کند [۹]. CNN روی تصاویر آموزش می‌بیند و مستقیماً کارایی تشخیص را بهبود می‌دهد. شبکه عصبی کانولوشن بسیار سریع‌تر و دقیق‌تر از دیگر روش‌های استخراج ویژگی است. در تحقیق جاری، از چهار لایه کانولوشنی به همراه لایه نرمال‌ساز و pooling و دو لایه کاملاً متصل با ابعاد ۱۶ و ۲ در انتهای شبکه استفاده شد. شکل ۲ نحوه چینش و مشخصات لایه‌ها را نشان می‌دهد. این لایه‌ها در CNN به شرح زیر تعریف می‌شوند:

۱- ورودی‌های این شبکه همگی از نوع تصاویر  $480 \times 640 \times 3$  می‌باشند که لایه کانولوشن اول شامل ۸ فیلتر و اندازه هسته ۷



|    | Name                                                                 | Type                  | Activations | Learnables                     |
|----|----------------------------------------------------------------------|-----------------------|-------------|--------------------------------|
| 1  | imageinput<br>480x640x3 images with 'zerocenter' normalization       | Image Input           | 480x640x3   | -                              |
| 2  | conv_1<br>8 7x7x3 convolutions with stride [1 1] and padding 'same'  | Convolution           | 480x640x8   | Weights 7x7x3x8<br>Bias 1x1x8  |
| 3  | batchnorm_1<br>Batch normalization with 8 channels                   | Batch Normalization   | 480x640x8   | Offset 1x1x8<br>Scale 1x1x8    |
| 4  | relu_1<br>ReLU                                                       | ReLU                  | 480x640x8   | -                              |
| 5  | maxpool_1<br>2x2 max pooling with stride [2 2] and padding [0 0 0 0] | Max Pooling           | 240x320x8   | -                              |
| 6  | conv_2<br>8 5x5x8 convolutions with stride [1 1] and padding 'same'  | Convolution           | 240x320x8   | Weights 5x5x8x8<br>Bias 1x1x8  |
| 7  | batchnorm_2<br>Batch normalization with 8 channels                   | Batch Normalization   | 240x320x8   | Offset 1x1x8<br>Scale 1x1x8    |
| 8  | relu_2<br>ReLU                                                       | ReLU                  | 240x320x8   | -                              |
| 9  | maxpool_2<br>2x2 max pooling with stride [2 2] and padding [0 0 0 0] | Max Pooling           | 120x160x8   | -                              |
| 10 | conv_3<br>8 3x3x8 convolutions with stride [1 1] and padding 'same'  | Convolution           | 120x160x8   | Weights 3x3x8x8<br>Bias 1x1x8  |
| 11 | batchnorm_3<br>Batch normalization with 8 channels                   | Batch Normalization   | 120x160x8   | Offset 1x1x8<br>Scale 1x1x8    |
| 12 | relu_3<br>ReLU                                                       | ReLU                  | 120x160x8   | -                              |
| 13 | conv_4<br>8 3x3x8 convolutions with stride [1 1] and padding 'same'  | Convolution           | 120x160x8   | Weights 3x3x8x8<br>Bias 1x1x8  |
| 14 | batchnorm_4<br>Batch normalization with 8 channels                   | Batch Normalization   | 120x160x8   | Offset 1x1x8<br>Scale 1x1x8    |
| 15 | relu_4<br>ReLU                                                       | ReLU                  | 120x160x8   | -                              |
| 16 | fc_1<br>16 fully connected layer                                     | Fully Connected       | 1x1x16      | Weights 16x153600<br>Bias 16x1 |
| 17 | fc_2<br>2 fully connected layer                                      | Fully Connected       | 1x1x2       | Weights 2x16<br>Bias 2x1       |
| 18 | softmax<br>softmax                                                   | Softmax               | 1x1x2       | -                              |
| 19 | classoutput<br>crossentropyx                                         | Classification Output | -           | -                              |

شکل ۲: لایه‌های شبکه عصبی کانولوشن پیشنهادی در این تحقیق

### تنظیمات آموزش شبکه عصبی کانولوشن

برای آموزش شبکه CNN از ۱۰۰ گام (Epoch) استفاده گردید. از آنجایی که شبکه در ابتدای فرآیند آموزش در حالت ناپایدار قرار دارد؛ بنابراین بهتر است نرخ یادگیری کم باشد و سپس به آرامی زیاد شود نرخ آموزش برای تکرارهای اولیه، از ۰/۰۱ شروع و به آرامی افزایش می‌یابد. معمولاً برای جلوگیری از برآزش بیش از حد (Overfitting) از داده‌سازی (Data Augmentation) استفاده می‌شود [۱۰]. در این تحقیق نیز برای جامعیت بیشتر مجموعه دادگان از داده‌سازی استفاده شد که برای داده‌سازی، مقیاس دادن (Scale) حداکثر ۵۰٪ اندازه تصویر اصلی، چرخش با میزان تصادفی تا ۲۰ درجه به هر جهتی و انتقال (Translation) تصادفی تا حداکثر ۳ پیکسل به کار برده شد.

### طبقه‌بندی تصاویر

بعد از اعمال شبکه پیچشی (CNN) بر روی هر تصویر، بردار ویژگی‌های مرتبط با آن به دست خواهد آمد. معمولاً در انتهای شبکه CNN از یک شبکه عصبی تماماً متصل برای کلاس‌بندی

تصاویر استفاده شد که سرعت و صحت مناسبی برای ویژگی‌های خود شبکه کانولوشن دارد، ولی برای مقایسه دقت و سرعت طبقه‌بندی کنن—ده‌ها در این تحقیق از دو کلاس‌بندی کننده FCNNs و SVM استفاده گردید و نتایج بررسی و مقایسه شد. ماشین بردار پشتیبانی یکی از روش‌های یادگیری بانظارت است که از آن برای طبقه‌بندی استفاده می‌کنند. این روش از جمله روش‌های نسبتاً جدیدی است که در سال‌های اخیر کارایی خوبی نسبت به روش‌های قدیمی‌تر برای طبقه‌بندی نشان داده است. [۱۱]. مبنای کاری دسته‌بندی کننده SVM دسته‌بندی خطی داده‌ها است و در تقسیم خطی داده‌ها سعی می‌شود خط مرزی انتخاب شود که حاشیه اطمینان بیشتری داشته باشد. از توابع هسته مختلفی از جمله هسته‌های نمایی، چندجمله‌ای و سیگموئید می‌توان برای تولید این مرزها هم استفاده نمود که پیچیدگی روش SVM و صحت آن را بیشتر می‌کند [۱۱]. الگوریتم‌های این پژوهش با استفاده از زبان برنامه‌نویسی متلب نسخه ۲۰۲۱ پیاده‌سازی شد.


## نتایج

در شکل ۳ نمودارهای صحت و خطا در هر مرحله از آموزش نشان داده شد. همان طور که ملاحظه می شود با افزایش گام های آموزش، شبکه تلفات خود را کم کرده و به دقت های بالا خواهد رسید. در جدول ۱ تعداد ویژگی های مرتبط با هر روش بیان شده است. همچنین در جدول ۲ نتایج مقایسه سرعت و صحت نتایج

مربوط به هر طبقه بندی کننده آورده شد. همان طور که مشاهده می شود شبکه ترکیبی CNN-SVM به میزان ۱/۶ برابر سرعت بالاتری نسبت به شبکه CNN-FC دارد. سیستم ویندوز استفاده شده دارای مشخصات ۸ گیگا رم، Intel(R) Core i5-  
x64-based processor 4430 CPU @ 3.00GHz است. شبکه CNN-FC گرچه دقت خوبی دارد، اما سرعت پایین تری نسبت به روش دیگر دارد.

جدول ۱: پارامترهای طبقه بندی کننده ها در روش پیشنهادی

| ابعاد ویژگی های ورودی | تابع         | طبقه بندی کننده |
|-----------------------|--------------|-----------------|
| ۴۳۴۴×۲                | softmaxLayer | FCNNs           |
| ۴۳۴۴×۲                | fitcSVM      | SVM             |



شکل ۳: نمودار پیشرفت آموزش شبکه CNN پیشنهادی

جدول ۲: مقایسه سرعت آموزش در تشخیص سرطان با روش های پیشنهادی





| سرعت بر حسب ثانیه | طبقه بندی کننده |
|-------------------|-----------------|
| ۳۳۶/۱             | FCNNs           |
| ۲۵۰/۷             | SVM             |

دویی، «نمودار مشخصه عملکرد» یا به اختصار منحنی ROC است. در نمودار ROC هر دو شاخص صحت و قابلیت اطمینان ترکیب شده و به صورت یک منحنی نمایش داده می شوند. اغلب

برای مقایسه بهتر نتایج از نمودار ( Receiver Operating Characteristic) ROC و ماتریس درهم ریختگی استفاده شد. یکی از روش های بررسی و ارزیابی عملکرد دسته بندی دو

افرادی که به نادرست تشخیص داده شده‌اند به ترتیب ۱۱۸ و ۱۴۸ نفر می‌باشد. جدول ۳ نیز به بررسی صحت در مراحل آزمون روش‌های پیشنهادی می‌پردازد. همان‌گونه که مشاهده می‌شود، در این جا صحت آموزش طبقه‌بندی کننده SVM بیشتر از دیگر طبقه بندی کننده است.

برای بررسی کارایی الگوریتم‌های دسته‌بندی یا ایجاد داده‌های دسته‌ای از منحنی ROC استفاده می‌کنند. در شکل ۴ نمودار ROC و ماتریس درهم ریختگی استخراج شده برای دو شبکه ترکیبی پیشنهادی نمایش داده شده است. در شبکه‌های ترکیبی CNN-SVM و CNN-FC تعداد



شکل ۴: نمودار ROC و ماتریس درهم ریختگی برای شبکه‌های ترکیبی پیشنهادی: سطر بالا نمودار ROC و جدول در هم ریختگی مربوط به شبکه ترکیبی CNN-SVM، سطر پایینی نمودار ROC و جدول در هم ریختگی CNN-FC

جدول ۳: مقایسه نتایج دقت تشخیص فرد سرطانی در شبکه‌های ترکیبی پیشنهادی با طبقه‌بندی کننده‌های مختلف

| شبکه‌های ترکیبی عمیق | Accuracy | Sensitivity | 1-Specificity |
|----------------------|----------|-------------|---------------|
| CNN-FC               | ۹۴/۲٪    | ۹۳/۲٪       | ۹۱/۲٪         |
| CNN-SVM              | ۹۵/۰٪    | ۹۰/۴٪       | ۹۶/۵٪         |

## بحث و نتیجه گیری

در این مطالعه، هدف اصلی تشخیص سرطان پستان با استفاده از ترکیب تکنیک‌های یادگیری عمیق و الگوریتم‌های یادگیری ماشین از تصاویر ترموگرافی بود. در ساختار کلی الگوریتم طبقه‌بندی پیشنهادی، تصاویر ورودی با ابعاد  $480 \times 640 \times 3$  به یک شبکه عصبی پیچشی (CNN) برای استخراج بهترین ویژگی‌ها داده می‌شود و سپس ویژگی‌های مطلوب برای کلاس‌بندی تصاویر به دو کلاس نرمال و بیمار، وارد طبقه‌بندی کننده می‌شوند. در این پژوهش دو روش کلاس‌بندی FCNNs و SVM مورد بررسی و مقایسه قرار گرفتند.

در روش SVM تعداد افرادی که به نادرست تشخیص داده شده‌اند مجموعاً ۱۱۸ نفر می‌باشد، ولی برای طبقه‌بندی با FCNNs این تعداد به ۱۴۸ نفر می‌رسد. همان‌گونه که بیان شد صحت آموزش الگوریتم‌های SVM بیشتر از FCNNs است، ولی با این وجود صحت در شبکه ترکیبی CNN-FC هم بالا است. این صحت تشخیص بالا به علت هسته تشخیص شیء در الگوریتم کانولوشن است که برای تصاویر با رزولوشن بالا این روش بسیار مفید خواهد بود. ضمناً باید به این نکته هم توجه کرد که در زمان اجرا، فقط یکبار تصویر در شبکه اجرا شده است. از این رو، یک شبکه عصبی کانولوشن در حالت اجرا روی کارت‌های پردازش موازی فوق‌العاده سریع است و می‌تواند در

زمان واقعی اجرا شود. همچنین نتایج نشان می‌دهد که روش SVM کمترین حساسیت را داراست درحالی که نرخ مثبت غلط برای روش FCNNs کمتر خواهد بود.

محدودیت‌های مطالعه شامل استفاده تصویر به صورت یک‌باره و کامل به علت رزولوشن پایین در شبکه بوده است که در صورت داشتن تصاویر با رزولوشن بالا می‌توان تصاویر را به صورت تقسیم‌بندی شده و مرحله به مرحله به شبکه آموزش داد. سیستم مورد استفاده در این تحقیق هیچ کارت GPU ای نداشت؛ لذا تنها از مقایسه زمانی برای بررسی سرعت الگوریتم‌ها استفاده شد. جهت ادامه تحقیقات بر تشخیص سرطان در تصاویر ترموگرافی، استفاده از معماری‌های شبکه‌های عصبی عمیق جدیدتر، شبکه‌های از پیش آموزش دیده عمیق، شبکه‌های عصبی سریع‌تر و استفاده از روش‌های طبقه‌بندی دیگر مثل الگوریتم ژنتیک در ترکیب با شبکه پیچشی پیشنهاد می‌گردد. نتایج به دست آمده توسط سیستم پیشنهادی با استفاده از تصاویر ترموگرافی با برخی از روش‌ها در پژوهش‌های مرتبط مقایسه و در جدول ۴ آورده شده است.

## تعارض منافع

بین نویسندگان هیچ‌گونه تعارض منافی وجود ندارد.

جدول ۴: مقایسه نتایج دقت تشخیص در روش پیشنهادی با مقالات منتشر شده

| دقت تشخیص | تکنیک‌های طبقه‌بندی                               | تعداد بیماران/تصاویر حرارتی                         | تکنیک‌های استخراج ویژگی                                                                                         | مرجع                      |
|-----------|---------------------------------------------------|-----------------------------------------------------|-----------------------------------------------------------------------------------------------------------------|---------------------------|
| ۷۹/۵۳٪    | rule-based و Genetic algorithm for rule-reduction | ۱۴۶ تصویر حرارتی (۲۹ مرد و ۱۱۷ بیمار)               | ویژگی‌های آماری ابتدایی، ویژگی‌های مومنت، ویژگی‌های همبستگی، ویژگی‌های متقابل، اطلاعات مشترک و توصیفگرهای فوریه | Schaefer و همکاران [۱۲]   |
| ۸۰٪       | Perceptron                                        | ۶۰ تصویر حرارتی                                     | انحراف، کورتوزیس، آنتروپی، آنتروپی مشترک و ماتریس هم‌آمیختگی مانند انرژی، یکنواختی و همبستگی                    | Kapoor و Prasad [۱۳]      |
| ۸۸/۱۰٪    | SVM Classifier                                    | ۵۰ تصویر حرارتی (۲۵ نرمال و ۲۵ کانسر)               | ۱۶ ویژگی متنوع از جمله یکنواختی، انرژی، آنتروپی و ...                                                           | Acharya و همکاران [۱۴]    |
| ۹۰/۹۱٪    | SVM                                               | ۲۲ تصویر حرارتی (۱۱ کانسر و ۱۱ نرمال)               | ویژگی‌های مبتنی بر Curvelet از مطالب ترکیبی که توسط Haralick پیشنهاد شده است                                    | Francis و همکاران [۸]     |
| ۹۰/۴۸٪    | Feedforward Multilayer perceptron network         | ۳۰۶ تصویر حرارتی از ۱۰۲ فرد (۱۲۳ بیمار و ۱۸۳ نرمال) | ویژگی‌های آماری از تصاویر نقاط ویژگی اولیه (IFI)                                                                | Pramanik و همکاران [۱۵]   |
| ۹۶/۵٪     | SVM-CNN                                           | ۴۵۰۰ فرد سالم و ۲۸۰۰ فرد سرطانی                     | ویژگی‌های شبکه کانولوشنال طراحی شده                                                                             | روش پیشنهادی در این مقاله |

## References

1. Mousavi H, Bagherian R. Health literacy and breast cancer: review paper. *Journal of Health Psychology* 2019; 8(31): 91-102. <https://doi.org/10.30473/hpj.2019.46660.4426>
2. Mohamed AA, Berg WA, Peng H, Luo Y, Jankowitz RC, Wu S. A deep learning method for classifying mammographic breast density categories. *Medical Physics* 2018;45(1):314-21. <https://doi.org/10.1002/mp.12683>
3. Clady X, Negri P, Milgram M, Poulenard R. Multi-class vehicle type recognition system. *Artificial Neural Networks in Pattern Recognition*; 2008 Jul 2-4; Paris, France: ANNPR; 2008. p. 228-39.
4. Li Z, Liu F, Yang W, Peng S, Zhou J. A survey of convolutional neural networks: analysis, applications, and prospects. *IEEE Transactions on Neural Networks and Learning Systems*. 2021 Jun 10; IEEE; 2021. p. 6999 - 7019 doi: 10.1109/TNNLS.2021.3084827
5. Desai M, Shah M. An anatomization on breast cancer detection and diagnosis employing multi-layer perceptron neural network (MLP) and Convolutional neural network (CNN). *Clinical eHealth* 2021;4:1-1. <https://doi.org/10.1016/j.ceh.2020.11.002>
6. Awotunde JB, Panigrahi R, Khandelwal B, Garg A, Bhoi AK. Breast cancer diagnosis based on hybrid rule-based feature selection with deep learning algorithm. *Research on Biomedical Engineering* 2023;39(1):115-27.
7. Francis SV, Sasikala M, Saranya S. Detection of breast abnormality from thermograms using curvelet transform based feature extraction. *J Med Syst* 2014;38(4):23. <https://doi.org/10.1007/s10916-014-0023-3>
8. Silva LF, Saade DC, Sequeiros GO, Silva AC, Paiva AC, Bravo RS, et al. A new database for breast research with infrared image. *Journal of Medical Imaging and Health Informatics* 2014;4(1):92-100. <https://doi.org/10.1166/jmihi.2014.1226>
9. Venkatesan R, Li B. *Convolutional neural networks in visual computing: a concise guide*. CRC Press; 2017.
10. Taylor L, Nitschke G. Improving deep learning with generic data augmentation. In *2018 IEEE Symposium Series on Computational Intelligence (SSCI)* Nov 18 Bangalore, India: IEEE; 2018. doi: 10.1109/SSCI.2018.8628742
11. Burges CJ. A tutorial on support vector machines for pattern recognition. *Data mining and knowledge discovery*. 1998;2(2):121-67.
12. Schaefer G, Závisek M, Nakashima T. Thermography based breast cancer analysis using statistical features and fuzzy classification. *Pattern Recognition*. 2009;42(6):1133-7. <https://doi.org/10.1016/j.patcog.2008.08.007>
13. Kapoor P, Prasad SV. Image processing for early diagnosis of breast cancer using infrared images. *2nd International Conference on Computer and Automation Engineering (ICCAE)*; Feb 26-28; Singapore: IEEE; 2010. p. 564-6. doi: 10.1109/ICCAE.2010.5451827
14. Acharya UR, Ng EY, Tan JH, Sree SV. Thermography based breast cancer detection using texture features and support vector machine. *J Med Syst*. 2012;36:1503-10. <https://doi.org/10.1007/s10916-010-9611-z>
15. Pramanik S, Bhattacharjee D, Nasipuri M. Wavelet based thermogram analysis for breast cancer detection. *International Symposium on Advanced Computing and Communication (ISACC)*; Sep 14-15; Silchar, India: IEEE; 2015. p. 205-12. doi: 10.1109/ISACC.2015.7377343