

**Intelligent Breast Cancer Detection in Thermography Images Using Extreme Learning Machine and Image Processing****Hamid Reza Khodadad<sup>1</sup>, M.Sc, Homayoun Mahdavi-Nasab<sup>1,2</sup>, Associate Professor**<sup>1</sup>Department of Electrical Engineering- Najafabad Branch, Islamic Azad University, Najafabad, Iran  
<sup>2</sup>Digital Processing and Machine Vision Research Center, Najafabad Branch, Islamic Azad University,  
Najafabad, Iran

hamid.r1992@gmail.com, mahdavinab@iaun.ac.ir

**Abstract**

Since breast cancer is known as one of the main mortality reasons of women around the world, it would be most important to provide and develop early recognition methods for timely diagnosis, especially without using invasive imaging techniques and with fast response. Thermography with the contactless property and low cost, combined with a fast and reliable method to classify imaging results can be an ideal option to achieve this goal. This research aims at using breast thermography and a recent neural network method called extreme learning machine (ELM) as an intelligent and efficient classifier to recognize the cancer. We have also studied the development of this classifier as the kernel-based multilayer ELM. In the proposed method, at first, breast images are segmented using an automated segmentation to generate the region of interest (ROI) of the left and right breasts. Then, by extracting texture, color, and shape features, and presenting them separately or in combination with the neural network, the performance and efficiency of the method are evaluated. By experimenting with various models of local texture extraction, such as local binary pattern (LBP) and local ternary pattern (LTP), as well as using RGB and YCbCr color templates, the best results of this research in the database for mamma research with infrared image (DMR-IR) database belonged to the proposed combined LBP-Mix and the LTP texture features achieving more than 96% accuracy and 100% precision.

**Keywords:** automatic segmentation, breast thermography, feature extraction, local binary pattern, neural networks, extreme learning machine**Received:** 19 October 2022**Revised:** 11 November 2022**Accepted:** 14 February 2023**Corresponding Author:** Dr. Homayoun Mahdavi-Nasab

<https://dorl.net/dor/20.....>

مقاله پژوهشی

## تشخیص هوشمند سرطان سینه در تصاویر ترموگرافی با استفاده از ماشین یادگیری پیشینه و پردازش تصویر

حمیدرضا خداداد<sup>۱</sup>، دانش‌آموخته کارشناسی‌ارشد، همایون مهدوی نسب<sup>۲</sup>، دانشیار

۱- دانشکده مهندسی برق- واحد نجف‌آباد، دانشگاه آزاد اسلامی، نجف‌آباد، ایران

۲- مرکز تحقیقات پردازش دیجیتال و بینایی ماشین- واحد نجف‌آباد، دانشگاه آزاد اسلامی، نجف‌آباد، ایران

hamid.r1992@gmail.com, mahdavinabasab@iaun.ac.ir

**چکیده:** از آنجا که سرطان پستان به‌عنوان یکی از دلایل اصلی مرگ و میر زنان در سراسر جهان شناخته شده، طبیعی است که ارائه و توسعه روش‌هایی برای تشخیص زود هنگام آن، به‌ویژه بدون استفاده از ابزارهای تصویربرداری تهاجمی و نیز با سرعت پاسخ مناسب، از ارزش بالایی برخوردار باشد. تصویربرداری ترموگرافی، در صورتی که با روشی سریع و قابل اعتماد برای طبقه‌بندی نتایج تصویربرداری همراه گردد می‌تواند گزینه‌ای مناسب در جهت تحقق این هدف باشد. در این پژوهش با استفاده از ترموگرافی پستان و بهره‌گیری از نوعی از شبکه‌های عصبی متأخر به نام ماشین یادگیری پیشینه به‌عنوان یک طبقه‌بند هوشمند و کارآمد به مسئله تشخیص سرطان پستان اشاره شده است. همچنین، یک توسعه این طبقه‌بند تحت عنوان ماشین یادگیری پیشینه چندلایه مبتنی بر هسته را نیز مورد بررسی قرار گرفته است. در روش پیشنهادی، ابتدا با استفاده از یک روش تقسیم‌بندی خودکار تصاویر پایگاه داده به پستان‌های چپ و راست قطعه‌بندی و تفکیک شده و سپس با استخراج ویژگی‌های بافت محلی، رنگ و شکل و ارائه این ویژگی‌ها به‌صورت مجزا و یا ترکیبی به شبکه، عملکرد و کارایی سیستم مورد مطالعه قرار گرفته است. با آزمایش مدل‌های استخراج ویژگی بافت محلی گوناگون، مانند الگوی دودویی محلی (LBP) و الگوی سه‌تایی محلی (LTP) و نیز ویژگی‌های رنگ RGB و  $YCbCr$ ، برترین نتیجه این تحقیق از تصاویر ترموگرافی پستان در پایگاه داده برای تحقیقات ماما با تصویر مادون قرمز (DMR-IR) برای یک ویژگی ترکیبی جدید پیشنهادی LBP-Mix و ویژگی بافت LTP حاصل از استخراج بافت محلی در شعاع‌های مختلف، با صحت بیش از ۹۶ درصد و دقت ۱۰۰ درصد به‌دست آمده است.

**کلمات کلیدی:** استخراج ویژگی، ترموگرافی پستان، تقسیم‌بندی خودکار، شبکه‌های عصبی، الگوی دودویی محلی، ماشین یادگیری پیشینه

تاریخ ارسال مقاله: ۱۴۰۱/۷/۲۷

تاریخ بازنگری مقاله: ۱۴۰۱/۸/۲۰

تاریخ پذیرش مقاله: ۱۴۰۱/۱۱/۲۵

نام نویسنده‌ی مسئول: دکتر همایون مهدوی نسب

نشانی نویسنده‌ی مسئول: نجف‌آباد- بلوار دانشگاه- دانشگاه آزاد اسلامی واحد نجف‌آباد- دانشکده مهندسی برق

## ۱- مقدمه

سرطان یکی از چالش برانگیزترین و کشنده‌ترین بیماری‌ها در سراسر جهان است که هر ساله منجر به از دست رفتن جان میلیون‌ها انسان می‌شود. مطابق گزارش سازمان بهداشت جهانی، فقط در سال ۲۰۱۵ سرطان باعث مرگ ۸/۸ میلیون نفر شده است [۱،۲]. نئوپلاسم یا سرطان بدخیم، به دلیل تغییر ژنتیکی سلول‌های بدنی به‌عنوان یک اختلال ژنتیکی در نظر گرفته می‌شود [۳]. سرطان پستان یکی از شایع‌ترین سرطان‌ها در خانم‌ها است که پزشکان و متخصصان توجیه دقیقی برای بروز آن در برخی از زنان ندارند. علائم رایجی وجود دارد که نشانگر وجود سرطان پستان است. برخی از این علائم، درد در برخی مناطق نزدیک به پستان، تغییر در رنگ پوست (قرمز یا نارنجی شدن)، تغییر شکل غیرمعمول و حساسیت نوک پستان (نیپل) است [۴]. برای تشخیص سرطان پستان در گذشته از روش معاینه دستی و خودآزمایی و امروزه از انواع روش‌های تشخیصی تهاجمی<sup>۱</sup>، نیمه تهاجمی<sup>۲</sup> و غیرتهاجمی<sup>۳</sup> استفاده می‌شود [۵،۶]. مزیت روش‌های غیرتهاجمی عدم نیاز به بی‌حسی و نمونه‌برداری از پوست یا فشار و تابش اشعه بالقوه خطرناک به شخص است. یک روش مؤثر غیرتهاجمی تشخیص زودهنگام این سرطان تصویربرداری ترموگرافی با استفاده از دوربین‌های حرارتی و تحلیل آنهاست [۷].

یکی از اهداف این مطالعه، بررسی کارایی ماشین یادگیری پیشینه<sup>۴</sup> (ELM) در تشخیص سرطان پستان با استفاده از تصویربرداری ترموگرافی به‌عنوان یک روش غیرتهاجمی و امن است. در اینجا از تصاویر حرارتی برای آشکارسازی نواحی غیرطبیعی مشابه تومور و از ELM جهت طبقه‌بندی آنها به سالم و سرطانی بر اساس مجموعه ویژگی‌های مستخرج استفاده شده است. تا آنجا که از بررسی و جستجوی مؤلفین برمی‌آید از این روش تشخیص و طبقه‌بندی (ELM) با ورودی بردار ویژگی‌های ترموگرافی، در مطالعاتی که تاکنون برای این کاربرد ارائه شده، استفاده نشده است. همچنین، برخی ویژگی‌های بافت حاصل از ترکیب شعاع‌های متفاوت الگوی دودویی محلی<sup>۵</sup> (LBP) که در این پژوهش طراحی و ارائه شده‌اند را می‌توان از نوآوری‌ها و دستاوردهای این تحقیق دانست. قابل توجه است که برخی از این ویژگی‌ها برترین نتایج تشخیص را نیز به همراه داشته‌اند.

بنابر پژوهش‌های صورت گرفته استفاده از ویژگی‌های مستخرج از ترموگرافی و انواع طبقه‌بندی‌های آموزش‌پذیر متداول، مانند شبکه‌های عصبی پرسپترون چندلایه<sup>۶</sup> (MLP) و ماشین بردار پشتیبان<sup>۷</sup> (SVM) و در سال‌های اخیر شبکه‌های عصبی عمیق<sup>۸</sup> (DNN)، در این زمینه نتایج قابل قبولی را به‌دست آورده‌اند [۸]. اما این طبقه‌بندی‌ها از پیچیدگی نسبتاً بالایی برخوردار هستند و به زمان آموزش قابل توجهی نیاز دارند. شبکه‌های ELM در مقابل، با ساختاری به نسبت ساده‌تر، ساز و کار آموزش ساده و سریع‌تری نیز دارند که خود، همراه با توانایی تعمیم‌پذیری مناسب، دلیل انتخاب آنها جهت این تحقیق بوده است.

در ماشین یادگیری پیشینه وزن‌های لایه مخفی شبکه مقادیر تصادفی است و برخلاف دیگر روش‌های مذکور نیازی به تنظیم و آموزش آنها نیست؛ آموزشی که در شبکه‌های عصبی متداول عموماً براساس یک الگوریتم بهینه‌سازی بصورت برگشتی انجام شده و برای هر پایگاه داده با صرف زمان قابل توجه نیازمند تکرار و تکمیل است. شبکه عصبی ELM به‌صورت پایه تنها دارای یک لایه مخفی است که همراه با لایه خروجی ساختار کلی شبکه را تشکیل می‌دهد. اگرچه می‌توان ELM را با چند لایه خود رمزگذار<sup>۹</sup> (AE) که با استفاده از هسته‌های<sup>۱۰</sup> متفاوت آرایش می‌یابند برای رسیدن به تعمیم و پایداری بیشتر توسعه داد [۹]. در این پژوهش کارکرد شبکه ELM مبتنی بر هسته نیز جهت شناسایی سرطان پستان مورد بررسی و ارزیابی قرار گرفته است. ساختار مقاله شامل ۶ بخش است. در بخش‌های دوم و سوم به اختصار به مواد لازم برای انجام این تحقیق، یعنی ویژگی‌های تصویر و ماشین یادگیری پیشینه، اشاره شده است. بخش چهارم روش پیشنهادی را بیان می‌کند. این بخش ابتدا به نحوه تقسیم‌بندی خودکار پستان‌ها پرداخته و سپس روش پیشنهادی استخراج ویژگی تصاویر و سپس به‌کارگیری آنها در شبکه عصبی را ارائه کرده است. نتایج به‌دست آمده از طریق آزمایش‌ها و شبیه‌سازی‌های انجام شده در بخش پنجم گزارش شده‌اند. در نهایت در بخش ششم، نتیجه‌گیری و پیشنهادهایی برای ادامه تحقیق ارائه شده‌اند.

## ۲- استخراج ویژگی

در این قسمت الگوهای دودویی و سه‌تایی محلی همراه با ویژگی‌های شکلی و رنگ بیان می‌شود.

### ۱-۲- الگوی دودویی محلی

الگوی دودویی محلی ابزاری توانمند برای تحلیل بافت تصاویر است که ضمن سادگی، ویژگی‌های متمایزکننده مناسبی را در اختیار قرار می‌دهد. توصیف‌گر بافت LBP در شکل ابتدایی خود از عدد دودویی حاصل از اختلاف شدت روشنایی پیکسل‌های همسایگی یک پیکسل مرکزی استفاده می‌کند [۱۰]. توسعه این توصیف‌گر با امکان استفاده از همسایگی‌های با شعاع دلخواه  $r$  از پیکسل مرکزی انعطاف بیشتری را فراهم کرده و قادر به استخراج ویژگی‌های پیچیده‌تری است [۱۱]، به‌ویژه در شکل‌های ترکیبی با چند شعاع مختلف. این ویژگی از توزیع مساوی  $N$  نمونه از نقاط با شعاع  $r$  و پیکسل مرکزی  $p_c$  که در  $(x_c, y_c)$  واقع شده است، حاصل می‌شود. نقاط همسایه‌های نقطه  $c$  با  $p$  و مختصات زیر هستند.

$$(x_p, y_p) = (x_c + r \cos(2\pi p / N), y_c - r \sin(2\pi p / N)) \quad p \in \{0, 1, \dots, N-1\} \quad (1)$$

کد LBP برای نقطه با مختصات  $(x_c, y_c)$  با شدت روشنایی  $g_c$  با  $N$  همسایگی در شعاع  $r$  گرد آن به صورت زیر محاسبه می‌شود:

$$LBP_r(x, y) = \sum_{p=0}^{N-1} s(g_p - g_c) 2^p \quad (2)$$

که در آن:

$$s(\lambda) = \begin{cases} 1 & \lambda \geq 0 \\ 0 & \text{else} \end{cases} \quad (3)$$

اگر نقطه  $p$  با مرکز یک پیکسل مطابقت نداشته باشد برای محاسبه شدت خاکستری  $g_p$  از درون‌یابی دوخطی استفاده می‌شود. در نهایت، هیستوگرامی از کدهای دودویی ایجاد شده در یک ناحیه، یک بردار ویژگی بافت آن ناحیه را تشکیل می‌دهد [۱۲]. پس از معرفی LBP، با توسعه بیشتر این توصیف‌گر ویژگی‌های بافت دیگری با ساختار پایه مشابه اما عموماً پیچیده‌تر ارائه شده‌اند که در ادامه برخی از آنها معرفی می‌گردد.

### ۲-۲- الگوهای سه‌تایی محلی

برای مقابله با نویز تصویر که ویژگی LBP قادر به تشخیص آن نیست، توصیف‌گر سه‌تایی محلی<sup>۱۱</sup> (LTP) معرفی شده است که اختلاف بین شدت پیکسل مرکزی و نقاط همسایه را با سه مقدار و با استفاده از یک آستانه اختلاف رمزگذاری می‌کند [۱۲]. در اینجا، تفاوت بین مقادیر همسایه  $g_p$  و مقدار پیکسل مرکزی  $g_c$  با فرض آستانه  $t_1$  به صورت ویژگی زیر تعیین می‌شود:

$$LTP_r(x, y) = \sum_{p=0}^{N-1} s_3(g_p, g_c, t_1) 2^p \quad (4)$$

که در آن:

$$s_3(g_p, g_c, t_1) = \begin{cases} 1 & , \quad g_p \geq g_c + t_1 \\ 0 & , \quad g_c - t_1 \leq g_p < g_c + t_1 \\ -1 & , \quad \text{else} \end{cases} \quad (5)$$

معمولاً به جای استفاده از یک کد سه‌تایی و رمزگذاری سه حالت، از دو کد دودویی که نمایانگر اجزای مثبت و منفی کد سه‌گانه هستند، استفاده می‌کنند. این کدهای دودویی در دو هیستوگرام جداگانه جمع‌آوری شده و در آخرین مرحله، هیستوگرام‌ها برای تشکیل بردار ویژگی LTP به هم متصل می‌شوند.

### ۳-۲- ویژگی‌های شکلی

تفاوت شکل بین پستان چپ و راست سرنخی برای طبقه‌بندی است که به خودی خود یک پارامتر مورد توجه پزشکان است. به این جهت می‌توان از ویژگی‌های مساحت (A)، که از شمارش تعداد پیکسل‌های داخل مرز تعیین می‌شود، و محیط (P) تصویر پستان استفاده کرد. میزان گرد بودن (R) ویژگی قابل استفاده دیگر در این مطالعه است. این ویژگی‌ها در جدول (۱) مشخص و تعریف شده‌اند.

Table (1): Definition of the used shape features  
جدول (۱): توصیف ویژگی‌های شکل مورد استفاده

توصیف	شکل
$A = n.Pixels$	مساحت
$P = \sqrt{(x_i - x_{i-1})^2 + (y_i - y_{i-1})^2}$	محیط
$R = 4\pi(A / P^2)$	گرد بودن

#### ۴-۲- ویژگی رنگ

یک روش برای تمایز بین نواحی حاوی عروق خونی، مقایسه هیستوگرام سطوح رنگی تصویر است. رنگ قرمز نشان دهنده دمای بالا و خون‌رسانی زیاد به ناحیه مربوط به ناهنجاری پستان است. در اینجا از دو مدل رنگ RGB و  $YCbCr$  برای تمایز بین سطوح رنگی استفاده شده است. فضای رنگ RGB از بخش‌های قرمز، سبز و آبی تشکیل شده است. از این فضای رنگی به طور گسترده برای تقسیم‌بندی رنگی به دلیل سادگی و نتایج مطلوب استفاده شده است ولی حاوی ویژگی مستقل روشنایی نیست [۱۳]. در فضای رنگ  $YCbCr$  جزء  $Y$  روشنایی تصویر را نشان می‌دهد،  $Cb$  از اختلاف رنگی آبی و روشنایی و  $Cr$  که از اختلاف رنگ قرمز و روشنایی به دست می‌آید.

#### ۳- ماشین یادگیری پیشینه

هوانگ و بابری نشان دادند که یک شبکه عصبی پیش‌رو با یک لایه مخفی<sup>۱۲</sup> (SLFN) با حداکثر  $N$  گره مخفی با هر تابع فعالیت غیرخطی می‌تواند  $N$  مشاهده مجزا را یاد بگیرد [۱۴]. شبکه‌های موسوم به ELM با ساختار SLFN با وزن‌ها و بایاس‌های لایه ورودی (مخفی) تصادفی طراحی شده و نیازی به یادگیری ندارند. به‌علاوه برخی از نتایج شبیه‌سازی در مورد کاربردهای گوناگون نشان داده‌اند که این شبکه و برخی انواع توسعه یافته آن نه تنها یادگیری بسیار سریع‌تری دارند، بلکه در مقایسه با شبکه‌های عصبی متداول توانایی تعمیم برتری را نیز ارائه می‌کنند [۱۵]. پس از انتخاب وزن‌های ورودی و بایاس لایه مخفی به طور تصادفی، SLFN را می‌توان به سادگی به‌عنوان یک سیستم خطی در نظر گرفته و ماتریس وزن‌های لایه خروجی آن را از طریق یک نگاشت شبه‌معکوس ماتریس به‌صورت تحلیلی تعیین کرد. بر این اساس یک الگوریتم آموزش ساده ارائه می‌شود که سرعت یادگیری آن می‌تواند هزاران بار سریع‌تر از الگوریتم‌های یادگیری شبکه پیش‌روی معمول مانند الگوریتم پس‌انتشار<sup>۱۳</sup> (BP) باشد. علاوه بر این، الگوریتم آموزش ELM نه تنها به کم‌ترین خطای آموزشی بلکه به کوچک‌ترین نرم وزن نیز می‌رسد [۱۶]. عملکرد ELM را می‌توان این‌صورت تبیین کرد. برای  $N$  نمونه متمایز دلخواه  $(x_i, t_i)$  که:

$$\mathbf{x}_i = [x_{i1}, x_{i2}, \dots, x_{in}]^T \in \square^n \quad (6)$$

$$\mathbf{t}_i = [t_{i1}, t_{i2}, \dots, t_{im}]^T \in \square^m \quad (7)$$

با  $\tilde{N}$  گره مخفی و تابع فعالیت  $g(x)$ ، هر خروجی شبکه عبارت است از [۱۶]:

$$o_j = \sum_{i=1}^N \beta_i g_i(\mathbf{x}_j) = \sum_{i=1}^N \beta_i g(\mathbf{w}_i \cdot \mathbf{x}_j + b_i), \quad j = 1, \dots, N \quad (8)$$

که در آن:

$$\mathbf{w}_i = [w_{i1}, w_{i2}, \dots, w_{im}]^T \quad (9)$$

$$\beta_i = [\beta_{i1}, \beta_{i2}, \dots, \beta_{im}]^T \quad (10)$$

$w_i$  بردار وزن است که گره مخفی  $i$ -ام و گره‌های ورودی را بهم متصل می‌کند.  $\beta_i$  بردار وزن است که گره مخفی  $i$ -ام و گره‌های خروجی را بهم متصل می‌کند و  $b_i$  آستانه‌ای (بایاس) برای گره مخفی  $i$ -ام است.  $\mathbf{x}_j \cdot \mathbf{w}_i$  ضرب داخلی  $\mathbf{x}_j$  در  $\mathbf{w}_i$  است. فرض  $t_i$  به‌عنوان بردار مطلوب خروجی برای ورودی  $\mathbf{x}_i$  در یک SLFN با  $\tilde{N}$  گره مخفی و تابع فعالیت  $g(x)$  توانایی شبکه در تقریب خروجی به مقادیر مطلوب برای  $N$  نمونه موجود با میانگین خطای صفر به این معناست که:

$$\sum_{j=1}^N \|o_j - t_j\| = 0 \quad (11)$$

که یعنی  $\beta_i, w_i$  و  $b_i$  وجود دارند به طوری که:

$$\sum_{i=1}^N \beta_i g(w_i \cdot x_j + b_i) = t_j, \quad j = 1, \dots, N \quad (12)$$

که می‌توان آنرا به صورت مختصر در زیر نوشت:

$$\mathbf{H}\beta = \mathbf{T} \quad (13)$$

که در آن:

$$\mathbf{H}(w_1, \dots, w_N, b_1, \dots, b_N, x_1, \dots, x_N) = \begin{bmatrix} g(w_1 \cdot x_1 + b_1) & \dots & g(w_N \cdot x_1 + b_N) \\ \vdots & \dots & \vdots \\ g(w_1 \cdot x_N + b_1) & \dots & g(w_N \cdot x_N + b_N) \end{bmatrix}_{N \times N} \quad (14)$$

$$\beta = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_N^T \end{bmatrix}_{N \times m}$$

$$\mathbf{T} = \begin{bmatrix} t_1^T \\ \vdots \\ t_N^T \end{bmatrix}_{N \times m}$$

ماتریس  $\mathbf{H}$  ماتریس خروجی لایه مخفی نامیده می‌شود. حال می‌توان ماتریس وزن‌های لایه خروجی  $\beta$  را با استفاده از معکوس تعمیم‌یافته مور-پنروز<sup>۱۴</sup> ماتریس  $\mathbf{H}$  محاسبه کرد [۱۷، ۱۸].

$$\beta = \mathbf{H}^+ \mathbf{T} \quad (15)$$

### ۳-۱- ماشین یادگیری پیشینه چندلایه مبتنی بر هسته

ماشین یادگیری پیشینه چند لایه<sup>۱۵</sup> (ML-ELM) با به‌کارگیری ELM بر اساس خود رمزگذار یا خود رمزگذار دسته‌ای<sup>۱۶</sup> (SAE) پیشنهاد شده است [۱۹]. خود رمزگذار یک شبکه با الگوریتم محاسباتی مستقیم و کارآمد است که با جایگزینی خروجی  $t$  با ورودی  $x$ ، نماینده داده را می‌آموزد. مهم‌ترین مزیت ML-ELM نسبت به یادگیری عمیق سرعت بسیار بالاتر آموزش آن است. نتایج تجربی نشان می‌دهد که ML-ELM با تعمیم حتی بالاتر از SAE و روش‌های مبتنی بر یادگیری عمیق مانند شبکه باور عمیق<sup>۱۷</sup> به سرعت آموزش بسیار بیشتری دست می‌یابد. ساختار و عملکرد شبکه‌های ML-ELM در مرجع [۹] به تفصیل ارائه و بررسی شده است. ماشین یادگیری نهایی چند لایه مبتنی بر هسته<sup>۱۸</sup> (ML-KELM) از دو بخش کلی ماشین یادگیری مبتنی بر هسته (K-ELM) و ماشین یادگیری مبتنی بر هسته خود رمزگذار (KELM-AE) تشکیل شده است که در ادامه به معرفی آن‌ها می‌پردازیم.

### ۳-۱-۱- ماشین یادگیری مبتنی بر هسته

روش K-ELM با ادغام مفهوم هسته در ELM منجر به تعمیم بهتر و دخالت کمتر کاربر می‌شود [۲۰]. این الگوریتم همانند الگوریتم ELM ساده است با این تفاوت که در انجام محاسبه ماتریس خروجی وزن‌ها  $\beta$  از رابطه زیر استفاده می‌شود.

$$\beta = \mathbf{H}^+ \mathbf{T} = \mathbf{H}^T \left( \frac{\mathbf{I}}{c} + \mathbf{H}\mathbf{H}^T \right)^{-1} \mathbf{T} \quad (16)$$

$$\Omega = \mathbf{H}\mathbf{H}^T \quad (17)$$

که در آن  $\mathbf{I}$  ماتریس همانی و  $c$  توسط کاربر مشخص شده و ماتریس هسته با جایگزینی (۱۷) در رابطه (۱۶) با استفاده از عملکرد هسته (نگاشت قابل تعریف)  $K$  برای نمونه‌ای آموزشی تعیین می‌شود:

$$\Omega_{k,j} = \mathbf{K}(x_k, x_j) \quad k, j = 1, \dots, N \quad (18)$$

### ۳-۱-۲- ماشین نهایی یادگیری مبتنی بر هسته خود رمزگذار

روش KELM-AE مشابه با ELM-AE است که در آن شبکه داده آموزشی را به عنوان خروجی مطلوب فرا می گیرد. جهت کاهش پیچیدگی،

$$\Gamma^{(i)} = [\gamma_1^{(i)}, \dots, \gamma_n^{(i)}] \quad (19)$$

به عنوان نماینده  $i$ -امین ماتریس تبدیل، در KELM-AE استفاده می شود [۹]:

$$\Omega^{(i)} \Gamma^{(i)} = \mathbf{x}^{(i)} \quad (20)$$

و مطابق عملکرد خود رمزگذاری برای نماینده داده  $\mathbf{x}^{i+1}$ :

$$\mathbf{x}^{i+1} = \mathbf{g}(\mathbf{x}^{(i)} (\Gamma^{(i)})^T) \quad (21)$$

که در آن  $\mathbf{g}$  تابع فعالیت است. در نهایت نماینده نهایی داده (در لایه آخر خود رمزگذار دسته ای)  $\mathbf{x}^{final}$  محاسبه و به عنوان ورودی برای آموزش یک مدل طبقه بندی K-ELM، به شرح زیر تغذیه می شود:

$$\Omega^{final} \beta = \mathbf{T} \quad (22)$$

$\Omega^{final}$  ماتریس هسته ای حاصل از  $\mathbf{x}^{final}$  است. نهایتاً بر اساس رابطه (۲۲) ماتریس وزن های شبکه محاسبه می گردد [۹]:

$$\beta = \left( \frac{\mathbf{I}}{c} + \Omega^{final} \right)^{-1} \mathbf{T} \quad (23)$$

### ۴- روش پیشنهادی

روش پیشنهادی تشخیص سرطان پستان شامل چهار مرحله اصلی پیش پردازش، قطعه بندی، استخراج ویژگی و طبقه بندی است که در شکل (۱) مشاهده می شود.

#### ۴-۱- پیش پردازش

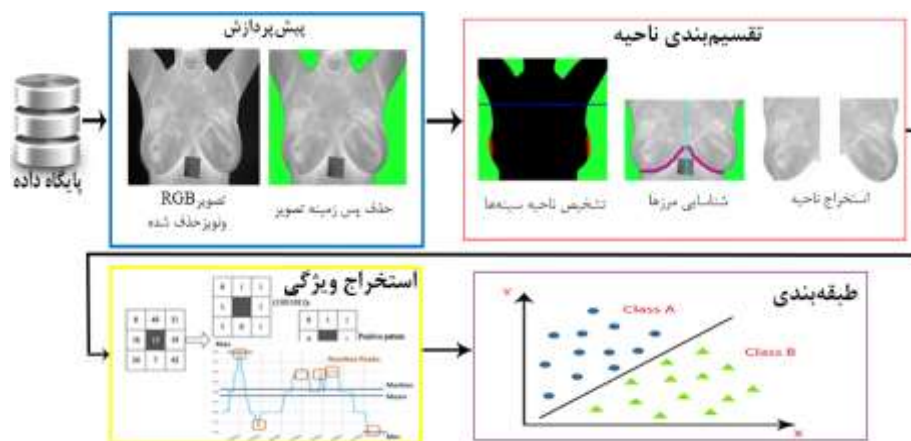
مهم ترین عمل در پیش پردازش تصویر RGB ورودی تقسیم بندی ناحیه مطلوب و تفکیک به دو تصویر پستان چپ و راست است که در ادامه توضیح داده می شوند.

#### ۴-۲- تقسیم بندی ناحیه

برای تفکیک ناحیه مورد نظر در ابتدا شناسایی نقاطی جهت برش ناحیه بالا تنه (سر، گردن و دستها) مورد نیاز است که این خود بستگی به بودن یا نبودن بالاتنه، یا پایین یا بالا بودن دستها، یا حتی بالا و پایین بودن و دور یا نزدیک بودن پستانها دارد که باید به آن توجه کرد. بر این اساس برای به دست آوردن ناحیه مورد نظر<sup>۱۹</sup> (ROI)، به ترتیب گام های زیر را طی می کنیم:

گام اول- در این مرحله به ترتیب بخشی از تصویر که حاصل از برش قسمت بالای تصویر است را تشکیل داده و با تبدیل آن به سیاه و سفید با استفاده از آستانه گذاری تجربی، میزان پیوستگی رنگی آن با برشی از قسمت میانی تصویر، مقایسه می شود [خط افقی تصویر اول بلوک تقسیم بندی ناحیه شکل (۱)]. به این ترتیب می توان بالا بودن دستها در تصویر یا وجود قسمت بالاتنه به عنوان بخش متفاوتی از تصویر را شناسایی و حذف کرد.

گام دوم- در این گام بیرون زدگی قوس پستان از بدن شخص در صورت وجود، تعیین و محاسبه می شود. این عمل برای پستان چپ، با سیاه و سفید کردن تصویر و با نزدیک شدن به اولین ستون از یک های موجود در ماتریس تصویر، از طرف راست تصویر، با استفاده از یک حلقه تکرار به دست می آید. همچنین برای پستان راست، از طرف چپ تصویر برای رسیدن به اولین نقطه سفید موجود در تصویر اقدام می شود و مقدار عدد سطری قوس استخراج می گردد [تصویر اول بلوک تقسیم بندی ناحیه شکل (۱)].



شکل (۱): نمودار کلی روش پیشنهادی  
Figure (1): Schematic of the proposed method

Table (2): ROI determination algorithm (Algorithm 1)

جدول (۲): الگوریتم تعیین ROI (الگوریتم ۱)

عنوان	شرح
ورودی	تصاویر ورودی از یک پایگاه داده مشخص
خروجی	تصاویر با محدوده ناحیه مورد نظر
گام اول	برش دادن بخش‌های بالا تنه تصویر و حذف آن
گام دوم	پیدا کردن مکان‌های نیپل چپ و راست پستان‌ها یا کناره‌های پستان‌ها با استفاده از دو حلقه تکرار و میانگین‌گیری
گام سوم	ثابت کردن تصویر (حذف صفرهای اضافه در تصویر دودویی)

با تعیین مختصات نقاط قوس پستان چپ و راست، برای تشکیل شکل کلی پستان و اضافه کردن قسمت قفسه پستان یک مقدار عددی متناسب با ابعاد تصویر پایگاه داده به مقدار عددی قوس اضافه می‌شود. در ادامه با استفاده از میانگین‌گیری از دو مقدار عددی ستون‌های مرزی چپ و راست مختصات تقریبی نیپل‌ها به دست می‌آید. گام سوم- در آخر، تصویر به دست آمده به تصویر سیاه و سفید تبدیل کرده و از جایی که مقدار ۱ وجود دارد، از چپ تا راست و از بالا تا پایین تصویر را ذخیره می‌کنیم. به طور مختصر در جدول (۲) الگوریتم ۱ آمده است.

### ۳-۴- تقسیم‌بندی پستان چپ و راست

در این بخش به معرفی روش پیشنهادی برای تقسیم‌بندی تصویر به تصاویر پستان چپ و راست با استفاده از نقشه راهی که بر تغییرات شدت نور و شدت رنگ تمرکز دارد، می‌پردازیم [تصویر میانه بلوک تقسیم‌بندی شکل (۱)]. در این روش، تقسیم‌بندی پستان‌های چپ و راست به صورت جداگانه صورت می‌پذیرد. به این صورت که ابتدا بعد از مرحله تعیین ناحیه ROI، پستان چپ و راست را با استفاده از نصف کردن تصویر ROI، جداسازی می‌کنیم و سپس برای استخراج شکل پستان از الگوریتم زیر استفاده می‌کنیم:

گام ۱- در ابتدا، برای نمایش پررنگ‌تر قسمت زیرین یا خط زیر پستان عمل تیز کردن با شعاع (انحراف معیار فیلتر گوسی)  $2/7$  و مقدار شدت  $33$  انجام شده و مقادیر با شدت بیشینه، با مقدار شدت روشنایی ۱ (حداکثر شدت) جایگزین می‌شود. سپس لکه‌ها و نقاط مزاحم به کمک عملگر ریخت‌شناسی بازکردن  $20$  (برای اجزای تصویر با مساحت کمتر از  $200$  پیکسل) حذف می‌شوند.

گام ۲- با استفاده از روش آستانه‌گذاری چندسطحی Otsu تصویر را با سه و چهار سطح آستانه‌گذاری و از مقدار اعداد به دست آمده در هر سطح واریانس گرفته و اندازه تفاضل هر دو واریانس را محاسبه می‌کنیم. اگر مقدار حاصل از  $600$  کم‌تر بود،



تصویری که تا سه سطح آستانه گذاری شده را ذخیره می‌کنیم و در غیر این صورت، تصویری را که تا چهار سطح آستانه گذاری شده است را در نظر می‌گیریم. در ادامه بعد از کوانتیزه کردن با مقدار آستانه مورد نظر، مقادیر بیشینه تصویر حاصل را استخراج می‌کنیم تا یک تصویر دودویی حاصل گردد و به کمک دستور ریخت‌شناسی بازکردن نقاط و لکه‌های مزاحمی که مقدار مساحت کمتر از ۸۰۰ پیکسل دارند را حذف می‌کنیم.

گام ۳- تصاویر نهایی دودویی که از تیز کردن تصویر در گام ۱ و از تصویری که با آستانه گذاری چند سطحی به روش Otsu و سپس کوانتیزه کردن آن در گام ۲ به دست آمده را با یکدیگر AND می‌کنیم.

گام ۴- براساس بررسی عناصر مجزای موجود در تصویر و به کارگیری خصوصیات اجزاء کوچک‌تر آن، عناصر با طول و مساحت کمتر و زاویه متفاوت نسبت به خط زیر پستان را با استفاده از عملگر ریخت‌شناسی باز کردن حذف می‌کنیم. سپس با استفاده از ماسک تهیه شده از مختصات خط زیر پستان و ضرب آن با تصاویر پستان‌های قطعه‌بندی شده چپ و راست بالای شکل، تصاویر نهایی شکل (۲) حاصل می‌شوند.

گام ۵- اگر در تصویر خط زیر پستان نمایان نشد از روش پیدا کردن نیپل استفاده می‌کنیم. به این صورت که ابتدا تصویر را با استفاده از یک روش لبه‌یابی مانند canny لبه‌یابی کرده و سپس با استفاده از عملیات ریخت‌شناسی فضاهای بسته و حفره‌ها را پر کرده و آن را از تصویر لبه‌یابی شده کم می‌کنیم. سپس تصویر حاصل را با عنصر ساختاری ریخت‌شناسی دایره‌ای به شعاع ۳ گسترش داده و با تصویر لبه‌یابی شده AND می‌کنیم و در نهایت دایره نیپل را با استفاده از تبدیل هاف دایروی<sup>۲۳</sup> به دست می‌آوریم در جدول (۳) الگوریتم ۲ آمده است.

شکل (۲) نمونه‌ای از تصاویر پایگاه داده است که مراحل تقسیم‌بندی پستان‌های چپ و راست (با استفاده از الگوریتم ۲، در حالی که خط زیر پستان در آن نمایان شده) را نشان می‌دهد. شکل (۳) نمونه‌ای از تصویر پایگاه داده است که با استفاده از روش تیزکردن و Otsu که خط زیر پستان در آن نمایان نشده است و مراحل تقسیم‌بندی پستان‌های چپ و راست را که با استفاده از الگوریتم ۲ صورت گرفته را نشان می‌دهد. در اکثر موارد با استفاده از تیز کردن تصویر و آستانه گذاری Otsu خط زیر پستان نمایان می‌شود و سپس اضافات تصویری که برای جداسازی یا استخراج پستان‌های در تصویر به جا مانده است حذف می‌شوند. اگر خط پستان در تصویر نمایان نشد (به علت عمل جراحی یا حرارت کم بدن) با لبه‌یابی و تبدیل هاف دایروی می‌توان به مکان پستان با استفاده از تشخیص نیپل پستان دست یافت. برای تقسیم‌بندی تصاویر رنگی، ابتدا با استفاده از الگوریتم ۱ تصویر ROI (بدون دست‌ها و سر) را استخراج کرده و سپس به روش فوق‌الذکر پستان‌های چپ و راست تفکیک می‌شوند [شکل (۴)].

#### ۴-۴- استخراج ویژگی‌های بافت

##### ۴-۴-۱- توصیف‌گر بافت الگوی دودویی محلی

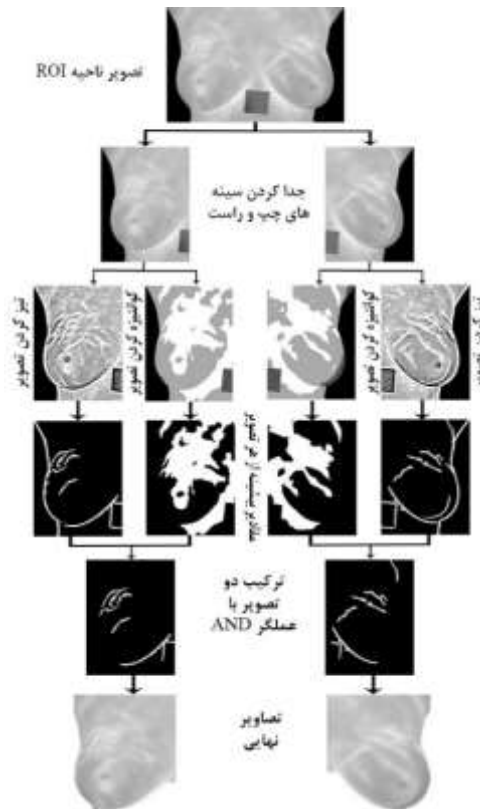
در روش پیشنهادی از LBP و مدل‌های وابسته آن جهت استخراج ویژگی‌های بافت تصویر استفاده شده است. این توصیف‌گر یک‌بار بر روی کل تصویر و بار دیگر با تقسیم تصویر به ۹ بلوک مساوی و تعیین هیستوگرام LBP هر بلوک (به طول ۱۰) و سپس اتصال آنها و تشکیل یک بردار به طول ۹۰ به کار رفته است. در اینجا مدل دوم LBP-9Block نام گذاری می‌شود. همچنین در روش پیشنهادی با ترکیب بردارهای LBP در چند شعاع r مختلف، LBP<sub>r</sub> بردارهای ویژگی بافت محلی متفاوتی تولید و بررسی شده است. از میان اینها بردار ویژگی حاصل از هیستوگرام‌های LBP در ۴ شعاع مختلف با رابطه ریاضی (۲۴) دارای نتایج قابل توجهی است.

$$(LBP_4 - LBP_1)^2 - (LBP_3 - LBP_2)^2 \quad (24)$$


با به کارگیری این مدل بر روی هر یک از ۹ بلوک یک تصویر یک بردار ویژگی (به طول ۹۰) وجود خواهد داشت که در این مقاله LBP-Mix نامیده می‌شود. لازم به ذکر است که شعاع‌های انتخاب شده در اینجا به صورت تجربی و با سعی و خطا انتخاب شده و تعیین شده‌اند.

Table (3): Breast segmentation into left and right parts (Algorithm 2)  
 جدول (۳): تقسیم‌بندی پستان به قسمت‌های چپ و راست (الگوریتم ۲)


عنوان	شرح
ورودی	تصویر ROI
خروجی	دو تصویر که شامل تصویر پستان چپ و راست
گام ۱	تیز کردن خط زیر پستان و حذف قسمت‌های با مساحت کم
گام ۲	کوانتیزه کردن تصویر با انتخاب یکی از سطح‌های ۳ یا ۴ به روش آستانه‌گذاری چند سطحی Otsu
گام ۳	به‌کارگیری عملگر AND برای ترکیب تصاویر دودویی به‌دست آمده از آستانه‌گذاری
گام ۴	حذف مقادیر ناخواسته و مزاحم و فقط ذخیره خط زیر پستان
گام ۵	در صورتی که در یک تصویر که خط پستان توسط گام ۳ حاصل نشد، پیدا کردن نیپل با استفاده از روش هاف دایروی



شکل (۲): استخراج پستان‌های چپ و راست از تصویر ناحیه مورد نظر به روش تیز کردن و آستانه‌گذاری Otsu  
 Figure (2): Extraction of left and right breasts from the ROI with sharpening and Otsu thresholding



شکل (۳): تقسیم‌بندی پستان‌های چپ و راست تصویر با روش لبه‌یابی  
 Figure (3): Left and right breasts segmentation using edge detection



شکل (۴): تقسیم‌بندی تصویر رنگی با استفاده از ناحیه مورد نظر  
Figure (4): Color image segmentation using the ROI

#### ۲-۴-۴- توصیف‌گر بافت الگوی سه‌تایی محلی

در الگوریتم تشخیص بافت LTP با مقدار آستانه ۲، چنانچه در بخش ۲ بیان شده است، برای هر تصویر دو هیستوگرام به دست می‌آید که هر کدام دارای طول ۲۵۶ است. در واقع در این روش دو ماتریس LOW و UP حاصل می‌شود که اولی از اعداد ۱- و صفر و دومی از دو مقدار ۱+ و صفر تشکیل شده است. در ادامه، با نسبت دادن اعداد دودویی به آنها و اتصال این دو هیستوگرام، هیستوگرام اصلی شامل ۵۱۲ المان است. برای LTP نیز همانند LBP، هر تصویر را به ۹ بلوک تقسیم کرده و با استخراج ویژگی هر بلوک و اتصال آنها به بردار ویژگی LTP-9Block می‌رسیم. مشابه روش بیان شده برای LBP بردار ویژگی ترکیبی LTP-Mix نیز تعریف و تعیین شده است.

#### ۵-۴- شبکه‌های عصبی ماشینی یادگیری پیشینه و ماشینی یادگیری پیشینه چندلایه مبتنی بر هسته

چنانچه در بخش قبل بیان شد، در این تحقیق ELM به علت داشتن سرعت بسیار بالای آموزش و سادگی علاوه بر قابلیت تعمیم‌دهی قابل توجه در مقایسه با دیگر شبکه‌های عصبی جهت اجرای طبقه‌بندی نهایی به کار رفته است. همچنین ML-KELM به علت داشتن خصوصیات مشابه با ELM، پایداری بیشتر و امکان حصول دقت‌های بالاتر نسبت به ELM مورد بررسی قرار گرفته است. به این موضوع نیز می‌توان اشاره کرد که در ML-KELM برخلاف ELM نیازی به تعیین تعداد گره‌های مخفی نیست. همچنین شایان ذکر است که در ELM چهار تابع فعالیت سینوسی، سیگموئید، تابع پایه مثلثی<sup>۲۴</sup> (tribas) و تابع پایه شعاعی<sup>۲۵</sup> (radbas) و برای ML-KELM توابع فعالیت هسته تابع پایه شعاعی<sup>۲۶</sup> (RBF)، هسته خطی<sup>۲۷</sup>، هسته چند جمله‌ای<sup>۲۸</sup> و هسته ویولت<sup>۲۹</sup> جهت نورون‌های شبکه، مورد بررسی قرار گرفته‌اند.

#### ۵- شبیه‌سازی و نتایج

در این بخش تصاویر پایگاه داده را به دو گروه رنگی و خاکستری تقسیم کرده و با استفاده از روش‌های مذکور در بخش ۴ قطعه‌بندی انجام می‌شود. سپس با استفاده از روش‌های اشاره شده در بخش ۲ به استخراج ویژگی‌های تصاویر پرداخته شده و از آنها به‌عنوان ورودی شبکه‌های عصبی MLP، ELM و ML-KELM استفاده می‌گردد و نتایج آزمایش‌ها ارائه می‌شود.

#### ۱-۵- آزمایش‌ها

در این پژوهش تصاویر ترموگرافی پستان از پایگاه داده برای تحقیقات ماما با تصویر مادون قرمز<sup>۳۰</sup> (DMR-IR)، به‌عنوان تنها پایگاه داده در دسترس عموم استفاده شده است [۲۱]. دوربین مورد استفاده در این پایگاه FLIR SC-620 و تصاویر خاکستری دارای دقت  $640 \times 480$  پیکسل و تصاویر رنگی با فرمت JPEG و دقت  $160 \times 120$  برای هر رنگ هستند. آزمایش‌های انجام شده در محیط نرم‌افزار متلب ۲۰۱۸ اجرا گردیده است. در اجرای شبیه‌سازی‌ها دو مجموعه تصاویر سالم و تصاویر غیرطبیعی اما غیرسرطانی را در یک مجموعه تصاویر "سالم" (غیرسرطانی) و تصاویر با تومور بدخیم را در مجموعه تصاویر "سرطانی" قرار داده‌ایم. تصاویر را با استفاده از الگوریتم‌های ارائه شده در بخش ۴ به صورت خودکار به دو قسمت قطعه‌بندی شده‌اند. با توجه به نسبتاً کم بودن تعداد تصاویر پایگاه جهت آموزش مناسب شبکه‌های عصبی، عمل تقسیم‌بندی تصاویر به دو تصویر پستان چپ و راست در این تحقیق برای افزایش تعداد تصاویر پایگاه داده نیز انجام می‌گیرد. به‌علاوه، بنابر مشاهدات این پژوهش تفکیک پستان‌ها به تصاویر مجزا برای پردازش دقیق‌تر نیز مفید است. قطعه‌بندی تصاویر رنگی فقط با استفاده از عمل تقسیم‌بندی با استفاده از الگوریتم ROI، انجام می‌شوند. با اجرای تقسیم‌بندی خودکار پستان‌های چپ و راست، هر تصویر از پایگاه داده DMR-IR [از بیست-امین تصویر به روش تصویربرداری ترموگرافی دینامیک<sup>۳۱</sup> (DTI)] در مجموع ۲۱۱ تصویر پایگاه به ۴۲۲ تصویر سالم و بیمار دسته‌بندی شده‌اند که ۳۳۸ پستان سالم (از ۱۶۹ تصویر سالم) و ۸۴ پستان بیمار (۴۲ تصویر بیمار) هستند. بنابر آزمایش بیوپسی، از ۸۴ تصویر بیمار، ۳۲ تصویر از آن "سرطانی" و ۵۲ تصویر غیرسرطانی هستند. همچنین با توجه به نقشه راه این مقاله برای تشخیص تصاویر سرطانی، تصاویر غیرسرطانی را در دسته تصاویر سالم دسته‌بندی می‌کنیم. برای طراحی آزمایش‌ها و روند اجرای آن، با توجه به حجم پایگاه داده از نسبت ۸۰ به ۲۰، به ترتیب برای آموزش و آزمون استفاده شده است. به این صورت که از تصاویر حاصل از تقسیم‌بندی خودکار پستان‌ها، ۳۳۷ تصویر برای آموزش و ۸۵ تصویر پستان برای آزمون انتخاب شده‌اند. بنابر نسبت مذکور، از مجموع تصاویر آموزش ۳۱۲ تصویر در دسته سالم و ۲۵ عدد در دسته سرطانی، و از ۸۵ تصویر آزمون ۷۸ تصویر سالم و ۷ تصویر سرطانی خواهیم داشت. برای شبکه عصبی MLP با انجام آزمایش‌های متعدد جهت کسب بهترین نتایج، نهایتاً یک لایه مخفی با ۶ نورون در نظر گرفته شده است. الگوریتم آموزش شبکه لونیگ-مارکارت<sup>۳۲</sup> (LM) توابع فعالیت لایه‌های مخفی و خروجی، به ترتیب، سیگموئید و خطی و تعداد دوره‌های آموزش شبکه نیز برابر ۱۰۰۰۰ بوده است. شبکه ELM با تعداد ۱۰ گره در لایه مخفی برای توابع فعالیت گوناگون مورد بررسی قرار گرفته است. برای شبکه ML-KELM ابتدا شبکه با ۳ لایه خودکدشونده و تابع فعالیتی معین آموزش دیده و سپس با افزایش تعداد لایه برای همان تابع فعالیت اجرا می‌گردد. این روند را برای دیگر تابع فعالیت‌ها نیز به کار گرفته‌ایم. ویژگی‌های بافت، رنگ و شکل در ابتدا به صورت جداگانه به شبکه‌های عصبی اعمال و نتایج عملکرد آنها بررسی شده است. سپس نتایج استفاده ترکیبی از این ویژگی‌ها ارائه شده‌اند. همچنین از روش تحلیل مؤلفه اصلی<sup>۳۳</sup> (PCA) مبتنی بر الگوریتم تجزیه مقادیر منفرد در هر مرحله جهت کاهش بعد داده‌های آموزش و آزمون استفاده شده و نتایج حاصل از آن مورد بررسی و مقایسه قرار گرفته است. بهترین نتایج حاصل از آزمایش‌ها با توجه به پارامترهای صحت<sup>۳۴</sup>، دقت<sup>۳۵</sup>، تشخیص‌پذیری<sup>۳۶</sup> و حساسیت<sup>۳۷</sup> در جدول-های (۴) الی (۱۰) ارائه شده است. جدول (۴) بهترین نتایج به دست آمده از ویژگی‌های بافت بدون استفاده از PCA با استفاده از انواع شبکه‌های عصبی مورد مطالعه در این پژوهش را نشان می‌دهد. در صورتی که مقدار صحت و دقت را ملاک قرار دهیم برترین نتایج متعلق به شبکه ELM و با ویژگی بافت LTP-9Block (با مجموع ۴۶۰۸ ویژگی) و تابع فعالیت sigmoid است. با ملاک قرار دادن مقادیر حساسیت و صحت می‌توان شبکه ELM و ویژگی بافت LBP-9Block با تابع فعالیت tribas را موفق‌ترین سیستم تشخیص دانست. در هر حال شبکه ELM بهترین نتایج این گروه را ارائه می‌کند.

Table (4): Results obtained from texture features without PCA (percent)  
جدول (۴): نتایج حاصل از ویژگی بافت بدون تحلیل مؤلفه اصلی (به درصد)

حساسیت	تشخیص‌پذیری	دقت	صحت	شبکه عصبی (ویژگی، تابع فعالیت)
۴۲/۸۶	۱۰۰	۱۰۰	۹۵/۲۹	MLP (LBP, LM)
۵۷/۱۴	۱۰۰	۱۰۰	۹۶/۴۷	ELM (LTP-9Block, sigmoid)
۷۱/۴۳	۹۸/۷۲	۸۳/۳۳	۹۶/۴۷	ELM (LBP-9Block, tribas)
۵۷/۱۴	۹۴/۸۷	۵۰	۹۱/۷۶	ML-KELM (LBP-9Block, poly-kernel)

Table (5): Best results obtained from texture features with PCA (percent).  
جدول (۵): برترین نتایج به دست آمده از ویژگی بافت با استفاده از تحلیل مؤلفه اصلی (به درصد)

حساسیت	تشخیص پذیری	دقت	صحت	طول بردار ویژگی	شبکه عصبی (ویژگی، تابع فعالیت)
۴۲/۸۶	۱۰۰	۱۰۰	۹۵/۲۹	۲۲	MLP (LTP-9Block, LM)
۵۷/۱۴	۱۰۰	۱۰۰	۹۶/۴۷	۱۷	ELM (LBP-Mix, tribas)
۷۱/۴۲	۹۸/۸۲	۷۵	۹۴/۱۲	۳	ELM (LTP-9Block, sigmoid)
۴۲/۸۶	۹۸/۷۲	۷۵	۹۴/۱۲	۳۰	ML-KELM, 5 Layer (LTP-9Block, poly-kernel)
۵۷/۱۴	۹۷/۴۴	۶۶/۶۷	۹۴/۱۲	۳	ML-KELM, 4 Layer (LBP-Mix, RBF-kernel)

جدول (۵) بهترین نتایج حاصل از ویژگی بافت پس از کاهش بعد با استفاده از PCA را نشان می‌دهد. با فرض اولویت معیارهای دقت و صحت مجدداً این شبکه ELM است که برترین نتایج را ارائه می‌کند، البته با ویژگی بافت LBP-Mix. با اولویت معیارهای صحت و حساسیت نیز همچنان ELM شبکه برتری است (با ویژگی LTP-9Block و تابع فعالیت sigmoid). بهترین نتایج به دست آمده از ویژگی رنگ بدون استفاده از PCA (با ۲۵۶ ویژگی برای هر لایه رنگ) و با استفاده از آن، به ترتیب در جدول‌های (۶) و (۷) نشان داده شده است. به وضوح برترین نتایج بنابر کلیه معیارها و با ویژگی‌های تقریباً یکسان متعلق به شبکه ELM است، مگر در خصوص معیار حساسیت که در آن ML-KELM عملکرد برتری دارد. همچنین شبکه MLP با الگوریتم LM قابل اجرا نبوده (بدلیل بُعد بالای ورودی) و از میان سایر الگوریتم‌ها برای آموزش شبکه الگوریتم BP-ارجاعی<sup>۳۸</sup> (trainrp) بهترین نتیجه را ارائه داده که در جدول (۶) قابل مشاهده است. شایان ذکر است که کاهش قابل توجه تعداد ویژگی‌ها، به‌ویژه برای ویژگی‌های رنگ و بافت، که نتایج مشابه و گاه برتری نیز در برداشته است، همراه با افزایش سرعت آموزش و اجرای شبکه، لزوم به‌کارگیری PCA را در عمل تأیید می‌کنند.

بهترین نتایج حاصل از اعمال ترکیب ویژگی‌های بافت، رنگ و شکل به شبکه‌های تحت مطالعه در جدول‌های (۸) و (۹)، به ترتیب برای ELM و MLP ارائه شده‌اند. به جهت مطلوب نبودن عملکرد شبکه ML-KELM نتایج آن در اینجا ارائه نشده است. همان‌طور که در جدول (۸) مشاهده می‌شود، برای شبکه ELM ترکیب ویژگی رنگ Y, Cr, Blue, Green به صورت تکی با ویژگی بافت LBP\_9Block و همچنین ترکیب ویژگی رنگ Y, Cr, Green به صورت تکی با ویژگی بافت LBP-9Block تابع فعالیت radbas نتایج مشابهی به دست آمد و در جدول (۹) شبکه MLP ویژگی بافت LTP-9Block همراه با ویژگی رنگ Cb برای حصول بالاترین دقت و تشخیص پذیری و علاوه بر آن ویژگی‌های شکل مطرح شده، برای رسیدن به بهترین مقادیر صحت و حساسیت هستند. در هر حال قابل توجه است که با لحاظ کلیه موارد، شبکه ELM بطور مشخصی نتایج برتری را در مقایسه با MLP ارائه می‌کند و به راحتی می‌توان آن را به‌عنوان طبقه‌بند برتر جهت کاربرد در تشخیص سرطان پستان از تصاویر ترموگرافی دانست. همچنین قابل توجه است که ترکیب ویژگی‌های بافت محلی برتر پیشنهادی، یعنی LTP-9Block (بدون کاهش بعد) و LBP-Mix (با کاهش بعد)، با سایر ویژگی‌ها به‌عنوان بردار ورودی شبکه ELM تأثیر مثبت قابل توجهی بر نتیجه تشخیص نداشته است. نهایتاً، در جدول (۱۰) نتایج تشخیص با اعتبارسنجی متقابل سه‌گانه که با سه بار تکرار آزمایش با انتخاب تصادفی نمونه‌های آزمون و آموزش از پایگاه داده به دست آمده‌اند ارائه شده است. این نتایج با به‌کارگیری ELM با ویژگی LBP-Mix و کاهش بعد توسط PCA و با تابع فعالیت tribas حاصل شده‌اند. نتایج حاصل از اعتبارسنجی تصادفی مقادیر قابل توجه ۱۰۰ درصد و بیش از ۹۶ درصد را به ترتیب برای دقت و صحت روش پیشنهادی تأیید می‌کنند.

Table (6): Best results obtained from color features without PCA  
جدول (۶): برترین نتایج به دست آمده از ویژگی رنگ بدون تحلیل مؤلفه اصلی

حساسیت	تشخیص پذیری	دقت	صحت	شبکه عصبی (ویژگی، تابع فعالیت)
۱۴/۲۹	۱۰۰	۱۰۰	۹۲/۹۴	MLP((G, B), ({tansig, purelin}, trainrp))
۴۲/۸۶	۱۰۰	۱۰۰	۹۵/۲۹	ELM ((Y, Cb), sigmoid)
۵۷/۱۴	۹۷/۴۴	۶۶/۶۷	۹۴/۱۲	ELM ((Y, Cb, Cr), sigmoid)
۷۱/۴۳	۱۳/۸۹	۶۱/۱۸	۷۱/۴۲	ML-KELM ((Y, Cr), poly-kernel)

Table (7): Best results obtained from color features with PCA

جدول (۷): برترین نتایج به‌دست آمده از ویژگی رنگ با تحلیل مؤلفه اصلی

حساسیت	تشخیص پذیری	دقت	صحت	طول بردار ویژگی	شبکه عصبی (ویژگی، تابع فعالیت)
۲۸/۵۷	۱۰۰	۱۰۰	۹۴/۱۲	۲۲	MLP (Cb, LM)
۴۲/۸۶	۱۰۰	۱۰۰	۹۵/۲۹	۵۵	ELM ((G, B, Y, Cr)), radbas)
۷۱/۴۲	۸۵/۹۰	۳۱/۲۵	۸۴/۷۱	۸۲	ML-KELM, 4 Layer (G, poly-kernel)

Table (8): Best results obtained from combination of features with the ELM

جدول (۸): برترین نتایج ارائه تر کیب ویژگی‌ها با شبکه ماشین یادگیری پیشینه

حساسیت	تشخیص پذیری	دقت	صحت	ترکیب ویژگی‌ها
۲۸/۵۷	۱۰۰	۱۰۰	۹۴/۱۲	LBP_Mix, Green, Shape (sigmoid)
۷۱/۴۳	۹۲/۳۱	۴۵/۴۵	۹۰/۵۹	LBP_9Block, Blue, Shape (sin)
۲۸/۵۷	۱۰۰	۱۰۰	۹۴/۱۲	LBP_9Block, Green (radbas)
۲۸/۵۷	۱۰۰	۱۰۰	۹۴/۱۲	LBP_Mix, Green (sigmoid)

Table (9): Best results obtained from combination of features with the MLP

جدول (۹): برترین نتایج حاصل از ارائه ترکیب ویژگی‌ها به شبکه پرسپترون چندلایه

انحراف از میانگین صحت	حساسیت	تشخیص پذیری	دقت	صحت	ترکیب ویژگی‌ها
۳۰/۰۳	۱۴/۲۹	۱۰۰	۱۰۰	۹۲/۹۴	LTP9-Block, Cb
۳۰/۳۰	۲۸/۵۷	۹۴/۸۷	۸۰	۹۵/۲۹	LTP-9Block, Cb, Shape
۳۲/۷۵	۴۲/۸۶	۹۷/۴۴	۶۰	۹۲/۹۴	LTP-9Block, Shape
۳۰/۰۲	۱۴/۲۹	۹۸/۷۲	۵۰	۹۱/۷۶	Cb, Shape

Table (10): 3-fold random validation for the ELM

جدول (۱۰): اعتبارسنجی تصادفی سه‌گانه حاصل از ماشین یادگیری پیشینه

حساسیت	تشخیص پذیری	دقت	صحت	ویژگی	آزمایش
۵۰	۱۰۰	۱۰۰	۹۶/۴۳	ELM, LBP-Mix	۱
۳۳/۳۳	۱۰۰	۱۰۰	۹۵/۲۴		۲
۵۰	۱۰۰	۱۰۰	۹۶/۴۷		۳
۴۴/۴۴	۱۰۰	۱۰۰	۹۶/۰۵	میانگین	*

## ۲-۵- مقایسه عملکرد

هرچند استفاده از دادگان متفاوت و بعضاً اختصاصی، معیارهای متفاوت و یا روش‌های پیچیده و با بار محاسباتی گاه بسیار بیشتر امکان مقایسه منصفانه نتایج را دشوار می‌سازد، برای تأکید بر ارزش نتایج پژوهش حاضر، در این قسمت به نتایج چند پژوهش اخیر به صورت مختصر اشاره می‌شود. در مرجع [۲۲] نتایج تشخیص و آشکارسازی سرطان سینه با استفاده از شبکه‌های عصبی گوناگون مورد بررسی و مقایسه قرار گرفته است. مطابق انتظار برترین نتایج گزارش شده متعلق به شبکه‌های عصبی عمیق و مبتنی بر تصاویر تشدید مغناطیسی یا ماموگرافی است که به دقت‌های بیش از ۹۸ درصد نیز دست یافته‌اند. البته این شبکه‌ها از پیچیدگی ساختاری و زمان آموزش بسیار بیشتری در مقایسه با روش پژوهش حاضر برخوردارند. پژوهش مرجع [۲۳] نیز با کمک روش هوشمند متأخر کرم شب‌تاب دقت تشخیص تا ۹۵ درصد را در تصاویر ماموگرافی گزارش کرده است. اما برای دادگان ترموگرافی می‌توان به تحقیق در مرجع [۲۴] اشاره کرد که در روشی نسبتاً پیچیده، پس از قطعه‌بندی پستان در تصاویر یک پایگاه داده بومی، به استخراج ویژگی‌های متعدد آماری، ریخت‌شناسی، فرکانسی، هیستوگرام و بافت (مبتنی بر ماتریس هم‌رخدادی<sup>۳۹</sup>) پرداخته‌اند. سپس، انتخاب ویژگی و طبقه‌بندی به سالم و غیرسالم به روش‌های گوناگون بررسی شده است. برترین نتایج گزارش شده، با انتخاب ویژگی به وسیله الگوریتم ژنتیک و طبقه‌بند آداپوست، صحت در حدود ۸۵ و ۸۷ درصد، به ترتیب برای پستان‌های چپ و راست، ارائه کرده‌اند که البته به طور قابل توجهی کمتر از صحت حاصل از

ماشین یادگیری بیشینه با ویژگی‌های پیشنهادی این تحقیق است [جدول (۱۰)]، هرچند بدلیل تفاوت دادگان چنانچه گفته شد مقایسه نتایج کاملاً معتبر نخواهد بود. در مرجع [۲۵] از یادگیری عمیق و شبکه‌های عصبی کانولوشن<sup>۴۱</sup> (CNN) و بهینه‌سازی بیزی برای طبقه‌بندی تصاویر سینه به دو حالت سالم و بیمار استفاده شده است. روش مذکور با بار محاسباتی بسیار بیشتر در مقایسه با روش پیشنهادی این تحقیق (هم از لحاظ آموزش و هم اجرا) به میزان صحت ۹۸/۹۵ درصد برای تصاویر ترموگرافی موجود در پایگاه داده‌ای شامل ۱۴۰ فرد دست یافته است. اگرچه علاوه بر تفاوت اساسی در پیچیدگی ساختار، استفاده از دادگان متفاوت و اختصاصی در تحقیق مذکور مجدداً مقایسه منصفانه را دشوار می‌کند، نزدیکی نتایج پژوهش حاضر با این تحقیق را می‌توان قابل توجه دانست. از جمله پژوهش‌های متأخر با دادگان عمومی پژوهش حاضر (DMR-IR) می‌توان به مرجع [۲۶] اشاره کرد که روشی با به‌کارگیری ترکیبی ترموگرافی دینامیک (دنباله تصویر) و استاتیک (تک تصویر) با استفاده از ویژگی‌های بافت و ماتریس هم‌رخدای ارائه شده که در مرحله غربال‌گری (تعیین موارد مشکوک) به دقت ۹۹ درصد دست یافته است. روش مذکور در مرحله تشخیص نهایی سرطان با استفاده از طبقه‌بند SVM و تصاویر ترموگرافی استاتیک دقت ۹۵ درصد را ثبت کرده که در حدود و کمی کمتر از نتایج شبکه یادگیری بیشینه پیشنهادی است که البته دارای ساختار و آموزش ساده‌تری است. همچنین، در یک پژوهش جدید دیگر، در مرجع [۲۷] با استفاده از دادگان ترموگرافی و پردازش و طبقه‌بندی تصاویر به تشخیص سرطان پستان اشاره شده است. پژوهشگران در تحقیق مذکور با قطعه‌بندی تصاویر و استخراج ویژگی از آنها و سپس استفاده از یک روش تحلیل آماری جهت بررسی و انتخاب ویژگی‌های مطلوب و در نهایت به‌کارگیری طبقه‌بند SVM با هسته شعاعی موفق به تشخیص سرطان شده‌اند. صحت طبقه‌بندی حاصل در این پژوهش در بهترین حالت برابر ۹۲/۸۶ درصد گزارش شده است. براساس نتایج فوق‌الذکر و روش‌های مشابه که عموماً از بار محاسباتی و پیچیدگی بیشتری نسبت به پژوهش حاضر برخوردار هستند، می‌توان نتایج ارائه شده را قابل توجه و مؤید روش پیشنهادی دانست.

## ۶- نتیجه‌گیری

نتایج و دستاوردهای این پژوهش در خصوص به‌کارگیری ماشین یادگیری بیشینه جهت تشخیص سرطان پستان مبتنی بر ویژگی‌های مستخرج از داده‌های ترموگرافی را می‌توان در موارد زیر خلاصه کرد:

- شبکه ELM در مقایسه با شبکه‌های عصبی پیش‌رو قادر است با استفاده از ویژگی‌های مشابه به نتایج طبقه‌بندی برتری دست یابد. این برتری برای مؤثرترین ویژگی‌های ارزیابی شده برای هر کدام از این شبکه‌ها بین یک تا دو درصد در صحت طبقه‌بندی و بیش از ده درصد در حساسیت آن بوده است. با توجه به سهولت و سرعت بسیار بیشتر آموزش این شبکه نسبت به شبکه‌های عصبی متداول و سادگی ساختار آن به‌راحتی می‌توان استفاده از آن را برای هدف مذکور پیشنهاد کرد.
- در میان ویژگی‌های مورد مطالعه در این پژوهش، ویژگی‌های تعمیم‌یافته بافت محلی منجر به بهترین نتایج شده‌اند، به‌ویژه ویژگی‌های LBP-Mix معرفی شده در این تحقیق. جالب توجه است که افزودن ویژگی‌های دیگر مانند رنگ و بخصوص شکل، بهبود قابل توجهی در نتایج تشخیص ایجاد نکرده است. تعیین شعاع‌های الگوی دودویی محلی و نحوه ترکیب آنها یک چالش مهم و نیز دستاورد این پژوهش بوده است. همچنین، در اینجا از شکل‌های توسعه یافته این ویژگی مانند LTP و مشتقات آن نیز استفاده شده است. در نهایت چنانچه نتایج تجربی حاصل از شبیه‌سازی‌ها نشان دادند و در جدول‌های (۴)، (۵) و (۸) الی (۱۰) قابل مشاهده است، الگوی دودویی محلی برای تصویر بلوک‌بندی شده و نیز الگوی ترکیبی با شعاع‌های ۱ تا ۴ برترین‌های این کاربرد هستند. برتری ویژگی‌های مذکور در این کاربرد را می‌توان در تقطیع مناسب تصویر و تعیین و ترکیب شعاع‌ها متناسب با ویژگی‌های خاص دادگان این کاربرد دانست.
- مورد قابل توجه دیگر آنست که استفاده از مدل‌های پیچیده‌تر ماشین یادگیری بیشینه مانند مدل چندلایه مبتنی بر هسته، اگرچه در بعضی گزارش‌ها در مورد کاربردهای دیگر منجر به دقت و تعمیم‌دهی بهتر شده است، در کاربرد این پژوهش نتایج برتری ارائه نکرده است، مگر در مورد معیار حساسیت برای ویژگی‌های رنگ، و بنابراین در کل در اینجا قابل توصیه نیست.

جهت ادامه این تحقیق استفاده از پایگاه‌های داده دیگر، در صورت ارائه در آینده، پیشنهاد می‌شود. در زمان انجام این پژوهش، پایگاه داده DMR-IR تنها پایگاه در دسترس عموم بوده و لاجرم نتایج پژوهش بر روی آن ارائه شده‌اند. از آنجا که روش‌های پیشنهادی، از جمله قطعه‌بندی خودکار پستان، طبقه‌بند ELM و ویژگی‌های بافت محلی معرفی شده، به‌سادگی قابلیت استفاده در سایر مجموعه‌های داده را دارند، اجرای این پیشنهاد به‌راحتی ممکن بوده و با توجه به مزایای قابل توجه روش و طبقه‌بند پیشنهادی می‌توان انتظار نتایج مشابه را داشت.

### سپاسگزاری

این مقاله مستخرج از پایان‌نامه دوره کارشناسی ارشد در دانشگاه آزاد اسلامی واحد نجف‌آباد است. نویسنده‌گان بر خود لازم می‌دانند مراتب تشکر صمیمانه خود را از همکاران حوزه پژوهشی دانشگاه آزاد اسلامی و داوران محترم که ما را در انجام و ارتقای کیفی این مقاله یاری نموده‌اند، اعلام نمایند.

### References

#### مراجع

- [1] M. Plummer, C. Martel, J. Vignat, J. Ferlay, F. Bray, S. Franceschi, "Global burden of cancers attributable to infections in 2012: a synthetic analysis", *Lancet Glob Health*, vol. 4, no. 9, pp. 609-616, Sept. 2016 (doi: 10.1016/S2214-109X(16)30143-7).
- [2] Y.X. Lim, Z.L. Lim, P.J. Ho, J. Li, "Breast cancer in asia: Incidence, mortality, early detection, mammography programs, and risk-based screening initiatives", *Cancers*, vol. 14, no. 4218, pp. 1-21, Aug. 2022 (doi: 10.3390/cancers14174218).
- [3] S. Chakraborty and T. Rahman, "The difficulties in cancer treatment", *Ecancermedicalsecience*, vol. 6, Nov. 2012 (doi: 10.3332/ecancer.2012.ed16).
- [4] R.C. Travis, A. Balkwill, G.K. Fensom, P.N. Appleby, G.K. Reeves, X. Wang, A.W. Roddam, T. Gathani, R. Peto, J. Green, T.J. Key, V. Beral, "Night shift work and breast cancer incidence: three prospective studies and meta-analysis of published studies", *Journal of the National Cancer Institute*, vol. 108, no. 12, pp. 1-12, Dec. 2016 (doi: 10.1093/jnci/djw169).
- [5] M.A. Aldhaeabi, K. Alzoubi, T.S. Almoneef, S.M. Bamatraf, H. Attia, O.M. Ramahi, "Review of microwaves techniques for breast cancer detection", *Sensors*, vol. 20, no. 2390, pp. 1-38, April 2020 (doi: 10.3390/s20082390).
- [6] S.V. Sree, E.Y. Ng, R.U. Acharya, O. Faust, "Breast imaging: A survey", *World Journal of Clinical Oncology*, vol. 2, no. 4, pp. 171-178, April 2011 (doi: 10.5306/wjco.v2.i4.171).
- [7] D. Singh, A.K. Singh, S. Tiwari, "Breast thermography as an adjunct tool to monitor the chemotherapy response in a triple negative BIRADS V cancer patient: A case study", *IEEE Trans. on Medical Imaging*, vol. 41, no. 3, pp. 737-745, Mar. 2022 (doi: 10.1109/TMI.2021.3122565).
- [8] M. Madani, M.M. Behzadi, S. Nabavi, "The role of deep learning in advancing breast cancer detection using different imaging modalities: A systematic review", *Cancers*, vol. 14, no. 21, Article Number: 5334, Oct. 2022 (doi: 10.3390/cancers14215334).
- [9] C. M. Wong, C. M. Vong, P. K. Wong, J. Cao, "Kernel-based multilayer extreme learning machines for representation learning", *IEEE Trans. on Neural Networks and Learning Systems*, vol. 29, no. 3, pp. 757-762, Mar. 2018 (doi: 10.1109/TNNLS.2016.2636834).
- [10] T. Ojala, M. Pietikainen, D. Harwood, "A comparative study of texture measures with classification based on feature distributions", *Pattern Recognition*, vol. 29, no. 1, pp. 51-59, Jan. 1996 (doi: 10.1016/0031-3203(95)00067-4).
- [11] T. Ojala, M. Pietikainen, T. Maenpaa, "Multiresolution gray scale and rotation invariant texture classification with local binary patterns", *IEEE Trans. on Pattern Analysis and Machine Intelligence*, vol. 24, no. 7, pp. 971-987, July 2002 (doi: 10.1109/TPAMI.2002.1017623).
- [12] X. Tan, B. Triggs, "Enhanced local texture feature sets for face recognition under difficult lighting conditions", *IEEE Trans. on Image Processing*, vol. 19, no. 6, pp. 1635-1650, June 2010 (doi: 10.1109/TIP.20-10.2042645).
- [13] F.Z. Chelali, N. Cherabit, A. Djeradi, "Face recognition system using skin detection in RGB and YCbCr color space", *Proceeding of the WSWAN*, pp. 21-23, Mar. 2015 (doi: 10.1109/WSWAN.2015.7210329).



- [14] G.B. Huang, H.A. Babri, "Upper bounds on the number of hidden neurons in feedforward networks with arbitrary bounded nonlinear activation functions", *IEEE Trans. on Neural Networks*, vol. 9, no. 1, pp. 224-229, Jan. 1998 (doi: 10.1109/72.655045).
- [15] G.B. Huang, Q.Y. Zhu, C.K. Siew, "Real-time learning capability of neural networks", *IEEE Trans. on Neural Networks*, vol. 17, no. 4, pp. 863-878, Aug. 2006 (doi: 10.1109/TNN.2006.875974).
- [16] G.B. Huang, Q.Y. Zhu, C.K. Siew, "Extreme learning machine: Theory and applications", *Neurocomputing*, vol. 70, pp. 489-501, Dec. 2006 (doi: 10.1016/j.neucom.2005.12.126).
- [17] D. Serre, *Matrices: Theory and Applications*, Springer, New York, 2002 (doi: 10.1007/b98899).
- [18] C. R. Rao, S. K. Mitra, *Generalized Inverse of Matrices and its Applications*, Wiley, 1971 (doi: 10.2307/2344631).
- [19] J. Zhang, Y. Li, W. Xiao, Z. Zhang, "Non-iterative and fast deep learning: Multilayer extreme learning machines", *Journal of Franklin Institute*, vol. 357, no. 13, pp. 8925-8955, Sept. 2020 (doi: 10.1016/j.jfranklin.2020.04.033).
- [20] G. B. Huang, H. Zhou, X. Ding, R. Zhang, "Extreme learning machine for regression and multiclass classification", *IEEE Trans. on Systems, Man, and Cybernetics, Part B (Cybernetics)*, vol. 42, no. 2, pp. 513-529, April 2012 (doi: 10.1109/TSMCB.2011.2168604).
- [21] L. F. Silva, D. C. M. Saade, G. O. Sequeiros, A. C. Silva, A. C. Paiva, R. S. Bravo, A. Conci, "A new database for breast research with infrared image", *Journal of Medical Imaging and Health Informatics*, vol. 4, no. 1, pp. 92-100, 2014 (doi: 10.1166/jmihi.2014.1226).
- [22] H. Yektaei, M. Manthour, "A review of neural network detection methods for breast cancer", *Tehran University Medical Journal*, vol. 78, no. 6, pp. 344-350, Sept. 2020.
- [23] G. Mardanian, N. Behzadfar, "A new method for detection of breast cancer in mammography images using a firefly algorithm", *Journal of Intelligent Procedures in Electrical Technology*, vol. 10, no. 40, pp. 23-32, Jan. 2020.
- [24] A. Lashkari, F. Pak, M. Firouzmand, "Full intelligent cancer classification of thermal breast images to assist physician in clinical diagnostic applications", *Journal of Medical Signals and Sensors*, vol. 6, no. 1, pp. 12-24, Jan./Mar. 2016.
- [25] S. Ekici, H. Jawzal, "Breast cancer diagnosis using thermography and convolutional neural networks", *Medical Hypotheses*, vol. 137, Article Number: 109542, April 2020 (doi: 10.1016/j.mehy.2019.109542).
- [26] R. Resmini, L. Faria, S. Petrucio, R. T. M. Adriel, S. A. Débora, C. Muchaluat-Saadec, A. Conci, "A hybrid methodology for breast screening and cancer diagnosis using thermography", *Computers in Biology and Medicine*, vol. 135, Aug. 2021 (doi: 10.1016/j.compbio.2021.104553).
- [27] S. Periyasamy, A. Prakasarao, M. Menaka, B. Venkatraman, M. Jayashree, "Support vector machine based methodology for classification of thermal images pertaining to breast cancer", *Journal of Thermal Biology*, vol. 110, Dec. 2022 (doi: 10.1016/j.jtherbio.2022.103337).

#### زیر نویس ها

- |   |   |
|---|---|
| 1. Invasive   | 21. Fill  |
| 2. Semi-invasive                                      | 22. Dilate  |
| 3. Non-invasive                                       | 23. Circular hough transform                        |
| 4. Extreme learning machine                           | 24. Triangular basis function                       |
| 5. Local binary pattern                               | 25. Radial basis function                           |
| 6. Multi-layer perceptron                             | 26. Radial basis function kernel                    |
| 7. Support vector machines                            | 27. Linear kernel                                   |
| 8. Deep neural networks                               | 28. Polynomial kernel                               |
| 9. Auto-encoder                                       | 29. Wavelet kernel                                  |
| 10. Kernel  | 30. Database for mamma research with infrared image |
| 11. Local ternary pattern                             | 31. Dynamic thermography image                      |
| 12. Single-hidden layer feedforward neural network    | 32. Levenberg–Marquardt                             |
| 13. Back-propagation                                  | 33. Principal component analysis                    |
| 14. Moore-penrose generalized inverse                 | 34. Accuracy  |
| 15. Multilayer-extreme learning machines              | 35. Precision                                       |
| 16. Stacked auto-encoder                              | 36. Specificity                                     |
| 17. Deep belief network                               | 37. Sensitivity                                     |
| 18. Multilayer kernel-based extreme learning machines | 38. Resilient                                       |
| 19. Region of interest                                | 39. Gray-level co-occurrence matrix (GLCM)          |
| 20. Opening   | 40. Convolutional neural network                    |



