



دانشگاه کاشان  
University of Kashan

مجله محاسبات نرم

## SOFT COMPUTING JOURNAL

تارنمای مجله: scj.kashanu.ac.ir



### بهبود کاهش نویز، تقطیع و طبقه‌بندی توده‌های سرطان توسط فیلتر تطبیقی معکوس کوانتومی، عنکبوت اجتماعی و ELM بهبود یافته

محسن افتخاریان<sup>۱</sup>، دانشجوی دکتری، علی نودهی<sup>۱\*</sup>، استادیار، رسول عنایتی فر<sup>۲</sup>، استادیار  
<sup>۱</sup> گروه کامپیوتر، واحد گرگان، دانشگاه آزاد اسلامی، گرگان، ایران.  
<sup>۲</sup> گروه کامپیوتر، واحد فیروزکوه، دانشگاه آزاد اسلامی، فیروزکوه، ایران.

#### چکیده

سیستم‌های تشخیص هوشمند پزشکی امروزه به لطف هوش مصنوعی، دچار تغییرات و همچنین چالش‌هایی شده‌اند. یکی از این سیستم‌های هوشمند پزشکی، سیستم‌های تشخیص و طبقه‌بندی توده‌های سرطانی از نواحی سینه می‌باشد. تشخیص زودهنگام می‌تواند منجر به افزایش گزینه‌های درمانی شود. انواع تکنیک‌های غربالگری برای سرطان سینه مانند ماموگرافی، MRI و التراساند وجود دارد. بسته به روش تشخیص نوع توده‌های سرطانی، از هر کدام از این تصاویر استفاده شده و تکنیک‌های پردازشی متفاوتی برای آنها ارائه شده است. این تحقیق به استفاده از مجموعه داده‌های ماموگرافی MIAS می‌پردازد و بر اساس اصول پردازش تصویر و یادگیری ماشین، سعی در تشخیص و طبقه‌بندی توده‌های خوش‌خیم، بدخیم و مشکوک را دارد. لذا به ارائه یک رویکرد تکامل یافته می‌پردازد، بدین صورت که در ابتدا عملیات پیش‌پردازش با هدف کاهش نویز و بهسازی تصویر مبتنی بر روش پیشنهادی Quantum Inverse MFT انجام می‌شود و سپس بر اساس شدت روشنایی و لبه، عملیات تقطیع تصویر با استفاده از الگوریتم عنکبوت اجتماعی صورت می‌گیرد. در ادامه عملیات استخراج ویژگی‌ها و طبقه‌بندی با هدف تشخیص نوع توده‌های سرطانی، با روش Extreme Learning Machine و مدل توسعه یافته آن یعنی Moore Penrose Matrix - Extreme Learning Machine انجام می‌شود. نتایج تحقیق نشان می‌دهد که رویکرد پیشنهادی از لحاظ معیارهای ارزیابی همچون دقت، حساسیت، نرخ ویژگی‌ها و همین‌طور ROC و AUC نسبت به روش‌های پیشین دارای برتری عملکردی است.

© ۱۴۰۱ - مجله محاسبات نرم، کلیه حقوق محفوظ است.

#### اطلاعات مقاله

##### تاریخچه مقاله:

دریافت ۱۶ آذر ماه ۱۴۰۰  
پذیرش ۰۸ فروردین ماه ۱۴۰۱

##### کلمات کلیدی:

سرطان سینه  
تشخیص و طبقه‌بندی  
الگوریتم عنکبوت اجتماعی  
Quantu Inverse MFT  
مدل MPM-ELM

#### ۱. مقدمه

می‌شود و دارای علائمی همچون وجود یک توده در سینه، تغییر شکل سینه، گودی پوست، ترشح مایع از نوک سینه و یا پوسته‌شدن قسمتی از سطح آن می‌باشد. به منظور توسعه سرطان بایستی ژن تنظیم رشد و تکثیر سلولی دگرگون شود. سپس این جهش‌ها از طریق تکثیر سلولی تبدیل به یک توده خواهد شد. با شناسایی ژن انتقال‌دهنده این سرطان می‌توان گام مهمی در زمینه

سرطان سینه نوعی سرطان است که از بافت سینه در زنان آغاز

\* نوع مقاله: پژوهشی

# نویسنده مسئول

پست(های) الکترونیک: m.eftekharian@gorganiau.ac.ir (افتخاریان)

ali.nodehi@gorganiau.ac.ir (نودهی)

r.enayatifar@iaufb.ac.ir (عنایتی فر)

سعی بر آن است تا با استفاده از اصول پردازش تصویر و یادگیری ماشین، یک سیستم تشخیص تومورهای سرطان سینه و جداکننده حالت خوش خیم و بدخیم، ارائه گردد. با توجه به این که تصاویر ماموگرافی به صورت ذاتی دارای نویز هستند، در ابتدا نیاز به حذف نویزهای آن، امری ضروری است که با استفاده از روشی به نام Invers MFT Filtering به صورت کوانتومی این کار، انجام می‌شود. سپس روش‌های پردازش تصویر شامل لبه‌یابی<sup>۳</sup> با روش سمبل<sup>۴</sup> و سپس تقطیع<sup>۵</sup> مبتنی بر الگوریتم عنکبوت اجتماعی<sup>۶</sup> مدنظر واقع می‌گردد. حال نیاز به آموزش در استخراج ویژگی‌ها، امری ضروری به نظر می‌رسد که برای این کار، از روش ELM<sup>۷</sup> استفاده می‌شود.

دلیل استفاده از این روش، سرعت اجرای بالا و همین‌طور آموزش به صورت ناظر<sup>۸</sup> است که قابلیت تعمیم‌پذیری<sup>۹</sup> را هم دارد و همچنین می‌تواند در مراحل آموزش و آزمون، اولاً عملیات کاهش ابعاد، انتخاب و استخراج ویژگی‌ها را انجام دهد و ثانياً در طبقه‌بندی، تومورهای خوش خیم و بدخیم و حالات مشکوک را توسط ELM بهینه‌شده، شناسایی کند.

## ۲. مروری بر کارهای گذشته

با توجه به این که تشخیص سرطان سینه به صورت هوشمند، یکی از مباحث به‌روز می‌باشد، لذا مطالعات فراوانی بر روی آن با روش‌های مختلف انجام شده است.

در [۶] توسط هوش مصنوعی یک سیستم تشخیص سونوگرافی سینه، ایجاد کردند که با اضافه کردن داده‌های یادگیری بیشتر برای کاربردهای بالینی، حساسیت و ویژگی را بهبود می‌بخشید. در [۷] روش نوین جهت استخراج ویژگی‌های برجسته سینه بر اساس داده‌های زیستی، بررسی و تحلیل تصویر ارائه کردند. این اطلاعات استخراج شده از یک دوربین حرارتی بوده و از آن

پیش‌بینی سرطان سینه برداشت. یکی از مهم‌ترین مشکلات در نشان دادن ساختار و عملکرد مولکول‌های زیستی، وجود حجم بالای اطلاعات ژنتیکی است. همچنین یکی از مهم‌ترین چالش‌ها در بیوانفورماتیک این است که نیازمند طراحی و تولید روش‌ها، الگوریتم‌ها و ابزارهایی به منظور تبدیل این حجم وسیع از داده‌های غالباً ناهمگون به دانش زیستی است [۱].

مناسب‌ترین روش برای کاهش فوت ناشی از بیماری سرطان، امکان تشخیص به‌موقع یا زودهنگام آن می‌باشد تا بتوان رویه درمانی را آغاز نمود. این تشخیص به‌موقع باید با یک روش مطمئن انجام شود. از بین روش‌های موجود تشخیص بیماری سرطان سینه، ماموگرافی بسیار رایج بوده و مقبولیت بالایی دارد [۲]. اما این روش تشخیص سرطان سینه دارای اشکالاتی است. زیرا در مواردی احتمال خراب شدن فیلم و یا حتی نامناسب بودن تصویر ماموگرافی برای تشخیص بیماری وجود دارد که باید مجدداً تصویر برداری تکرار شود [۳]. همچنین مشکل دیگر تصاویر ماموگرافی مستهلک شدن آن به مرور زمان است. تشخیص بصری بیماری از روی تصاویر ماموگرافی، همواره توأم با خطا بوده و متأسفانه بین ۳ تا ۲۰٪ می‌تواند اشتباه در تشخیص ایجاد کند [۴].

توده‌ها به دو دسته خوش خیم و بدخیم تقسیم می‌شوند. توده خوش خیم از لحاظ تصویری، حاشیه‌هایی بسیار ملایم و یکنواخت دارد، درحالی‌که توده بدخیم، حاشیه‌هایی تیره‌رنگ و برجسته دارد و با گذشت زمان، این حاشیه‌ها به صورت تیز و سوزنی شکل در می‌آیند. همچنین ذرات بسیار ریز آهکی، ذرات بسیار کوچک کلسیم هستند که به صورت نقاط روشن در تصاویر ماموگرافی ظاهر می‌شوند و آنها معمولاً با ذرات نویزی موجود در شکل، اشتباه گرفته می‌شوند [۵].

استفاده از اصول و تکنیک‌های پردازش تصویر<sup>۱</sup> به همراه شناسایی آماری و شناختی الگو<sup>۲</sup> در تشخیص و تعیین خودکار سرطان سینه از تصاویر ماموگرافی، باعث کم شدن خطاهای انسانی و افزایش سرعت تشخیص شده است. در این تحقیق،

<sup>۳</sup> Edge Detection

<sup>۴</sup> Sobel

<sup>۵</sup> Segmentation

<sup>۶</sup> Social Spider Algorithm (SSA)

<sup>۷</sup> Extreme Machine Learning

<sup>۸</sup> Supervised Learning

<sup>۹</sup> Generalized

<sup>۱</sup> Image Processing

<sup>۲</sup> Statistical and Cognitive Pattern Recognition

MRI، از تکنیکی به نام افزایش پارنچیمال پس‌زمینه<sup>۷</sup> استفاده شده است. در [۱۲] نیز به مرور روش‌های پردازش تصویر، طبقه‌بندی تصاویر ماموگرافی و MRI برای تشخیص سرطان سینه پرداخته شده است. استفاده از پردازش تصویر جهت تشخیص تومورهای سینه از تصاویر ماموگرافی با استفاده از تصاویر میکرو آرایه<sup>۸</sup> در [۱۳] مورد مطالعه واقع شده است. دقت این روش در تشخیص توده‌های سرطانی سینه ۹۵/۴۵٪ می‌باشد. در [۱۴] به طبقه‌بندی تصاویر ماموگرافی با هدف تشخیص سرطان سینه پرداخته شده است. این تحقیق از شبکه عصبی پس انتشار<sup>۹</sup> استفاده می‌کند. دقت در طبقه‌بندی و تشخیص با این روش ۷۰/۴٪ بیان شده است. همین‌طور یک بررسی کلی بر روش‌های هوشمند در تشخیص سرطان سینه در [۱۵] ارائه شده است که اکثر روش‌های طبقه‌بندی با اصول یادگیری ماشین و همین‌طور روش‌های پردازش تصویر را مورد مطالعه قرار می‌دهد و بررسی‌ها نشان می‌دهد که شبکه‌های عصبی دارای نرخ بهینه‌تری در تشخیص این بیماری از تصاویر ماموگرافی هستند.

در [۱۶] به استفاده از یک طبقه‌بند به نام نایو بیزین<sup>۱۰</sup> مبتنی بر تئوری بیزین در تصاویر ماموگرافی پرداخته شده است. نتایج طبقه‌بندی با هدف تشخیص در این مقاله برای معیارهای ارزیابی حساسیت، نرخ ویژگی و دقت به ترتیب ۹۹/۱۱٪، ۹۸/۲۵٪ و ۹۸/۵۴٪ است که نتایج قابل توجهی نسبت به روش‌های مشابه پیشین خود دارد. در [۱۷] به ارائه یک سیستم تصمیم‌گیری هوشمند تطبیقی جهت تشخیص سرطان سینه از تصاویر ماموگرافی پرداخته شده است. این روش که بر اساس تکاملی مبتنی بر رگرسیون<sup>۱۱</sup> است، به عنوان یک روش جالب توجه ارائه و ذکر گردیده است. میزان از دست رفتن زندگی افراد بر اساس نوع توده در این تحقیق تشخیص داده می‌شود و عمر باقیمانده بر اساس بزرگی توده، پیش‌بینی می‌گردد.

در [۱۸] به تشخیص سرطان سینه از تصاویر ماموگرافی بر

اطلاعات با استفاده از شبکه عصبی کانولوشن<sup>۱</sup> بهینه شده توسط الگوریتم بیز، برای دسته‌بندی تصاویر سینه به نرمال و مشکوک استفاده می‌شود. با استفاده از این الگوریتم، دقت ۹۸/۹۵٪ برای داده‌های مربوط به ۱۴۰ نفر به دست آمد.

در [۸] تشخیص سرطان سینه با استفاده از یادگیری عمیق انجام شده و در آن از ترکیب مدل‌های شبکه عصبی حلقوی و خودکار استفاده کرده‌اند. در مرحله آزمایش، از ویژگی‌های حاصل از مدل شبکه عصبی کانولوشن استفاده شده و با استفاده از روش رگرسیون ریج، ویژگی‌های مهم انتخاب و پس از طبقه‌بندی دقت ۹۸/۵۹٪ به دست آمد.

در [۹] توسط شبکه کانولوشن و ترکیب آن با روش چند مقیاسی، دقت ۹۷/۳٪ را اندازه‌گیری کردند. در این مرجع نظر نویسندگان بر این بود که با افزایش لایه‌های کانولوشن، دقت نیز افزایش می‌یابد.

در [۱۰] به طبقه‌بندی تومورهای خوش‌خیم و بدخیم سینه از تصاویر ماموگرافی پرداخته شده است که مبتنی بر اصول پردازش تصویر و یادگیری ماشین است. در این تحقیق، از روش تقطیع رشد ناحیه‌ای<sup>۲</sup> به همراه شبکه عصبی سلولی با آستانه مشخص، استفاده شده است. متغیرهای شبکه عصبی سلولی جهت تقطیع و هم طبقه‌بندی با استفاده از الگوریتم ژنتیک، بهینه‌سازی شده است. مقایسه نتایج با روش‌های دیگر شامل نایو بیزین<sup>۳</sup>، الگوریتم جنگل تصادفی<sup>۴</sup>، ماشین بردار پشتیبان<sup>۵</sup> و نزدیک‌ترین همسایه K<sup>۶</sup> از لحاظ دقت، حساسیت و نرخ ویژگی‌ها، به عنوان معیارهای ارزیابی، انجام گرفته است. روش پیشنهادی این تحقیق در تشخیص سرطان سینه از تصاویر ماموگرافی، دارای نرخ دقت ۹۶/۴۷٪، حساسیت ۹۶/۸۷٪ و نرخ ویژگی‌های ۹۵/۹۴٪ است. استفاده از مجموعه داده‌های MIAS و DDSM مدنظر این تحقیق بوده است.

در [۱۱] برای از بین بردن نویز و بهبود تصاویر ماموگرافی و

<sup>۷</sup> Background parenchymal enhancement (BPE)

<sup>۸</sup> Micro Array Images

<sup>۹</sup> Back-Propagation Neural Network (BPNN)

<sup>۱۰</sup> Naïve Bayesian

<sup>۱۱</sup> Regression

<sup>۱</sup> CNN

<sup>۲</sup> Region Growing

<sup>۳</sup> Naïve Bayesian

<sup>۴</sup> Random Forest

<sup>۵</sup> Support Vector Machine (SVM)

<sup>۶</sup> K-Nearest Neighbor

هوشمند در سرطان سینه ارائه شده، مورد مطالعه قرار گرفته است. روش‌های هوشمند با کمک کامپیوتر<sup>۸</sup> بر اساس روش‌های پردازش تصویر، یادگیری ماشین، سیستم‌های تصمیم‌گیری، منطق فازی<sup>۹</sup> و سایر روش‌های مشابه و ترکیبی، مورد مطالعه واقع شده است. در یک رویکرد متفاوت که در [۲۱] ارائه شده است، به ارزیابی عملکرد دوربین کامپتون<sup>۱۰</sup> با لنزهای Si/CZT با هدف تشخیص تومورهای سینه پرداخته شده است. این شبیه‌سازی برای تشخیص تومورهای سینه با دوربین کامپتون و لنز Si/CZT به کمک روش مونت کارلو<sup>۱۱</sup> انجام گرفته است و نتایج نشان می‌دهد که تشخیص دقیق نواحی تومور، امکان‌پذیر می‌باشد. در [۲۲] نیز به استفاده از روش‌های یادگیری عمیق<sup>۱۲</sup> برای تشخیص و طبقه‌بندی تومورهای ناحیه سینه پرداخته شده است. سه معماری مختلف از یادگیری عمیق شامل VGGNet، GoogLeNet و ResNet مدنظر بوده و تحلیل بین این روش‌ها انجام گرفته است. نتایج این روش نشان می‌دهد که رویکرد پیشنهادی دارای دقت بالایی در تشخیص و طبقه‌بندی نواحی تومور می‌باشد.

تشخیص بصری و ارزیابی تومورهای سینه با اصول یادگیری عمیق در [۲۳] نیز ارائه شده است. بدین صورت که ۳۲۲ تصویر از یک مجموعه داده کلینیکی، به عنوان ورودی وارد سیستم شده است و عملیات تقطیع بر اساس خوشه‌بندی صورت گرفته و به صورت ترکیبی الگوریتم‌های K-means و SURF<sup>۱۳</sup> را مدنظر قرار داده است. در مرحله طبقه‌بندی، یک لایه جدید برای کلاس‌بندی در ساختار شبکه یادگیری عمیق اضافه شده است که به صورت ماشین بردار پشتیبان چند کلاسی<sup>۱۴</sup> است. در مرحله آموزش، ۷۰٪ داده‌ها به عنوان آموزش و ۳۰٪ داده‌ها به عنوان آزمون مدنظر قرار گرفته‌اند. بهبود رویکرد پیشنهادی از لحاظ معیارهای ارزیابی مانند ROC، دقت در تشخیص و طبقه‌بندی با روش‌های دیگری همچون شبکه عصبی پرسپترون

اساس تحلیل ویژگی‌ها تصویری پرداخته شده است. حذف نویز اولیه و تقطیع بر اساس اصول پردازش تصویر در این تحقیق به چشم می‌خورد. در ادامه نیز از یک طبقه‌بند مبتنی بر ویژگی‌های استخراج شده در آموزش، استفاده می‌شود که توانایی تشخیص تومورهای بدخیم و خوش‌خیم و همین‌طور تخمین اندازه احتمالی توده در تصویر را دارد. بعد از اعمال روش پیشنهادی، مقادیر معیارهای ارزیابی برای حساسیت ۹۶/۵٪، برای ویژگی ۸۹٪ و برای دقت ۹۵/۶٪ می‌باشد.

در [۱۹] یک رویکرد جدید جهت تشخیص بیماری سرطان سینه بر اساس داده‌های تصویری ماموگرافی ارائه شده است. استفاده از پردازش‌های سطح پایین مانند حذف نویز تصویر، میانگین‌گیری<sup>۱</sup> و آستانه‌گذاری<sup>۲</sup> مدنظر واقع شده است. در واقع از میانگین‌گیری جهت ارائه اسموتینگ<sup>۳</sup> و از آستانه‌گذاری جهت استخراج ویژگی‌ها، استفاده گردیده است. بر اساس این ویژگی‌های مشخص شده، ناحیه تومور تقریباً مشخص خواهد بود که با اصول پردازش تصویر، یک مستطیل به دور آن نواحی احتمالی کشیده شده و به‌عنوان لبه‌های جدا شده از تصویر و بافت اصلی آن در نظر گرفته می‌شود. شدت روشنایی آنها کمی متفاوت است و این عملیات با استفاده از پنجره‌یابی<sup>۴</sup> انجام می‌شود. در ادامه میانگین محلی و واریانس هر زیر پنجره از بخش‌های جدا شده و مشخص، انجام می‌شود. سپس روش Max-Mean و واریانس کمتر<sup>۵</sup> بر روی نواحی که دور آنها خط کشیده شده است در بخش پنجره‌یابی، به مشخص نمودن توده‌های سرطانی می‌پردازند. شناسایی نواحی مرزی بین تومورهای سینه با استفاده از پردازش ریخت شناسانه<sup>۶</sup> و تکنیک گرادیان تصویر<sup>۷</sup> انجام می‌شود. در نهایت یک تقطیع مبتنی بر عملگرهای ریخت شناسانه انجام می‌شود که ناحیه دارای تومور را نشان خواهد داد.

در [۲۰] مطالعاتی بر اساس پیشرفت‌هایی که جهت تشخیص

<sup>8</sup> Computer Aided Design (CAD)

<sup>9</sup> Fuzzy Logic

<sup>10</sup> Compton

<sup>11</sup> Monte Carlo

<sup>12</sup> Deep Learning

<sup>13</sup> Speed-Up Robust Features

<sup>14</sup> Multi-Class Support Vector Machine

<sup>1</sup> Averaging

<sup>2</sup> Thresholding

<sup>3</sup> Smoothing

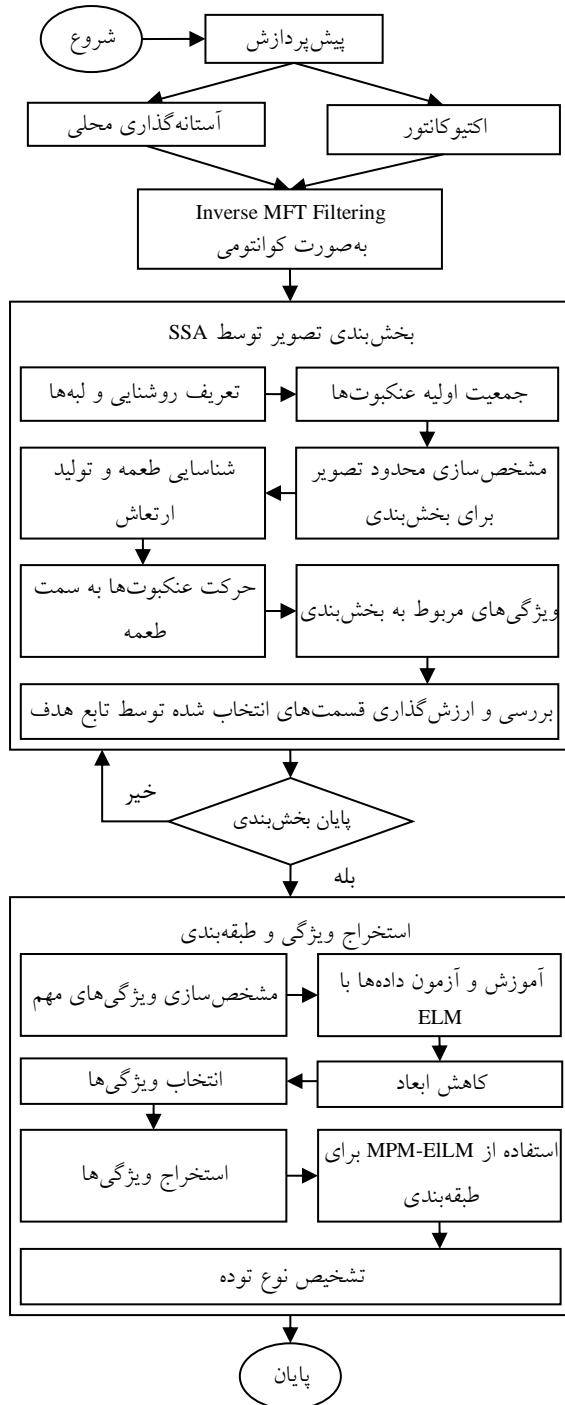
<sup>4</sup> Windowing

<sup>5</sup> Least Variance

<sup>6</sup> Image Morphology

<sup>7</sup> Image Gradient

طبقه‌بندی برای تشخیص نوع سرطان شامل بدخیم، خوش‌خیم و مشکوک به سرطان، را انجام می‌دهد و می‌تواند ناحیه دقیق توده‌های سرطانی را نیز بر روی تصویر، مشخص نماید. در ادامه هر بخش به صورت کامل و به تفصیل مورد بررسی واقع می‌گردد.



شکل (۱): فلوچارت پیشنهادی

چندلایه<sup>۱</sup>، درخت تصمیم<sup>۲</sup>، الگوریتم K نزدیک‌ترین همسایه<sup>۳</sup> و ماشین بردار پشتیبان، مورد مقایسه قرار گرفته است که نتایج، نشان از بهبود رویکرد پیشنهادی نسبت به روش‌های پیشین را نشان می‌دهد. در [۲۴] به ارائه یک سیستم تشخیص هوشمند پزشکی جهت پیش‌بینی عود سرطان سینه<sup>۴</sup> با استفاده از آموزش گروهی بهینه<sup>۵</sup>، پرداخته شده است.

در [۲۵] رویکرد عناصر محدود<sup>۶</sup> مبتنی بر اصول یادگیری ماشین برای مدل‌سازی رفتار مکانیکی بافت سینه مورد بررسی قرار گرفته است. رویکرد این تحقیق که به اختصار HBPCR نام گرفته است، با روش‌های دیگری مانند ماشین بردار پشتیبان<sup>۷</sup>، شبکه عصبی پرسپترون چندلایه<sup>۸</sup> و درخت‌های تصمیم<sup>۹</sup> مورد مقایسه واقع شده که از لحاظ معیارهای ارزیابی، بهبود روش پیشنهادی را نمایش می‌دهد. مهم‌ترین نتایج ارزیابی این تحقیق شامل نرخ ویژگی‌ها با ۹۳٪، حساسیت با ۷۷٪ و دقت با ۸۵٪ بوده است.

### ۳. رویکرد پیشنهادی

در رویکردی که ارائه می‌شود، سه بخش اصلی وجود دارد (شکل (۱)). در ابتدا پیش‌پردازش با هدف بهسازی و کاهش نویز تصاویر ماموگرافی بوده و از روشی به نام Inverse MTF Filtering به صورت کوانتومی استفاده می‌کند. سپس مرحله تقطیع تصویر و ناحیه‌بندی آن با استفاده از الگوریتم عنکبوت اجتماعی وارد کار می‌شود. در واقع این دو، در حوزه پردازش تصویر و بینایی ماشین هستند، اما مرحله بعدی که به صورت دوگانه با الگوریتم بهینه‌شده ELM کار می‌کند و تحت عنوان MPM-ELM<sup>۱۰</sup> نامیده خواهد شد، استخراج ویژگی شامل بخش کاهش ابعاد، انتخاب و استخراج ویژگی‌ها و همین‌طور عملیات

<sup>۱</sup> Multi-Layered Perceptron (MLP)

<sup>۲</sup> Decision Tree

<sup>۳</sup> K-Nearest Neighbor (KNN)

<sup>۴</sup> Breast Cancer Recurrence

<sup>۵</sup> Optimized Ensemble Learning

<sup>۶</sup> Finite Element

<sup>۷</sup> Support Vector Machine (SVM)

<sup>۸</sup> Multi-Layered Perceptron (MLP)

<sup>۹</sup> Decision Tree

<sup>۱۰</sup> Moore Penrose Matrix Extreme Learning Machine

### ۳.۱. مرحله پیش پردازش

قبل از انجام هرگونه عملیات، ابتدا باید بر روی داده‌ها پیش‌پردازش انجام شود [۵۵]. در مرحله پیش‌پردازش مقاله ما، داده‌های ورودی که تصویرهای دارای نویز و غیرنویز هستند، نرمال‌سازی می‌شوند و در صورت نیاز برای افزایش کارایی تشخیص سیستم، بهسازی می‌گردند. تغییر اندازه تصویر به یک اندازه مشخص به همراه فیلترینگ منطقی با استفاده از رویکردی به نام Inverse MFT Filtering به صورت کوانتومی، به این منظور اعمال شده است. روش MFT<sup>۱</sup> برگرفته از [۲۶] و همچنین فیلتر کوانتومی تصویر در حوزه فرکانس از [۲۷] بوده و بر اساس تبدیل فوریه سریع یا FFT<sup>۲</sup> عمل می‌کند.

پس از انجام مراحل پیش‌پردازش، تصویر ورودی نرمال‌سازی می‌شود. هر تصویر منفرد در روش ترکیبی آستانه‌گذاری محلی و اکتیوکانتور توسط یک آرایه دو بعدی از پیکسل‌ها نمایش داده می‌شود که مقادیر آن اعداد صحیحی در بازه [۰-۲۵۵] است. آستانه‌گذاری محلی، مقداردهی اولیه به تصاویر را در دو مرحله انجام می‌دهد. تصویر نویزی ورودی به عنوان تصویر اولیه در نظر گرفته می‌شود و عملیات حذف نویز، به آن اعمال خواهد شد. برای این منظور از روش Inverse MFT Filtering استفاده می‌شود.

استفاده از آستانه‌گذاری محلی و اکتیوکانتور به این دلیل انتخاب شده است که از نظر محاسباتی، دارای سرعت بالاتری نسبت به سایر روش‌ها می‌باشد و همچنین می‌تواند تاثیر قابل توجهی در روند ادامه کار و نتایج نهایی داشته باشد. بدین ترتیب، در پایان مرحله اول، تصویری به صورت تجزیه شده وجود خواهد داشت. در مرحله دوم، آستانه‌گذاری بر روی ضرایب جزئیات انجام می‌شود و یکی از این بخش‌های تجزیه شده به صورت تصادفی انتخاب شده و به یک عملیات بازسازی ارسال می‌شود. بخش بازسازی را می‌توان به صورت ذیل تعریف نمود:

- محو گوسی<sup>۳</sup>: تصویر را با استفاده از یک فیلتر گوسین،

بازسازی می‌کند. اندازه فیلتر به صورت تصادفی بین مقادیر  $3 \times 3$  و  $5 \times 5$  انتخاب می‌شود.

- فیلتر میانگین<sup>۴</sup>: تصویر را با استفاده از یک فیلتر میانگین، بازسازی می‌کند.
- تغییر شدت<sup>۵</sup>: تمام پیکسل‌های تصویر، در یک مقدار یکسان که به صورت تصادفی در بازه  $[0.7-1.3]$  انتخاب شده است، ضرب می‌شود.
- تطبیق بخش‌های دارای شدت نور به صورت پردازش کوانتومی و معکوس که ساختار Quantum Inverse را از روش Inverse MFT Filtering انجام می‌دهد.

سپس عملیات ذیل صورت می‌پذیرد:

- ردیف تک نقطه‌ای<sup>۶</sup>: یک ردیف از پیکسل‌ها، که به صورت تصادفی انتخاب شده‌اند.
- ستون تک نقطه‌ای<sup>۷</sup>: همانند روش قبل است، اما به جای ردیف، ستون مدنظر است.
- تصادف نقطه به نقطه<sup>۸</sup>: به صورت تصادفی، یک پیکسل را برای بررسی انتخاب می‌کند.
- شناسایی تمامی نقاط به صورت سطری و ستونی در تصویر و همین‌طور مورب برای کاهش حداکثر نویزها به صورت Quantum MFT.

پس از تجزیه، تمام تصویر، به صورت انفرادی توسط ارزش پیکسلی خود، مرتب شده و بهترین اندازه ضرایب در تصویر، به عنوان یک مقدار کوانتومی در ادامه کار، در نظر گرفته می‌شود. از آستانه‌گذاری محلی و اکتیوکانتور می‌توان برای تجزیه یک تصویر به اجزای تشکیل دهنده آن استفاده نمود. در واقع می‌توان عملیات بخش‌بندی یا ناحیه‌بندی یا تقطیع تصویر<sup>۹</sup> را با بعد از اعمال Quantum Inverse MFT Filtering همراه با روش آستانه‌گذاری محلی و اکتیوکانتور، انجام داد. در این صورت ضرایب آستانه‌گذاری محلی و اکتیوکانتور مبتنی بر Quantum

<sup>4</sup> Mean Filter (Averaging Filter)

<sup>5</sup> Intensity Change

<sup>6</sup> One-Point Row

<sup>7</sup> One-Point Column

<sup>8</sup> Point-to-Point Random

<sup>9</sup> Image Segmentation

1 Matched Filter Technique

2 Fast Fourier Transform

3 Gaussian Blur

آنجایی نشات گرفته می‌شود که شناسایی دقیق فضای تصویر، نیازمند نقاط شناساگر از بقیه بر اساس پس‌زمینه و پیش‌زمینه است. در این مرحله، لبه‌یابی، داخلی است و بر اساس لبه‌ها، می‌توان نواحی مختلف را از یکدیگر از لحاظ شدت نور و رنگ، جداسازی نمود. در واقع خروجی بخش پیش‌پردازش که عملیات بهسازی و کاهش نویزها را از تصاویر ماموگرافی انجام داده است، ورودی بخش تقطیع تصویر است. برای تقطیع تصویر، از الگوریتم بهینه‌سازی عنکبوت اجتماعی استفاده می‌گردد. دلیل استفاده از این الگوریتم این است که یک تصویر، به عنوان فضای جستجو شناخته می‌شود و این فضای جستجو را می‌توان با عملیات تقطیع، به عنوان یک بخش بهبود دهنده مدنظر قرار داد. لذا بهبود تقطیع، می‌تواند عملیات کاهش ابعاد، انتخاب و استخراج ویژگی‌ها و همین‌طور طبقه‌بندی دقیق را به صورت کامل انجام دهد تا دقت و معیارهای ارزیابی و اعتبارسنجی تا جای ممکن، افزایش یابند. همین‌طور سرعت اجرا و همگرایی بالا و عدم به دام افتادن در بهینه محلی در دستگاه‌های پردازش تصویر، می‌تواند مساله دیگری برای انتخاب الگوریتم عنکبوت اجتماعی در حل این بخش باشد. نیاز به توضیحات تئوری اولیه این الگوریتم و سپس معادل‌سازی آن با بخش تقطیع تصویر، امری ضروری است.

در الگوریتم عنکبوت اجتماعی به فرموله سازی فضای جستجوی مساله بهینه‌سازی، به عنوان تار عنکبوت با ابعاد بسیار بالا پرداخته می‌شود. هر موقعیت در تار به نمایش راه‌حل عملی برای مساله بهینه‌سازی و همه پاسخ‌های عملی برای مساله‌ای که دارای جواب در تار است، می‌پردازد. تار به عنوان رسانه انتقال ارتعاش تولید شده توسط عنکبوت‌ها، به خدمت گرفته می‌شود. هر عنکبوت در تار به نگره‌داشتن موقعیت و برازش راه‌حل بر پایه تابع هدف و همین‌طور توانایی در پیدا کردن منابع غذایی در موقعیت را نشان می‌دهد. عنکبوت‌ها می‌توانند به صورت آزادانه در تار حرکت کنند، اما نمی‌توانند تا زمانی که به جوابی عملی در مساله بهینه‌سازی نرسیده‌اند، تار را ترک کنند. زمانی که یک عنکبوت به سمت موقعیت جدید حرکت می‌کند، یک ارتعاش تولید می‌کند که در تمام تار انتشار می‌یابد و هر

Inverse MFT Filtering را می‌توان برای از بین بردن برخی جزئیات استفاده کرد. آستانه‌گذاری محلی و اکتیو کانتور مبتنی بر Quantum Inverse MFT Filtering، مزیت فوق‌العاده‌ای برای جدا کردن جزئیات ریز در یک تصویر را دارا هستند. از اکتیو کانتور می‌توان برای مجزا کردن جزئیات خیلی ریز یک تصویر استفاده کرد؛ در حالی که با آستانه‌گذاری محلی می‌توان جزئیات درشت را تشخیص داد. حال با ترکیب جزئیات ریز و درشت و خواندن تمامی سطر و ستون‌ها به صورت خطی و مورب، عملیات کاهش نویز انجام شده تا حداقل نویز در تصویر ماموگرافی باقی بماند. یک تابع آستانه‌گذاری محلی و اکتیو کانتور با Quantum Inverse MFT Filtering دو ویژگی اصلی دارد. این تابع، نوسانی است و ظاهری موجی مانند رابطه (۱) دارد.

$$\int_{-\infty}^0 |\Psi(t)|^2 dt < \infty \quad (1)$$

که در این حالت بیشتر انرژی در  $\Psi(t)$  به دوره زمانی محدودی منحصر می‌شود که رابطه آن به صورت رابطه (۲) است.

$$\int_{-\infty}^0 \Psi(t) dt = 0 \quad (2)$$

روش ارائه شده به صورت کلی جهت کاهش نویز در رابطه (۳) محاسبه می‌شود.

$$Method(I) = \left( \sum_{\Omega} \sqrt{1 + \beta^2 |\nabla I|^2} \right) + \frac{\lambda}{2} (I - I_0)^2 \quad (3)$$

تابع موجود در رابطه (۳) نسبت به لبه‌های تصویر، آگاهی دارد و در جهت حفظ خصیصه‌های مهم تصویر، تلاش می‌کند. بخش  $(I - I_0)^2$  درجه خاصی از صحت و اعتبار بین تصویر مورد ارزیابی و تصویر اصلی را تضمین می‌کند که در آن  $I$  تصویر مورد ارزیابی و  $I_0$  تصویر نویزدار می‌باشد. متغیر  $\nabla I$  دوره تنظیم تنوع مجموع است،  $\beta$  و  $\lambda$  متغیرهای تعادل و  $\Omega$  مجموع نقاط موجود در تصویر است. با کمینه کردن رابطه (۳)، هدف کاهش تنوع مجموع تصویر با حفظ صحت و اعتبار است.

### ۳.۲. مرحله تقطیع تصویر

تقطیع تصویر به عنوان یک فرایند پیچیده در دستگاه‌های پردازش تصاویر دیجیتال برشمرده می‌شود. این پیچیدگی از



ارتعاش، اطلاعات یک عنکبوت را نگه می‌دارد.

نیاز است تا یک معادل‌سازی در بخش تقطیع تصویر با الگوریتم عنکبوت اجتماعی، ارائه گردد. در واقع تصویر، به عنوان فضای جستجو یا همان تار در الگوریتم عنکبوت اجتماعی مطرح است. نیاز به ایجاد یک جمعیت اولیه از عنکبوت‌ها بر روی فضای جستجو یا تصویر که همان تار است، ضروری می‌باشد. در واقع عنکبوت‌ها، عامل‌ها خواهند بود. حرکت عنکبوت‌ها بر روی تار، با هدف شناسایی دقیق نواحی مرزی، یعنی لبه‌ها که شدت روشنایی و نور مختلفی از سایر بخش‌ها دارند، خواهد داشت و این کار را بر اساس هیستوگرام رنگی یا سیاه و سفید، انجام می‌دهد. در واقع عنکبوت‌ها، بر روی لبه‌ها، راه می‌روند و با ایجاد لرزش در خطوط یا لبه‌ها و وجود نور و شدت روشنایی، حرکت به آن سمت را برای ناحیه‌بندی دقیق، انجام می‌دهند و این کار را تا زمان رسیدن به شرط خاتمه، یعنی تقطیع کل ناحیه تصویر، ادامه می‌دهد. بعد از این که تقطیع دقیق صورت گرفت، می‌توان ویژگی‌ها را بر اساس لبه، شدت روشنایی، نور و نمایش توده‌ها، مشخص نمود و سپس نوع توده‌ها مورد بررسی قرار گیرد که این عملیات به صورت کلی، به عنوان ورودی سیستم الگوریتم ماشین آموزش افراطی بهینه‌شده خواهد بود.

### ۳.۳. استخراج ویژگی‌ها و طبقه‌بندی

در این بخش، از روش ماشین آموزش افراطی یا ELM استفاده می‌گردد که قابلیت استخراج ویژگی‌ها و طبقه‌بندی را به صورت همزمان دارد. برای این منظور ابتدا ویژگی‌های سرطان سینه را مشخص و سپس ناحیه دقیق توده‌ها را تشخیص بدهد و در انتها آنها بر اساس کلاس‌های خوش‌خیم، بدخیم و مشکوک، طبقه‌بندی نماید. در واقع این بخش به صورت MPM-ELM خواهد بود. روش ELM کلاسیک، یک شبکه عصبی است، اما در اکثر ساختارهای شبکه‌های عصبی دو ضعف کلی وجود دارد. اول استفاده از گرادینان نزولی<sup>۱</sup> برای تنظیم وزن‌ها در مرحله آموزش و زمانبر بودن آن و دوم، زمانی که حجم

داده‌های آموزشی زیاد باشند، کندی در سیستم آموزشی ایجاد می‌گردد. همین طور شبکه‌های عصبی، این قابلیت را ندارند که اگر داده جدیدی به همان مجموعه داده وارد گردید، به صورت بدون آموزش دوباره به نتیجه برسد، در واقع شبکه‌های عصبی، تعمیم‌پذیر<sup>۲</sup> نمی‌باشند. این مساله در ساختارهای یادگیری عمیق از یادگیری ماشین نیز وجود دارد. لذا ارائه یک روش هوشمند که سرعت اجرا به همراه قابلیت تعمیم‌پذیری را داشته باشد، امری جالب توجه است که این تحقیق به بهینه‌سازی ELM تحت عنوان MPM-ELM خواهد پرداخت و دلیل استفاده از آن رفع مشکلات موجود در ساختارهای شبکه‌های عصبی است. وجود سرعت یادگیری بالا و تنظیم یک پارامتری در مرحله آموزش بجای تنظیم پارامترهای فراوان در مرحله آموزش در شبکه‌های عصبی، از جمله دلایل استفاده از این الگوریتم است. ضعف اصلی ELM این است که به صورت عادی، نمی‌تواند مانند روش‌های یادگیری عمیق، عملیات استخراج ویژگی‌ها و طبقه‌بندی را انجام دهد، اما با بهینه‌سازی ELM و ایجاد ساختار MPM-ELM، این مشکل مرتفع گردیده است. در ELM، لایه ورودی با یک سری وزن به لایه پنهان متصل شده است. در ابتدا به این وزن‌ها، یک مقدار تصادفی داده می‌شود تا باعث وقت‌گیر شدن مرحله آموزش نشود. در ELM، درون‌های لایه پنهان یا مخفی، یک نرون معمولی بوده و نیازی به یافتن مراکز و سیگما برای نرون‌ها نیست و در نهایت تنها پارامتری که ELM نیاز به تنظیم دارد، وزن‌های سیناپسی بین لایه پنهان و لایه خروجی است. به صورت کلی، ELM یک ساختار رو به جلو یا Feed-Forward دارد و از ساختارهای شبه معکوس<sup>۳</sup> برای محاسبه وزن‌های سیناپسی به صورت بلادرنگ<sup>۴</sup> استفاده می‌کند که همین امر، منجر به افزایش سرعت یادگیری و آزمون داده‌ها می‌گردد. معماری کلی ELM در شکل (۲) مشخص است.

از جمله مهم‌ترین دلایل استفاده از ELM در مرحله طبقه‌بندی و استخراج ویژگی به نسب طبقه‌بندهای دیگری مانند شبکه

<sup>2</sup> Generize

<sup>3</sup> Inverse Psuedo

<sup>4</sup> Realtime

<sup>1</sup> Gradient Descent



لایه ورودی یعنی  $w_{ij}$  و بایاس یعنی  $b_j$  به صورت تصادفی، تخصیص می‌یابد. تابع فعال‌ساز  $g(\cdot)$  در شروع تعداد نرون لایه ورودی یا  $n$  و تعداد نرون‌های لایه مخفی یا  $m$  تخصیص می‌یابند. با توجه به این اطلاعات، اگر متغیرهای شناخته شده در تعادل کلی با هم ترکیب شوند و از نو تنظیم گردند، لایه خروجی مانند رابطه (۵) خواهد بود. در تمامی مدل‌های الگوریتم‌های آموزش محور، هدف اصلی، کمینه‌سازی خطا است. تابع خطای خروجی  $y_p$  توسط خروجی واقعی  $y_{main}$  در ELM به دست می‌آید که می‌توان با دو بخش آموزش یعنی  $\sum_k^s (y_{main} - y_p)$  و بخش آزمون یعنی  $\|\sum_k^s (y_{main} - y_p)^2\|$  حاصل شود. برای هر دو تابع، خروجی  $y_p$  که توسط خروجی واقعی یعنی  $y_{main}$  به دست می‌آید، می‌بایست برابر با همان  $y_p$  باشد. زمانی که این معادله انجام شود، نتایج آن قابل قبول می‌گردد.


$$H(w_{i,j}, b_j, x_i) = \begin{bmatrix} g(w_{1,1}x_1 + b_1) & \dots & g(w_{1,m}x_m + b_m) \\ g(w_{n,1}x_n + b_1) & \dots & g(w_{n,m}x_m + b_m) \end{bmatrix} \quad (5)$$

and  $y = H\beta$

ماتریس  $H$  می‌تواند ماتریسی باشد که ممکن است در آن تعداد داده‌ها در مرحله آموزش، با تعداد کل ویژگی‌های داده‌ها، برابر نباشد. بنابراین عملیات معکوس کردن  $[H]$  و پیدا کردن وزن‌ها یا  $\beta$  یک مساله اصلی و چالش خواهد بود. برای غلبه بر این چالش در ELM، از ماتریسی به نام مورپنروز<sup>۸</sup> استفاده می‌شود که می‌تواند به توسعه محاسبه معکوس تقریبی ماتریس‌ها که قابل برگشت نیستند، پردازد و می‌تواند عملیات کاهش ابعاد، انتخاب و استخراج ویژگی‌ها به همراه طبقه‌بندی را با دقتی بالا و سرعتی باور نکردنی نسبت به روش‌های دیگر، انجام دهد. با استفاده از ماتریس مورپنروز، ماتریس  $\beta^*$  ماتریس خروجی و  $H^*$  ماتریس مورپنروز معکوس تعمیم‌یافته از  $H$  به دست می‌آید. بنابراین با توجه به بهینه‌سازی ELM که به صورت MPM-ELM یعنی Moore Penrose Matrix Extreme Learning Machine بیان شد، مشکل وزن‌های خروجی در ELM حل و به شکل  $B^* = H^*$  تبدیل شد.

<sup>۸</sup> Moore Penrose Matrix

عصبی کانولوشن<sup>۱</sup>، شبکه عصبی بازگشتی<sup>۲</sup>، ماشین بردار پشتیبان<sup>۳</sup> و نایویزین<sup>۴</sup> می‌توان به جدول (۱) استناد نمود.



شکل (۲) معماری کلی ELM

به صورت کلی می‌توان گفت که ELM دقیقاً نقطه مقابل روش‌های یادگیری عمیق و طبقه‌بندهای متناوب مانند ماشین بردار پشتیبان و نایویزین است. الگوریتم ELM به دلیل انعطاف‌پذیری بالایی که دارد، می‌تواند علاوه بر استفاده از تابع خطی برای فعال‌سازی سلول‌ها یا نرون‌ها در لایه مخفی، از توابع فعال‌ساز غیرخطی مانند زیگموئید<sup>۵</sup> و یا سینوسی<sup>۶</sup> و یا توابع فعال‌سازی غیرمشتق و همین‌طور متناوب نیز استفاده نماید. به صورت استاندارد، ELM دارای رابطه‌ای مانند رابطه (۴) است.

$$y(p) = \sum_{j=1}^m \beta_j \beta_j g\left(\sum_{i=1}^n w_{i,j} x_i + b_j\right) \quad (4)$$

که طبق این رابطه،  $\beta_j$  نشان‌دهنده وزن‌های بین لایه ورودی و لایه پنهان و  $\beta_j$  بیانگر وزن‌ها بین لایه خروجی و لایه ورودی است. در ضمن  $b_j$  مقدار آستانه نرون‌ها در لایه مخفی یا همان بایاس<sup>۷</sup> است و  $g(\cdot)$  تابع فعال‌ساز یا محرک است. وزن‌های

<sup>۱</sup> Convolutional Neural Network (CNN)

<sup>۲</sup> Recurrent Neural Network (RNN)

<sup>۳</sup> Support Vector Machine (SVM)

<sup>۴</sup> Naïve Bayesian

<sup>۵</sup> Sigmoid

<sup>۶</sup> Sinsusoidal

<sup>۷</sup> Bias

جدول (۱): تفاوت‌های ELM با سایر روش‌های هوشمند مرسوم امروزی

نایو بی‌زین	ماشین بردار پشتیبان	شبکه عصبی کانولوشن	شبکه عصبی بازگشتی	ELM-MPM
مکانیزم آموزشی کُند	مکانیزم آموزشی کُند	مکانیزم آموزشی کُند	مکانیزم آموزشی کُند و برگشت پذیر	آموزش سریع تر
قابلیت اداره طبقه‌بندی به صورت دودویی	قابلیت اداره طبقه‌بندی به صورت دودویی	قابلیت اداره طبقه‌بندی به صورت چند کلاسه	قابلیت اداره طبقه‌بندی به صورت چند کلاسه	قابلیت اداره طبقه‌بندی به صورت چند کلاسه و در صورت بهبود ELM به MPM-ELM به صورت چندهدفه چند کلاسه بلادرنگ
سیستم برنامه‌نویسی درجه دوم	سیستم برنامه‌نویسی درجه دوم	سیستم برنامه‌نویسی چند هدف غیرخطی	سیستم برنامه‌نویسی درجه دوم چندهدفه	سیستم برنامه‌نویسی چندهدفه چند کلاسی غیرخطی

جدول (۲): مشخصات داده‌های استفاده‌شده

مقدار	متغیر
۱-۱۰	ضخامت کلوم <sup>۱</sup>
۱-۱۰	یکنواختی اندازه سلول <sup>۲</sup>
۱-۱۰	یکنواختی شکل سلول <sup>۳</sup>
۱-۱۰	چسبندگی حاشیه‌ای <sup>۴</sup>
۱-۱۰	اندازه سلول‌های اپیتلیال منفرد <sup>۵</sup>
۱-۱۰	هسته‌های برهنه <sup>۶</sup>
۱-۱۰	کروماتین بلند <sup>۷</sup>
۱-۱۰	هسته‌های عادی <sup>۸</sup>
۱-۱۰	میتوز <sup>۹</sup>
در بازه رنگی ۰ الی ۲۵۵ برای RGB و ۰ و ۱ برای تصاویر سیاه و سفید	شدت روشنایی
خطوط با رنگ‌های مختلف جداکننده	لبه‌ها

در این تحقیق از مجموعه داده MIAS به صورت تصویری و بر اساس ویژگی‌های آماری استفاده شده است. در این مجموعه داده، هم تصاویر با ویژگی‌های دارای سرطان سینه و هم عدم سرطان سینه و حالت‌های مشکوک وجود دارد که بر اساس داده بخش آماری آن، این عملیات تشخیص به صورت صحیح انجام خواهد گرفت. این مجموعه داده در پیوند <http://peipa.essex.ac.uk/info/mias.html> قابل دریافت بوده و شامل ۷ ستون است که شرح آن در ادامه ذکر شده است.

به صورت کلی MPM-ELM به یک زنجیره از ماژول‌های تکرار شونده در طول زمان، در مرحله آموزش تبدیل می‌گردد. در ضمن MPM-ELM این قابلیت را خواهد داشت که مانند یک نوار نقاله کار کند، یعنی اطلاعاتی را به نرون‌ها اضافه نماید و یا از آنها کم کند. برخلاف ساختارهای یادگیری عمیق و مدل‌های طبقه‌بندی دیگر مانند ماشین بردار پشتیبان و یا نایو بی‌زین، هیچ‌گونه عملیات به‌روزرسانی وزن در زمان آموزش انجام نمی‌گیرد، اما MPM-ELM می‌تواند ویژگی‌ها را مشخص نماید. از آنجایی که بخش‌های تقطیع شده حاصل از الگوریتم بهینه‌سازی عنکبوت اجتماعی وارد مرحله استخراج ویژگی‌ها شده‌اند و اصلی‌ترین ویژگی‌ها که شدت روشنایی و لبه‌ها هستند، استخراج شده‌اند، عملیات کاهش ابعاد و انتخاب ویژگی‌ها با MPM-ELM انجام می‌پذیرد و ناحیه دقیق توده‌ها را در تصویر به صورت طیفی، نمایش می‌دهد. همین‌طور MPM-ELM قابلیت تفکیک کلاس‌ها بر اساس داده‌ای موجود را خواهد داشت تا بتواند سه کلاس اصلی شامل توده‌های سرطانی خوش‌خیم، بدخیم و حالات مشکوک را مشخص نماید. جدول مشخصات کلی برای داده‌های توده، به صورت جدول (۲) است.

#### ۴. شبیه‌سازی و نتایج

شبیه‌سازی در محیط MATLAB و در یک سیستم با پردازنده ۷ هسته‌ای و پردازنده ۳/۴ گیگاهرتزی اینتل به همراه ۶ مگابایت کَش و همین‌طور ۶ گیگابایت حافظه، انجام شده است.

<sup>1</sup> Clump thickness

<sup>2</sup> Uniformity of cell size

<sup>3</sup> Uniformity of cell shape

<sup>4</sup> Marginal adhesion


<sup>5</sup> Single epithelial cell size

<sup>6</sup> Bare Nuclei

<sup>7</sup> Bland chromatin

<sup>8</sup> Normal nucleoli


<sup>9</sup> Mitoses



شکل (۴) نتیجه کاهش نویز با QUANTUM INVERSE MFT FILTERING

از لحاظ آماری، رویکرد کاهش نویز ارائه شده دارای توانمندی‌های بالایی نسبت به روش‌های پیشین است که در جدول (۳) مقایسه‌ای موردی بین آنها از لحاظ معیارهای ارزیابی انجام گرفته است.

سپس عملیات تقطیع تصویر، با الگوریتم بهینه‌سازی عنکبوت اجتماعی با سرعت ۰/۵ ثانیه، انجام می‌شود که خروجی آن به صورت شکل (۵) است.



شکل (۵) تقطیع تصویر با الگوریتم عنکبوت اجتماعی

1st column:

MIAS database reference number.

2nd column:

Character of background tissue:

F Fatty

G Fatty-glandular

D Dense-glandular

3rd column:

Class of abnormality present:

CALC Calcification

CIRC Well-defined/circumscribed masses

SPIC Spiculated masses

MISC Other, ill-defined masses

ARCH Architectural distortion

ASYM Asymmetry

NORM Normal

4th column:

Severity of abnormality;

B Benign

M Malignant


5th, 6th columns:

x,y image-coordinates of centre of abnormality.

7th column:

Approximate radius (in pixels) of a circle enclosing the abnormality.

در ابتدا تصویر ورودی که به صورت شکل (۳) است، خوانده می‌شود.



شکل (۳) ورودی تصویر برای انجام عملیات سرطان سینه


پس از نرمال‌سازی و کاهش اندازه تصویر به صورت استاندارد، عملیات Quantum Inverse MFT Filtering برای کاهش نویز و بهسازی تصویر انجام می‌شود که نتیجه آن به صورت شکل (۴) است.

انجام می‌شود. از لحاظ آماری، رویکرد تقطیع تصویر ارائه شده دارای توانمندی‌های بالایی نسبت به روش‌های پیشین است که در جدول (۴) از لحاظ معیارهای ارزیابی، مورد مقایسه قرار گرفته‌اند.

جدول (۴): مقایسه روش تقطیع تصویر این تحقیق با روش‌های پیشین

مرجع	سال	زمان تقطیع	دقت (%)
[۲۸]	۲۰۱۶	۲ ثانیه	۹۲/۵۰
[۳۸]	۲۰۱۸	۱/۷ ثانیه	۹۷/۸۰
[۳۹]	۲۰۱۹	۴ ثانیه	۹۸/۵۰
[۴۰]	۲۰۲۰	۷ ثانیه	۸۰
[۴۱]	۲۰۲۰	۳/۵ ثانیه	۹۳/۳۲
[۴۲]	۲۰۲۰	۲ ثانیه	۹۵/۱۰
[۴۳]	۲۰۲۱	۳ ثانیه	۹۸/۸۷
[۴۴]	۲۰۲۱	۲ ثانیه	۹۸
روش پیشنهادی		۰/۵ ثانیه	۹۹/۸۰

در عملیات Quantum Inverse MFT Filtering for Noise Reduction in Segmentation برای کاهش نویز در مرحله تقطیع با الگوریتم بهینه‌سازی عنکبوت اجتماعی انجام می‌شود که دلیل این امر، کاهش نویزها تا حد ممکن برای عملیات تشخیص دقیق ناحیه تومور و طبقه‌بندی نهایی است و خروجی آن به صورت شکل (۶) است.




شکل (۶) کاهش دوباره نویز بعد از تقطیع

جدول (۳): مقایسه روش کاهش نویز این تحقیق با روش‌های پیشین

مرجع	سال	نام روش استفاده شده	اندازه پنجره‌بندی بر روی تصویر ورودی	نرخ PSNR (dB)
[۲۰]	۲۰۱۶	فیلتر میانگین	۳×۳	۲۵/۰۸
			۵×۵	۲۱/۶۸
			۷×۷	۲۰/۱۶
[۲۰]	۲۰۱۶	فیلتر میانه	۳×۳	۳۰/۶۹
			۵×۵	۲۳/۹۴
			۷×۷	۲۲/۵۱
[۲۰]	۲۰۱۶	فیلتر وینر	۳×۳	۳۵/۶۹
			۵×۵	۳۲/۴۰
			۷×۷	۳۰/۷۸
[۴۵]	۲۰۱۸	فیلتر میانه فازی تطبیقی	۳×۳	۳۳/۶۰
			۵×۵	۳۷/۱۵
			۷×۷	۳۸/۳۹
[۴۶]	۲۰۱۹	روش فازی مبتنی بر آنتروپی	۳×۳	۲۲/۴۷
			۵×۵	۲۵
			۷×۷	۳۰
[۴۷]	۲۰۱۹	تبدیل موجک	۳×۳	۳۹/۹۵
			۵×۵	۳۲
			۷×۷	۳۱/۲۰
[۴۸]	۲۰۲۰	یکسان‌سازی محیطی چند آستانه‌ای	۳×۳	۳۵
			۵×۵	۳۵
			۷×۷	۳۳/۵۰
[۴۹]	۲۰۲۰	Wang-Mendel	۳×۳	۳۳/۱۹
			۵×۵	۳۶/۱۲
			۷×۷	۳۷/۵۱
[۵۰]	۲۰۲۰	یکسان‌سازی هیستوگرام	یکسان‌سازی هیستوگرام	۳۲/۱۴
				۳۵/۹۴
				۳۳/۷۸
روش پیشنهادی		Quantum Inverse MFT Filtering	۳×۳	۳۴/۵۷
			۵×۵	۳۸/۴۱
			۷×۷	۴۳/۵۰

در عملیات تقطیع با الگوریتم عنکبوت اجتماعی، عملگرهای این الگوریتم می‌بایست تعریف شوند که شامل ۱۰۰ عنکبوت به‌عنوان جمعیت اولیه، نرخ ارتعاش در تار برابر ۲ و نرخ حمله به طعمه برابر ۰/۰۲ به صورت استاندارد و ارائه اولیه این الگوریتم، مدنظر قرار گرفته است و در ۱۰۰ دور تکرار، تقطیع



شکل (۸) نمایش ناحیه دارای تومور سرطانی از تصاویر سینه به صورت طیفی با روش MPM-ELM

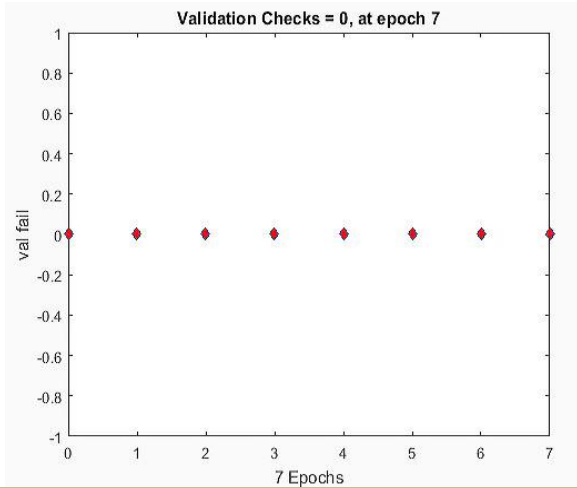
تا به اینجا، نتیجه عملیات بر روی یک تصویر ورودی نشان داده شد، اما تمامی این تصاویر نیاز به طبقه‌بندی دارند. بدین منظور نیاز به طبقه‌بندی داده‌های تحلیلی و آماری MIAS نیز وجود دارد که مبتنی بر رویکرد ارائه شده و بهبود یافته یعنی MPM-ELM است. همان‌طور که پیش از این گفته شد، دلیل استفاده از این الگوریتم، سادگی و نرخ همگرایی بالا در آموزش است، البته ضعف‌هایی هم دارد که می‌توان آن را با توابع محرک و همین‌طور هسته آموزشی و اعمال رویکردی به نام ماتریس مور پنروز، پوشش داد. رویکرد MPM-ELM دارای ۹ ورودی اصلی، ۱۰ لایه پنهان در لایه اول و ۲ لایه پنهان در لایه دوم و همچنین دو خروجی که شامل تشخیص وجود تومور یا توده در سینه و یا عدم آن است، می‌باشد. البته حالت سوم، حالت مشکوک است که اگر هیچ کدام از حالت دارای توده یا تومور سینه و یا عدم آن نیست. شکل (۹) برای کارایی، شکل (۱۰) برای حالات آموزشی، شکل (۱۱) برای ماتریس درهم‌ریختگی و شکل (۱۲) نمودار ROC و نرخ AUC نهایی رویکرد پیشنهادی برای تشخیص توده‌های سرطان سینه و شکل (۱۳) نمودار ROC برای MPM-ELM جهت تشخیص سرطان سینه از تصاویر در مجموعه داده MIAS را نشان می‌دهند. شایان ذکر است که ROC به عنوان روش اعتبارسنجی همراه با K Fold و AUC مدنظر قرار گرفته است.

در ادامه الگوریتم ELM وارد کار می‌شود که به صورت دوگانه مورد استفاده قرار می‌گیرد، یعنی می‌تواند عملیات استخراج ویژگی‌ها و همین‌طور طبقه‌بندی نهایی را انجام دهد. لذا برای بخش استخراج ویژگی‌ها که شامل دو بخش کاهش ابعاد و انتخاب ویژگی‌ها و در نهایت استخراج ویژگی‌ها است، از ELM استفاده می‌شود و برای طبقه‌بندی و مشخص کردن دقیق توده‌ها به صورت طیفی در تصویر، از MPM-ELM استفاده می‌گردد. حال در این مرحله می‌بایست کاهش ابعاد، انتخاب و استخراج ویژگی‌ها صورت گیرد که بر اساس الگوی آموزش و آزمون داده‌ها و به صورت ۷۰٪ آموزش و ۳۰٪ آزمون است و یک خروجی کلی نیز به صورت شکل (۷) دارد که در آن فقط ناحیه سینه را مشخص می‌کند. این عملیات با استفاده از ویژگی‌هایی جدول (۲) شامل مواردی همچون ضخامت کلوم، یکنواختی اندازه سلول، یکنواختی شکل سلول، چسبندگی حاشیه‌ای، اندازه سلول‌های اپیتلیال منفرد، هسته‌های برهنه، کروماتین بلند، هسته‌های عادی، میتوز، شدت روشنایی و لبه‌ها، انجام می‌گیرد.




شکل (۷) خروجی عملیات استخراج ویژگی‌ها با ELM

در ادامه عملیات طبقه‌بندی با تعریف سه کلاس خوش‌خیم، بدخیم و مشکوک و نمایش ناحیه تومور سرطانی در تصاویر ماموگرافی، انجام می‌پذیرد که خروجی آن به صورت شکل (۸) است. لازم به ذکر است که عملیات طبقه‌بندی با توجه به آموزش و آزمون داده‌ها از تصاویر و داده‌های متنی MIAS و ویژگی‌ها و بازه‌های عددی تعریف‌شده در آن طبق جدول (۲) و سایر ویژگی‌های موجود در مجموعه داده‌ها، انجام گرفته است.



شکل (۱۰) حالات آموزشی در طبقه‌بندی با MPM-ELM

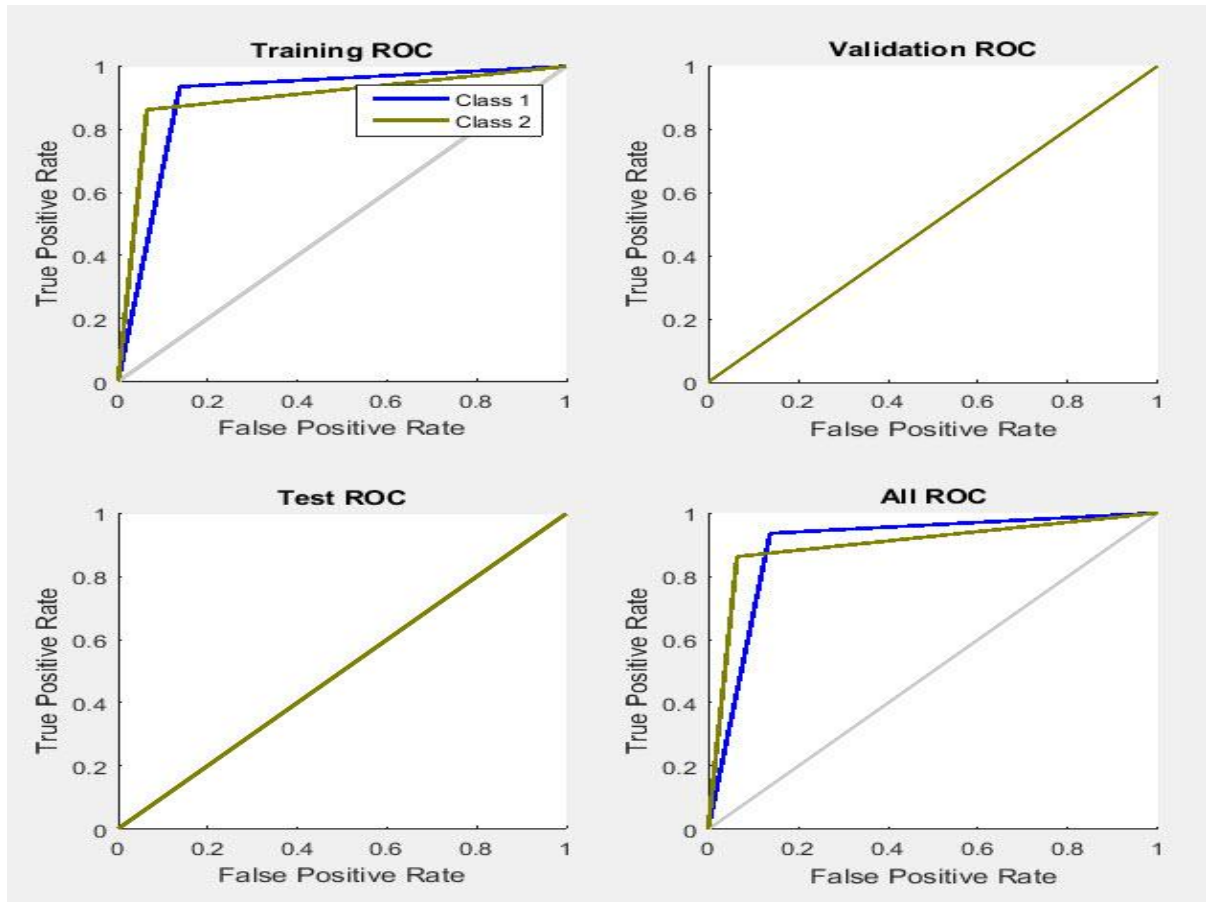


شکل (۹) کارایی در طبقه‌بندی با MPM-ELM




شکل (۱۱) ماتریس درهم‌ریختگی در طبقه‌بندی با MPM-ELM





شکل (۱۲) نمودار ROC و نرخ AUC نهایی رویکرد پیشنهادی برای تشخیص توده‌های سرطان سینه

است. همچنین در شکل (۱۰) که حالات آموزشی در طبقه‌بندی با MPM-ELM را نشان می‌دهد، مقدار خطا به صورت خطی و با نرخ صفر بوده که در تکرار هفتم روند آموزش متوقف شده است. دو عاملی که ممکن است در این مرحله اختلال ایجاد کنند نویز تصاویر و یا همپوشانی اطلاعات خواهند بود. شکل (۱۳) نمودار ROC در طبقه‌بندی با MPM-ELM را تبیین می‌کند. همان‌طور که می‌دانیم نمودار ROC، حساسیت و بازیابی را در یک منحنی نشان می‌دهد و هر چه منحنی آن از نیمساز بالاتر و به یک نزدیک‌تر باشد، سیستم عملکرد بهتری داشته و بهتر توانسته مثبت درست و غلط درست را تشخیص دهد. در نمودار ما مقدار  $AUC=0.8677$  به دست آمده که نشان دهنده نتیجه عالی است. در واقع بازه  $0.9$  تا  $1$ ، بازه بسیار عالی بوده و بندرت به دست می‌آید. اما مقدار عددی AUC در بازه  $0.8$  تا  $0.9$  عالی بوده که در این تحقیق به دست آمده است. در ادامه، نتایج معیارهای ارزیابی در جدول (۵) نشان داده شده است.



شکل (۱۳) نمودار ROC در طبقه‌بندی با MPM-ELM

شکل (۹) کارایی طبقه‌بندی با MPM-ELM را نشان می‌دهد. در هر مرحله، میانگین مربعات خطای آن کمتر شده و در تکرار هفتم به کمترین مقدار خورد رسیده و آموزش آن پایان یافته



یکسان‌سازی، توانستیم تا حد قابل توجهی نویزهای موجود در تصویر را، با توجه به ابعاد مناسب به دست آمده از فیلتر کاهش نویز، به شکل مؤثری کاهش دهیم. مقدار PSNR به دست آمده با این روش ۴۳/۵۰ بوده که نتیجه بسیار مناسبی است. همچنین به دلیل استفاده از ساختار پیمایش کوانتومی، که پیمایش سطری، ستونی و مورب را در پی دارد، توانستیم سرعت انجام عملیات را بهبود بخشیم.

در مرحله تقطیع، با توجه به وجود روش‌های مختلف جداسازی ناحیه تومور از تصاویر ماموگرافی که برخی از آن‌ها در جدول (۴) نشان داده شده است، از الگوریتم تکاملی عنکبوت اجتماعی استفاده شد. خوشبختانه به دلیل اینکه به خوبی می‌توان فضای مساله را بر روی این الگوریتم نگاشت کرد، نتایج بهتری نسبت به سایر روش‌ها حاصل شد. در این روش تار به تصویر ماموگرافی و طعمه به ویژگی‌های آن شامل لبه، شدت روشنایی و نور نگاشت گردید. همین‌طور سرعت اجرا و همگرایی بالا و عدم به دام افتادن در بهینه محلی دلیل دیگر موفقیت این روش نسبت به سایر روش‌ها و به دست آوردن زمان تقطیع ۰/۵ ثانیه می‌باشد.

در مرحله طبقه‌بندی، چند نکته باید مدنظر قرار گیرد. آموزش سریع و قابلیت تعمیم ELM یکی از دلایل عمده انتخاب و موفقیت این طبقه‌بند می‌باشد و از طرفی برای بالا بردن دقت در کلاس‌بندی و همچنین قابلیت تشخیص حالت‌های مشکوک به خوش‌خیم و بدخیم، ELM با مورپنروز ترکیب شده و منجر به دقت ۹۹/۵۰٪ گردیده است.

## ۶. نتیجه‌گیری

وجود توده در نواحی سینه، منجر به ایجاد سرطان سینه می‌شود. شناسایی و تشخیص زودهنگام این توده‌ها، می‌تواند در امر درمان و حفظ سلامت افراد بسیار مؤثر باشد. لذا ارائه سیستم‌های تشخیص هوشمند پزشکی امری لازم است که به عنوان یک سیستم مستقل و یا دستیار پزشکان در ارائه نظرات، به کار گرفته شوند. تحقیقات فراوانی در زمینه تشخیص تومورهای سینه طی سالیان اخیر ارائه شده است که مبتنی بر

جدول (۵): نتایج معیارهای ارزیابی رویکرد پیشنهادی

مقدار	معیار
۰/۰۱	میانگین مربعات خطا
۹۹/۵۰٪	دقت (%)
۸۵/۰۰٪	نرخ ویژگی‌ها
۹۰/۰۰٪	حساسیت
۰/۸۶۷۷	نرخ ناحیه زیر منحنی

در انتها می‌بایست یک مقایسه از لحاظ معیارهای ارزیابی انجام شود. برای این مقایسه نیاز به استفاده از یک سری مقالات پیشین است که از مجموعه داده MIAS استفاده کرده باشند که بتوان در شرایط یکسان، مقایسه را انجام داد. معیار اصلی مقایسه برای تشخیص و طبقه‌بندی سرطان سینه، معیار دقت برحسب درصد است. جدول (۶) نتایج مقایسه رویکرد پیشنهادی را با سایر روش‌های پیشین نشان می‌دهد.

جدول (۶): نتایج مقایسه رویکرد پیشنهادی با سایر روش‌های پیشین

مرجع	سال	دقت (%)
[۱۴]	۲۰۱۶	۷۰/۴۰
[۱۹]	۲۰۱۷	۸۵
[۱۰]	۲۰۱۵	۹۸/۵۴
[۱۱]	۲۰۱۸	۹۷/۱۰
[۴]	۲۰۱۵	۹۶/۴۷
[۷]	۲۰۲۰	۹۸/۹۵
[۸]	۲۰۲۰	۹۸/۵۸
[۵۱]	۲۰۲۱	۹۷/۸۰
[۵۲]	۲۰۲۱	۹۷/۲۰
[۵۳]	۲۰۲۱	۹۷/۱۸
[۵۴]	۲۰۲۱	۷۷
رویکرد پیشنهادی		۹۹/۵۰

## ۵. تحلیل نتایج

همان‌طور که در جدول‌های (۳) تا (۵) مشاهده می‌شود، روش پیشنهادی بهبود قابل توجهی نسبت به روش‌های پیشین دارد و تا میزان قابل توجهی بر چالش‌های روش‌های پیشین فائق آمده است. در قسمت کاهش نویز به دلیل استفاده از فیلترهای

شروع به حمله به سمت طعمه می‌کنند و نتیجه آن تقطیع نواحی تومور با توجه به همان دو ویژگی محلی است. بعد از تقطیع، عملیات استخراج ویژگی شامل کاهش ابعاد ویژگی‌ها و همین‌طور انتخاب بهترین ویژگی‌ها برای استخراج از تقطیع با رویکرد ELM انجام می‌شوند. در این بخش، بر اساس ۹ ویژگی ساختاری در ایجاد توده‌ها، این کار انجام شده و ویژگی‌هایی مشخص می‌گردد، اما نیاز به طبقه‌بندی برای تشخیص نوع توده‌ها، امری ضروری است. با توجه به این‌که روش‌های قبلی ساختار ایجاد کلاس را، به صورت دستی داشته‌اند و عملکرد آنها بعد از استخراج ویژگی‌ها کند بوده است و همچنین از آنجا که روش ELM در بخش طبقه‌بندی مانند روش‌های پیشین عمل می‌نماید، لذا به استفاده از ماتریس مورپنروز و تلفیق آن با ELM به صورت MPM-ELM پرداخته شده است تا بتواند یک طبقه‌بندی خودکار با ایجاد کلاس‌های خوش‌خیم، بدخیم و مشکوک (دارای حالت مشکوک به خوش‌خیم و مشکوک به بدخیم) را انجام دهد. نتایج طبقه‌بندی از لحاظ معیار ارزیابی دقت، نشان می‌دهد که این روش نسبت به روش‌های پیشین دارای برتری عملکردی است و تا ۹۹/۵۰٪ دارای دقت می‌باشد.

تعارض منافع: نویسندگان اعلام می‌کنند که هیچ تعارض منافعی ندارند.

تصاویر ماموگرافی، MRI و التراساند می‌باشند. نقطه ضعف اکثر روش‌های موجود، عدم شناسایی و تشخیص دقیق نواحی دارای تومور و همین‌طور عدم طبقه‌بندی نوع توده‌ها است. رویکرد پیشنهادی این تحقیق برای غلبه بر چالش‌های قبلی، دارای ساختاری سه مرحله‌ای شامل پیش‌پردازش، تقطیع و در انتها عملیات استخراج ویژگی‌ها همراه با طبقه‌بندی برای تشخیص توده‌های سرطانی از تصاویر ماموگرافی از مجموعه داده MIAS است. در بخش پیش‌پردازش، بهسازی و کاهش نویز تصاویر ماموگرافی با رویکرد Quantum Inverse MFT انجام می‌شود که در دل خود شامل سه بخش هیستوگرام تطبیقی، آستانه‌گذاری محلی و اکتیوکانتور است تا نویزها را برای پردازش به صورت سطری، ستونی و مورب به شکل بلادرنگ و بدون تکرار تا حد ممکن کاهش دهد. نتایج کاهش نویز با پنجره‌بندی ۷×۷ نشان می‌دهد که رویکرد پیشنهادی از لحاظ معیار ارزیابی PSNR دارای نتایج بهتری نسبت به روش‌های ارائه شده در این زمینه است. در ادامه عملیات تقطیع تصویر با تعریف عملگرهای الگوریتم عنکبوت اجتماعی شامل جمعیت اولیه یا عنکبوت‌ها، ایجاد تار، لرزش بر روی تار و شکار طعمه‌ها، انجام می‌شود. این تقطیع بدین صورت کار می‌کند که عنکبوت‌ها به سمت دو ویژگی محلی تصویر شامل شدت روشنایی و لبه‌ها می‌روند. در واقع تار، همان تصویر اصلی ماموگرافی است و عنکبوت‌ها بر اساس این دو ویژگی محلی تصویر، لرزش را ایجاد می‌کنند و در دور تکراری مشخص،

## مراجع

- [1] Nathan M. R. and Schmid P., "The emerging world of breast cancer immunotherapy", *The Breast*, 37:200-206, 2018.
- [2] Kavya N., Sriraam N., Usha N., Hiremath B., Suresh A., Sharath D., Venkatraman B., and Menaka M., "Breast Cancer Lesion Detection From Cranial-Caudal View of Mammogram Images Using Statistical and Texture Features Extraction", *International Journal of Biomedical and Clinical Engineering*, 9(1):16-32, 2020.
- [3] Barinov L., Jairaj A., Becker M., Seymour S., Lee E., Schram A., Lane E., Goldszal A., Quigley D., and Paster L., "Impact of data presentation on physician performance utilizing artificial intelligence-based computer-aided diagnosis and decision support systems", *Digital Imaging*, 32(3):408-416, 2019.
- [4] Keavey E., Phelan N., and Fitzpatrick P., "Clinical performance of digital mammography systems in a breast screening programme—An update", *Physica Medica*, 52:179-180, 2018.
- [5] Houssami N., Bernardi D., Pellegrini M., Valentini M., and Macaskill P., "Breast cancer detection using

- single-reading of breast tomosynthesis (3D-mammography) compared to double-reading of 2D-mammography, Evidence from a population-based trial”, *Cancer Epidemiology*, 47:94-99, 2017.
- [6] Kikuchi M., Hayashida T., Watanuki R., Nakashoji A., Kawai Y., and Nagayama A., “Diagnostic system of breast ultrasound images using Convolutional Neural Network”, *Cancer Research*, 80(4), 2020.
- [7] Ekici S. and Jawzal H., “Breast cancer diagnosis using thermography and convolutional neural networks”, *Medical Hypotheses*, 137, 2020.
- [8] Toğaçar M., Ergen B., and Cömert Z., “Application of breast cancer diagnosis based on a combination of convolutional neural networks, ridge regression and linear discriminant analysis using invasive breast cancer images processed with autoencoders”, *Medical Hypotheses*, 135, 2020.
- [9] Yektaei H., Manthouri M., and Farivar F., “Diagnosis of Breast Cancer Using Multiscale Convolutional Neural Network”, *Biomedical Engineering Applications, Basis and Communications*, 31(5), 2019.
- [10] Rouhi R., Jafari M., Kasaei S., and Keshavarzian P., “Benign and malignant breast tumors classification based on region growing and CNN segmentation”, *Expert Systems with Applications*, 42:990-1002, 2015.
- [11] Telegrafo M., Rella L., Stabile A., Ianora A., Angelelli G., and Moschetta M., “Effect of background parenchymal enhancement on breast cancer detection with magnetic resonance imaging”, *Diagnostic and Interventional Imaging*, 97:313-318, 2016.
- [12] Guo R., Lu G., Qin B., and Fei B., “Ultrasound Imaging Technologies for Breast Cancer Detection and Management: A Review”, *Ultrasound in Medicine and Biology*, 44(1):37-70, 2018.
- [13] Dehghan-Khalilabad N. and Hassanpour H., “Employing image processing techniques for cancer detection using microarray images”, *Computers in Biology and Medicine*, 81(1):139-147, 2016.
- [14] Kaymak S., Helwan A., and Uzun D., “Breast cancer image classification using artificial neural networks”, *Procedia Computer Science*, 120:129-131, 2016.
- [15] Yassin, I. R. N., Omran S., El.Houby S. M. F., and Allam H., “Machine learning techniques for breast cancer computer aided diagnosis using different image modalities: A systematic review”, *Computer Methods and Programs in Biomedicine*, 156:25-45, 2018.
- [16] Karabatak M., “A new classifier for breast cancer detection based on Naïve Bayesian”, *Measurement*, 72:32-36, 2015.
- [17] Wang F., Zhang S., and Henderson L. M., “Adaptive decision-making of breast cancer mammography screening: A heuristic-based regression model”, *Omega*, 76:70-84, 2018.
- [18] Patel B. C. and Sinha G. R., “Mammography Feature Analysis and Mass Detection in Breast Cancer Images”, *International Conference on Electronic Systems, Signal Processing and Computing Technologies*, January, pp. 474-478, 2014.
- [19] Singh A. K. and Gupta B., “A Novel Approach for Breast Cancer Detection and Segmentation in a Mammogram. Eleventh International Multi-Conference on Information Processing”, *Procedia Computer Science*, 54:676-682, 2015.
- [20] Tang J., Rangayyan R. M., Xu J., Naqa I. E., and Yang Y., “Computer-Aided Detection and Diagnosis of Breast Cancer with Mammography: Recent Advances”, *IEEE Transactions on Information Technology in Biomedicine*, 13(2):236-251, 2009.
- [21] Lee Y., “Preliminary evaluation of dual-head Compton camera with Si/CZT material for breast cancer detection: Monte Carlo simulation study”, *Optik*, 202, October 2019.
- [22] Ullah Khan S., Islam N., Jan Z., Ud Din I., and Rodrigues J. P. C. J., “A novel deep learning based framework for the detection and classification of breast cancer using transfer learning”, *Pattern Recognition Letters*, 125:1-6, 2019.
- [23] Kaur P., Singh G., and Kaur P., “Intellectual detection and validation of automated mammogram breast cancer images by multi-class SVM using deep learning classification”, *Informatics in Medicine Unlocked*, 16:100239, 2019.
- [24] Martínez-Martínez F., Rupérez-Moreno M. J., Martínez-Sober M., Solves-Llorens J. A., and Martín-Guerrero J. D., “A finite element-based machine learning approach for modeling the mechanical behavior of the breast tissues under compression in real-time”, *Computers in Biology and Medicine*, 90:116-124, 2017.
- [25] Mohebian R. M., Marateb R. H., Mansourian M., Angel Mañanas M., and Mokarian F., “A Hybrid Computer-aided-diagnosis System for Prediction of Breast Cancer Recurrence (HPBCR) Using Optimized Ensemble Learning”, *Computational and Structural Biotechnology Journal*, 15:75-85, 2017.
- [26] Panelli G., Benjamin M. R., and Derevianko A., “Applying the matched-filter technique to the search for dark matter transients with networks of quantum sensors”, *EPJ Quantum Technology*, 7, 2020.
- [27] Mascarade P., “Quantum Image Filtering in the Frequency Domain”, *IEEE Open Access*, 2018.

- [28] Kannan S., Subiramaniyam N. P., Rajamanickam A. T., and Balamurugan A., "Performance Comparison Of Noise Reduction Inmammogram Images", *International Journal of Research in Engineering and Technology*, 5(2):31-33, 2016.
- [29] Ball J. E. and Bruce L. M., "Digital mammogram spiculated mass detection and spicule segmentation using level sets", In *Proceedings of the IEEE 29th Annual International Conference on Engineering in Medicine and Biology Society*, pp. 4979–4984, August 2007.
- [30] Ball J. E. and Bruce L. M., "Digital mammographic computer aided diagnosis (CAD) using adaptive level set segmentation", In *Proceedings of the IEEE 29th Annual International Conference on Engineering in Medicine and Biology Society*, pp. 4973–4978, 2007.
- [31] Tao Y., Freedman M. T., Makariou E., and Xuan J., "Multilevel learning-based segmentation of ill-defined and spiculated masses in mammograms", *Medical Physics*, 37:5993-6002, 2010.
- [32] Xu S., Liu H., and Song E., "Marker-controlled watershed for lesion segmentation in mammograms", *Digital Imaging*, 24:754-763, 2011.
- [33] Rahmati P., Adler A., and Hamarneh G., "Mammography segmentation with maximum likelihood active contours", *Medical Image Anal*, 16:1167-1186, 2012.
- [34] Abbas Q., Celebi M. E., and Garcia I. F., "Breast mass segmentation using region-based and edge-based methods in a 4-stage multiscale system", *Biomedical and Signal Process*, 8:204-214, 2013.
- [35] Pereira D. C., Ramos R. P., and Do Nascimento M. Z., "Segmentation and detection of breast cancer in mammograms combining wavelet analysis and genetic algorithm", *Computer Methods and Programs in Biomedicine*, 114:88-101, 2014.
- [36] Cordeiro F. R., Santos W. P., and Silva-Filho A. G., "An adaptive semi-supervised Fuzzy GrowCut algorithm to segment masses of regions of interest of mammographic images", *Applied Soft Computing*, 46:613-628, 2016.
- [37] Punitha S., Amuthan A., and Suresh Joseph K., "Benign and malignant breast cancer segmentation using optimized region growing technique", *Future Computing and Informatics Journal*, 3(2): 348-358, 2018.
- [38] El Adoui M., Ahmed Mahmoudi S., Amine Larhman M., and Benjelloun M., "MRI Breast Tumor Segmentation Using Different Encoder and Decoder CNN Architectures", *MDPI Computers*, 8(52):11, 2019.
- [39] Ahmed L., Iqbal M. M., Aldabbas H., Khalid S., Saleem Y., and Saeed S., "Images data practices for Semantic Segmentation of Breast Cancer using Deep Neural Network", *Journal of Ambient Intelligence and Humanized Computing*, pp. 1–17, 2020.
- [40] Zeiser F. A., da Costa C. A., Zonta T., Marques N. M. C., Roehle A. V., Moreno M., and da Rosa Righi R., "Segmentation of masses on mammograms using data augmentation and deep learning", *Journal of digital imaging*, 33(4):858–868, 2020.
- [41] Abdelhafiz D., Bi J., Ammar R., Yang C., and Nabavi S., "Convolutional neural network for automated mass segmentation in mammography", *BMC Bioinformatics*, 21(S1):1–19, 2020.
- [42] Salama W. M. and Aly M. H., "Deep learning in mammography images segmentation and classification: automated cnn approach", *Alexandria Engineering Journal*, 60(5):4701–4709, 2021.
- [43] Tsochatzidis L., Koutla P., Costaridou L., and Pratikakis I., "Integrating segmentation information into cnn for breast cancer diagnosis of mammographic masses", *Computer Methods and Programs in Biomedicine*, 200:p. 105913, 2021.
- [44] Devakumari D. and Punithavathi V., "Comparison Of Noise Removal Filters For Breast Cancer detection In Mammogram Images", *International Journal of Pure and Applied Mathematics*, 119(18): 3863-3874, 2018.
- [45] Dabass J., Arora S., Vig R., and Hanmandlu M., "CLAHE and entropy based Intuitionistic Fuzzy Method", *International Conference on Signal Processing and Integrated Networks (SPIN)*, 2019, doi: 10.1109/SPIN.2019.8711696.
- [46] Zebari D. A., Haron H., Zeebaree S. R. M., and Zeebaree D. Q., "Enhance the Mammogram Images for Both Segmentation and Feature Extraction Using Wavelet Transform", In *2019 International Conference on Advanced Science and Engineering (ICOASE)*, Duhok, Iraq, 100–05, 2019.
- [47] Al-Antari M. A., Han S.-M., and Kim T.-S., "Evaluation of deep learning detection and classification towards computer-aided diagnosis of breast lesions in digital X-ray mammograms", *Computer methods and programs in biomedicine* 196:105584, 2020.
- [48] Shen L., He M., Shen N., Yousefi N., Wang C., and Liu G., "Optimal breast tumor diagnosis using discrete wavelet transform and deep belief network based on improved sunflower optimization method", *Biomedical Signal Processing and Control* 60:101953, 2020.
- [49] Arora R., Rai P. K., and Raman B., "Deep feature-based automatic classification of mammograms", *Medical and biological engineering and computing*,

58(6):1199-1211, 2020.

- [50] Mahmood T., Li J., Pei Y., and Akhtar F., "An Automated In-Depth Feature Learning Algorithm for Breast Abnormality Prognosis and Robust Characterization from Mammography Images Using Deep Transfer Learning", *Biology*, 10, 859, 2021.
- [51] AmineNaji M., Aarika K., HabibBenlahmar E. L., AitAbdelouahid R., and Debauche O., "Machine Learning Algorithms For Breast Cancer Prediction And Diagnosis", *Procedia Computer Science*, 191:487-492, 2021.
- [52] Resmini R., Silva L., L. Araujo L., L. Medeiros L., Muchaluat-Saade D., and Conci A., "Combining Genetic Algorithms and SVM for Breast Cancer Diagnosis Using Infrared Thermography", *sensors* 21(14):4802, 2021.
- [53] Chabert S., Castro J. S., Muñoz L., Cox P., Riveros R., Vielma J., Huerta G., Querales M., Saavedra C., Veloz A., and Salas R., "Image Quality Assessment to Emulate Experts' Perception in Lumbar MRI Using Machine Learning", *Applied Sciences*, 11(14), 2021.

[۵۴] آخوندی ر.، حسینی ر.، «ارایه مدل هوشمند هایپریدی فازی-تکامل ژنتیکی تفاضلی در یک سیستم خبره فازی برای پیش‌بینی خطر ابتلا به بیماری قلبی»، *مجله محاسبات نرم*، جلد ۱، شماره ۵، ص. ۳۵-۱۲، ۱۳۹۱.

[۵۵] ویسی ه.، قایدشرف ح.، ابراهیمی م.، «بهبود کارایی الگوریتم‌های یادگیری ماشین در تشخیص بیماری‌های قلبی با بهینه‌سازی داده‌ها و ویژگی‌ها»، *مجله محاسبات نرم*، جلد ۸، شماره ۱، ص. ۸۵-۷۰، ۱۳۹۸.

[۵۶] وثیقی ذاکر ا.، جلیلی س.، «پیش‌بینی ژن‌های بیماری با استفاده از دسته‌بند تک کلاسی ماشین بردار پشتیبان»، *مجله محاسبات نرم*، جلد ۴، شماره ۱، ص. ۸۳-۷۴، ۱۳۹۴.