

# روش جدید آسیب‌شناسی توده‌ها در تصاویر ماموگرافی به کمک ترکیب ویژگی‌های منطبق بر استاندارد BI-RADS و کلاسه‌بندی کننده مبتنی بر تضاد

فاطمه ساکی، امیر طهماسبی و شهریار برادران شکوهی

تشخیص زودهنگام سرطان، نرخ بهبودی و گزینه‌های درمان را افزایش می‌دهد [۳]. ماموگرافی یکی از قابل اعتمادترین روش‌ها برای تشخیص زودهنگام سرطان سینه و معالجه آن بوده و نرخ مرگ و میر حاصل از این سرطان را به‌طور چشم‌گیری کاهش داده است [۴]. البته ماموگرافی به‌طور مطلق بی‌نقص نیست و اشکالاتی از قبیل وابستگی به محیط، سختی تفسیر و وابستگی به میزان تجربه رادیولوژیست را داراست [۲]. خوشبختانه سیستم‌های آسیب‌شناسی کامپیوتری (CADx) می‌توانند به بهبودی عملکرد رادیولوژیست کمک کنند [۳].

مهم‌ترین علایم اولیه سرطان سینه که رادیولوژیست‌ها در تصاویر ماموگرافی به دنبال آنها هستند، خوشه‌های میکروکلسیفیکیشن، توده‌ها، عدم تقارن بین دو پستان و در هم ریختگی ساختاری می‌باشد [۲]. یک توده عبارت است از یک ضایعه فضاگیر که حداقل از دو نمای مختلف قابل رؤیت باشد [۵]. اگرچه محققین الگوریتم‌های گوناگونی را در زمینه‌های ناحیه‌بندی، استخراج ویژگی و کلاسه‌بندی به‌منظور آسیب‌شناسی توده‌ها در تصاویر ماموگرافی معرفی کرده‌اند، هنوز نیاز به تحقیقات بیشتری در این زمینه احساس می‌شود.

این تحقیق در راستای معرفی روش جدید جهت آسیب‌شناسی توده‌ها در تصاویر ماموگرافی می‌باشد که بر بخش استخراج ویژگی و کلاسه‌بندی سریع و بهینه ویژگی‌ها متمرکز شده است. هدف، بهبود عملکرد سیستم‌های CADx در آسیب‌شناسی توده‌ها و همچنین داشتن سیستمی با سرعت یادگیری بالا نسبت به دیگر سیستم‌های مشابه می‌باشد. بدین منظور از شبکه عصبی MLP<sup>۵</sup> با یادگیری مبتنی بر وزن‌های متضاد (OWBP) استفاده شده است.

یادگیری مبتنی بر تضاد، یک مفهوم بسیار ساده است که در سال ۲۰۰۵ توسط دکتر تیزهوش معرفی شد [۶] و می‌تواند باعث بهبود در همگرایی یا عملکرد الگوریتم‌های هوش محاسباتی شود [۷]. این یادگیری تا به حال به‌طور موفقیت‌آمیزی در بهبود یادگیری تقویتی، الگوریتم‌های تکاملی مانند الگوریتم تجمع‌ی پرندگان، الگوریتم بهینه‌سازی مورچگان، الگوریتم بازپخت تدریجی و الگوریتم ژنتیک به‌کار گرفته شده است [۸]. همچنین در بهبود و سرعت‌بخشی روند یادگیری شبکه‌های عصبی مصنوعی، استفاده شده است. به عنوان مثال در [۶] یادگیری resilient back propagation با تعریف وزن‌های متضاد و [۷] یادگیری پس‌انتشار (BP) با بهره‌گیری از توابع انتقال متضاد بهبود یافته‌اند.

در این تحقیق سعی شده است جهت سرعت‌بخشیدن یادگیری BP معمولی از وزن‌های متضاد استفاده شود. الگوریتم پیشنهادی به همین

چکیده: تفکیک توده‌های خوش‌خیم و بدخیم در ماموگرام‌های دیجیتال یکی از مراحل بسیار مهم تشخیص زودهنگام سرطان سینه است، چرا که می‌تواند تا حد زیادی شانس بقای بیمار را افزایش دهد. در این مقاله یک سیستم CADx<sup>۱</sup> نوین با به‌کارگیری کلاسه‌بندی کننده مبتنی بر تضاد<sup>۲</sup> (OWBP) جهت آسیب‌شناسی توده‌ها در تصاویر ماموگرافی معرفی خواهد شد. هدف، بهبود عملکرد و سرعت یادگیری الگوریتم‌های CADx با استفاده از ترکیب ویژگی‌های منطبق بر استاندارد BI-RADS و کلاسه‌بندی کننده پیشنهادی می‌باشد. ورودی سیستم یک ROI<sup>۳</sup> بوده که حاوی یک توده مشکوک است. این ناحیه ابتدا تحت پیش‌پردازش‌هایی قرار گرفته، سپس ۱۲ ویژگی که توصیف‌کننده‌های مناسبی از شکل، مرز و چگالی توده هستند، استخراج می‌شوند. منحنی ROC<sup>۴</sup> و عملکرد آسیب‌شناسی حاصل از ترکیب تمام این ویژگی‌ها توسط دو کلاسه‌بندی کننده با یادگیری متداول پس‌انتشار و یادگیری پیشنهادی OWBP ارزیابی شده و سیستم‌های حاصل از لحاظ سرعت یادگیری نیز مورد مقایسه قرار گرفته‌اند. همچنین در این تحقیق قابلیت آسیب‌شناسی هر گروه از ویژگی‌های شکل، مرز و چگالی به‌طور جداگانه بررسی شده است. پایگاه داده مورد استفاده در این تحقیق MIAS است. سیستم نهایی پیشنهادی دارای Az ۰/۹۲۴، با سرعت یادگیری تقریباً ۴ برابر سرعت یادگیری سیستم با کلاسه‌بندی کننده پس‌انتشار و همچنین عملکرد ۹۲/۸۶٪ می‌باشد.

کلید واژه: استخراج ویژگی، استاندارد BI-RADS، سیستم CADx، کلاسه‌بندی کننده مبتنی بر تضاد، ماموگرافی.

## ۱- مقدمه

سرطان سینه همواره یکی از خطرناک‌ترین بیماری‌ها در بین زنان بوده و خطر ابتلا به سرطان سینه بدخیم در بین زنان معادل با نسبت ۱ به ۸ است [۱] و [۲]. می‌توان گفت با وجود پیشرفت تکنولوژی در زمینه‌های ماموگرافی، ترموگرافی، ترموگرافی نوری و دیگر روش‌های ضد سرطان در ۲۰ سال اخیر، سرطان پستان هنوز مشکلی عمده محسوب می‌شود.

این مقاله در تاریخ ۲۰ آبان ماه ۱۳۸۹ دریافت و در تاریخ ۱۹ آبان ماه ۱۳۹۰ بازنگری شد.

فاطمه ساکی، دانشکده مهندسی برق، دانشگاه علم و صنعت ایران، تهران، (email: fatemeh.saki@utdallas.edu).

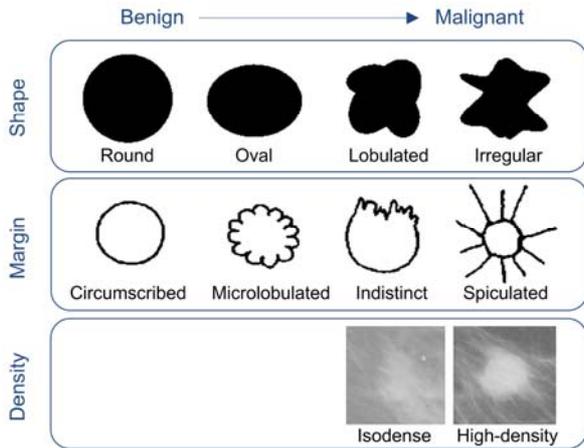
امیر طهماسبی، دانشکده مهندسی برق، دانشگاه علم و صنعت ایران، تهران، (email: a.tahmasbi@utdallas.edu).

شهریار برادران شکوهی، استادیار دانشکده مهندسی برق، دانشگاه علم و صنعت ایران، تهران، (email: bshokouhi@iust.ac.ir).

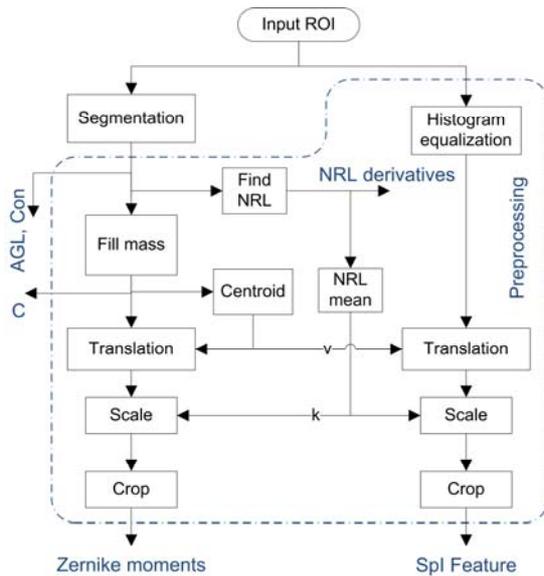
1. Computer - Aided Diagnosis
2. Opposite Weighted Back Propagation
3. Regions of Interest
4. Receiver Operational Characteristics

5. Multilayer Perceptron

6. Back Propagation



شکل ۱: حالات گوناگون شکل، مرز، چگالی توده‌ها و امکان بدخیمی هر یک [۱۱].



شکل ۲: بلوک دیاگرام مراحل لازم جهت پیش‌پردازش.

## ۲- پایگاه داده

برای تأمین تصاویر ماموگرافی از پایگاه داده MIAS استفاده شده است [۱۲]. این پایگاه شامل ۳۲۲ تصویر ماموگرافی از پستان‌های چپ و راست ۱۶۱ خانم مختلف می‌باشد. ابعاد هر یک از تصاویر پایگاه داده ۱۰۲۴×۱۰۲۴ بوده که با رزولوشن ۲۰۰ micron pixel edge دیجیتایز شده‌اند. در واقع تصاویر ماموگرافی دیجیتالی، از نوع سطح خاکستری با عمق ۸ بیت هستند.

این تصاویر از نقطه نظر نوع آسیب، شامل پستان‌های نرمال، حاوی توده، حاوی خوشه میکروکلسیفیکیشن، نامتقارن و دچار در هم ریختگی ساختاری می‌باشند. این پایگاه شامل ۲۰۹ پستان نرمال، ۶۷ ROI با آسیب‌های خوش خیم و ۵۴ ROI با آسیب‌های بدخیم است [۱۲].

## ۳- پیش‌پردازش و ناحیه‌بندی

شکل ۲ بلوک دیاگرام مرحله پیش‌پردازش را نشان می‌دهد. وظیفه هر بخش آماده‌سازی تصاویر ROI ورودی به‌گونه‌ای است که برای استخراج ویژگی خاصی مناسب باشد.

در این مقاله، ناحیه‌بندی به‌صورت دستی و توسط دو رادیولوژیست خبره صورت گرفته است. در واقع ابتدا هر ROI از ماموگرام مربوطه استخراج شده و توسط دو رادیولوژیست خبره ناحیه‌بندی شده‌اند تا توجه

جدول ۱: لیست ویژگی‌های استفاده‌شده در این تحقیق.

Category	Feature name	Explanation
Shape	C	Circularity
	$Z'_r$	Zernike moments
	$Z'_s$	
	$Z'_x$	
Margin	NRLs	NRL standard deviation
	NRLm	NRL mean
	NRLzcc	NRL zero crossing count
	NRLar	NRL area ratio
	NRLen	NRL entropy
	Spl	Spiculation index
Density	AGL	Average gray level
	Con	Contrast

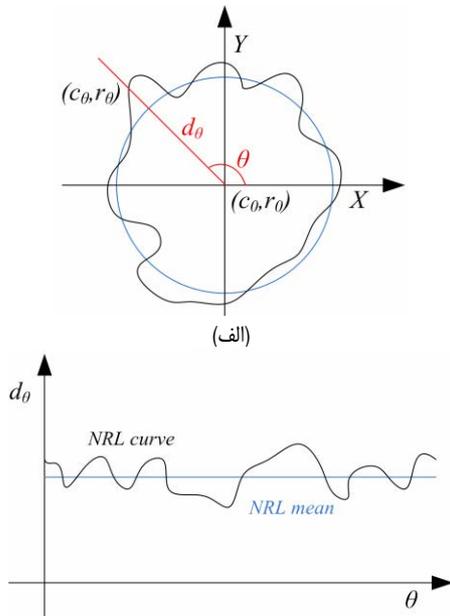
دلیل، OWBP نامیده می‌شود [۹]. هدف این است که کلاسه‌بندی کننده حاصل نسبت به کلاسه‌بندی کننده MLP با یادگیری BP رایج سریع‌تر به همگرایی مطلوب برسد و در زمان یادگیری یکسان عملکرد بهتری داشته باشد.

بر اساس استاندارد گزارش تصویربرداری سینه و سیستم‌های اطلاعاتی (BI - RADS)، رادیولوژیست‌های خبره در هنگام بررسی ماموگرام روی سه گروه ویژگی مختلف تمرکز می‌کنند [۲]. این سه گروه عبارتند از شکل، مرز و چگالی توده. شکل توده می‌تواند گرد، بیضوی، لاله‌گون و یا غیر عادی باشد. مرز توده می‌تواند محدود با لبه‌های لاله‌دار، نامشخص و یا سوزنی‌شکل باشد. همچنین توده می‌تواند دارای چگالی بیشتر، چگالی برابر یا چگالی کمتر، نسبت به بافت نرمال پستان بوده و یا حتی حاوی چربی باشد [۵]. شکل ۱ انواع مختلف شکل، مرز و چگالی توده‌ها و امکان بدخیمی هر یک را نشان می‌دهد.

در این مقاله پس از اعمال پیش‌پردازش‌هایی نظیر ناحیه‌بندی، انتقال، مقیاس‌بندی تصویر و متعادل کردن هیستوگرام روی مناطق مورد توجه (ROI) از تصاویر ورودی، تعداد ۱۲ ویژگی که توصیف‌کننده‌های مناسبی از اطلاعات موجود در شکل، مرز و چگالی توده‌ها هستند، استخراج می‌شوند. برخی از این ویژگی‌ها در مقالات مرجع معرفی و استفاده شده‌اند [۴] و [۱۰] و برخی نیز برای اولین بار در این مقاله معرفی می‌شوند. این ویژگی‌ها در جدول ۱ آمده‌اند. نکته قابل توجه این است که این دسته ویژگی‌ها توانایی استخراج اطلاعات مورد نظر یک متخصص ماموگرافی را داشته و با استفاده از تجربیات یک رادیولوژیست خبره انتخاب شده‌اند.

هر یک از گروه ویژگی‌های شکل، مرز و چگالی در بخش کلاسه‌بندی عملکرد آسیب‌شناسی به‌طور جداگانه به کمک کلاسه‌بندی کننده MLP رایج بررسی می‌شود. سپس ترکیب هر سه گروه ویژگی به هر دو کلاسه‌بندی کننده MLP با یادگیری BP و کلاسه‌بندی کننده OWBP اعمال و عملکرد آسیب‌شناسی و سرعت یادگیری سیستم‌های حاصل بررسی می‌شود. سیستمی به‌عنوان سیستم برتر انتخاب خواهد شد که سرعت یادگیری بالاتر و همچنین از عملکرد آسیب‌شناسی مطلوبی برخوردار باشد. مبنای ارزیابی سیستم‌ها سرعت همگرایی خطای یادگیری و منحنی مشخصه عملکردی گیرنده (ROC) آنها می‌باشد.

در بخش ۲ در مورد پایگاه داده مورد استفاده توضیح داده خواهد شد. بخش ۳ تا ۵ در مورد بخش‌های مختلف الگوریتم پیشنهادی است. در بخش ۶ نتایج شبیه‌سازی آورده شده و در مورد آنها بحث می‌گردد و در نهایت نتیجه‌گیری عملکرد تحقیقات ارائه می‌شود.



شکل ۴: اصول استخراج بردار NRL از یک توده.

توده با مرکز ثقل آن به‌زاي یک زاويه خاص. با استفاده از (۳) می‌توان بردار  $d$  را محاسبه کرد [۱۳]

$$d^j(i) = \sqrt{(c_\theta^j(\theta) - c^j)^2 + (r_\theta^j(\theta) - r^j)^2}, \quad (3)$$

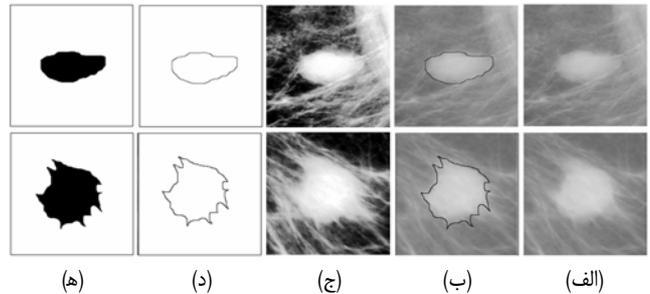
$$\theta = \frac{2\pi i}{M}, \quad i = 1, \dots, M$$

که در آن  $d^j = (d^j(1), \dots, d^j(M))^T$  مربوط به توده موجود در ROI  $j$ ام می‌باشد. زوج مرتب  $(r, c)$  مختصات مرکز ثقل توده می‌باشد که اکنون منطبق بر مرکز ROI است. همچنین زوج مرتب  $(r(\theta), c(\theta))$  مختصات مرکز توده به‌زاي زاويه  $\theta$  است. لازم به ذکر است که زاويه  $\theta$  به‌طور پیوسته تغییر نمی‌کند و در بازه  $[0, 2\pi]$  دارای  $M$  حالت گسسته است. بردار  $d$  در شکل ۴-ب نمایش داده شده است. با استفاده از مقدار متوسط بردار  $d$  می‌توان مقیاس توده‌ها را به‌گونه‌ای تنظیم کرد که تمامی آنها شعاع تقریباً یکسانی داشته باشند.

پیش‌پردازش‌های لازم جهت استخراج ویژگی  $SpI^H$  عبارت هستند از متعادل کردن هیستوگرام، انتقال، مقیاس‌بندی، اصلاح ابعاد تصویر و برش. این مراحل دقیقاً مشابه با مراحل توضیح داده شده برای گشتاورهای زرنیک می‌باشند، با این تفاوت که روی تصویر سطح خاکستری اعمال می‌شوند. لازم به ذکر است که بعد از پردازش‌های انتقال و اصلاح ابعاد توده‌ها، تعدادی از سطر و ستون‌های حاشیه تصویر مقدارشان نامعتبر می‌گردد. به همین دلیل به کمک پردازش برش، این سطر و ستون‌ها باید با حفظ اطلاعات مفید تصویر حذف شوند.

#### ۴- استخراج ویژگی‌ها

همان‌طور که در جدول ۱ قابل مشاهده است، ویژگی‌های  $C$  و گشتاورهای زرنیک برای استخراج اطلاعات موجود در شکل توده‌ها، ویژگی‌های  $SpI$  و مشتقات NRL برای استخراج اطلاعات موجود در مرکز توده‌ها و در نهایت ویژگی‌های  $AGL$  و  $Con$  برای استخراج اطلاعات چگالی توده‌ها مناسب هستند. در ادامه توضیحات بیشتری در مورد هر یک داده خواهد شد.



شکل ۳: مراحل مختلف پیش‌پردازش توده، (الف) ROI ورودی، (ب) ROI بعد از مرحله ناحیه‌بندی، (ج) ROI بعد از اصلاح هیستوگرام، (د) تصویر ناحیه‌بندی شده در فرمت باینری و (ه) توده پرشده و آماده استخراج ویژگی‌های شکل.

به این که مرز توده در هر ناحیه‌بندی قدری متفاوت با حالت قبل است، برای به‌دست آوردن مرز نهایی توده، از میانگین‌گیری شعاعی استفاده شده است.

همان‌طور که در شکل ۲ دیده می‌شود، برای استخراج ویژگی‌های  $AGL$  و  $Con$  نیاز به پیش‌پردازش خاصی نبوده و مستقیماً از تصویر ROI بخش‌بندی شده به‌دست می‌آیند. پیش‌پردازش‌های لازم جهت محاسبه ویژگی  $C$  عبارتند از ناحیه‌بندی تصویر ورودی و پرکردن فضای داخل توده. همچنین برای استخراج ویژگی‌های NRL باید بردار NRL با استفاده از تصویر ناحیه‌بندی شده، محاسبه شود [۱۳]. شکل ۳ تصویر یک ROI را در مراحل مختلف پیش‌پردازش نشان می‌دهد.

گشتاورهای زرنیک دسته دیگری از ویژگی‌های مورد استفاده در این تحقیق می‌باشند. این گشتاورها در واقع نگاهی از تصویر به مجموعه‌ای از چندجمله‌ای‌های مختلط زرنیک هستند و از آنجایی که چندجمله‌ای‌های زرنیک نسبت به هم متعامد می‌باشند، می‌توانند ویژگی‌های تصویر را بدون هیچ گونه افزونگی در اطلاعات و یا تداخل اطلاعاتی بین گشتاورها، نشان دهند. نکته مهم قابل ذکر این است که گشتاورهای زرنیک کاملاً مستقل از زاویه چرخش موضوع بوده ولی به شدت وابسته به مقیاس و انتقال شیء در ناحیه مربوطه می‌باشند [۱۴]. بنابراین باید در مرحله پیش‌پردازش این وابستگی‌ها جبران شوند. بدین منظور، ابتدا باید تمامی توده‌ها را در مرکز ناحیه ROI قرار دهیم. بنابراین مرکز ثقل توده را محاسبه [۱۵] و سپس به کمک بردار ذکرشده در (۱)، توده به مرکز ROI انتقال داده می‌شود

$$\vec{v} = (\text{round}(\frac{N}{2}) - c) \vec{c} + (\text{round}(\frac{N}{2}) - r) \vec{r} \quad (1)$$

که در آن زوج مرتب  $(r, c)$  مختصات مرکز ثقل توده می‌باشد. با توجه به این که ابعاد تصاویر  $N \times N$  می‌باشد،  $N/2$  نماینده مرکز ROI بوده و اپراتور round عدد را به نزدیک‌ترین عدد صحیح گرد می‌کند. بدین ترتیب مرکز ثقل توده در مرکز ROI قرار می‌گیرد.

بهترین روش برای حذف اثر وابستگی گشتاورهای زرنیک به مقیاس توده‌ها، استخراج بردار فاصله شعاعی نرمالیزه (NRL) برای توده می‌باشد. در کاربردهای زیادی از بردار NRL به‌عنوان ویژگی توصیف‌کننده مرزهای توده استفاده شده است [۱۳]. شکل ۴ اصول استخراج این بردار را نشان می‌دهد. هر یک از مؤلفه‌های بردار  $d$  عبارت است از فاصله اقلیدسی مرکز

1. Average Gray Level
2. Contrast
3. Circularity
4. Normalized Radial Length

بردار از مبدأ تا نقطه  $(x, y)$  می‌باشد. برای محاسبه توابع پایه زرنیک که دوجدی و مختلط هستند از  $(\delta)$  استفاده می‌شود

$$V_{n,m}(\rho, \theta) = R_{n,m}(\rho)e^{jm\theta} \quad , \quad |\rho| \leq 1 \quad (\delta)$$

نهایتاً گشتاورهای زرنیک با مرتبه  $n$  و تکرار  $m$  طبق  $(\epsilon)$  تعریف می‌شوند

$$Z_{n,m} = \frac{n+1}{\pi} \int_0^{2\pi} \int_0^1 f(\rho, \theta) V_{n,m}^*(\rho, \theta) \rho d\rho d\theta \quad (\epsilon)$$

که در آن  $f(\cdot)$  تابع تصویر است. برای تصاویر دیجیتال، انتگرال‌های  $(\epsilon)$  را می‌توان با عملگر مجموع تعویض کرد. از طرفی مختصات تصویر باید با استفاده از یک نگاشت به بازه  $[0, 1]$  نگاشته شود. حالت گسسته گشتاورهای زرنیک برای یک تصویر با ابعاد  $N \times N$  با استفاده از  $(\gamma)$  به‌دست می‌آید  $[11]$  و  $[17]$

$$\begin{aligned} Z_{n,m} &= \frac{n+1}{\lambda_N} \sum_{c=0}^{N-1} \sum_{r=0}^{N-1} f(c, r) V_{n,m}^*(c, r) \\ &= \frac{n+1}{\lambda_N} \sum_{c=0}^{N-1} \sum_{r=0}^{N-1} f(c, r) R_{n,m}(\rho_{cr}) e^{-jm\theta_{cr}} \end{aligned} \quad (\gamma)$$

که در آن  $\lambda_N$  ضریب نرمالیزه بوده که در حالت گسسته برابر با تعداد پیکسل‌های داخل دایره واحد است.

گشتاورهای زرنیک استفاده‌شده در این مقاله عبارتند از  $Z_0^0$ ،  $Z_1^0$  و  $Z_2^0$ . در شکل ۵ اندازه این گشتاورها در فضای سه‌بعدی نشان داده شده است. گشتاور  $Z_2^0$  قابلیت خوبی در توصیف شکل بیضوی دارد. این گشتاور برای توده‌های با شکل بیضوی که غالباً خوش‌خیم می‌باشند، مقدار بزرگی دارد.

گشتاور  $Z_2^0$  را می‌توان به‌عنوان توصیف‌کننده خوب توده‌های با اشکال نامنظم به کار برد. به عبارتی هر چه شکل توده نامنظم‌تر باشد، مقدار این گشتاور کمتر خواهد بود و در نهایت، هر چه مرز توده نامشخص‌تر باشد، اندازه گشتاور  $Z_2^0$  بزرگ‌تر می‌شود  $[11]$  و  $[18]$ .

### ۴-۲ ویژگی‌های مربوط به مرز توده

ویژگی‌های NRL به‌طور گسترده جهت آسیب‌شناسی در تصاویر ماموگرافی استفاده شده‌اند. این ویژگی‌ها توصیف‌کننده‌های خوبی از مرز توده می‌باشند. در این تحقیق ۵ مورد از مشتقات بردار NRL به‌عنوان ویژگی مورد استفاده قرار گرفته‌اند که عبارتند از میانگین، انحراف معیار، انتروپی، نسبت مساحت و تعداد گذر از صفرها. این ویژگی‌ها را به‌ترتیب می‌توان با استفاده از  $(\alpha)$  تا  $(\epsilon)$  یا محاسبه کرد  $[13]$

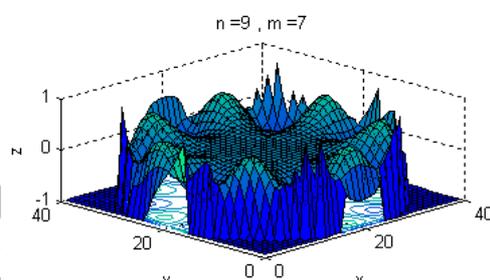
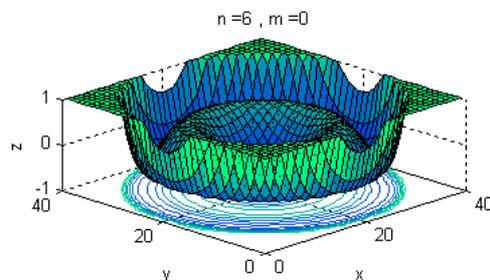
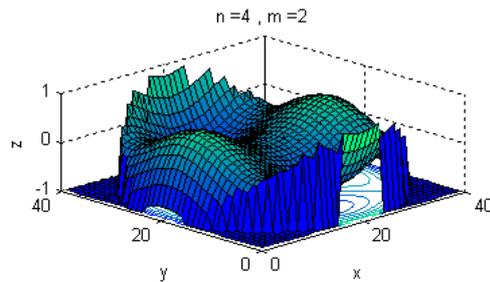
$$NRLm = \mu = \frac{1}{M} \sum_{i=1}^M d(i) \quad (\alpha)$$

$$NRLs = \sqrt{\frac{1}{M} \sum_{i=1}^M (d(i) - \mu)^2} \quad (\beta)$$

$$NRLen = - \sum_{l=1}^{\infty} n(l) \log_2(n(l)) \quad (\gamma)$$

$$NRLar = \begin{cases} \frac{1}{\mu M} \sum_{i=1}^M (d(i) - k) & d(i) > \mu \\ \cdot & \text{otherwise} \end{cases} \quad (\delta)$$

که در آن  $n$  یک عدد صحیح غیر منفی بوده و مرتبه چندجمله‌ای شعاعی نامیده می‌شود.  $m$  یک عدد صحیح است که در شرایط  $|m| \leq n$  و



شکل ۵: اندازه گشتاورهای زرنیک  $Z_2^0$ ،  $Z_1^0$  و  $Z_0^0$  در فضای سه‌بعدی.

### ۴-۱ ویژگی‌های مربوط به شکل توده

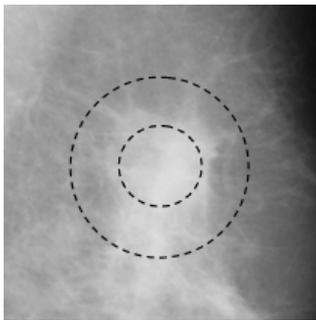
ویژگی C همواره یک ویژگی پرکاربرد برای استخراج اطلاعات موجود در شکل و تعیین میزان مدوربودن توده بوده است  $[4]$ . در این تحقیق از آن به‌عنوان توصیف‌کننده شکل‌های استاندارد معرفی‌شده توسط BI-RADS استفاده می‌کنیم  $[16]$ . این ویژگی طبق  $(3)$  محاسبه می‌شود و در این رابطه  $P$  و  $A$  به‌ترتیب اشاره به محیط و مساحت توده دارند

$$C = \frac{P^2}{A} \quad (3)$$

گشتاورهای زرنیک ویژگی‌های دیگری هستند که جهت توصیف اطلاعات شکل توده‌ها استفاده شده‌اند. این گشتاورها با وجود این که شدیداً وابسته به انتقال و مقیاس‌بندی شیء می‌باشند، اما اندازه آنها کاملاً مستقل از زاویه دوران آن است  $[14]$ . بنابراین از آنها می‌توان برای توصیف اطلاعات موجود در شکل توده‌ها بهره برد و اطمینان داشت که چرخش توده مشکلی در فرایند آسیب‌شناسی ایجاد نمی‌کند. محاسبه گشتاورهای زرنیک از یک تصویر شامل ۳ مرحله است: محاسبه چندجمله‌ای‌های شعاعی، محاسبه توابع پایه زرنیک و محاسبه گشتاورهای زرنیک با استفاده از نگاشت تصویر به فضای توابع پایه زرنیک. چندجمله‌ای‌های شعاعی را می‌توان با استفاده از  $(4)$  محاسبه کرد  $[14]$

$$R_{n,m} = \sum_{s=0}^{(n-|m|)/2} (-1)^s \frac{(n-s)!}{s! \binom{n+|m|}{s} \binom{n-|m|}{s}} \rho^{n-2s} \quad (4)$$

که در آن  $n$  یک عدد صحیح غیر منفی بوده و مرتبه چندجمله‌ای شعاعی نامیده می‌شود.  $m$  یک عدد صحیح است که در شرایط  $|m| \leq n$  و



شکل ۷: ماسک حلقوی مورد نظر برای حذف پیکسل‌های غیر مفید ROI.

و  $q$  هستند. ماسک سوم حاصل از ترکیب این دو ماسک بوده و ماسک مختلط و یا  $H(x, y)$  نامیده می‌شود. این ماسک در شکل ۶-ج قابل مشاهده است و با استفاده از رابطه زیر می‌توان آن را به‌دست آورد

$$H(x, y) = T(x, y) \& R(x, y) \quad (17)$$

لازم به ذکر است ماسک شعاعی و ماسک مماسی به‌ترتیب شکل ساده‌ای از توده‌های با مرز سوزنی و توده‌های با مرز محدود می‌باشند. بنابراین با فیلترکردن ناحیه ROI توسط این دو ماسک، اطلاعات مفیدی از میزان سوزنی بودن و محدودبودن مرز توده به‌دست می‌آید. ماسک مختلط را می‌توان شکل ساده‌شده‌ای از تمام مرزهای احتمالی توده‌ها دانست.

هر یک از این سه ماسک بر تصویر ROI پیش پردازش شده، اعمال می‌شوند. سپس میزان همسانی تصویر حاصل از ماسک مختلط را یک بار با تصویر حاصل از اعمال ماسک مماسی و بار دیگر با تصویر حاصل از اعمال ماسک شعاعی محاسبه می‌کنیم. با توجه به این که تمامی پیکسل‌های این تصاویر حاوی اطلاعات مفید نبوده و تنها حجم محاسباتی را افزایش می‌دهند، تنها پیکسل‌هایی را مورد توجه قرار می‌دهیم که در نقاط مرزی توده قرار گرفته‌اند. برای به‌دست آوردن این پیکسل‌های مرزی، از یک ماسک حلقوی استفاده می‌کنیم که در شکل ۷ نشان داده شده است.

برای محاسبه همسانی بین دو تصویر از (۱۸) استفاده می‌شود [۱۹]

$$S(f, g) = \frac{1}{\lambda} \sqrt{\sum_{x=0}^{N-1} \sum_{y=0}^{N-1} (f(x, y) - g(x, y))^2} \quad (18)$$

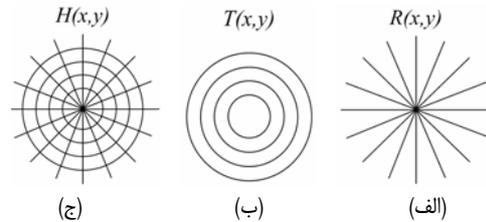
به‌طوری که  $S(f, g)$  بیانگر میزان همسانی تصاویر  $f$  و  $g$  است.  $\lambda$  ضریب نرمالیزه و  $N$  بیانگر ابعاد تصاویر می‌باشد. در نهایت، ویژگی SPI به‌صورت زیر محاسبه می‌شود

$$SPI = \frac{S(H, R)}{S(H, T)} \quad (19)$$

که در آن پارامترهای  $S(H, R)$  و  $S(H, T)$  به‌ترتیب میزان همسانی تصویر حاصل از اعمال ماسک مختلط با تصاویر حاصل از اعمال ماسک شعاعی و مماسی را نشان می‌دهند. در صورتی که توده مرز سوزنی‌تری داشته باشد، ویژگی SPI مقدار بزرگ‌تری خواهد داشت. بنابراین این ویژگی می‌تواند معیار مناسبی جهت سنجش میزان غیر مشخص بودن مرز توده باشد.

### ۴-۳ ویژگی‌های مربوط به چگالی توده

در این تحقیق از ویژگی‌های میانگین سطح خاکستری (AGL) و کنتراست (Con)، به‌عنوان توصیف‌گرهای چگالی توده استفاده شده است.



شکل ۶: (الف) ماسک شعاعی، (ب) ماسک مماسی و (ج) ماسک مختلط.

$d(i)$  و  $d(i) + 0.1d(i)$  باشد را نشان می‌دهد.  $n(l)$  با استفاده از یک هیستوگرام نرمالیزه محاسبه می‌شود. تعداد گذر از صفرها عبارت است از تعداد برخوردهای بردار NRL با مقدار متوسط آن. در شکل ۴-ب این موضوع نشان داده شده است. در این مقاله تعریف کامل‌تری از تعداد گذر از صفرها ارائه می‌شود؛ تعداد گذر از صفرها عبارت است از تعداد برخوردهای بردار NRL با مقدار متوسط آن، در نقاطی که نمودار NRL صعودی مطلق و یا نزولی مطلق باشد. با این کار تعداد پاسخ‌های مثبت کاذب کاهش داده می‌شود. این ویژگی طبق (۱۲) محاسبه می‌شود

$$NRL_{zcc} = \sum zc \quad (12)$$

$$zc \in \{[(d(i) < \mu) \& (d(i+1) > \mu) \& (d(i+2) > \mu)] \text{ or } [(d(i) > \mu) \& (d(i+1) < \mu) \& (d(i+2) < \mu)]\}$$

ویژگی جدید SPI، میزان سوزنی شکل بودن مرز توده را مشخص می‌کند و به همین دلیل نام SPI به آن اختصاص داده شده است. عملکرد این ویژگی وابسته به عملکرد الگوریتم ناحیه‌بندی نمی‌باشد، چرا که مستقیماً از تصویر سطح خاکستری توده که قبلاً پیش‌پردازش‌های لازم روی آن انجام شده، استخراج می‌شود. جهت استخراج این ویژگی سه ماسک مناسب تعریف شده‌اند. ماسک اول متشکل از تعدادی خطوط شعاعی است که به‌طور متقارن در کنار یکدیگر قرار گرفته‌اند. این ماسک شعاعی را  $R(x, y)$  نامیده و در شکل ۶-الف نشان داده‌ایم. برای به‌دست آوردن این ماسک می‌توان از (۱۳) و (۱۴) استفاده کرد

$$R_b(x, y) = \begin{cases} 1, & y = b(x - \frac{N}{2}) + \frac{N}{2} \\ 0, & \text{otherwise} \end{cases} \quad (13)$$

$$R(x, y) = \bigcup_p R_b(x, y) \quad (14)$$

که در این روابط  $b$  شیب خط و  $N$  ابعاد ماسک می‌باشند و همچنین  $p$  مشخص‌کننده تعداد خطوط شعاعی است. لازم به ذکر است که  $N$  و  $p$  درجه‌های آزادی این ماسک بوده و به‌گونه‌ای انتخاب می‌شوند که ویژگی مورد نظر بهترین عملکرد را داشته باشد. ماسک دوم که در شکل ۶-ب نشان داده شده است، شامل تعدادی دایره هم‌مرکز به مختصات مرکز ماسک می‌باشد. این ماسک مماسی،  $T(x, y)$  نامیده شده و به کمک (۱۵) و (۱۶) به‌دست می‌آید

$$T_a(x, y) = \begin{cases} 1, & (x - \frac{N}{2})^2 + (y - \frac{N}{2})^2 = a^2 \\ 0, & \text{otherwise} \end{cases} \quad (15)$$

$$T(x, y) = \bigcup_q T_a(x, y) \quad (16)$$

$$\forall a = 0.5 + \frac{N/2 - 0.5}{q}, 1.5 + \frac{N/2 - 0.5}{q}, \dots, \frac{N}{2} - 0.5$$

که در این روابط  $a$  شعاع دایره است و همچنین پارامتر  $q$  تعداد دایره‌های هم‌مرکز درون ماسک را مشخص می‌کند. درجه‌های آزادی این ماسک  $N$  و  $q$  هستند. ماسک سوم حاصل از ترکیب این دو ماسک  $N$

$f(\bar{x})$  محاسبه می‌شوند. اگر  $g(f(x)) \geq g(f(\bar{x}))$  باشد، یادگیری با مقدار  $x$  و در غیر این صورت با  $\bar{x}$  ادامه می‌یابد [۸]. به عبارتی دیگر، یادگیری با پاسخی ادامه می‌یابد که از شایستگی بالاتری برخوردار و به پاسخ بهینه نزدیک‌تر باشد.

در [۶] از مفهوم وزن‌های متضاد جهت بهبود سرعت همگرایی شبکه عصبی با الگوریتم یادگیری resilient back propagation استفاده شده است. در این تحقیق جهت بهبود سرعت همگرایی الگوریتم BP از مفهوم وزن‌های متضاد برای ساخت شبکه متضاد استفاده می‌شود. منظور از شبکه متضاد، شبکه‌ای است که کاملاً با شبکه اصلی یکسان است اما تمام وزن‌های متضاد وزن‌های شبکه اصلی هستند.

در شکل ۸ مراحل اصلی پیاده‌سازی الگوریتم OWBP در هر دوره یادگیری آمده است. همان طور که دیده می‌شود، در هر دوره یادگیری، دو شبکه متضاد (شبکه اصلی (N) و شبکه متضادش (ON)) طبق یادگیری متداول BP آموزش می‌بینند. در انتهای دوره یادگیری، خطای جمعی  $SSE^2$  [۲۱]، برای هر دو شبکه N و ON محاسبه می‌شود. شبکه‌ای که خطای کمتری داشته باشد و به عبارتی به هدف نزدیک‌تر باشد، به عنوان شبکه برتر انتخاب و وزن‌های آن ذخیره می‌شوند. این شبکه برتر در دوره بعدی یادگیری به عنوان شبکه اصلی استفاده می‌شود و وزن‌های شبکه متضاد به کمک وزن‌های شبکه برتر و با استفاده از (۲۱) محاسبه می‌شوند. وزن‌های متضاد در شکل ۸ با نام OW نشان داده شده‌اند.

$$\bar{w}_{k,ij}^l = \frac{2}{L} \times \left( \sum_{n=k-L+1}^k n w_{n,ij}^l \right) \times w_{k,ij}^l \quad (21)$$

که در آن  $w_{k,ij}^l$  وزن بین گره  $i$  ام در لایه  $l-1$  و گره  $j$  ام در لایه  $l$  مربوط به شبکه برنده در دوره یادگیری  $k$  می‌باشد. همچنین  $L$  بیانگر تعداد شبکه‌های برنده‌ای است که تا کنون وزن‌های آنها ذخیره شده است. در اینجا  $L=3$  انتخاب شده است، به عبارت دیگر وزن‌های سه شبکه برنده در بافر ذخیره می‌گردد. اگر  $k < L$  باشد، فرض می‌شود وزن‌های ذخیره شده صفر می‌باشند.

قابل ذکر است که در این مقاله برای ارزیابی شایستگی یادگیری شبکه‌ها از تابع محاسبه خطای SSE استفاده می‌کنیم. برای درک بهتر و شبیه‌سازی الگوریتم پیشنهادی می‌توان مراحل ذکر شده در جدول ۲ را دنبال کرد.

## ۶- نتایج شبیه‌سازی

همان طور که می‌دانیم معیار سنجش عملکرد سیستم‌های CADx، درصد پاسخ‌های منفی کاذب (FNR)، درصد پاسخ‌های مثبت کاذب (FPR) و همچنین منحنی ROC است که مساحت زیر نمودار آن (Az)، توانایی کلاسه‌بندی صحیح آسیب‌ها را نشان می‌دهد [۲۲]. پاسخ منفی کاذب (FNR)<sup>۳</sup> می‌تواند باعث مرگ بیمار شود، در حالی که پاسخ مثبت کاذب (FPR)<sup>۴</sup> منجر به نمونه‌برداری بیهوده خواهد شد [۲]. بنابراین در درجه اول باید سیستم به گونه‌ای طراحی شود که FNR کمی داشته باشد. همان طور که اشاره شد در بخش کلاسه‌بندی، به منظور ارزیابی قابلیت آسیب‌شناسی هر دسته از ویژگی‌های شکل، مرز و چگالی، هر گروه از این ویژگی‌ها و همچنین ترکیب آنها را به شبکه عصبی MLP با یادگیری BP اعمال می‌کنیم و عملکرد سیستم‌های حاصل ارزیابی می‌شود. سیستم‌های

ویژگی کنتراست از اختلاف میانگین سطح خاکستری توده (ویژگی AGL) با میانگین سطح خاکستری بافت نرمال نوار اطراف مرز توده به دست می‌آید [۴] و به خوبی قابلیت توصیف چگالی‌های مختلف تعریف شده توسط استاندارد BI-RADS را داراست.

## ۵- کلاسه‌بندی

شبکه‌های عصبی مصنوعی به عنوان یک کلاسه‌بندی کننده خوب، همواره در آسیب‌شناسی تصاویر ماموگرافی کاربرد داشته‌اند که شامل آسیب‌شناسی میکروکلسیفیکیشن‌ها، یافتن خوشه‌های میکروکلسیفیکیشن، آسیب‌شناسی توده‌ها و یافتن توده‌های مشکوک بوده است [۲۰]. در این تحقیق مرحله کلاسه‌بندی شامل دو بخش است: در بخش اول عملکرد آسیب‌شناسی هر یک از گروه ویژگی‌های شکل، مرز، چگالی و همچنین ترکیب همه آنها به طور جداگانه به کمک شبکه عصبی MLP با یادگیری BP متداول ارزیابی می‌شود. در بخش دوم به کمک کلاسه‌بندی کننده با یادگیری BP و کلاسه‌بندی کننده OWBP عملکرد آسیب‌شناسی ترکیب ۱۲ ویژگی بررسی خواهد شد و سیستم‌های حاصل از لحاظ سرعت یادگیری و پارامترهای آسیب‌شناسی مقایسه می‌شوند. ساختار شبکه‌های در نظر گرفته شده بدین صورت است که همواره در لایه اول، تعداد گره‌ها برابر با تعداد ویژگی‌های استفاده شده است و در لایه آخر تنها یک گره وجود دارد که مقدار این گره به ازای توده‌های بدخیم ۱ و برای توده‌های خوش‌خیم ۰ است. همچنین تعداد لایه‌های مخفی و گره‌های آنها آن قدر تغییر داده می‌شود تا بهترین ساختار که سرعت یادگیری مطلوب و مقدار FNR<sup>۱</sup> کمی دارد، یافت شود. در ادامه ابتدا یادگیری مبتنی بر تضاد و کلاسه‌بندی کننده OWBP تشریح خواهند شد.

## ۱-۵ کلاسه‌بندی کننده OWBP

یادگیری در بسیاری از الگوریتم‌های محاسبات نرم به طور کلی کند است، چرا که معمولاً یادگیری از حالتی تصادفی و با مقدارهای اولیه تصادفی آغاز می‌شود، مانند مقدارگذاری اولیه وزن‌ها در شبکه عصبی، جمعیت اولیه در الگوریتم‌های تکاملی مانند الگوریتم بهینه‌سازی مورچگان، الگوریتم تجمع‌ی پرندگان، الگوریتم ژنتیک و دیگر الگوریتم‌های تکاملی مشابه. اگر این پاسخ تصادفی از پاسخ بهینه دور نباشد یادگیری می‌تواند با سرعت بالاتری همگرا شود. اما اگر از پاسخ بهینه بسیار دور یا به عبارتی در موقعیتی متضاد باشد، یادگیری بسیار کند خواهد شد و در بدترین حالت ممکن است واگرا شود. بدیهی است در حالتی که شناخت اولیه‌ای نسبت به مسأله و فضای پاسخ نیست، امکان این که پاسخ تصادفی اولیه به پاسخ بهینه نزدیک باشد بسیار ضعیف است. بنابراین بهترین راه حل، جستجوی تمام فضای پاسخ یا به عبارت بهتر جستجو در جهت‌های متضاد و به طور هم‌زمان است.

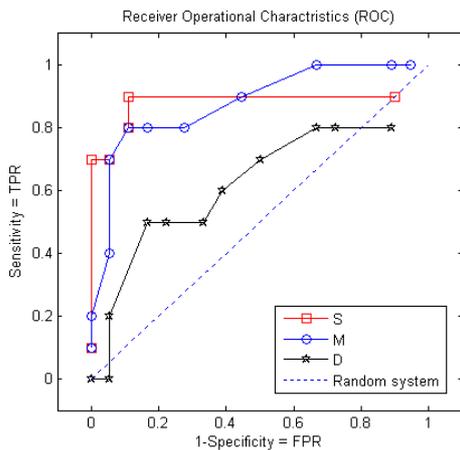
اگر ما دنبال پاسخ  $x$  مسأله باشیم و بپذیریم که جستجو در جهت مخالف می‌تواند مفید باشد، باید هم‌زمان اثر پاسخ تصادفی  $x$  و متضادش،  $\bar{x}$  را بررسی کنیم. اگر  $p(x_1, x_2, \dots, x_n)$  نقطه‌ای با مختصات  $n$  بعد باشد، مختصات نقطه متضادش طبق (۲۰) محاسبه می‌شود [۶]

$$x_i \in R, x_i \in [a_i, b_i] \Rightarrow \bar{x}_i = a_i + b_i - x_i, \quad i = 1, \dots, n \quad (20)$$

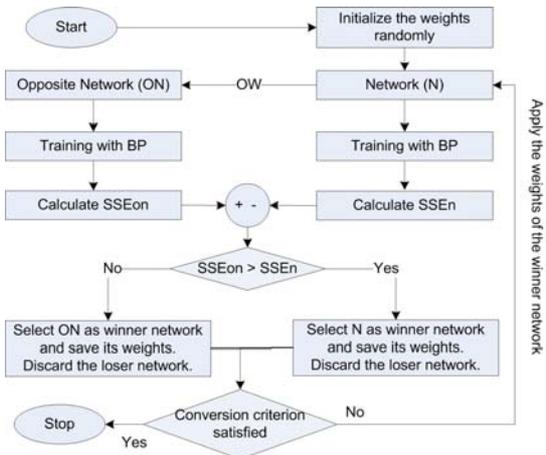
در یادگیری مبتنی بر تضاد، اگر تابع تحت بررسی  $f(x)$  و تابع ارزیابی شایستگی  $g(\cdot)$  باشد، در هر تکرار یادگیری، دو مقدار  $f(x)$  و

2. Sum Squared Error
3. False Negative Rate
4. False Positive Rate

1. False Negative Rate



شکل ۹: منحنی ROC برای سیستم‌های S، M و D.



شکل ۸: بلوک دیاگرام مراحل اصلی الگوریتم OWBP در هر دوره یادگیری.

جدول ۲: تشریح مراحل اصلی شبیه‌سازی الگوریتم OWBP.

مرحله	تشریح مراحل
۱	انتخاب وزن‌های تصادفی برای شبکه اصلی (N) مد نظر.
۲	تشکیل شبکه متضاد (ON)، وزن‌های متضاد به کمک (۲۰) محاسبه می‌شوند.
۳	شبکه اصلی و شبکه متضاد به کمک الگوریتم BP آموزش می‌بینند.
۴	برای هر دو شبکه، خطای جمعی SSE محاسبه می‌شود.
۵	شبکه‌ای که خطای جمعی کمتری دارد، به‌عنوان شبکه برتر انتخاب می‌شود و وزن‌های آن ذخیره می‌شوند.
۶	وزن‌های متضاد را به کمک آخرین $m$ وزن ذخیره‌شده و طبق (۲۱) محاسبه می‌کنیم.
۷	اگر شرایط همگرایی فراهم شده باشند، یادگیری متوقف می‌شود و در غیر این صورت وزن‌های جدید ذخیره‌شده و وزن‌های متضاد حساب‌شده، به‌ترتیب به شبکه N و شبکه ON اعمال شده و به مرحله ۳ برای ادامه یادگیری می‌رویم.

جدول ۳: عملکرد آسيب‌شناسی هر یک از سیستم‌های S، M، D و T.

Name	Selected features	FPR	FNR	Accuracy	Az
S	Shape features	%۱۱٫۱	%۹٫۹	%۸۹٫۳	۰٫۸۰۵
M	Margin features	%۵٫۶	%۲۹	%۸۵٫۷	۰٫۸۷۵
D	Density features	%۱۶٫۶	%۵۱	%۷۱٫۴	۰٫۶۱۷
T	All of ۱۲ features	%۰٫۱	%۹٫۸	%۹۶٫۴	۰٫۹۲۵

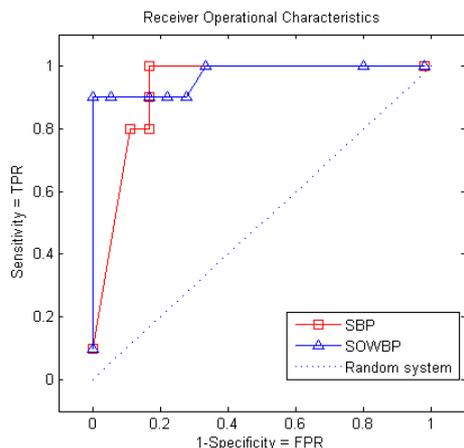
جدول ۴: میانگین نتایج ارزیابی سیستم‌های دارای کلاس‌بندی کننده‌های BP و OWBP.

Net	FPRm	FNRm	Accm	Azm	CEm	BP/OWBP
BP	%۱۸٫۰۹	%۱۱٫۹۶	%۸۴٫۷۷	۰٫۸۵۴	۱۳۰۶۰	NA
OWBP	%۱۷٫۹۴	%۱۶٫۹	%۸۹٫۲۸	۰٫۸۹۷	۳۱۶۷	۴٫۱۲۴

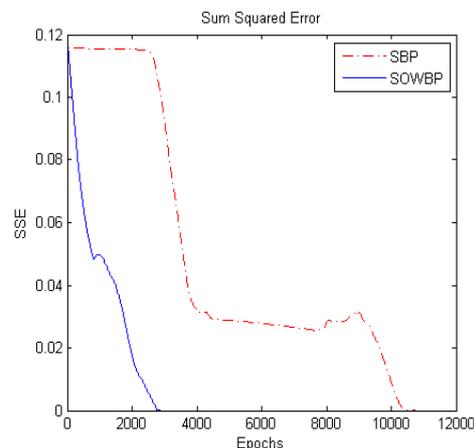
می‌باشد. به عبارتی برای داشتن سیستم قابل اطمینان و با عملکرد آسيب‌شناسی مطلوب باید از تمام گروه ویژگی‌های شکل، مرز و چگالی برای توصیف اطلاعات توده استفاده کرد تا سیستم حاصل به خوبی قابلیت تفکیک توده‌های خوش‌خیم از توده‌های بدخیم را داشته باشد. در مرحله بعدی، ترکیب تمام ویژگی‌های پیشنهادی به کلاس‌بندی کننده‌های MLP با یادگیری OWBP و BP اعمال می‌شود و سرعت همگرایی یادگیری هر یک از سیستم‌ها و عملکرد آسيب‌شناسی آنها با هم مقایسه می‌گردد. بدین منظور شبکه‌های عصبی با ساختارهای مختلف و پارامترهای متفاوت یادگیری، ۱۱۰ بار بررسی شده‌اند و در جدول ۴ میانگین این بررسی‌ها گزارش شده است. سطر اول مربوط به میانگین نتایج کلاس‌بندی کننده‌های با یادگیری BP می‌باشد و سطر دوم نتایج کلاس‌بندی کننده‌های با یادگیری OWBP را نشان می‌دهد.

در این جدول FPRm، FNRm، Accm و Azm به‌ترتیب نشان‌دهنده مقادیر میانگین پارامترهای FPR، FNR، Az و عملکرد حاصل از تمام

S، M و D به‌ترتیب شامل ویژگی‌های توصیف‌کننده شکل، مرز و چگالی توده‌ها می‌باشند. در جدول ۳ پارامترهای آسيب‌شناسی هر یک از این سیستم‌ها نشان داده شده است. همچنین شکل ۹ منحنی ROC این سه سیستم را نشان می‌دهد. همان‌طور که دیده می‌شود سیستم‌های S و M نسبت به سیستم D منحنی ROC بهتر و Az بزرگ‌تری دارند. سیستم D که تنها از ویژگی‌های Con و AGL استفاده می‌کند دارای میزان خطای FNR بالایی است و در حالت کلی قابلیت آسيب‌شناسی خوبی ندارد. به‌عبارتی اگرچه دو ویژگی Con و AGL به‌طور گسترده در بسیاری از سیستم‌های آسيب‌شناسی استفاده می‌شوند، اما به تنهایی نمی‌توانند توصیف‌کننده‌های مناسبی از توده‌ها باشند و قابلیت آسيب‌شناسی خوبی به سیستم نمی‌دهند و در صورت ترکیب با دیگر ویژگی‌ها می‌توانند مفید باشند. همچنین دیده می‌شود سیستم T که از ترکیب تمام ویژگی‌ها استفاده می‌کند، دارای بالاترین مقدار Az و بهترین عملکرد آسيب‌شناسی با میزان خطای صفر برای FPR و همچنین مقدار %۹٫۸ برای FNR



شکل ۱۱: منحنی ROC سیستم‌های SBP و SOWBP.



شکل ۱۰: خطای همگرایی یادگیری دو سیستم SBP و SOWBP.

جدول ۵: ارزیابی سریع‌ترین سیستم‌های حاصل از کلاسه‌بندی کننده‌های BP و OWBP.

System	FPR	FNR	Accuracy	Az	CE	BP/OWBP
SBP	٪۱۱٫۱۱	٪۹٫۸	٪۸۹٫۲۸	۰٫۸۹	۱۰۳۸۸	NA
SOWBP	٪۵٫۶	٪۹٫۸	٪۹۲٫۸۶	۰٫۹۲۴	۲۸۱۵	۳٫۶۹

جدول ۶: مقایسه عملکرد سیستم پیشنهادی با دیگر سیستم‌های CADX موجود.

Reference	Year	Features	Classifier	Database	Accuracy	Az
This Research (SOWBP)	۲۰۱۰	All of 12 features	OWBP	MIAS	٪۹۲٫۸۶	۰٫۹۲۴
This Research (SBP)	۲۰۱۰	All of 12 features	Standard MLP classifier	MIAS	٪۸۹٫۲۸	۰٫۸۹
Tahmasbi <i>et al.</i> [۲۳]	۲۰۱۰	FTRD features	Standard MLP classifier	MIAS	٪۹۲٫۸	۰٫۹۸
Verma <i>et al.</i> [۲۰]	۲۰۱۰	Density, patient age, subtlety value, abnormality assessment rank, mass shape and margin	Standard MLP classifier	DDSM	٪۸۸٫۷۵	-
Verma <i>et al.</i> [۲۰]	۲۰۱۰	Density, patient age, subtlety value, abnormality assessment rank, mass shape and margin	SCBDL classifier	DDSM	٪۹۷٫۵	-
Abdalla <i>et al.</i> [۲۴]	۲۰۰۷	Texture features (SGLD matrix)	SVM classifier	DDSM	٪۸۲٫۵	-
Manrique <i>et al.</i> [۲۵]	۲۰۰۶	Size of mass, morphology of the mass, margins and density	GARBFN classifier	DDSM	٪۸۳	-
Mudigond <i>et al.</i> [۲۶]	۲۰۰۰	Texture features	Jack-knife classifier	MIAS	٪۸۲٫۱	۰٫۸۵

الگوریتم‌ها آورده شده است. سیستم SBP و SOWBP به ترتیب مربوط به سیستم‌های دارای کلاسه‌بندی کننده‌های BP و OWBP می‌باشند. همان‌طور که دیده می‌شود، نه تنها زمان یادگیری سیستم SOWBP سریع‌تر از سیستم SBP است، بلکه تمام پارامترهای آسیب‌شناسی آن نیز بهتر می‌باشند. در شکل ۱۰ خطای همگرایی یادگیری این دو سیستم نشان داده شده است. همچنین در شکل ۱۱ منحنی ROC هر دو سیستم نشان داده شده است. همان‌طور که دیده می‌شود مساحت زیر نمودار ROC سیستم SOWBP نسبت به سیستم SBP بیشتر می‌باشد و بسیار سریع‌تر به همگرایی مطلوب رسیده است.

در جدول ۶ مقایسه‌ای بین عملکرد آسیب‌شناسی سیستم پیشنهادی و دیگر سیستم‌های موجود صورت گرفته است. در این جدول سیستم SOWBP و SBP از لحاظ پارامترهای آسیب‌شناسی با دیگر سیستم‌ها مقایسه می‌شوند، همچنین پایگاه داده و روش استفاده‌شده در هر سیستم آورده شده است. همان‌طور که دیده می‌شود سیستم‌های پیشنهادی با وجود این که از ویژگی‌های با محاسبات ساده استفاده می‌کند، اما از قابلیت آسیب‌شناسی مطلوبی برخوردار بوده و در بین سیستم‌های اشاره‌شده، در جایگاه دوم قرار دارد. متأسفانه معیاری جهت مقایسه سرعت یادگیری سیستم پیشنهادی SOWBP و سیستم‌های مذکور موجود نمی‌باشد.

بررسی‌های صورت گرفته شده می‌باشند. از طرفی پارامتر CEM بیانگر شماره دوره‌ای است که به‌طور میانگین سیستم‌های پیاده‌شده، در آن همگرا شده‌اند. لازم به ذکر است یادگیری سیستم‌ها تا زمانی ادامه می‌یابد که خطای جمعی SSE کمتر از  $10^{-5}$  گردد. در صورت عدم تحقق این میزان خطا، یادگیری بعد از ۱۶۰۰۰ دوره متوقف می‌شود. در ستون آخر جدول نیز نسبت متوسط دوره همگرایی الگوریتم OWBP به الگوریتم BP نشان داده شده است. از این پارامتر می‌توان برای ارزیابی میزان سرعت نسبی دو الگوریتم استفاده کرد. همان‌طور که دیده می‌شود به‌طور متوسط سیستم‌های دارای کلاسه‌بندی کننده OWBP چهار برابر سریع‌تر از سیستم‌های دارای کلاسه‌بندی کننده BP به همگرایی مطلوب رسیده‌اند. به‌طور متوسط، به‌جز نرخ FNR دیگر پارامترهای آسیب‌شناسی سیستم‌های با کلاسه‌بندی کننده OWBP نسبت به BP بهتر می‌باشند. نکته قابل ذکر این است که حجم محاسباتی الگوریتم یادگیری پیشنهادی تقریباً دو برابر الگوریتم رایج BP می‌باشد، با این وجود سرعت یادگیری آن بیش از چهار برابر سرعت یادگیری BP است. بنابراین می‌توان از اثر افزایش حجم محاسباتی صرف نظر کرده و از الگوریتم پیشنهادی با اطمینان از سرعت همگرایی بالا و عملکرد مطلوب، در سیستم‌های آسیب‌شناسی توده‌ها استفاده کرد. به‌عنوان تأکیدی بیشتر بر این مطلب در جدول ۵ نتایج عملکرد سریع‌ترین سیستم‌های حاصل توسط هر یک از

- [13] L. M. Bruce and R. R. Adhami, "Classifying mammographic mass shapes using the wavelet transform modulus-maxima method," *IEEE Trans. on Medical Imaging*, vol. 18, no. 12, pp. 1170-1177, Dec. 1999.
- [14] W. Wang, J. E. Mottershead, and C. Mares, "Mode-shape recognition and finite element model updating using the zernike moment descriptor," *J. of Mechanical Systems and Signal Processing*, vol. 23, no. 7, pp. 2088-2112, Oct. 2009.
- [15] W. K. Pratt, *Digital Image Processing: PIKS Inside*, 3rd Edition, John Wiley & Sons, Ch. 18, 2001.
- [16] C. Balleyguier et al., "BIRADSTM classification in mammography," *European J. of Radiology*, vol. 61, no. 2, pp. 192-194, Feb. 2007.
- [17] A. Tahmasbi, F. Saki, and S. B. Shokouhi, "An effective breast mass diagnosis system using Zernike moments," in *Proc. 17th Iranian Conf. on Biomedical Engineering, ICBME'2010*, 4 pp., Isfahan, Iran, 2010.
- [18] A. Tahmasbi, F. Saki, H. Aghapanah, and S. B. Shokouhi, "A novel breast mass diagnosis system based on Zernike moments as shape and density descriptors," in *Proc. 18th Iranian Conf. on Biomedical Engineering, ICBME'2011*, pp. 100-104, Tehran, Iran, 2011.
- [19] K. V. Augustine and H. Dongjun, "Image similarity for rotation invariants image retrieval system," in *Proc. of the IEEE, Int. Conf. on Multimedia Computing and System, ICMCS'09*, pp. 133-137, 2-4 Apr. 2009.
- [20] B. Verma, P. McLeod, and A. Klevansky, "Classification of benign and malignant patterns in digital mammograms for the diagnosis of breast cancer," *J. of Expert Systems with Application*, vol. 37, no. 4, pp. 3344-3351, Apr. 2010.
- [21] F. O. Karray and C. de Silva, *Soft Computing and Intelligent Systems Design*, Pearson Education Limited, 2004.
- [22] J. Bozek, M. Mustra, K. Delac, and M. Grgic, "A survey of image processing algorithms in digital mammography," in *Recent Advances in Multimedia Signal Processing and Communication*, vol. 231, pp. 631-657, Oct. 2009.
- [23] A. Tahmasbi, F. Saki, and S. B. Shokouhi, "Mass diagnosis in mammography images using novel FTRD features," in *Proc. of the IEEE, 17th Iranian Conf. on Biomedical Engineering, ICBME'2010, Isfahan, Iran*, 5 pp., 3-4 Nov. 2010.
- [24] A. M. Abdalla et al., "Breast cancer detection based on statistical textural features classification," in *Proc. of the IEEE, 4th Int. Conf. on Innovations in Information Technology*, pp. 728-730, 18-20 Nov. 2007.
- [25] D. Manrique, J. Rios, and A. Rodriguez-Paton, "Evolutionary system for automatically constructing and adapting radial basis function networks," *J. of Neurocomputing*, vol. 69, no. 4, pp. 2268-2283, Apr. 2006.
- [26] N. R. Mudigonda, R. M. Rangayyan, and J. E. L. Desautels, "Gradient and texture analysis for the classification of mammographic masses," *IEEE Trans. on Medical Imaging*, vol. 19, no. 10, pp. 1032-1043, Oct. 2000.

**فاطمه ساکی** تحصیلات خود را در مقاطع کارشناسی و کارشناسی ارشد مهندسی برق - الکترونیک به ترتیب در سال‌های ۱۳۸۷ و ۱۳۸۹ از دانشگاه شهید چمران اهواز و دانشگاه علم و صنعت ایران به پایان رسانده است. او هم اکنون دانشجوی دکتری در گروه برق دانشگاه تگزاس - دالاس امریکا می‌باشد. زمینه‌های تحقیقاتی مورد علاقه ایشان عبارتند از: پردازش سیگنال‌های دیجیتال، پردازش تصویر، پردازش تصاویر پزشکی مانند ماموگرافی و چند طیفی در زمینه سرطان پوست و سینه می‌باشد.

**امیر طهماسبی** تحصیلات خود را در مقاطع کارشناسی و کارشناسی ارشد مهندسی برق - الکترونیک به ترتیب در سال‌های ۱۳۸۷ و ۱۳۸۹ از دانشگاه صنعتی شیراز و دانشگاه علم و صنعت ایران به پایان رسانده است. او هم اکنون دانشجوی دکتری در گروه برق دانشگاه تگزاس - دالاس امریکا می‌باشد. همچنین نام‌برده در آزمایشگاه ایمنولوژی در مرکز تحقیقات پزشکی دانشگاه تگزاس مشغول به تحقیق می‌باشد. زمینه‌های مورد علاقه ایشان عبارتند از: پردازش آماری سیگنال‌ها، پردازش تصاویر و سیگنال‌های دیجیتال، پردازش تصاویر پزشکی در کاربردهای میکروسکوپی فلورسانس، مکان‌یابی تک مولکولی، پردازش زمان واقعی سیگنال‌ها بر روی TMS320C6xxx.

**شهریار برادران شکوهی** مقطع کارشناسی و کارشناسی ارشد خود را در مهندسی برق به ترتیب در سال‌های ۱۳۶۵ و ۱۳۶۸ در دانشگاه علم و صنعت ایران به پایان رساند و در سال ۱۳۷۸ دکتری خود را از دانشگاه بٹ انگلستان دریافت نمود. هم اکنون ایشان عضو هیأت علمی دانشکده برق دانشگاه علم و صنعت ایران است. پردازش تصویر، پردازش سیگنال، بنیای ماشین، الگوشناسی و طراحی سیستم‌های هوشمند از زمینه‌های مورد علاقه ایشان می‌باشند.

## ۷- نتیجه‌گیری

در این تحقیق سیستم CADx نوینی جهت آسيب‌شناسي توده‌ها در تصاویر ماموگرافي معرفی شده است. در این سیستم از کلاسه‌بندی مبتنی بر تضاد OWBP و ویژگی‌های منطبق بر استاندارد BI - RADS استفاده می‌شود. این ویژگی‌ها متناسب با گروه‌بندی تعریف‌شده توسط استاندارد BI - RADS جهت توصیف اطلاعات توده‌ها، انتخاب شده‌اند و به‌خوبی قابلیت توصیف اطلاعات شکل، مرز و چگالی توده‌ها را دارند. از طرفی در این تحقیق دو ویژگی SpI و NRLzcc برای توصیف مشخصات مرز توده برای اولین بار مورد استفاده قرار گرفته‌اند. در تحقیق صورت‌گرفته، عملکرد آسيب‌شناسي هر یک از گروه ویژگی‌های شکل، مرز، چگالی و ترکیب همه آنها به‌طور جداگانه به کمک کلاسه‌بندی کننده MLP با یادگیری BP ارزیابی شده است. همان‌طور که دیده شد سیستم‌هایی که از ترکیب تمام ویژگی‌ها استفاده می‌کنند، عملکرد بهتری دارند. همچنین ترکیب تمام ویژگی‌ها به دو کلاسه‌بندی کننده BP و OWBP اعمال شده و سیستم‌های حاصل از لحاظ سرعت همگرایی و پارامترهای آسيب‌شناسي مقایسه شده‌اند. جهت اطمینان از پایداری روش پیشنهادی، این بررسی‌ها بیش از ۱۰۰ بار تکرار شده و نتایج نشان داده است که سیستم پیشنهادی با کلاسه‌بندی کننده OWBP به‌طور متوسط ۴ برابر سریع‌تر از سیستم‌های با کلاسه‌بندی کننده BP به همگرایی مطلوب رسیده و قابلیت آسيب‌شناسي بهتری را نیز دارا می‌باشند. علاوه بر آن دیده شد که سریع‌ترین سیستم حاصل توسط کلاسه‌بندی کننده OWBP نسبت به دیگر سیستم‌های مقایسه‌شده از قابلیت آسيب‌شناسي مطلوبی برخوردار است و با سرعت مناسب همگرا می‌شود.

## مراجع

- [1] American Cancer Society, *Breast Cancer Facts & Figures 2009-2010*, Atlanta, 2009.
- [2] A. C. Bovik, *Handbook of Image and Video Processing*, 2nd ed., Elsevier Academic Press, pp. 1195-1217, 2005.
- [3] R. M. Rangayyan, F. J. Ayres, and J. E. L. Desautels, "A review of computer aided diagnosis of breast cancer: toward the detection of subtle signs," *J. of the Franklin Institute*, vol. 344, no. 3-4, pp. 312-348, May/Jul. 2007.
- [4] H. D. Cheng, X. J. Shi, R. Min, L. M. Hu, X. P. Cai, and H. N. Du, "Approaches for automated detection and classification of masses in mammograms," *J. of Pattern Recognition*, vol. 39, no. 4, pp. 646-668, 2006.
- [5] American College of Radiology, *ACR BI-RADS-Mammography, Ultrasound & Magnetic Resonance Imaging*, 4th ed., American College of Radiology, Reston, VA, 2003.
- [6] H. R. Tizhoosh, "Opposition-based learning: a new scheme for machine intelligence," in *Proc. of the IEEE, International Conf. on Computational Intelligence for Modeling, Control, and Automation*, vol. 1, pp. 695-701, Vienna, Austria, 2005.
- [7] M. Ventreca and H. R. Tizhoosh, "Improving the convergence of back propagation by opposite transfer function," in *Proc. of Int. Joint Conf. on Neural Networks*, pp. 4777-4784, 2006.
- [8] H. R. Tizhoosh and M. Ventresca, *Oppositional Concepts in Computational Intelligence*, Springer, 2008.
- [9] F. Saki, A. Tahmasbi, and S. B. Shokouhi, "A novel opposition-based classifier for mass diagnosis in mammography images," in *Proc. of the IEEE, 17th Iranian Conf. on Biomedical Eng. ICBME'2010*, 4 pp., Isfahan, Iran, 3-4 Nov. 2010.
- [10] X. Zhang, X. Gao, and Y. Wang, "MCs detection with combined image features and twin support vector machines," *J. of Computers*, vol. 4, no. 3, pp. 215-221, Mar. 2009.
- [11] A. Tahmasbi, F. Saki, and S. B. Shokouhi, "Classification of benign and malignant masses based on zernike moments," *J. of Computers in Biology and Medicine*, vol. 41, no. 8, pp. 726-735, 2010.
- [12] J. Suckling et al., "The mammographic image analysis society digital mammogram database," *Exerpta Medical, Int. Congress Series 1069*, pp. 375-378, 1994.