

## خوشه بندی و غربالگری سرطان پستان بر اساس تصاویر حرارتی با استفاده از ترکیب شبکه‌ی عصبی SOM و MLP

حسین قیومی زاده: دانشجو دکتری مهندسی پزشکی دانشگاه حکیم سبزواری

علی دروگر مقدم: دانشجوی کارشناسی ارشد مهندسی پزشکی، دانشگاه حکیم سبزواری و عضو مرکز تحقیقات فناوری های نوین پزشکی دانشگاه علوم پزشکی سبزواری

جواد حدادنیا: دانشیار گروه مهندسی پزشکی دانشگاه حکیم سبزواری و عضو مرکز تحقیقات فناوری های نوین پزشکی دانشگاه علوم پزشکی سبزواری

محمد محمد زاده: استادیار فیزیولوژی، مرکز تحقیقات سلولی - مولکولی و گروه فیزیولوژی - دانشگاه علوم پزشکی سبزواری

### چکیده

**مقدمه:** سرطان پستان یکی از شایع ترین سرطان ها بین بانوان می باشد. با توجه به اهمیت غربالگری سرطان پستان و نقش آن در شناسایی به موقع بیماران و همچنین کاهش هزینه‌های درمان، جزو اولویت های بهداشتی یک کشور قرار می گیرد. تصویربرداری حرارتی به دلیل سرعت عملکرد در تشخیص و عدم تابش پرتو مضر می تواند در این مرحله از جایگاه ویژه ای برخوردار می باشد.

**موارد و روش ها:** در روش ارائه شده سعی شده است از هوش مصنوعی در جهت شناسایی و غربالگری سرطان پستان استفاده شود تا خطای احتمالی ناشی از تشخیص پزشک تا حد امکان کاهش یابد. به همین منظور ابتدا به کمک شبکه های عصبی خودسازمان ده به خوشه بندی یک تصویر حرارتی که از بیمار گرفته شده است می پردازیم سپس نواحی مشکوک را از تصویر جداسازی می نماییم نتیجه این مرحله را به الگوریتمی شبیه الگوریتم ابتدایی اما با مشخصات متفاوت اعمال مینماییم تا ویژگی های تشخیصی برای غربالگری استخراج شود این ویژگی ها در نهایت به شبکه های عصبی MLP داده خواهد شد تا فرایند غربالگری به اتمام برسد.

**نتایج:** تعداد تصاویری که برای این تحقیق در جهت آزمایش در نظر گرفته شده است شامل دو پایگاه ۲۰۰ نفری و یک پایگاه ۵۰ نفری از بیماران بوده است که در مورد اول ۱۵ نفر و در مورد دوم ۴ نفر سرطانی بوسیله ماموگرافی تشخیص داده شده اند. نتایج حاصل از روش در پایگاه اول حساسیت ۹۳٪ و در پایگاه دوم ۱۰۰٪ را نشان می دهد.

**بحث و نتیجه گیری:** نتایج این تحقیق بیانگر آن است که تصاویر حرارتی به کمک روش ارائه شده که مبتنی بر هوش مصنوعی می باشد می تواند در غربالگری سرطان پستان به دلیل عدم تابش پرتو مضر از جایگاه ویژه ای برخوردار باشد. همیشه مواردی وجود دارد که پزشک نمی تواند با قاطعیت بگوید که الگوی مشاهده شده در عکس خوش خیم یا بدخیم است در این موارد پاسخ مدل کامپیوتری می تواند راهنمای بسیار خوبی برای پزشک باشد تا او بتواند با تکیه بر پاسخ مدل کامپیوتری با صراحت بیشتری نسبت به نوع الگوی تصویر برداری اظهار نظر نماید.

**کلمات کلیدی:** غربالگری سرطان پستان، شبکه های عصبی خود سازمان یافته، شبکه های عصبی MLP.

## مقدمه

غربالگری سرطان سینه و نقش آن در شناسایی به موقع بیماران و کاهش هزینه‌های درمان، بر هیچ شخصی پنهان نمی باشد. غربالگری بیماری‌های مختلف از جمله سرطان سینه علاوه بر موضوعات اخلاقی و معنوی ناشی از نجات جان یک نفر، حتی به لحاظ مالی نیز برای اقتصاد بهداشت یک جامعه به صرفه است؛ چرا که اگر بیماری مانند سرطان سینه در مراحل ابتدایی تشخیص داده شود احتمالاً نیازی به شیمی درمانی و تحمیل هزینه بالای داروهای نظیر هرستین نخواهد داشت. سرطان پستان شایع ترین نوع سرطان بین خانم‌ها می باشد که حدود ۳۰ درصد از آنها را شامل می شود (۱).

در طول سال‌های ۲۰۰۳-۲۰۰۷، متوسط سن مرگ و میر ناشی از سرطان پستان ۶۸ سال بوده است. تقریباً ۰،۰٪، ۰،۹٪، ۶،۰٪، ۱۵،۰٪، ۲۰،۸٪، ۱۹،۷٪، ۲۲،۶٪ و ۱۵،۱٪ درصد مرگ و میر در بین گروه‌های سنی به ترتیب زیر ۲۰ سال، ۲۰-۳۴، ۳۵-۴۴، ۴۵-۵۴، ۵۵-۶۴، ۶۵-۷۴، ۷۵-۸۴ و بالاتر از ۸۵ سال رخ داده است (۲). گزارش ارایه شده نشان می دهد که ۰٪، ۳۵-۴۴، ۴۵-۵۴، ۵۵-۶۴، ۶۵-۷۴، ۷۵-۸۴ و بالاتر از ۸۵ سال امکان تشخیص پذیر بوده است در زیر سن ۲۰ سال، در حالی که به ترتیب ۱،۹٪، ۲،۱۰٪، ۶،۲۲٪، ۴،۲۴٪، ۷،۱۹٪، ۵،۱۵٪ و ۵،۶٪ در تشخیص‌ها در داخل گروه‌های سنی ۲۰-۳۴، ۳۴-۴۴، ۴۵-۵۴، ۵۵-۶۴، ۶۵-۷۴، ۷۵-۸۴ و بالاتر از ۸۵ سال امکان پذیر بوده است (۲). مطالعات نشان می دهد که، تشخیص زود هنگام می تواند منجر به ۸۵ درصد شانس بقا شود (۳). تشخیص به موقع سرطان پستان یکی از مهمترین مسائلی بوده است که محققان همیشه در پی آن بوده اند.

با توجه به هزینه‌های بالای درمان و گسترش بیماری بین بانوان، شناسایی به موقع این عارضه، گام مهمی در کاهش عوارض اجتماعی و سلامتی جامعه خواهد بود (۴). بنابراین، تشخیص زودرس سرطان سینه عامل کلیدی برای موفقیت و درمان می باشد. در سال ۱۹۸۲، اداره مواد غذایی و دارویی ایالات متحده آمریکا FDA روش تصویر برداری به کمک دوربین حرارتی را به عنوان یک ابزار کمکی برای تشخیص پستان مورد تایید قرار داد.

تصویر برداری مادون قرمز یک روش تصویر برداری غیرتهاجمی است که به عنوان یک ابزار تشخیصی به کار می رود. منشأ اصلی اشعه‌های مادون قرمز گرمای برخاسته از بدن‌های مختلف است که دمای آنها از صفر مطلق بیشتر است. بنابراین، ترموگرام از یک بیمار توزیع گرما در بدن را فراهم می کند. با توجه به نسبت‌های متابولیسمی بالا و پیشرفت عروق angiogenesis سلول‌های سرطانی نسبت به سلول‌های طبیعی اطرافشان، دمای بیشتری دارند. بنابراین، می توان در تصاویر مادون قرمز، سلول‌های سرطانی را به صورت کانون‌های بحرانی نشان داد (۵-۶). در (۷) کندی و همکاران، به مطالعه تکنیک IRT<sup>۲</sup> و دیگر تصویر برداری‌ها برای غربالگری پستان پرداختند و به این نتیجه رسیدند که IRT اطلاعات کارکردی بیشتری از شرایط حرارتی و عروقی بافت‌ها ارایه می دهد. در (۱۰) پوکر یک بررسی عالی از IRT به عنوان یک روش غیر تهاجمی در تومور شناسی پستان ارائه می دهد. که او به توصیف روش اصلی، شیوه‌های استاندارد، ضبط تصویر و تجزیه و تحلیل تصاویر می پردازد. تحقیقات صورت پذیرفته حتی در حوزه میکروسکوپی در زمینه سرطان پستان نیز صورت گرفته که در (۱۱) به تصویر برداری میکروسکوپی حرارتی از بافت تومور پرداخته و به تجزیه و تحلیل آن می پردازند. در (۱۲) نویسنده با کمک منطق فازی توانسته است به تشخیص سرطان پستان در تصاویر حرارتی بپردازد که دارای حساسیت ۷۶ درصد است. در (۱۳) محققان به بررسی نتایج بالینی و ماموگرافی و تصویر برداری حرارتی در پایگاه خود پرداخته به صورتی که حساسیت به شناسایی توسط

۱ Food and Drug Administration

۲ InfraRed Thermography

روش بالینی ۶۱٪، ماموگرافی ۶۶٪ و تصویر برداری حرارتی ۸۳٪ درصد می باشد نکته قابل توجه در این تحقیق این می باشد که با ترکیب روش ماموگرافی و تصویر برداری حرارتی حساسیت به ۹۵٪ افزایش می یابد.

خوشه بندی عبارت است از فرآیند طبقه بندی مجموعه داده های موجود به خوشه های مختلف بطوریکه داده های دارای ویژگی های مشترک در یک خوشه قرار گیرند. الگوریتم های خوشه بندی سعی دارند در خوشه بندی سعی می شود تا داده ها به خوشه هایی تقسیم شوند که شباهت بین داده های درون هر خوشه حداکثر و شباهت بین داده های درون خوشه های متفاوت حداقل شود (۸).

در روش ارایه شده سعی شده است از هوش مصنوعی در جهت شناسایی و غربالگری سرطان پستان استفاده شود تا خطای احتمالی ناشی از تشخیص پزشک تا حد امکان کاهش یابد. به همین منظور ابتدا از به کمک شبکه های عصبی خودسازمان ده به خوشه بندی یک تصویر حرارتی که از بیمار گرفته شده است می پردازیم سپس نواحی مشکوک را از تصویر جداسازی می نماییم نتیجه این مرحله را به الگوریتمی شبیه الگوریتم ابتدایی اما با مشخصات متفاوت اعمال مینمایم تا ویژگی های تشخیصی برای غربالگری فراهم شود این ویژگی ها در نهایت به شبکه های عصبی MLP داده خواهد شد تا فرایند غربالگری به نتیجه برسد. اطلاعات لازم برای این پژوهش از یک تحقیق عملی در شهر سبزوار در دانشگاه حکیم سبزواری و با همکاری دانشگاه علوم پزشکی سبزوار به دست آمده است. این تحقیق روی اطلاعات جمع آوری شده از تصاویر حرارتی که شامل دو پایگاه ۲۰۰ نفری و ۵۰ نفری ارایه شده است.

### پردازش تصویر

برای تشخیص سرطان به روش حرارتی لازم است که عملیاتی بر روی تصاویر صورت پذیرد که در ادامه به طور جامع بر روی آنها بحث خواهد شد. در طبقه بندی هر داده به یک طبقه (کلاس) از پیشین مشخص شده تخصیص می یابد ولی در خوشه بندی هیچ اطلاعی از کلاس های موجود درون داده ها وجود ندارد و به عبارتی خود خوشه ها نیز از داده ها استخراج می شوند (۹). الگوریتم های خوشه بندی به سه گروه تقسیم بندی می گردند: سلسله مراتبی، تقسیمی هم پوشانی، در یادگیری با نظارت از ابتدا دسته ها مشخص هستند و هر یک از داده های آموزشی به دسته ای خاص نسبت داده شده است و اصطلاحاً گفته می شود نظارت وجود دارد که در هنگام آموزش اطلاعاتی علاوه بر داده های آموزش در اختیار یادگیرنده (Learner) قرار می دهد. ولی در یادگیری بدون نظارت هیچ اطلاعاتی بجز داده های آموزشی در اختیار یادگیرنده قرار ندارد و این یادگیرنده است که بایستی در داده ها به دنبال ساختاری خاص بگردد. به جهتی که خواستیم روش ارایه شده در بیشتر تصاویر قابل پاسخ باشد پس از روش غیر نظارت شده، کمک گرفته شده است. بهره گیری از پردازش اولیه SOM بر روی مجموعه داده های اولیه است که منجر به کاهش ابعاد، دسته بندی مجدد و مصورسازی داده ها می شود. در شبکه ی خودسازمان ده، از روش یادگیری رقابتی برای آموزش استفاده می شود و مبتنی بر مشخصه های خاصی از مغز انسان توسعه یافته است. سلولها در مغز انسان در نواحی مختلف طوری سازمان دهی شده اند که در نواحی حسی مختلف، با نقشه های محاسباتی مرتب و معنی دار ارائه می شوند. برای نمونه، ورودیهای حسی لامسه - شنوایی و ... با یک ترتیب هندسی معنی دار به نواحی مختلف مرتبط هستند (۱۴). در یک شبکه ی خود سازمان ده واحد های پردازش گر در گره های یک شبکه ی یک بعدی، دو بعدی یا بیشتر قرار داده می شوند. واحد ها در یک فرآیند یادگیری رقابتی نسبت به الگوهای ورودی منظم می شوند. محل واحدهای تنظیم شده در شبکه به گونه ای نظم می یابد که برای ویژگیهای ورودی، یک دستگاه مختصات معنی دار روی شبکه ایجاد شود. لذا یک نقشه ی خود سازمان ده، یک نقشه ی توپوگرافیک از الگوهای ورودی را تشکیل می دهد که در آن، محل قرار گرفتن واحدها، متناظر ویژگیهای ذاتی الگوهای ورودی است. یادگیری رقابتی که در این قبیل شبکه ها بکار گرفته می شود

بدین صورت است که در هر قدم یادگیری، واحدها برای فعال شدن با یکدیگر به رقابت می پردازند، در پایان یک مرحله رقابت تنها یک واحد برنده می شود، که وزنه‌های آن نسبت به وزنه‌های سایر واحدها به شکل متفاوتی تغییر داده می شود. این نوع از یادگیری را یادگیری بی نظارت می نامند. نقشه خودسازماندهی SOM، یک شبکه عصبی بدون نظارت است که از نورون‌های عصبی در یک ساختار گرید منظم با ابعاد پایین تشکیل شده است. هر نورون دارای یک بردار وزن  $n$  بعدی است که در آن  $n$  برابر با ابعاد بردارهای ورودی است. بردارهای وزن (سیناپس‌ها) لایه ورودی را به لایه خروجی (که نقشه یا لایه رقابتی نامیده می شود) متصل می کنند (۱۵). نورون‌ها توسط یک تابع همسایگی به یکدیگر متصل شده اند. هر بردار ورودی، بر اساس بیشترین شباهت، نورونی در لایه خروجی را که سلول برنده خوانده می شود، فعال می کند. شباهت معمولاً بر اساس فاصله اقلیدسی بین دو بردار اندازه گیری می شود. (رابطه ۱)

$$(۱) D_j = \sum_{i=1}^n \|w_{i,j} - x_i\|^2$$


که در آن  $x_i$ ،  $i$  امین بردار ورودی بوده،  $w_{i,j}$  بردار وزنی است که ورودی  $i$  را به نورون خروجی  $j$  متصل می کند و  $D_j$  حاصل جمع فاصله اقلیدسی بین نمونه ورودی  $x_i$  و بردار وزن ارتباطی آن به  $j$  امین سلول خروجی است که یک واحد نقشه نامیده می شود. مهمترین تفاوت الگوریتم آموزشی SOM با سایر الگوریتم‌های اندازه گیری برداری این است که علاوه بر وزن ارتباطی واحد دارای بیشترین انطباق (سلول عصبی برنده)، وزن‌های سلول‌های همسایه سلول برنده نیز به روزرسانی می شوند. مشاهدات نزدیک به هم در فضای ورودی، دو واحد نزدیک به هم در نقشه را فعال می سازند. مرحله آموزش تا زمانی که بردارهای وزن به حالت پایداری برسند و دیگر تغییر نکنند، ادامه می یابد. (رابطه ۲)

$$(۲) w_{i,j}^{new} = w_{i,j}^{old} + h_{i,j}(x_i - w_{i,j}^{old})$$

که  $x_i$  نمونه ورودی،  $w_{i,j}^{old}$  بردار وزن قبلی بین بردار ورودی  $x_i$  و بردار وزن ارتباطی به سلول عصبی خروجی  $j$  است.  $h_{i,j}$  تابع همسایگی و  $w_{i,j}^{new}$  بردار وزن به روزرسانی شده بین سلول ورودی  $i$  و سلول خروجی  $j$  است.

### پیش پردازش اطاعات

داده های که برای کلاستر بندی نمودن یک تصویر حرارتی وارد شبکه عصبی می نماییم شامل ۵ فاکتور می باشد. اگر شدت روشنایی پیکسل های تصویر حرارتی مانند تصویر ۱،  $f(x,y)$  باشد به نوعی  $x, y$  موقعیت مکانی پیکسل هارا تشکیل دهند  $g$  را می تواند طبق رابطه ۳ به عنوان ورودی وارد شبکه SOM نماییم.



شکل ۱- تصویر حرارتی گرفته شده از بیمار که بنا بر اختلاف دمای سطحی بدن دارای رنگ های متفاوتی از R,G,B می باشد.

$$(۳) \quad G = \begin{bmatrix} \overrightarrow{W1 * X_i} \\ \overrightarrow{W2 * Y_j} \\ \overrightarrow{W3 * R_{I,J}} \\ \overrightarrow{W4 * G_{I,J}} \\ \overrightarrow{W5 * B_{I,J}} \end{bmatrix}$$

$\overrightarrow{R_{I,J}}$  و  $\overrightarrow{G_{I,J}}$  و  $\overrightarrow{B_{I,J}}$  نیز شدت روشنایی پیکسل مورد نظر در سه بعدی رنگی می باشد.  $\overrightarrow{X_i}$  موقعیت پیکسل در جهت عمودی و  $\overrightarrow{Y_j}$  موقعیت در جهت افقی می باشد اما این نکته قابل ذکر می باشد که این دو موقعیت با توجه به سایز تصاویر حرارتی متغیر می باشند پس بهتر است نرمالیزه گردند. برای نرمال کردن داده ها با توجه به ماتریس کواریانس حاصل متوجه خواهیم شد که داده ها ارتباط مستقیمی با یکدیگر نخواهند داشت پس برای نرمالیزه کردن داده ها می توان از رابطه ۴ استفاده نمود:

$$(۴) \quad \hat{x} = \frac{x_i - \mu}{\sigma}$$

$\mu$  و  $\sigma$  میانگین و انحراف معیار هر بعد از داده ها می باشد  $W$  ها مقادیر وزن هایی است که به هر بعد از داده ها می دهیم نکته قابل توجه این می باشد که چون در تشخیص سرطان به نواحی قرمز تمرکز ما معطوف خواهد شد پس بایستی در شبکه عصبی به داده های  $R_{I,J}$  وزن بیشتری دهیم، پس رنگ های قرمز بایستی وزن بیشتری داشته باشند (۱۶). در این شبکه ها فرض می شود که سیگنال های ورودی  $n$  تایی در  $m$  خوشه قرار میگیرند و خوشه ها دارای آرایش یک بعدی یا دو بعدی منظم هستند. بردار وزن برای هر خوشه، بردار نمونه الگوهای ورودی پیوند یافته با آن خوشه می باشد. در کاربرد مورد نظر ما، آموزش از طریق کمینه کردن فاصله اقلیدسی بین نمونه های ورودی و نمونه های اولیه نقشه که توسط تابع همسایگی  $h_{i,j}$  وزن دهی می شوند، انجام می گیرد. بنابراین، معیاری که باید کمینه شود به صورت زیر تعریف می شود (۱۷):

$$(۵) \quad E_{SOM} = \frac{1}{N} \sum_{k=1}^N \sum_{j=1}^M h_{j,N(x^{(k)})} \|w_j - x^{(k)}\|^2$$

که در رابطه فوق،  $N$  تعداد نمونه‌های داده،  $M$  تعداد واحدهای نقشه،  $N(X_k)$  سلول عصبی با نزدیک‌ترین فاصله نسبت به نمونه داده  $N(X_k)$  است و  $h$  تابع همسایگی گوسی است که به صورت رابطه (۶) تعریف می‌شود:

$$(۶) \quad h_{ij}(t) = \exp\left(-\frac{\|r_j - r_i\|^2}{2\sigma_t^2}\right)$$

که در آن  $\|r_j - r_i\|^2$  فاصله بین واحد نقشه  $j$  و نمونه ورودی  $i$  بوده و  $\sigma_t$  شعاع همسایگی در زمان  $t$  است که به صورت زیر تعریف می‌شود:

$$(۷) \quad \sigma(t) = \sigma_0 \exp\left(-\frac{t}{T}\right)$$

که  $t$  شماره تکرار آموزش،  $T$  حداکثر تعداد تکرار یا طول آموزش است. فاصله بین  $X_k$  و بردارهای وزن همه سلول‌های عصبی نقشه محاسبه می‌شوند. سلول  $N(X_k)$  که کمترین فاصله را با نمونه ورودی  $X_k$  داشته باشد، در مرحله رقابت، برنده خواهد شد:

$$(۸) \quad N(X_k) = \arg_{1 < j < m} \min \|W_j - X_k\|^2$$

شعاع همسایگی در شروع، مقدار بزرگی است و با افزایش زمان الگوریتم آموزش، در هر بار تکرار، کاهش می‌یابد. بعد از مرحله رقابت، SOM باید بردار وزن سلول برنده  $N(X_k)$  و همه سلول‌های همسایه آن را که در شعاع همسایگی  $R^{N(X_k)}$  قرار گرفته‌اند را به روزرسانی کند. اگر  $W_j \in RN(X_k)$  آنگاه:

$$w_j(t+1) = w_j(t) + \alpha(t) h_{j,N(x_k)}(t) (x(t) - w_j(t)) \quad (۹)$$

در غیر این صورت:


$$(۱۰) \quad w_j(t+1) = w_j(t)$$

که در روابط بالا،  $h_{j,N(x_k)}(t)$  تابع همسایگی در زمان  $t$  و  $\alpha(t)$  عامل خطی آموزش در زمان  $t$  است که به صورت زیر تعریف می‌شود:


$$(۱۱) \quad \alpha(t) = \alpha_0 \exp\left(-\frac{t}{T}\right)$$

در رابطه فوق  $\alpha_0$  نرخ اولیه آموزش،  $t$  شماره تکرار الگوریتم آموزش و  $T$  حداکثر تکرار یا طول آموزش است. مرحله آموزش تا زمان پایداری بردارهای وزن تکرار می‌شود یعنی تا زمانی که دیگر تغییری در وزن ورودی‌ها دیده نشود. بعد از مرحله آموزش، شبکه عصبی نقشه خودسازماندهی، قادر خواهد بود  $n$  نمونه داده را در قالب  $m$  واحد نقشه (خوشه)، خوشه‌بندی کند.

اگر یک نمونه تصویر را وارد شبکه SOM نماییم و خروجی شبکه را نمایش دهیم به صورت شکل ۲ خواهد بود.



(الف)




(ب)

(ج)

شکل ۲-الف) تصویر اولیه حرارتی از فرد بیمار که دارای نواحی قرمز و مشکوک می باشد اما فرد دارای سرطان نمی باشد. (ب) جداسازی اولیه نواحی مشکوک توسط SOM. (ج) تطابق و هم ارز نمودن تصویر اولیه حرارتی با تصویر جداسازی شده توسط SOM همراه با ایجاد بزرگنمایی تصویری


### جداسازی نواحی سرطانی

با دقت و بررسی در نواحی جداسازی شده توسط SOM متوجه خواهیم شد برخی از نواحی دارای حرارت بالایی می باشندمانند نواحی شاهرگ گردن ، اما طبیعتاً این امر عادی می باشد پس روشی که در این مرحله به نظر می رسد جداسازی دوباره این نواحی می باشد. روش و ایده ای که برای حل این مسئله مطرح می شود این است که از شبکه خود سازمان ده استفاده نماییم اما این بار به این صورت که مرکز هر ناحیه جداسازی شده را استخراج نماییم تا نواحی از یکدیگر تفکیک شوند تا در مرحله تشخیص بتوانیم با توجه به مراکز جداسازی شده به تشخیص بپردازیم. توپولوژی شبکه SOM که این بار برای استفاده شده است از نوع grid می باشد تعداد نوروں های که برای این شبکه در نظر گرفته شده است به صورت ماتریسی ۲ در ۱ می باشد. اگر مراکز کلاس های تصاویر حرارتی مختلف را به دست آوریم مانند شکل ۳ و ۴ به نکاتی پی خواهیم برد در نمونه شکل ۳ که فرد غیر سرطانی می باشد مراکز کلاس های که توسط شبکه عصبی خودسازمان ده ایجاد شده در نواحی شاهرگ می باشد.




شکل ۳- مراکز کلاس های جداسازی شده شبکه SOM در نمونه غیر سرطانی که این مراکز در ناحیه شاهرگ قرار دارد

در نمونه سرطانی (شکل ۴) که مراکز کلاس قرار گرفته در ناحیه پستان صورت پذیرفته پس این مراکز کلاس می تواند به عنوان یک ویژگی مهم در تفکیک فرد سرطانی از فرد غیر سرطانی انتخاب گردد.



شکل ۴- مراکز کلاس های جداسازی شده شبکه SOM در نمونه سرطانی که این مراکز در ناحیه پستان ایجاد شده است .

اگر تمام تصاویر را در این فرایند قرار دهیم و تمام مراکز کلاس هایی که از تصاویر به دست می آید رسم نماییم تصویری ما شکل ۵ به دست خواهیم آورد. که با دقت در شکل متوجه می شویم چهار مرکز کلاس در ناحیه جدا از مراکز هایی که غیرسرطانی می باشند ایجاد شده اند.



شکل ۵- رسم تمام مراکز کلاس هایی که از طریق شبکه عصبی خود سازمان ده خوشه بندی شده است .



## غربالگری

در مرحله قبل ویژگی هایی که استخراج شد یعنی مراکز کلاس ها می تواند به عنوان ویژگی برای شناسایی استفاده گردد. حال می توانیم از این ویژگی ها برای شناسایی استفاده نماییم. برای این کار از شبکه عصبی  $mlp$  کمک می گیریم. علت اینکه از ابتدا از  $mlp$  استفاده نکردیم به خاطر حجم زیاد داده ها بود که وارد شبکه های عصبی می شد و می توانستیم از  $svm$  هم به عنوان جداساز کننده دو کلاس استفاده نماییم. از نقطه نظر بیوانفورماتیک باید هر کاهش بعدی دارای  $7$  شاخص مهم باشد: ۱- ویژگی های بدون اطلاعات تفکیک کننده (ویژگی های نامناسب) را دور بریزد. ۲- ویژگی های افزونه را دور بریزد. ۳- حتی الامکان ماهیت داده ها را حفظ کند. ۴- حتی الامکان ضریب کاهش بالایی داشته باشد. ۵- حتی الامکان پارامترهای کاربرگین نداشته باشد. ۶- منتج به بهبود اساسی در نرخ شناسایی، حساسیت یا قطعیت آزمایشات غربالگری شود. ۷- در همه الگوریتم ها، تحمیل حداقل هزینه محاسباتی برای افزایش سرعت و دقت محاسبات مطلوب است.

در استفاده از شبکه عصبی  $mlp$  ما تصاویری که از قبل بوسیله ماموگرافی می دانیم کدامیک سرطانی و کدامیک غیرسرطانی می باشد توسط مراحل قبل مراکز کلاس هایشان را جداسازی نموده سپس به عنوان آموزش وارد شبکه عصبی  $mlp$  می نماییم. سپس برای تست و نتیجه گیری آموزش چند تصویر را وارد شبکه می نماییم و نتایج حاصله را مورد بررسی قرار می دهیم.

در این پروژه ما از یک شبکه  $3$  لایه پیش خور با تابع فعالیت سیگموئید در لایه ورودی و میانی و تابع خطی برای لایه خروجی استفاده نمودیم. تعداد نورون های لایه ورودی این شبکه برابر دو ( مراکز کلاس های  $som$ ) در نظر گرفته شده است. تعداد نورون های لایه میانی  $3$  در نظر گرفته شده است. انتخاب تعداد نورونهای لایه میانی بسیار مهم است چراکه اگر تعداد آنها کم باشد شبکه برای حل مسایل غیر خطی و پیچیده با کمبود منابع یادگیری مواجه می شود و اگر زیاد باشد خود باعث ایجاد دو مشکل خواهد شد. اول آنکه زمان آموزش شبکه افزایش می یابد و دوم آنکه ممکن است شبکه نظام بی اهمیت داده های آموزش را یاد بگیرد و در حل مسایل ضعیف عمل نماید (۱۸).

در این پروژه برای آموزش شبکه از نوع خاصی از الگوریتم پس انتشار خطا استفاده شده است. در این روش ماتریس های وزنی شبکه به گونه ای تغییر می یابند تا مقدار متوسط مربعات خطای شبکه ( $mse$ ) از مقدار خاصی که در برنامه مشخص می شود ( $0/02$ ) کمتر شود. خروجی مطلوب شبکه در واقع همان نتایج ماموگرافی نمونه های می باشند. در این روش خطا به روش خاص لایه به لایه، به عقب برگشت داده می شود و در هر لایه اطلاعات لازم روی وزن ها انجام می گیرد. این روند آنقدر ادامه می یابد تا خطای خروجی کل به سمت مقدار کمینه ای به نام  $error\ goal$  همگرا شود و یا تعداد دفعات تکرار با تعداد دفعات حداکثر از قبل تعیین شده برابر شود.

در این مرحله از شبکه عصبی ما  $70\%$  از داده ها را برای آموزش و  $15\%$  برای داده های  $validation$  و  $15\%$  داده ها را برای تست و نتیجه گیری در نظر گرفتیم.

---

1 Support vector machine

2 Mean squared error

## آزمایشات

برای ارزیابی مدل از دو پایگاه ایجاد شده کمک گرفتیم که یکی شامل ۵۰ نمونه و دیگری شامل ۲۰۰ نمونه بود. علت انجام این کار خصوصیات و ویژگی‌هایی بود که در ۲ پایگاه متفاوت بوده است. در پایگاه اول روش عکس برداری با رعایت تمام استانداردهای لازم اعمال شده است اما در پایگاه دوم شرایط سخت گیرانه اعمال نشده است. معیارهای ما برای ارزیابی مدل میزان دقت، حساسیت و ویژگی تشخیصی و همچنین سطح زیر منحنی ROC<sup>۱</sup> برای این پایگاه می‌باشد. نتایج حاصل از پایگاه اول و دوم در جدول ۱ قابل مشاهده می‌باشد.

جدول ۱- نتایج به دست آمده از حساسیت و ویژگی در دو پایگاه داده تصاویر حرارتی


	پایگاه اول	پایگاه دوم
TN	۱۸۱	۴
TP	۱۴	۴۶
FN	۴	۰
FP	۱	۰
SEN	%۹۳	%۱۰۰
SPE	%۹۷	%۱۰۰

از آنجا که حساسیت، ویژگی و دقت، تا حد زیادی وابسته به جمعیت بیماران غالب است و از این رو ممکن است نتوانیم به درستی و به صورت دقیق کارایی شبکه و ماموگرافی را با یکدیگر مقایسه نماییم، لذا از تحلیل منحنی‌های ROC برای ارزیابی کارایی مدل در مقایسه با آنچه که از ماموگرافی بدست آمده استفاده شد. تحلیل ROC شکلی از یک اندازه‌گیری است که عمدتاً برای مقایسه کارایی روش‌های تشخیصی بکار می‌رود. در تحلیل ROC، کارایی تشخیص بر حسب دو شاخص ارزیابی می‌شود: ۱- کسر مثبت درست (TPF<sup>۲</sup>) - ۲- کسر مثبت نادرست (FPF<sup>۳</sup>). کسر اول به عنوان کسری از موارد بدخیم که به درستی تشخیص داده شده‌اند (مثل حساسیت) و کسر دوم به عنوان کسری از موارد خوش‌خیم که به اشتباه بدخیم تشخیص داد شده‌اند. منحنی ROC را می‌توان در شکل ۶ مشاهده نمود.

<sup>۱</sup> Receiver operating characteristic

<sup>۲</sup> True Positive Fraction

<sup>۳</sup> False Positive Fraction



شکل ۶ - منحنی ROC مدل شبکه عصبی MLP

#### بحث

علیرغم اینکه سرطان پستان بیماری جدیدی نیست، وقوع سرطان پستان در زنان در دهه های اخیر، به طور بی سابقه ای در سراسر جهان افزایش یافته است، در صورتی که به موقع تشخیص داده شود به راحتی قابل درمان می باشد. در تحقیقات گذشته روش های مختلف هوشمندانه شده ای در جهت تحقق یک مدل ریاضی برای طبقه بندی الگوهای سرطانی انجام گرفته است. اما تا کنون هیچ مدلی نتوانسته است به طور دقیق تمام الگوهای سرطانی را طبقه بندی نماید، و به عبارتی سعی در بهبود روش های قبلی گام نهاده اند.

در اهمیت به کارگیری مدل های کامپیوتری دلایل می توان برشمرد مانند: ۱- مدل کامپیوتری هزینه تشخیص بیماری را به نحو فوق العاده ای کاهش می دهد. ۲- همیشه مواردی وجود دارد که پزشک نمی تواند با قاطعیت بگوید که الگوی مشاهده شده در عکس خوش خیم یا بدخیم است در این موارد پاسخ مدل کامپیوتری می تواند راهنمای بسیار خوبی برای پزشک باشد تا او بتواند با تکیه بر پاسخ مدل کامپیوتری با صراحت بیشتری نسبت به نوع الگوی تصویر برداری اظهار نظر نماید. در این میان شبکه های عصبی مصنوعی همواره به دلیل توانایی در شبیه سازی توابع غیرخطی و پیچیده و قدرت تعمیم و قابلیت گسترش آنها، همواره مورد توجه محققین روش های CAD بوده است.

در روش ارائه شده برای طبقه بندی سعی شده است از روش نوین تصویر برداری حرارتی برای بالابردن قدرت تشخیص و همچنین افزایش دقت طبقه بندی گام برداریم. در این پروژه توانستیم با کمک شبکه های عصبی خود سازمان ده علاوه بر خوشه بندی به شناسایی سرطان از روی تصاویر حرارتی پردازیم.

با توجه به نتایج به دست آمده می توان با کارهای گذشته مقایسه که در جدول ۲ ارائه شده است.

جدول ۲. مقایسه نتایج به دست آمده از مقاله با کارهای گذشته

	کار انجام شده	(۱۹)	(۲۰)	(۲۱)
SEN	%۹۳	%۸۶	%۲۵	%۷۸
SPE	%۹۷	%۸۹	%۸۵	%۷۵

در مقایسه با کارهای ارایه شده نتایج حاصل مطلوب و قابل ملاحظه می باشد.

در صورتی خواسته شود محدودیت های این طرح مورد ارزیابی قرار گیرد می توان به مواردی از جمله: امکان دسترسی به دوربین های حرارتی پیشرفته که به ویژه برای موارد پزشکی طراحی شده اند، ایجاد آرامش و دور نمودن استرس از بیمار یا هر گونه عاملی که سبب افزایش غیر عادی دمای بدن گردد، ایجاد نمودن یک پایگاه داده کلی و جامع که شامل تمام موارد خاص مربوط به سرطان پستان که در فرایند آموزش در قسمت هوش مصنوعی، سیستم دچار مشکل نگردد، اشاره نمود. برای پیشنهادات آینده که محققین بتوانند این تحقیق را ادامه دهند مقایسه همزمان فرایند تشخیصی با استفاده از روش های از جمله PET-CT یا سونوگرافی و همچنین تلفیق و ترکیب این روش ها با تکنیک حرارتی که در مقاله مورد ارزیابی قرار گرفت، در جهت بالا بردن دقت تشخیصی می باشد.

## REFERENCE

1. American Cancer Society: Cancer facts and Figures. <[www.cancer.org](http://www.cancer.org) >.
2. National Cancer Institute: SEER Stat Fact Sheets: Breasts .< [www.seer.cancer.gov/statfacts/html/breast.html](http://www.seer.cancer.gov/statfacts/html/breast.html)>.
3. E.Y.K. Ng, N.M. Sudarshan, Numerical computation as a tool to aid thermo graphic Interpretation, *Journal of Medical Engineering & Technology* 25 2001; 53–60.
4. Harirchi I, Ebrahimi M, Zamani N, et al. “Breast cancer in Iran: a review of 903 case records”. *Public Health* 2000; 114: 140-145.
5. G.C. Wishart, M.Campisi, M.Boswell, D.Chapman, V.Shackleton, S.Iddles, A. Hallett, P.D.Britton.The accuracy of digital infrared imaging for breast cancer detection in women undergoing breast biopsy. *EJSO*2010; 36:535-540.
6. W.C. Amalu, W.B. Hobbins, J.F. Head, R.L. Elliot, Infrared imaging of the breast– an overview, in: J.D. Bronzino (Ed.), *Biomedical Engineering Handbook, third ed., Medical Devices and Systems*, CRC Press 2006; pp. 20.
7. D. Kennedy, T. Lee, D. Seely, A comparative review of thermography as a breast screening technique, *Integrative Cancer Therapies* 2009; 8: 9–16.
8. E. Alpaydin, "Introduction to Machine Learning", the MIT Press, 2004.
9. F. Keller, "Clustering", Computer University Saarlandes, Tutorial Slides.
10. E.Y.K. Ng, A review of thermography as promising non-invasive detection modality for breast tumor, *International Journal of Thermal Sciences* 2009; 48:849–859.
11. H. Fabiana, P. Lasch, M. Boese, W. Haenschc. Infrared micro spectroscopic imaging of benign breast Tumor tissue sections. *Journal of Molecular Structure* 2003; 411–417.
12. T.Z. Tan , C. Quek , G.S. Ng , E.Y.K. Ng .novel cognitive interpretation of breast cancer thermography with complementary learning fuzzy neural memory structure. *Expert Systems with Applications* 2007; 33: 652–666.
13. Keyserlignk, J.R., Ahlgren, P.D., et al., Infrared imaging of the breast; initial reappraisal using high resolution digital technology in 100 successive cases of stage 1 and 2 breast cancer. 1998.
14. Srdan Riber, Miroslav dramicanin, Tatjana Dramicanin, lidija matija.” classification of breast cancer luminescence data using self organizing mapping neural network”. *FME Transactions* 2006; 34: 87-91.
15. Le Yang, Zhongbin Ouyang, Yong Shi, “A Modified Clustering Method Based on Self-Organizing Maps and Its Applications”. *Proceedings of the International Conference on Computational Science* 2012; 9: 1371–1379.
16. Stephen Scheidta, Michael Ramsey, Nicholas Lancaster,”Radiometric normalization and image mosaic generation of ASTER thermal infrared data: An application to

- extensive sand sheets and dune fields". Remote Sensing of Environment 2008; 112(3): 920–933.
17. N.C. Yeo, K.H. Lee, Y.V. Venkatesh, S.H. Ong. "Color image segmentation using the self-organizing map and adaptive resonance theory". Image and Vision Computing 2005; 23(12): 1060–1079.
  18. Dursun Delen, Glenn Walker, Amit Kadam .Predicting breast cancer survivability: a comparison of three data mining methods. Artificial Intelligence in Medicine 2005; 34(2):113–127.
  19. Head, J.F., Lipari, C.A. and Elliot, R.L., Comparison of mammography, and breast infrared imaging: Sensitivity, specificity, false negatives, false positives, positive predictive value and negative predictive value. IEEE, 1999.
  20. M. Kontosa, R. Wilsonb, I. Fentiman . "Digital infrared thermal imaging (DITI) of breast lesions: sensitivity and specificity of detection of primary breast cancers". 2011, 66(6):536–539.
  21. Wishart GC, Campisi M, Boswell M, Chapman D, Shackleton V, Iddles S, Hallett A, Britton PD. "The accuracy of digital infrared imaging for breast cancer detection in women undergoing breast biopsy." 2010, 36(6):535-540.