

طبقه‌بندی خودکار تصاویر سرطان پستان با استفاده از یادگیری انتقال بر روی تصاویر ماموگرافی بهبودیافته

زهرا امیری و زهرا مرتضایی

آن غیر قابل انکار است.

در حال حاضر، مسئولیت تشخیص سرطان پستان عمدتاً بر عهده رادیولوژیست‌ها است. علی‌رغم اینکه این متخصصان مهارت بالایی دارند، اما مصون از اشتباه نیستند و خطاهای انسانی مانند تفسیر غلط تصاویر می‌تواند منجر به تشخیص‌های نادرست از جمله وجود موارد مثبت کاذب و منفی کاذب شود [۳]. یک مشکل مهم در طبقه‌بندی تصاویر ماموگرافی، وجود موارد مثبت کاذب است که در آن بافت سالم به اشتباه به‌عنوان بافت غیرطبیعی شناسایی می‌شود و در شرایط دیگر وجود موارد منفی کاذب است که در آن ناهنجاری‌های واقعی نادیده گرفته می‌شوند. هر دو وضعیت می‌تواند باعث استرس بیش از حد برای بیماران یا تأخیر در درمان‌های ضروری شود.

علاوه بر این، کیفیت تصاویر ماموگرافی می‌تواند به‌شدت متغیر باشد که تحت تأثیر عواملی مانند فناوری تصویربرداری مورد استفاده، نحوه قرارگیری بیمار و تراکم بافت پستانی است [۴]. چنین مسائلی می‌تواند ناهنجاری‌های بالقوه را مخفی کند و ارزیابی و تشخیص درست را تحت تأثیر منفی قرار دهد. همچنین به دلیل ترکیب پیچیده بافت پستانی، متخصصین ممکن است در تشخیص دچار خطا شوند [۵]. تمایز بین شکل‌های آناتومیک استاندارد و تغییرات پاتولوژیک احتمالی، حتی برای الگوریتم‌های پیشرفته نیز چالش‌برانگیز است. در همین حال، مجموعه داده‌های ماموگرافی معمولاً از عدم تعادل کلاس رنج می‌برند و نمونه‌های بافتی نرمال نسبت به یافته‌های غیرطبیعی یا سرطانی بیشتر هستند [۶]. این نابرابری می‌تواند مدل‌های یادگیری ماشین را به سمت پیش‌بینی کلاس اکثریت سوق دهد؛ بنابراین توانایی آنها در شناسایی دقیق موارد سرطان را کاهش می‌دهد.

برای حل این چالش‌ها، طراحی و توسعه یک سیستم هوشمند برای تجزیه و تحلیل تصاویر ماموگرافی و ارائه تشخیص‌های دقیق با درجه بالایی از اطمینان ضروری است. چنین سیستمی می‌تواند نقش کلیدی در تشخیص زودهنگام و دقیق سرطان پستان ایفا کند. در این مقاله به جزئیات چگونگی ایجاد چنین سیستمی می‌پردازیم که حول سه جزء اصلی سازماندهی شده است: پیش‌پردازش، استخراج ویژگی‌ها و طبقه‌بندی آنها. مرحله پیش‌پردازش برای آماده‌سازی تصاویر ماموگرافی در راستای تجزیه و تحلیل دقیق و مناسب، ضروری است. در این مرحله با افزایش کنتراست تصاویر می‌توان شناسایی ناهنجاری‌های بالقوه را آسان‌تر کرد. از این رو در این مقاله در مرحله پیش‌پردازش، روش بهبود هیستوگرام تطبیقی محدودشده توسط کنتراست^۱ (CLAHE) روی تصاویر پستان اعمال می‌شود تا کیفیت تصاویر را بهبود بخشد. سپس نواحی مورد نظر

چکیده: سرطان پستان، یکی از نگرانی‌های مهم در حوزه بهداشت جهانی محسوب می‌شود که به دو نوع خوش‌خیم و بدخیم تقسیم می‌شود. از این رو نیاز حیاتی به تشخیص سریع و دقیق دارد. علی‌رغم تخصص رادیولوژیست‌ها، خطاهای ناشی از تفسیر غلط منجر به تشخیص‌های نادرست می‌شود. برای حل این مشکل، این مقاله سیستم هوشمندی را برای تحلیل تصاویر ماموگرافی پیشنهاد می‌کند که شامل مراحل پیش‌پردازش، استخراج ویژگی‌ها و طبقه‌بندی آنها می‌باشد. در این سیستم، ابتدا با استفاده از تکنیک‌های پیش‌پردازشی مانند بهبود هیستوگرام تطبیقی محدودشده توسط کنتراست کیفیت تصویر را بهبود بخشیده و در ادامه از روش قطعه‌بندی به روش آستانه‌گذاری آتسو برای استخراج ناحیه مربوط به توده سرطانی استفاده می‌شود. همچنین با استفاده از دو مدل از پیش آموزش داده شده شبکه‌های عصبی پیچشی، یعنی ResNet۵۰ و InceptionV۳، ویژگی‌های کلیدی برای تمایز بین تومورهای خوش‌خیم و بدخیم استخراج می‌شود. نهایتاً با بهره‌مندی از طبقه‌بند ماشین بردار پشتیبان، ویژگی‌های استخراج‌شده به‌منظور پیش‌بینی نوع تومورها، تجزیه و تحلیل می‌شود. با ارزیابی مدل پیشنهادی بر روی مجموعه داده INBreast میانگین وزن‌دار معیارهای Precision و Recall مقدار ۰.۹۵۴ به دست آمده که نشان‌دهنده عملکرد قوی مدل در تفکیک صحیح توده‌های پستانی است. نتیجه این کار، بهبود دقت تشخیص و همچنین تشخیص زودهنگام سرطان پستان است که منجر به کاهش خطای انسانی و چالش‌های فعلی در تفسیر تصاویر ماموگرافی می‌شود.

کلیدواژه: بهسازی تصویر، بینایی ماشین، سرطان پستان، شبکه عصبی عمیق، یادگیری عمیق، ماموگرافی.

۱- مقدمه

سرطان پستان یکی از انواع شایع سرطان است که میلیون‌ها نفر در سراسر جهان را تحت تأثیر قرار می‌دهد [۱]. آنچه این بیماری را از بسیاری از انواع دیگر سرطان متمایز می‌کند، قابلیت تشخیص بالای آن از طریق تصاویر ماموگرافی است. ماموگرافی یک تکنیک تصویربرداری تشخیصی است که به‌طور خاص برای این نوع سرطان بسیار مؤثر است. سرطان‌های پستانی معمولاً به دو دسته سرطان‌های خوش‌خیم و بدخیم تقسیم می‌شوند [۲]. سرطان‌های پستانی بدخیم به دلیل تمایل به گسترش سریع، بسیار خطرناک‌تر هستند؛ بنابراین اهمیت تشخیص به‌موقع و دقیق

این مقاله در تاریخ ۱ آذر ماه ۱۴۰۳ دریافت و در تاریخ ۱۰ خرداد ماه ۱۴۰۴ بازنگری شد.

زهرا امیری (نویسنده مسئول)، دانشکده مهندسی برق و کامپیوتر، دانشگاه علم و فناوری مازندران، بهشهر، ایران، (email: zahra.amiri@mazust.ac.ir).
زهرا مرتضایی، دانشکده ریاضی و علوم کامپیوتر، دانشگاه حکیم سبزواری، سبزوار، ایران، (email: zm.mortezaie@gmail.com).

ویژگی‌ها از تصاویر ماموگرافی برای تشخیص ضایعات توده‌ای ارزیابی می‌کند. این مرجع نشان می‌دهد که شبکه‌های عصبی پیچشی، تجزیه و تحلیل تصاویر ماموگرافی را به‌طور قابل توجهی بهبود می‌دهند و رویکردی کارآمدتر و دقیق‌تر را نسبت به روش‌های متداول استخراج سنتی ویژگی‌ها از تصاویر پزشکی ارائه می‌کنند. مرجع [۹] پیچیدگی‌های موجود در تشخیص سرطان پستان را از طریق ماموگرافی با استفاده از روش‌های یادگیری عمیق حل می‌کند. در این مرجع یک مدل شبکه عصبی به نام شبکه عصبی DenseNet-II بهبودیافته معرفی می‌شود تا دقت و کارایی در تمایز بین تصاویر ماموگرافی خوش‌خیم و بدخیم افزایش یابد. این روش شامل پیش‌پردازش تصاویر و نرمال‌سازی و افزایش داده برای مقابله با محدودیت‌های مجموعه داده است. مدل شبکه عصبی DenseNet-II ساختار شبکه عصبی Inception را در لایه پیچشی اولیه خود ادغام می‌کند که قابلیت‌های طبقه‌بندی آن را افزایش می‌دهد.

مرجع [۱۰] از شبکه‌های عصبی پیچشی برای طبقه‌بندی تصاویر ماموگرافی به دو دسته خوش‌خیم یا بدخیم با استفاده از دو پایگاه داده mini-MIAS و BCDR استفاده می‌کند. راهکار ارائه‌شده در این مرجع با روش‌های پیش‌پردازش مانند برش نواحی حاشیه‌ای و مازاد تصاویر^۸ تقویت و دستکاری داده‌ها و تعادل‌سازی بین تعداد داده‌های موجود در دو کلاس، بهبود یافت. مرجع [۱۱] چارچوبی برای طبقه‌بندی تصاویر سرطان پستان معرفی می‌کند که از مدل‌های یادگیری عمیق مختلف مانند شبکه‌های عصبی InceptionV۳، DenseNet۱۲۱، ResNet۵۰، VGG۱۶ و MobileNetV۲ برای تمایز بین موارد خوش‌خیم و بدخیم در تصاویر ماموگرافی پایگاه‌های داده MIAS، DDSM و CBIS-DDSM استفاده می‌کند. علاوه بر این، از یک مدل U-Net اصلاح‌شده برای طبقه‌بندی منطقه پستان در تصاویر ماموگرافی استفاده می‌شود که هدف آن کمک به رادیولوژیست‌ها در تشخیص زودهنگام و افزایش کارایی سیستم است.

مرجع [۱۲] یک طبقه‌بند بر مبنای شبکه‌های عصبی پیچشی برای تشخیص سرطان پستان با استفاده از مجموعه داده MIAS ارائه می‌دهد که از یادگیری عمیق برای بهبود شناسایی و طبقه‌بندی تصویر استفاده می‌کند. با ادغام فیلتر وینر برای کاهش نویز و خوشه‌بندی K-means برای طبقه‌بندی، این روش تصاویر ماموگرافی را طبقه‌بندی و طبقه‌بندی می‌کند. مرجع [۱۳] یک شبکه عصبی پیچشی مبتنی بر یادگیری عمیق معرفی می‌کند که برای افزایش دقت تشخیص سرطان پستان با کاهش خطای انسانی در شناسایی بافت‌های بدخیم طراحی شده است. با ادغام یادگیری ویژگی با وظایف طبقه‌بندی، این مدل در تمایز خودکار بین مناطق خوش‌خیم و بدخیم در تصاویر ماموگرافی عملکرد مناسبی دارد. این مرجع با استفاده از ۳۲۲ تصویر از مجموعه داده MIAS و ۵۸۰ تصویر از پایگاه‌های داده خصوصی، پیش‌پردازش و یادگیری انتقالی را به کار می‌گیرد تا مجموعه داده‌ها را بهبود بخشد و ویژگی‌های دقیق نشان‌دهنده تومورهای پستانی را استخراج کند.

مرجع [۱۴] یک شبکه عصبی پیچشی را برای بهبود تشخیص سرطان پستان از طریق تجزیه و تحلیل تصاویر ماموگرافی معرفی می‌کند. با استفاده از مزایای شبکه‌های عصبی پیچشی در استخراج ویژگی‌ها و طبقه‌بندی، این مرجع قادر به دسته‌بندی تصاویر ماموگرافی از مجموعه داده mini-MIAS به کلاس‌های عادی، بدخیم و خوش‌خیم است. مراجع [۱۵] و [۱۶] چارچوبی برای طبقه‌بندی سرطان پستان با استفاده از تصاویر

(ROI)^۱ یعنی تومورها، با استفاده از توزیع نرمال و قطعه‌بندی به روش آستانه‌گذاری آتسو^۲ استخراج می‌شوند.

پس از پیش‌پردازش، مرحله استخراج ویژگی‌هاست که بر شناسایی و استخراج ویژگی‌های مرتبط و متمایز از تصاویر پردازش‌شده تمرکز دارد. این مرحله برای تمایز بین تومورهای خوش‌خیم و بدخیم ضروری است. ویژگی‌های مورد نظر ممکن است شامل الگوهای بافت، شکل و شدت رنگ در تصاویر باشد. شبکه‌های عصبی پیچشی^۳ (CNN) به دلیل کارآمدی در حل مشکلات استخراج ویژگی و طبقه‌بندی، به‌ویژه در تجزیه و تحلیل تصاویر، در این زمینه پرکاربرد هستند. بنابراین در مرحله استخراج ویژگی، ابتدا تصاویر بهبودیافته توسط روش CLAHE با ROI استخراج‌شده در یک فرم وزنی ترکیب می‌شوند و سپس تصویر ترکیبی به‌عنوان ورودی به دو مدل از پیش آموزش داده شده ResNet۵۰ و InceptionV۳ ارسال می‌شود تا ویژگی‌های تصاویر را استخراج کند.

در نهایت، مرحله طبقه‌بندی شامل تجزیه و تحلیل ویژگی‌های استخراج‌شده برای طبقه‌بندی تومورها به‌عنوان خوش‌خیم یا بدخیم است. در سومین مرحله، ویژگی‌های استخراج‌شده به یک طبقه‌بندی‌کننده ماشین بردار پشتیبان^۴ (SVM) منتقل می‌شود تا احتمالات کلاس‌ها را پیش‌بینی کند و در نتیجه تصویر را طبقه‌بندی کند. با ادغام این سه مرحله - پیش‌پردازش، استخراج ویژگی‌ها و طبقه‌بندی - سیستم پیشنهادی خطای انسانی در تفسیر تصاویر ماموگرافی را کاهش می‌دهد. در واقع با خودکارکردن تجزیه و تحلیل تصاویر ماموگرافی، این سیستم هوشمند توانایی زیادی برای افزایش دقت تشخیص سرطان پستان دارد و نهایتاً به تشخیص زودتر بیماری کمک می‌کند.

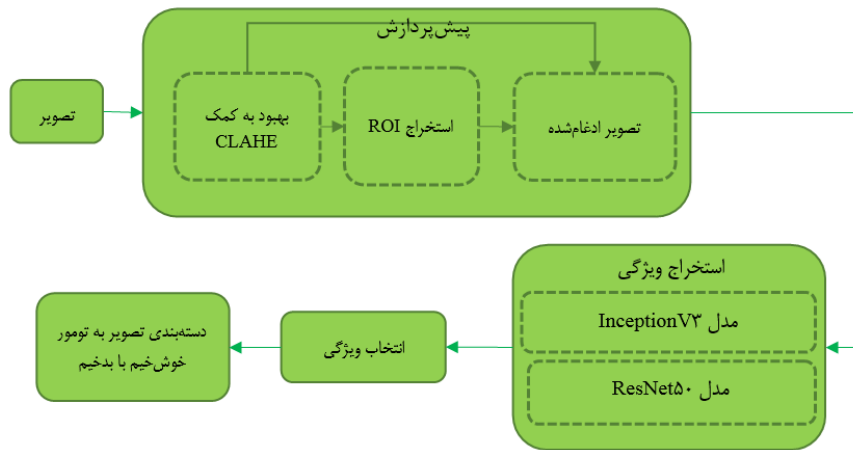
ساختار این مقاله به شرح زیر سازماندهی شده است: برخی از کارهای مرتبط به‌صورت خلاصه در بخش ۲ بررسی شده‌اند. بخش‌های ۳ و ۴ شامل روش پیشنهادی و نتایج تجربی هستند و نتیجه‌گیری مقاله در بخش ۵ ارائه شده است.

۲- کارهای گذشته

تلاش‌های زیادی برای بهبود طبقه‌بندی سرطان پستان انجام شده است. مرجع [۷] بر شناسایی و دسته‌بندی توده‌های پستانی به دو دسته خوش‌خیم یا بدخیم تمرکز دارد. این مرجع با استفاده از پایگاه داده mini-MIAS، پیش‌پردازش‌هایی را برای حذف مناطق غیرمرتبط و فیلترهایی مانند گاوسی، میانگین، میانی و وینر به همراه روش بهبود هیستوگرام تطبیقی محدودشده توسط کنتراست برای تأکید بر روی ناهنجاری‌های بالقوه انجام داد. در این مرجع استخراج ویژگی از تصاویر با استفاده از روش‌های هیستوگرام گرادینان چرخشی^۵ (HOG)، الگوی دودویی محلی^۶ (LBP) و ماتریس هم‌رخدادی سطح خاکستری^۷ (GLCM) انجام شد. سپس این ویژگی‌ها در سه گروه عادی، خوش‌خیم و بدخیم و دو گروه عادی و غیرطبیعی با استفاده از چندین الگوریتم یادگیری ماشین، طبقه‌بندی شدند.

مرجع [۸] اثربخشی شبکه‌های عصبی پیچشی را در یادگیری خودکار

1. Region of Interest
2. Otsu
3. Convolutional Neural Network
4. Support Vector Machine
5. Histogram of Gradient
6. Local Binary Pattern
7. Gray Level Co-Occurrence Matrix



شکل ۱- گام‌های اصلی روش پیشنهادی.

برجسته کردن مناطق تومور، تصویر بهبودیافته با استفاده از روش CLAHE و مناطق پیشنهادی استخراج شده در تصویر ادغام می‌شوند.

۳-۱-۱ پیش پردازش

برای حفظ انسجام در مجموعه داده که برخی تصاویر پستان در سمت چپ و برخی دیگر در سمت راست قرار دارند، ابتدا تمام تصاویر در صورت لزوم لازم چرخانده می‌شوند تا ناحیه پستان در سمت چپ تصویر قرار گیرد.

۳-۱-۲ بهبود تصویر

در این بخش، روش CLAHE به منظور افزایش کنتراست تصویر و آشکارسازی جزئیات دقیق تر استفاده می‌شود. پارامترهای مورد استفاده در این روش در جدول ۱ ذکر شده است. تصویر اولیه در شکل ۲-الف نشان داده شده و نتیجه پس از اعمال فیلتر در شکل ۲-ب ارائه می‌شود.

۳-۱-۳ استخراج ROI

معمولاً مناطق ضایعه در یک تصویر از نواحی اطراف متمایز هستند و هدف این بخش، استخراج این مناطق است. در اولین گام، یک ماسک از تصویر استخراج می‌شود که در آن به مناطق پستان مقدار ۱ و به مناطق غیر پستان مقدار ۰ اختصاص داده می‌شود. برای استخراج این ماسک، تصویر با استفاده از روش قطعه بندی Otsu با یک آستانه پایین (در اینجا ۰/۰۹) دودویی می‌شود. تصویر ماسک در شکل ۲-ج آمده است.

در مرحله بعد برای استخراج ROIها، یک نقشه تمایز منطقه پستان (پیکسل‌های غیر صفر) از این ناحیه استخراج می‌شود (شکل ۲-د). برای محاسبه تمایز هر پیکسل نسبت به پیش زمینه، یک توزیع نرمال برای پیکسل‌ها تخمین زده می‌شود. سپس میزان تعلق هر پیکسل به آن توزیع می‌تواند به عنوان یک معیار تمایز آن در نظر گرفته شود. یک توزیع نرمال با استفاده از میانگین (μ) و واریانس (σ^2) پیکسل‌های منطقه پستان به داده‌های تصویر متناسب می‌شود. احتمال تعلق هر پیکسل به این توزیع را می‌توان با استفاده از فرمول زیر تعیین کرد

$$f(x) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{1}{2} \frac{(x-\mu)^2}{\sigma^2}\right) \quad (1)$$

مکمل $f(x)$ را می‌توان با استفاده از $\overline{f(x)} = 1 - f(x)$ محاسبه کرد (شکل ۲-ه). برای ایجاد یک نقشه تمایز، ابتدا یک تصویر جدید تولید می‌شود که در آن مقدار هر پیکسل برابر با c برای آن پیکسل است. سپس تصویر تولید شده به دو سطح با استفاده از روش آستانه گذاری Otsu تقسیم می‌شود (شکل ۲-و). برای حذف نقاط اضافی از ROI

جدول ۱: پارامترهای روش CLAHE.

پارامتر	مقدار
اندازه بلاک	8×8
حد آستانه برای برش هیستوگرام	۰/۰۱
نوع توزیع	یکنواخت
تعداد سطوح هیستوگرام در هر بلاک	۲۵۶
بازه مقدار شدت پیکسل‌ها	[۰-۲۵۵]


ماموگرافی ارائه می‌دهند که در آن با ادغام ویژگی‌های استخراج شده از شبکه‌های عصبی پیچشی با ویژگی‌های سنتی مانند هیستوگرام گرادینان چرخشی، الگوی دودویی محلی و هیستوگرام رنگ دقت طبقه بندی بهبود می‌یابد.

مرجع [۱۷] یک مدل یک شبکه عصبی پیچشی را برای طبقه بندی خودکار سرطان سینه از انواع مختلف تصاویر، شامل ماموگرام و سونوگرافی پیشنهاد می‌دهد. این مدل شامل پنج لایه قابل آموزش است: چهار لایه کانولوشن و یک لایه کاملاً متصل. مدل به طور خودکار ویژگی‌های برجسته را از تصاویر استخراج می‌کند و تعداد پارامترهای قابل تنظیم کمتری دارد. نتایج شبیه سازی بر روی مجموعه داده‌های ماموگرام INbreast گزارش شده است. گزارش‌های مقاله نشان می‌دهد که روش ارائه شده عملکرد بهتری نسبت به روش‌های اخیر داشته است. در [۱۸] از یادگیری انتقال به کمک شبکه‌های NASNet Mobile، VGG۱۶ و VGG۱۹ برای طبقه بندی تصاویر ماموگرافی استفاده شده و از مجموعه داده INbreast بهره می‌برد. روش پیشنهادی با این دو مرجع اخیر در بخش نتایج مورد مقایسه قرار خواهد گرفت.

این مقاله سیستمی هوشمند به منظور بهبود تجزیه و تحلیل تصاویر ماموگرافی و طبقه بندی تومورهای سرطان پستان به دو دسته سرطان خوش خیم و بدخیم ارائه می‌دهد. این سیستم شامل مراحل پیش پردازش، استخراج ویژگی‌ها و طبقه بندی آنهاست. جزئیات این روش پیشنهادی در بخش بعدی شرح داده شده است.

۳-۲ روش پیشنهادی

مراحل اصلی روش پیشنهادی در شکل ۱ نشان داده شده است. در روش پیشنهادی، ابتدا کنتراست تصویر با استفاده از روش محدودیت کنتراست هیستوگرام تطبیقی بهبود می‌یابد. سپس مناطق متمایز در تصویر به عنوان نواحی مورد نظر در تصویر استخراج می‌شوند. پس از آن، این مناطق با استفاده از فیلترهای مورفولوژی تصفیه می‌شوند. نهایتاً برای



شکل ۲: گام‌های پیش‌پردازش، (الف) تصویر، (ب) تصویر بهبودیافته، (ج) ماسک، (د) PDF پیکسل‌های تصویر $f(x)$ ، (ه) $\overline{f(x)}$ ، (و) ROI اولیه، (ز) ROI استخراج شده تصفیه شده و (ح) تصویر ادغام شده نهایی.

هر دو مدل InceptionV3 و ResNet50 بر روی مجموعه داده ImageNet آموزش داده شده‌اند. با توجه به اندازه محدود مجموعه داده موجود برای سرطان پستان، از تنظیم دقیق مدل‌ها به منظور جلوگیری از بیش‌برازش [۲۱] اجتناب شده و در نتیجه، تصاویر مستقیماً به مدل‌ها وارد شدند و بردارهای ویژگی ۲۰۴۸ بعدی از لایه Average Pooling 2D هر مدل استخراج شدند.

۳-۳ انتخاب ویژگی

در مجموع ۴۰۹۶ ویژگی از مراحل قبلی استخراج گردید که شامل ۲۰۴۸ ویژگی از ResNet50 و ۲۰۴۸ ویژگی از InceptionV3 می‌شود. برای انتخاب زیرمجموعه‌ای از این ویژگی‌ها، از روش انتخاب ویژگی حداکثر ارتباط و حداقل افزونگی (MRMR) [۲۲] استفاده شده است. هدف این تکنیک به حداقل رساندن افزونگی ویژگی‌ها در عین به حداکثر رساندن ارتباط مجموعه ویژگی با متغیر پاسخ y (کلاس‌ها) است. MRMR تمام ویژگی‌ها را رتبه‌بندی می‌کند و نمایه‌ها و امتیازهای آنها را به ترتیب نزولی اهمیت ارائه می‌دهد. در این تحقیق از میان ویژگی‌های رتبه‌بندی شده نصف ویژگی‌های بااهمیت‌تر انتخاب می‌شود.

۳-۴ دسته‌بندی

ویژگی‌های انتخاب شده در ادامه به یک طبقه‌بندی کننده ماشین بردار پشتیبان [۲۳] وارد شدند تا تصاویر سرطان پستان را به عنوان خوش‌خیم یا بدخیم طبقه‌بندی کنند.

ماشین بردار پشتیبان یکی از روش‌های قدرتمند و پرکاربرد در حوزه یادگیری ماشین برای مسائل طبقه‌بندی دودویی و چندکلاسه است. عملکرد SVM مبتنی بر یافتن یک ابرصفحه بهینه است که بیشترین فاصله را بین داده‌های دو کلاس ایجاد می‌کند. این ویژگی باعث می‌شود که SVM در مواجهه با داده‌های با ابعاد بالا و مرزهای غیرخطی عملکرد بسیار خوبی از خود نشان دهد. علاوه بر این، SVM با بهره‌گیری از هسته‌های مختلف از جمله هسته چندجمله‌ای قادر است که داده‌ها را به فضای ویژگی‌های با ابعاد بالاتر نگاشت کند تا جداسازی کلاس‌ها

استخراج شده، از عملگرهای مورفولوژی استفاده می‌شود. بدین منظور، یک عنصر ساختاری دایره‌ای با شعاع دو پیکسل تعریف می‌شود و به ترتیب یک فرسایش و یک گسترش به تصویر اعمال می‌شود (شکل ۲-۳). آخرین مرحله پیش‌پردازش شامل ترکیب تصویر تقویت شده با روش CLAHE با ROI استخراج شده از مرحله قبل با استفاده از (۲) است

$$img_{merged} = w_1 \times img_{ROI} + w_2 \times img_{CLAHE} \quad (2)$$

w_1 و w_2 وزن‌هایی بین ۰ و ۱ هستند و مجموع آنها ۱ است. نتیجه در شکل ۲-۳ نشان داده شده است. تصویر خروجی ایجاد شده برای مرحله بعدی استفاده می‌شود.

۳-۱-۳ حاشیه‌گذاری و افزایش داده‌ها

تصویر پیش‌پردازش شده با افزودن حاشیه برای تطبیق با ورودی‌های مدل‌های از پیش آموزش داده شده در مرحله بعد، به یک مربع تبدیل می‌شود. سپس به منظور افزایش تصاویر برای آموزش مدل تصاویر در بازه ۳۰ تا ۲۷۰ درجه با فواصل ۳۰ درجه چرخانده و ذخیره می‌شوند. همچنین هر تصویر ایجاد شده یک مرتبه برگردانده شده و ذخیره می‌شود. تصاویر افزایش یافته به عنوان یک مجموعه داده برای فرآیند آموزش مورد استفاده قرار می‌گیرند. لازم به ذکر است که فرآیند افزایش داده‌ها تنها برای مجموعه داده‌های آموزش به کار گرفته شده است.

۳-۲ استخراج ویژگی

در این بخش از دو مدل از پیش آموزش داده شده، ResNet50 و InceptionV3، به عنوان استخراج کننده‌های ویژگی استفاده شده است. ResNet50 مبتنی بر مفهوم یادگیری باقیمانده [۱۹] از اتصالات میانبر برای کاهش مشکل ناپدید شدن گرادینان در شبکه‌های عمیق استفاده می‌کند. معماری آن از اصول طراحی خاصی پیروی می‌کند: تعداد فیلترها در لایه‌های با اندازه نقشه ویژگی خروجی یکسان ثابت می‌ماند و هنگام نصف شدن نقشه ویژگی دو برابر می‌شود. InceptionV3 یک معماری شبکه عصبی پیچشی شناخته شده برای کارایی آن در مدیریت داده‌های بصری پیچیده است. در واقع بخشی از سری مدل‌های Inception است که به طور گسترده برای دقت آن در تحلیل تصویر و تشخیص شیء شناخته شده است [۲۰].

جدول ۲: ارزیابی روش پیشنهادی بر روی پایگاه داده INBreast با معیارهای ارزیابی متفاوت.

F-M	Recall	Precision	FPR	FNR	AC	معیار کلاس
۰.۹۳۱	۰.۹۱۶	۰.۹۴۷	۰.۰۲۷	۰.۰۸۴	۰.۹۱۶	خوش خیم
۰.۹۶۵	۰.۹۷۳	۰.۹۵۷	۰.۰۸۴	۰.۰۲۷	۰.۹۷۳	بدخیم
۰.۹۵۴	۰.۹۵۴	۰.۹۵۴	۰.۰۶۴	۰.۰۴۶	۰.۹۵۴	میانگین وزن دار

جدول ۳: تأثیر مراحل مختلف روش پیشنهادی.

F-M	Recall	Precision	FPR	FNR	Accuracy	معیار کلاس
۰.۹۵۴	۰.۹۵۴	۰.۹۵۴	۰.۰۶۴	۰.۰۴۶	۰.۹۵۴	روش پیشنهادی
۰.۹۴۰	۰.۹۴۰	۰.۹۴۰	۰.۰۷۹	۰.۰۶۰	۰.۹۴۰	روش پیشنهادی بدون پیش پردازش
۰.۹۴۶	۰.۹۴۶	۰.۹۴۶	۰.۰۷۱	۰.۰۵۴	۰.۹۴۶	روش پیشنهادی بدون انتخاب ویژگی

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (۳)$$

$$Precision = \frac{TP}{TP + FP} \quad (۴)$$

$$Recall = \frac{TP}{TP + FN} = 1 - FNR \quad (۵)$$

$$FPR = \frac{FP}{FP + FN} \quad (۶)$$

$$FNR = \frac{FN}{FN + TP} \quad (۷)$$

$$F - M = 2 \frac{Precision \times Recall}{Precision + Recall} \quad (۸)$$


تمام معیارهایی که در این مطالعه استفاده شده‌اند، مقادیر بین ۰ و ۱ دارند. به طور کلی، مقادیر بالاتر برای این معیارها نشان دهنده عملکرد بهتر است، به جز مقادیر نرخ مثبت کاذب (FRR) و نرخ منفی کاذب (FNR) که زمانی بهتر هستند که پایین تر باشند.

۳-۴ نتایج

در این بخش روش پیشنهادی بر روی پایگاه داده معرفی شده مورد ارزیابی قرار می‌گیرد و با سایر روش‌های موجود مقایسه خواهد شد. در آزمایش اول، روش پیشنهادی روی مجموعه داده INBreast تست گردید و نتایج در جدول ۲ آمده است. نتایج نشان دهنده عملکرد بالای روش پیشنهادی در تشخیص تومورهای خوش خیم یا بدخیم است.

در آزمایش بعدی، تأثیر مراحل مختلف روش پیشنهادی شامل پیش پردازش و انتخاب ویژگی مورد ارزیابی قرار گرفته است. برای بررسی هر مرحله، آن مرحله از روش‌های پیشنهادی حذف شد و مراحل باقیمانده بر روی مجموعه داده آزمایش گردید. نتایج جدول ۳ نشان داد که حذف هر مرحله باعث کاهش عملکرد روش پیشنهادی در تمامی معیارهای ارزیابی شد؛ بنابراین هر مرحله تأثیر مثبتی بر روش پیشنهادی داشت.

در آزمایش بعد ساختارهای عمیق مورد استفاده و ساختارهای متداول دیگر مانند VGG۱۹، GoogleNet و AlexNet به عنوان استخراجگر ویژگی مورد بررسی قرار گرفتند. نتایج این مقایسه در جدول ۴ گزارش



(ب)

(الف)

شکل ۳: دو نمونه از تصاویر مجموعه داده INBreast، (الف) خوش خیم و (ب) بدخیم.

به صورت خطی ممکن شود. مزیت دیگر SVM در این است که تنها تعداد کمی از داده‌ها (بردارهای پشتیبان) در تعیین مرز تصمیم‌گیری نقش دارند که این موضوع منجر به تعمیم‌پذیری بالا و مقاومت در برابر بیش‌برازش به ویژه در مجموعه داده‌های کوچک یا نویزی می‌شود. به دلیل این ویژگی‌ها، SVM به طور گسترده در تحلیل تصاویر پزشکی، تشخیص بیماری‌ها و سایر کاربردهای حساس استفاده می‌شود [۲۴] تا [۲۶].

در روش پیشنهادی هسته انتخاب شده از نوع چندجمله‌ای با درجه دو بوده که توانایی مدل‌سازی روابط غیرخطی بین ویژگی‌ها را فراهم می‌کند. همچنین مقدار پارامتر جریمه خطا (c) برابر ۱ تنظیم شد. مدل SVM با استفاده از اعتبارسنجی متقابل ۱۰-لایه ارزیابی می‌شود تا از بروز بیش‌برازش جلوگیری گردد و عملکرد تعمیم‌پذیر مدل سنجیده شود.

۴- بحث و نتایج تحقیق

در این بخش، ابتدا مجموعه داده حاوی تصاویر سرطان پستان معرفی می‌شود. سپس نتایج پیاده‌سازی روش پیشنهادی بر روی این مجموعه داده ارائه می‌گردد و نهایتاً با سایر روش‌های موجود مقایسه می‌شود. در تمامی آزمایش‌های انجام شده از روش اعتبارسنجی متقابل ۱۰-لایه برای ارزیابی روش استفاده شده است. در این روش، داده‌ها به ۱۰ بخش تقسیم می‌شوند و در هر تکرار یک بخش به عنوان داده آزمون و بقیه به عنوان داده‌های آموزش مورد استفاده قرار می‌گیرند. نهایتاً میانگین عملکرد در ده تکرار گزارش می‌شود.

۴-۱ مجموعه داده

مجموعه داده‌های سنتی ماموگرافی اغلب شامل تصاویر آنالوگ هستند که دیجیتالی شده‌اند و در نتیجه حاوی مصنوعات و نویزهای مختلفی هستند. برای رفع این مشکلات، این مطالعه از مجموعه داده INBreast استفاده می‌کند که مجموعه دیجیتالی از فایل‌های تصویر dem همراه با حاشیه‌نویسی‌های xml ارائه شده توسط متخصصان است. این حاشیه‌نویسی‌ها نشان دهنده وجود یا عدم وجود توده‌ها در تصاویر هستند. اندازه تصاویر ۳۳۲۸×۲۵۶۰ یا ۴۰۸۴×۳۳۲۸ پیکسل است. داده‌ها از ۱۱۷ بیمار، هر کدام با چندین تصویر پستان، نشأت گرفته‌اند. شکل ۳ نمونه‌هایی از تصاویر از مجموعه داده را ارائه می‌دهد.

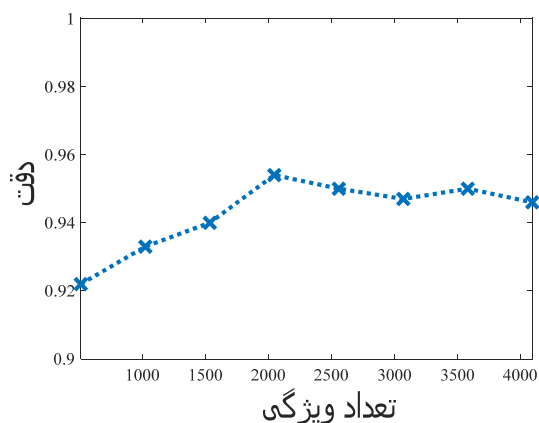
۴-۲ معیارهای ارزیابی

این مطالعه از چندین معیار رایج طبقه‌بندی تصویر پزشکی استفاده می‌کند: دقت (Accuracy)، صحت، فراخوانی، نرخ مثبت کاذب (FRR)، نرخ منفی کاذب (FNR)، ضریب همبستگی ماتریس (MCC) و معیار F-M. این معیارها توسط (۳) تا (۸) تعریف می‌شوند و بر چهار معیار اساسی تکیه دارند: مثبت‌های واقعی (TP)، مثبت‌های کاذب (FP)، منفی‌های کاذب (FN) و منفی‌های واقعی (TN)

روش ارائه‌شده شامل مراحل پیش‌پردازش، استخراج ویژگی‌ها و طبقه‌بندی است. در ابتدا کیفیت تصویر با استفاده از روش CLAHE بهبود یافت و سپس ناحیه توده‌های سرطانی با روش آستانه‌گذاری آتسو شناسایی شد. ویژگی‌های کلیدی با دو مدل پیش‌آموزش‌دیده شبکه‌های عصبی پیچشی ResNet50 و InceptionV3 استخراج شدند. نهایتاً با کمک طبقه‌بند SVM، ویژگی‌ها برای پیش‌بینی نوع تومورها تحلیل می‌شوند. این سیستم با دقت ۹۵/۴٪ نشان داد که می‌تواند یک روش مؤثر برای تشخیص و تسهیل تشخیص زودهنگام سرطان پستان باشد و خطای انسانی و چالش‌های تفسیر تصاویر را کاهش دهد.

مراجع

- [1] S. Łukasiewicz, M. Czezelewski, A. Forma, J. Baj, R. Sitarz, and A. Stanisławek, "Breast cancer-epidemiology, risk factors, classification, prognostic markers, and current treatment strategies-an updated review," *Cancers*, vol. 13, no. 17, pp. Article ID: 4287, 2021.
- [2] C. Cruz-Ramos, *et al.*, "Benign and malignant breast tumor classification in ultrasound and mammography images via fusion of deep learning and handcraft feature," *Entropy*, vol. 25, no. 7, Article ID: 991, 2023.
- [3] K. Korhonen, S. Weinstein, E. McDonald, and E. Conant, "Strategies to increase cancer detection: review of true-positive and false-negative results at digital breast tomosynthesis screening," *Radiographics*, vol. 36, no. 7, pp. 1954-1965, 2016.
- [4] E. Ekpo, M. Alakhras, and P. Brennan, "Errors in mammography cannot be solved through technology alone," *Asian Pacific J. of Cancer Prevention*, vol. 19, no. 2, pp. 291-301, 2018.
- [5] L. Nicosia, *et al.*, "History of mammography: analysis of breast imaging diagnostic achievements over the last century," *Healthcare*, vol. 11, no. 11, Article ID: 1596, 2023.
- [6] F. Shahidi, S. Daud, H. Abas, N. Ahmad, and N. Maarop, "Breast cancer classification using deep learning approaches and histopathology image: a comparison study," *IEEE Access*, vol. 8, pp. 187531-187552, 2020.
- [7] B. Bektaş, İ. Emre, E. Kartal, and S. Gulsecen, "Classification of mammography images by machine learning techniques," in *Proc. 3rd Int. Conf. on Computer Science and Engineering*, pp. 580-585, China, 21-22 Sept. 2018.
- [8] J. Arevalo, F. González, R. Ramos-Pollán, J. Oliveira, and M. Lopez, "Convolutional neural networks for mammography mass lesion classification," in *Proc. 37th Annual Int. Conf. of the IEEE Engineering in Medicine and Biology Society*, pp. 797-800, Milan, Italy, 25-29 Aug. 2015.
- [9] H. Li, L. Zhuang, D. Li, H. Zhao, and Y. Ma, "Benign and malignant classification of mammogram images based on deep learning," *Biomedical Signal Processing and Control*, vol. 51, pp. 347-354, May 2019.
- [10] P. Hepsağ, S. Özel, and A. Yazıcı, "Using deep learning for mammography classification," in *Proc. Int. Conf. on Computer Science and Engineering*, pp. 418-423, Antalya, Turkey, 5-8 Oct. 2017.
- [11] W. Salama and M. Aly, "Deep learning in mammography images segmentation and classification: automated CNN approach," *Alexandria Engineering J.*, vol. 60, no. 5, pp. 4701-4709, Oct. 2021.
- [12] U. Albalawi, S. Manimurugan, and R. Varatharajan, "Classification of breast cancer mammogram images using convolution neural network," *Concurrency and Computation: Practice and Experience*, vol. 34, no. 13, Article ID: e5803, 10 Jun. 2022.
- [13] T. Mahmood, *et al.*, "Breast lesions classifications of mammographic images using a deep convolutional neural network-based approach," *Plos One*, vol. 17, no. 1, Article ID: e0263126, 2022.
- [14] S. Agnes, J. Anitha, S. Pandian, and J. Peter, "Classification of mammogram images using multiscale all nonvolitional neural network (MA-CNN)," *J. of Medical Systems*, vol. 44, no. 1, Article ID: 30, 2019.
- [15] U. K. Sajid, R. A. Khan, S. M. Shah, and S. Arif, "Breast cancer classification using deep learned features boosted with handcrafted features," *Biomedical Signal Processing and Control*, vol. 86, Article ID: 105353, Sept. 2023.
- [16] A. Joseph, M. Abdullahi, S. Junaidu, H. Ibrahim, and H. Chiroma, "Improved multi-classification of breast cancer histopathological images using handcrafted features and deep neural network (dense



شکل ۴: تأثیر تعداد ویژگی انتخاب‌شده در گام انتخاب ویژگی بر دقت روش.

جدول ۴: استفاده از سایر شبکه‌های از پیش آموزش داده شده به عنوان استخراجگر ویژگی.

معیار شبکه	F-M	Recall	Precision	FPR	FNR	Accuracy
ResNet50	0.934	0.934	0.934	0.086	0.066	0.934
InceptionV3	0.916	0.917	0.916	0.116	0.084	0.917
VGG19	0.891	0.891	0.891	0.137	0.109	0.891
GoogleNet	0.888	0.888	0.888	0.138	0.112	0.888
AlexNet	0.887	0.887	0.887	0.129	0.112	0.887

جدول ۵: مقایسه روش پیشنهادی با روش‌های موجود.

معیار مرجع	سال انتشار	Accuracy
روش پیشنهادی	---	0.954
Falconi و همکاران [۱۸]	۲۰۲۰	0.910
Muduli و همکاران [۱۷]	۲۰۲۲	0.913

شده است. برای انجام این مقایسه در روش پیشنهادی، در گام استخراج ویژگی از شبکه معرفی‌شده در جدول ۴ استفاده شده و همچنین گام انتخاب ویژگی حذف گردیده و تمام ویژگی‌های استخراج‌شده به مرحله دسته‌بندی وارد می‌شوند. همان‌طور که مشاهده می‌شود بهترین عملکرد به ترتیب متعلق به دو شبکه ResNet50 و InceptionV3 بوده است. بنابراین در گام استخراج ویژگی از ترکیب ویژگی‌های استخراج‌شده از این دو شبکه استفاده شده است.

در گام انتخاب ویژگی از ۲۰۴۸ ویژگی که نمره بالاتری در الگوریتم MRMR کسب کرده بودند، استفاده شد. این مقدار با سعی و خطا به دست آمده است. در آزمایش بعدی دقت روش به ازای تعداد مختلف ویژگی‌ها به دست آمده و نتایج در نمودار شکل ۴ ترسیم شده است. همان‌طور که مشاهده می‌شود انتخاب ۲۰۴۸ ویژگی، مقدار مناسبی بوده است. در ادامه روش پیشنهادی با دو روش دیگر بر روی مجموعه داده INBreast مقایسه شده است. این دو روش که شامل روش Falconi و همکاران [۱۸] و روش Muduli و همکاران [۱۷] هستند بر روی معیار دقت نتایج خود را گزارش کرده‌اند. نتایج مقایسه در جدول ۵ گزارش شده که نشان می‌دهد بهترین عملکرد متعلق به روش پیشنهادی است.

۵- نتیجه‌گیری

در این مقاله یک سیستم هوشمند برای دسته‌بندی تصاویر دارای توده‌های سرطانی ماموگرافی به دو کلاس خوش‌خیم و بدخیم ارائه شد.

using ROI based color histogram and SVM2," *J. of Medical Systems*, vol. 43, no. 2, Article ID: 29, 2019.

- [25] Z. Amiri, H. Hassanpour, and A. Beghdadi, "Abnormalities detection in wireless capsule endoscopy images using EM algorithm," *the Visual Computer*, vol. 39, no. 7, pp. 2999-3010, 2023.
- [26] Z. Amiri, H. Hassanpour, and A. Beghdadi, "Combining deep features and hand-crafted features for abnormality detection in WCE images," *Multimedia Tools and Applications*, vol. 83, no. 2, pp. 5837-5870, 2024.

زهرا امیری مدرک کارشناسی خود را در رشته مهندسی فناوری اطلاعات در سال ۱۳۹۱ از دانشگاه صنعتی شاهرود و کارشناسی ارشد خود را در رشته مهندسی کامپیوتر (هوش مصنوعی) در سال ۱۳۹۳ از همان دانشگاه دریافت کرد. همچنین در سال ۱۴۰۰ موفق به اخذ مدرک دکتری مهندسی کامپیوتر (هوش مصنوعی) از دانشگاه صنعتی شاهرود شد. وی در حال حاضر عضو هیأت علمی دانشگاه علم و فناوری مازندران است. حوزه‌های پژوهشی او شامل پردازش سیگنال، تصویر، ویدیو و کاربردهای آن است. او مقالات متعددی در این زمینه‌ها منتشر کرده است

زهرا مرتضایی در سال ۱۳۹۲ مدرک کارشناسی، در سال ۱۳۹۶ مدرک کارشناسی ارشد و در سال ۱۴۰۰ مدرک دکترای مهندسی کامپیوتر را از دانشگاه صنعتی شاهرود دریافت کرده است. وی در حال حاضر استادیار گروه ریاضیات و علوم کامپیوتر در دانشگاه حکیم سبزواری است. علاقه‌مندی‌های پژوهشی او شامل پردازش سیگنال، تصویر و ویدئو، بهبود کیفیت تصویر و بازشناسایی افراد است. او مقالات متعددی در این زمینه‌ها منتشر کرده و در توسعه‌ی روش‌های پیشرفته برای بهبود تصویر و تحلیل ویدئو مشارکت داشته است.

layer)," *Intelligent Systems with Applications*, vol. 14, Article ID: 200066, May 2022.

- [17] D. Muduli, R. Dash, and B. Majhi, "Automated diagnosis of breast cancer using multi-modal datasets: a deep convolution neural network based approach," *Biomedical. Signal Processing and Control, pt. B*, vol. 71, Article ID: 102825, Jan. 2022.
- [18] L. Falconi, M. Pérez, W. Aguilar, and A. Conci, "Transfer learning and fine tuning in mammogram bi-rads classification," in *Proc. IEEE 33rd Int. Symp. on Computer-Based Medical Systems*, pp. 475-480, Rochester, MN, USA, 28-30 Jul. 2020.
- [19] C. Szegedy, S. Ioffe, V. Vanhoucke, and A. A. Alemi, "Inception-v4, inception-resnet and the impact of residual connections on learning," in *Proc. 31st AAAI Conf. on Artificial Intelligence*, pp. 4278-4284, San Francisco, CA, USA, 4-9 Feb. 2017.
- [20] B. Jena, G. K. Nayak, and S. Saxena, "Convolutional neural network and its pretrained models for image classification and object detection: a survey," *Concurrency and Computation: Practice and Experience*, vol. 34, no. 6, Article ID: e6767, 10 Mar. 2022.
- [21] A. Caroppo, A. Leone, and P. Siciliano, "Deep transfer learning approaches for bleeding detection in endoscopy images," *Computerized Medical Imaging and Graphics*, vol. 88, Article ID: 101852, Mar. 2021.
- [22] C. Ding and H. Peng, "Minimum redundancy feature selection from microarray gene expression data," *J. of Bioinformatics and Computational Biology*, vol. 3, no. 2, pp. 185-205, Apr. 2005.
- [23] M. M. AlyanNezhadi, H. Dabbaghan, S. Moghani, and M. Forghani, "A painting artist recognition system based on image processing and hierarchical SVM," in *Proc. 5th Conf. on Knowledge Based Engineering and Innovation*, pp. 537-541, Tehran, Iran, 28 Feb.-1 Mar. 2019.
- [24] P. S. Sundaram and N. Santhiyakumari, "An enhancement of computer aided approach for colon cancer detection in WCE images