

الحمد لله



دانشکده مهندسی برق و رباتیک

گروه مهندسی برق-الکترونیک

عنوان: استفاده از روش‌های آماری و آنالیز موجک جهت تشخیص تومورهای سرطانی در
تصاویر ماموگرافی

دانشجو: فرشته تاج‌نیا

استاد راهنما:

دکتر علیرضا احمدی فرد

استاد مشاور:

دکتر علی سلیمانی ایوری

پایان نامه ارشد جهت اخذ درجه کارشناسی ارشد

خرداد ۱۳۹۰

دانشگاه صنعتی شاهرود

دانشکده مهندسی برق و رباتیک

گروه مهندسی برق-الکترونیک

پایان نامه کارشناسی ارشد (رساله دکتری) آقای / خانم

تحت عنوان:

در تاریخ توسط کمیته تخصصی زیر جهت اخذ مدرک کارشناسی ارشد (رساله دکتری) مورد ارزیابی و با درجه مورد پذیرش قرار گرفت.

امضاء	اساتید مشاور	امضاء	اساتید راهنما
	نام و نام خانوادگی :		نام و نام خانوادگی :
	نام و نام خانوادگی :		نام و نام خانوادگی :

امضاء	نماینده تحصیلات تکمیلی	امضاء	اساتید داور
	نام و نام خانوادگی :		نام و نام خانوادگی :
			نام و نام خانوادگی :
			نام و نام خانوادگی :
			نام و نام خانوادگی :

تقدیم بہ پدر و مادر عزیز و مہربانم

مشکر و قدردانی:

با تشکر و سپاس فراوان از استاد راهنمای گرامی‌ام، جناب آقای دکتر علیرضا احمدی‌فرد، که با راهنمایی‌ها و کمک‌هایشان همواره در طول انجام این تحقیق روشن‌گر راهم بودند و من را در انجام این پایان‌نامه یاری و همراهی فرمودند.

دانشجو تأیید می نماید که مطالب مندرج در این پایان نامه (رساله) نتیجه تحقیقات خودش می باشد و در صورت استفاده از نتایج دیگران مرجع آن را ذکر نموده است.

کلیه حقوق مادی مترتب از نتایج مطالعات ، آزمایشات و نو آوری ناشی از تحقیق موضوع این پایان نامه (رساله) متعلق به دانشگاه صنعتی شاهرود می باشد .

خرداد ۱۳۹۰

چکیده:

امروزه تشخیص و درمان زودهنگام سرطان سینه یکی از دغدغه‌های اساسی پزشکان و رادیولوژیست‌ها می‌باشد. تشخیص سرطان سینه در مراحل ابتدایی بیماری باعث افزایش امید به زندگی شده و بیمار را برای مراجعه بعدی درمان آماده می‌کند. ۹۵٪ کسانی که سرطان آن‌ها در مراحل ابتدایی (یعنی زمانی که سرطان فقط در بافت سینه و یا بافت‌های زیرین آن قرار داشته باشد) تشخیص داده شده است، بیش از ۵ سال از زمان تشخیص زنده مانده‌اند. در حال حاضر ماموگرافی تنها روش تصویربرداری مورد استفاده و موثر برای تشخیص سرطان سینه می‌باشد. Micro-Calcificationها یا به طور مخفف، MCها، رسوب‌های کوچک کلسیم هستند که به صورت نقاط روشن کوچکی در تصاویر ماموگرافی دیده می‌شوند و نشانه‌ای از بیماری سرطان سینه می‌باشند. در این تحقیق هدف طراحی، شبیه‌سازی، بررسی و مقایسه سیستم‌های CAD^۱ می‌باشد که قادر به تشخیص MCها در تصاویر ماموگرافی با دقت بالایی باشند. هدف یک سیستم CAD تشخیص و پیدا کردن ناهنجاری‌ها و ناحیه‌های مشکوک در ماموگرام‌های دیجیتال با استفاده از کامپیوتر و کمک به رادیولوژیست‌هاست. هدف از این تحقیق، بررسی چند سیستم CAD و معرفی روش‌های تشخیص MC است که در این سیستم‌ها پیشنهاد، پیاده‌سازی و در نهایت تحلیل و مقایسه شده است. تفاوت اصلی سیستم‌های CAD طراحی شده و شبیه‌سازی شده در این تحقیق در مرحله استخراج ویژگی از تصاویر ماموگرافی و همچنین کلاسه‌بندی استفاده شده جهت تشخیص MCها می‌باشد. استفاده از ویژگی‌های آماری و فرکانسی به جای ویژگی‌های روشنایی تصویر و مقایسه نتایج آن‌ها با استفاده از کلاسه‌بندی‌های

^۱ Computer Aided Detection

SVM^۱ و NN^۲ عمده کار انجام شده در این تحقیق می‌باشد. در نهایت با آزمایشات انجام شده نتیجه شده است که سیستم CAD با استفاده از ویژگی‌های آماری و فرکانسی و SVM بهترین نتیجه‌ی خروجی را در تشخیص مناطق MC، در تصاویر ماموگرافی دارد. در این رابطه همچنین راهکارهایی جهت بهبود کیفیت تصویر ماموگرافی و بهبود تشخیص MCها داده شده و در آخر روشی برای جداسازی هر MC از بافت‌های مجاور ارائه گردیده است.

کلمات کلیدی: ماموگرافی - Micro Calcification - سیستم CAD - تبدیل موجک - کلاسه بند SVM - کلاسه بند شبکه عصبی - ساختار توپوگرافیک تصویر.

^۱ Support Vector Machine
^۲ Neural Network

لیست مقالات مستخرج از پایان نامه:

۱. تخمین واریانس نویز در تصاویر به کمک مدل هوشمند فازی (ICEE ۲۰۱۱)

۲. Detection of Micro-Calcification Clusters in Mammograms Using SVM classifier and Parzen-Window Technique (ICMLC ۲۰۱۱)

فهرست مطالب

فصل ۱: مقدمه	۱
فصل ۲: بررسی تشخیص سرطان سینه با استفاده از سیستم‌های CAD و مروری بر کارهای گذشته	۴
۱-۲-۱ تصویربرداری از سرطان سینه	۵
۱-۲-۱-۱ ماموگرافی دیجیتال و ماموگرافی فیلم	۵
۲-۲-۱ تشخیص به کمک کامپیوتر	۶
۱-۲-۲ مزایای استفاده از سیستم‌های CAD	۹
۲-۲-۲ نماهای چندگانه تکنیک‌های سیستم‌های CAD	۱۰
۳-۲-۲ شمای کلی یک سیستم CAD	۱۱
۳-۲-۳ بهبود کیفیت تصاویر (Image Enhancement)	۱۲
۱-۳-۲ روش‌های مستقیم بهبود کنتراست تصویر	۱۳
۲-۳-۲ روش‌های غیرمستقیم بهبود کنتراست تصویر	۱۵
۱-۲-۳-۲	۱۶
۴-۲-۲ روش‌های تشخیص MCها	۱۷
۱-۴-۲ روش‌های مبتنی بر بهبود کیفیت تصویر	۱۸
۲-۴-۲ روش‌های مبتنی بر مدل‌های آماری	۱۸
۳-۴-۲ روش‌های تجزیه چند مقیاسی	۱۹
۴-۴-۲ روش‌های آموزش ماشین	۲۰
۵-۲-۲ تشخیص توده‌ها (mass)	۲۱
مقدمه	۲۱
۱-۵-۲ روش‌های Pixel-based	۲۳
۲-۵-۲ روش‌های Region-based	۲۴
فصل ۳: بهبود کیفیت تصاویر ماموگرافی (IMAGE ENHANCEMENT)	۲۵
مقدمه	۲۶
۱-۳ حذف نویز در تصاویر ماموگرافی تبدیل موجک دیادیک	۲۷
۲-۳ عملیات پیش پرداز	۴۱
۱-۲-۳ حذف پس زمینه تصاویر ماموگرافی	۴۱
فصل ۴: تشخیص MCها در تصاویر ماموگرافی	۴۴
مقدمه	۴۵

۴۵	۱-۴ ویژگی‌های استخراج شده از تصاویر ماموگرافی
۴۶	۱-۱-۴ استخراج ویژگی‌های روشنایی تصویر
۴۹	۲-۱-۴ استخراج ویژگی‌های فرکانسی
۴۹	۱-۲-۱-۴ تبدیل موجک و خواص آن
۵۷	۳-۱-۴ استخراج ویژگی‌های آماری و ترکیب آن‌ها با ویژگی‌های فرکانسی
۵۸	۲-۴ کلاسه‌بندی در تصاویر ماموگرافی
۵۹	۱-۲-۴ کلاسه بند شبکه عصبی (NN)
۶۰	۱-۱-۲-۴ شبکه عصبی مصنوعی
۶۴	۲-۱-۲-۴ آموزش شبکه به روش پسانتشار خطا
۷۲	۳-۱-۲-۴ تشخیص MCها در تصاویر ماموگرافی با استفاده از شبکه عصبی
۷۳	۲-۲-۴ کلاسه بند ماشین بردار پشتیبان (SVM)
۱-۲-۲-۴	تشخیص MCها در تصاویر ماموگرافی با استفاده از کلاسه بند ماشین بردار پشتیبان
۷۹	نتیجه‌گیری
۸۰	۳-۴ نتیجه‌گیری
۸۳	فصل ۵: نتایج روش پیشنهادی در تشخیص MC در تصاویر ماموگرافی
۸۴	مقدمه
۸۴	۱-۵ پایگاه داده تصاویر ماموگرافی
۸۵	۲-۵ داده‌های آموزشی و داده‌های آزمایشی
۸۶	۳-۵ نتایج آزمایش بر روی سیستم‌های CAD
۸۸	۴-۵ نتایج آزمایش بر روی تصاویر ماموگرافی
۸۹	۵-۵ مقایسه سیستم‌های CAD مورد بررسی با رسم نمودارهای ROC
۸۹	۱-۵-۵ رسم نمودار ROC
۹۲	۲-۵-۵ اعمال آستانه بر نقشه احتمالاتی خروجی کلاسه بندها و رسم نمودار ROC
۱۰۴	فصل ۶: جداسازی مرز MCها در تصاویر ماموگرافی
۱۰۵	مقدمه
۱۰۵	۱-۶ جداسازی مرز MCها در تصاویر ماموگرافی
۱۰۷	۲-۶ تعیین ساختار توپوگرافیک تصاویر ماموگرافی
۱۰۸	۱-۲-۶ حذف نویز از تصویر ورودی
۱۱۰	۲-۲-۶ استخراج برجسب‌های توپوگرافیک
۱۱۷	۳-۶ جداسازی MC بر اساس استخراج ناحیه مبتنی بر روشنایی

۱۲۱	فصل ۷: نتیجه‌گیری و ارائه پیشنهادات
۱۲۲	نتیجه‌گیری
۱۲۳	پیشنهاداتی برای ادامه تحقیق
۱۲۵	مراجع:

فهرست شکل‌ها

۷	شکل ۱-۲
۹	شکل ۲-۲
۱۲	شکل ۳-۲
۱۳	شکل ۴-۲
۱۵	شکل ۵-۲
۱۷	شکل ۶-۲
۲۲	شکل ۷-۲
۲۳	شکل ۸-۲
۲۹	شکل ۱-۳
۳۱	شکل ۲-۳
۳۳	شکل ۳-۳
۳۵	شکل ۴-۳
۳۶	شکل ۵-۳

٣٦.....	شکل ٣-٦.....
٣٧.....	شکل ٣-٧.....
٣٨.....	شکل ٣-٨.....
٤٠.....	شکل ٣-٩.....
٤١.....	شکل ٣-١٠.....
٤١.....	شکل ٣-١١.....
٤٤-٤٣.....	شکل ٣-١٢.....
٤٩.....	شکل ٤-١.....
٤٩.....	شکل ٤-٢.....
٥٥.....	شکل ٤-٣.....
٥٥.....	شکل ٤-٤.....
٥٨-٥٧.....	شکل ٤-٥.....
٦١.....	شکل ٤-٦.....
٦٣.....	شکل ٤-٧.....
٦٤.....	شکل ٤-٨.....
٦٥.....	شکل ٤-٩.....
٧٤.....	شکل ٤-١٠.....
٧٥.....	شکل ٤-١١.....

۷۹	شکل ۴-۱۲
۸۳	شکل ۴-۱۳
۹۲	شکل ۵-۱
۱۰۱-۹۵	شکل ۵-۲
۱۰۲	شکل ۵-۳
۱۰۳	شکل ۵-۴
۱۰۵	شکل ۵-۵
۱۰۹	شکل ۶-۱
۱۱۱	شکل ۶-۲
۱۱۶-۱۱۴	شکل ۶-۳
۱۱۸	شکل ۶-۴
۱۲۰	شکل ۶-۵
۱۲۲	شکل ۶-۶

فهرست جدول‌ها

۸۷	جدول ۵-۱
۸۸	جدول ۵-۲

فصل ۱

مقدمه

سرطان به عنوان یک بیماری لاعلاج مدت‌هاست که بخش عظیمی از تحقیقات پزشکی و غیر پزشکی را به خود اختصاص داده است. علم ثابت کرده است با وجود این که یک درمان قطعی برای این بیماری نیست، اما تشخیص زودهنگام و به موقع این بیماری به پزشکان کمک می‌کند که حداقل از پیشرفت این بیماری جلوگیری کنند. یکی از رایج‌ترین سرطان‌ها به خصوص در بین زنان سرطان سینه است و از میان روش‌های مختلف تشخیص سرطان سینه، ماموگرافی به عنوان روشی با میزان مقبولیت بالا بسیار رایج و متداول می‌باشد.

سرطان زمانی به وجود می‌آید که سلول‌های قسمتی از بدن بطور غیرقابل کنترل رشد کنند و به سرعت تقسیم شوند و به سمت بافت‌های مختلف بدن هجوم ببرند و در تمام بدن منتشر شوند. به مجموعه‌ای از این سلول‌های غیرقابل کنترل تومور^۱ گفته می‌شود. در سرطان سینه، بیماری معمولاً در لوبول‌ها یا همان مجاری سینه آغاز شده و سپس می‌تواند از مجاری و دیواره‌های غدد نفوذ کرده و بافت‌های چربی اطراف و یا حتی سایر قسمت‌های بدن شخص را مورد حمله قرار دهد [۱].

۷۸ درصد موارد سرطان سینه در زنان بالای ۵۰ سال مشاهده شده است و ۶ درصد در زنان کمتر از ۴۰ سال گزارش شده است. در اکثر کشورهای پیشرفته مانند ایالت متحده مهم‌ترین عامل مرگ و میر در زنان بین ۲۰ تا ۵۹ سال سرطان سینه می‌باشد.

تشخیص و درمان زودهنگام سرطان سینه باعث افزایش امید به زندگی شده و بیمار را برای مراجعه بعدی درمان آماده می‌کند. ۹۵٪ کسانی که سرطان آن‌ها در مراحل ابتدایی (یعنی زمانی که سرطان فقط در بافت سینه و یا بافت‌های زیرین آن قرار داشته) تشخیص داده شده

^۱ Tumor

است، بیش از ۵ سال از زمان تشخیص زنده مانده‌اند. این مقدار مقایسه می‌شود با ۲۳٪ از زمانی که بیماران دارای سرطان پیشرفته بوده و حدود ۵ سال زنده مانده‌اند.

ماموگرافی نوع خاصی از تصویربرداری بوسیله‌ی اشعه ایکس می‌باشد که برای تهیه تصاویر دقیق از سینه استفاده می‌شود. در اکثر موارد ماموگرافی برای کمک به رادیولوژیست یا جراح برای هدایت بهتر چاقو در زمان جراحی استفاده می‌شود. در حال حاضر ماموگرافی تنها روش اثبات شده برای تشخیص سرطان سینه می‌باشد. یکی از آخرین پیشرفت‌های حاصل شده در زمینه ماموگرافی، ماموگرافی دیجیتال یا ماموگرافی با کمک کامپیوتر است [۱].

Micro-Calcificationها یا به طور مخفف، MCها، رسوب‌های کوچک کلسیم هستند که به صورت نقاط روشن کوچکی در ماموگرام‌ها دیده می‌شوند. توده‌های MC می‌توانند نماینده خوبی از سرطان سینه باشند. آنها در ۳۰٪ تا ۵۰٪ از موارد تشخیص داده شده با تصویربرداری ماموگرافی مشاهده می‌شوند.

محققان رشته پزشکی نیازمند اطلاع از تکنولوژی نظیر سیستم‌های CAD^۱ و همچنین همکاری با دانشمندان برای دستیابی به پیشرفت‌های مختلف هستند. تلاش‌های انجام گرفته در زمینه سیستم‌های CAD به منظور تجهیز پزشکان به روش‌های مختلف تجزیه و تحلیل، صورت پذیرفته است. هدف اصلی سیستم CAD تشخیص و پیدا کردن ناهنجاری‌ها و ناحیه‌های مشکوک در ماموگرام‌های دیجیتال با استفاده از اتوماتیک کردن مراحل تشخیص با استفاده از کامپیوتر می‌باشد [۱].

^۱ Computer Aided Diagnosis

در این تحقیق هدف طراحی، شبیه‌سازی، بررسی و مقایسه سیستم‌های CAD می‌باشد که قادر به تشخیص MCها در تصاویر ماموگرافی با دقت بالایی باشند. به همین منظور در فصل دوم پس از ارائه تاریخچه به ارائه‌ی اطلاعات کلی درباره اهمیت و چگونگی طراحی سیستم‌های CAD پرداخته‌ایم. سپس در فصل سوم بهبود کیفیت تصاویر ماموگرافی را مورد بررسی قرار داده و روشی بهینه برای انجام بهبود در این تصاویر ارائه داده‌ایم. در فصل چهارم پایان‌نامه، روش‌های پیشنهادی و شبیه‌سازی شده در این تحقیق به تفصیل شرح داده شده است. فصل پنجم شامل ارائه نتایج و مقایسه روش‌های پیشنهادی و شبیه‌سازی شده است. در فصل ششم جداسازی MCها از محیط اطراف آنها مورد بررسی قرار گرفته و روشی برای جداسازی پیشنهاد و شبیه‌سازی شده و به همراه نتایج آن در این فصل ارائه شده است. فصل هفتم شامل جمع‌بندی و ارائه پیشنهاداتی برای کارهای بعدی می‌باشد. در پایان فهرست منابع استفاده شده در این تحقیق آورده شده است.

فصل ۲

بررسی تشخیص سرطان سینه با استفاده از سیستم‌های CAD و

مروری بر کارهای گذشته

۲-۱- تصویربرداری از سرطان سینه

برای تشخیص سرطان از تصویر برداری‌های مختلفی از جمله تصاویر رزونانس مغناطیسی^۱، تصاویر فراصوت^۲ و تصاویر اشعه ایکس^۳ استفاده می‌شود [۲].

ماموگرافی^۴ یکی از روش‌های تصویر برداری با اشعه ایکس است که از پرتوهای اشعه ایکس دوز-پایین^۵ با کنتراست بالا و رزولوشن بالا در تشخیص سرطان استفاده می‌کند. تصاویر ماموگرافی، در حال حاضر، موثرترین روش برای تشخیص زودهنگام علائم سرطان سینه است [۳].

۲-۱-۱ ماموگرافی دیجیتال و ماموگرافی فیلم

ماموگرافی دیجیتال و ماموگرافی فیلم دو نوع تکنولوژی هستند که به طور همزمان جهت تشخیص سرطان سینه به کار می‌روند. ماموگرافی فیلم در واقع روش سنتی ماموگرافی است که در آن تصاویر اشعه X بر روی فیلم ذخیره می‌شود.

ماموگرافی دیجیتال همزمان با پیشرفت‌هایی که در تکنولوژی کامپیوتر و صنایع الکترونیک نوری بوجود آمد، توسعه و رشد یافت. در ماموگرافی دیجیتال ابتدا تصویر اشعه X از بافت سینه تولید می‌شود و سپس این تصویر مستقیماً به شکل الکترونیکی در یک ماشین ذخیره می‌گردد.

^۱ Magnetic resonance

^۲ Ultrasound


^۳ X-ray

^۴ Mammography

^۵ low-dose

هر کدام از روش‌های ماموگرافی دیجیتال و ماموگرافی فیلم مزایا و معایب مخصوص به خود را دارند. یکی از مزایای عمده ماموگرافی دیجیتال این است که تصویر ماموگرافی حاصل از این روش را می‌توان توسط سیستم‌های تشخیص با کمک کامپیوتر یا همان سیستم‌های CAD^۱ تجزیه و تحلیل کرد.

رایج‌ترین پروجکشن‌های تصویر سینه در ماموگرام‌ها شامل MLO^۲ و CC^۳ هستند [۴]. در تصویر MLO ماهیچه سینه‌ای در بالای تصویر مشاهده می‌شود. در شکل ۱-۲ نمونه‌ای از این تصاویر آورده شده است.



شکل ۱-۲: یک تصویر ماموگرافی شامل دو پروجکشن متداول MLO و CC [۴].

۲-۲ تشخیص به کمک کامپیوتر

یکی از مشکلات ماموگرام‌ها کنتراست نسبتاً پایین آن‌ها می‌باشد. این موضوع باعث می‌شود که تفسیر تصاویر ماموگرافی برای رادیولوژیست‌ها مشکل شود. مطالعات نشان می‌دهد

^۱ Computer Aided Diagnosis

^۲ Mediolateral Oblique

^۳ Craniocaudal

که تصاویر ماموگرافی دارای نرخ تشخیص مثبت و منفی بالایی هستند که این موضوع باعث می‌شود که تعدادی از زنانی که مبتلا به این بیماری نیستند تحت مراقبت‌های کلینیکی و نمونه‌برداری از سینه قرار بگیرند و یا تعدادی از زنان مبتلا به سرطان زمان مناسب برای درمان را از دست بدهند [۵]-[۸].

روش‌های زیادی تاکنون برای افزایش دقت و ویژگی‌ها و حساسیت تصاویر ماموگرافی پیشنهاد شده است که نیاز به نمونه‌برداری از بافت سینه را کاهش می‌دهد [۹]-[۱۲].

دوباره‌خوانی تصاویر روشی است که سهم نمونه‌های سرطانی تشخیص داده نشده را کاهش می‌دهد [۷]-[۸]. ایده اصلی این است که از دو رادیولوژیست در خواندن استفاده شود. در مرجع [۸] Warren و Duffy نشان داده‌اند که دوباره‌خوانی می‌تواند حساسیت و تاثیر تصویربرداری را در تشخیص افزایش دهد. به هر حال حجم کاری و هزینه مربوط به دوباره‌خوانی زیاد است. به جای این سیستم CAD به عنوان "چشم دوم رادیولوژیست" به رادیولوژیست‌ها در تفسیر تصاویر ماموگرافی کمک می‌کند [۹].

سیستم‌های CAD به رادیولوژیست‌ها در تعیین محل بیماری‌های بدخیم در تصاویر ماموگرافی دیجیتال کمک می‌کنند. این سیستم‌ها اولین بار در دهه ۱۹۹۰ استفاده شدند و سپس به مرور زمان با افزایش مزایا و دقت این سیستم‌ها استفاده از آنها افزایش پیدا کرد [۱۰].



شکل ۲-۲: تشخیص سرطان سینه به کمک کامپیوتر

تحقیقات صنعتی با پیشرفت‌های زیادی در زمینه ماموگرافی دیجیتال روبه‌رو است. در حال حاضر تنها سیستم CAD که توسط ارگان مدیریت غذا و دارو FDA^۱ به ثبت رسیده و تایید شده است ImageChecker می‌باشد. این سیستم در تصویربرداری و تشخیص در تصاویر ماموگرافی دیجیتال استفاده می‌شود. CA.ImageChecker، اولین سیستم CAD بود که در سال ۱۹۹۸ توسط FDA به ثبت رسید. سپس این سیستم در بیش از ۱۴۰۰ کلینیک تشخیص سرطان در سراسر جهان نصب شد. تحقیقات آکادمیک نقش مهمی را در پیشرفت سیستم‌های CAD و تصاویر ماموگرافی دیجیتال بازی می‌کند.

گروهی از دانشمندان دانشکده رادیولوژی دانشگاه شیکاگو اولین کسانی بودند که سیستم‌های CAD را در مراکز کلینیکی به کار بردند. در ژانویه ۲۰۰۵ مراکز پزشکی دانشگاه شیکاگو توافق کردند که برای توسعه یک مرکز کتابخانه‌ای از سیستم‌های CAD ماموگرافی با یکدیگر همکاری کنند.

۲-۲-۱ مزایای استفاده از سیستم‌های CAD

به کمک CADها برای خواندن تصویر ماموگرافی به جای دو رادیولوژیست، به یکی نیاز است. استفاده از CADها حجم کاری کارشناسان را کاهش می‌دهد. ثابت شده است که سیستم‌های CAD، احتمال تشخیص سرطان سینه را در مراحل اولیه آن افزایش می‌دهد. برای مثال Morton et al. در مرجع [۱۳] نشان داده‌اند که استفاده از سیستم‌های CAD باعث می‌شود که میزان تشخیص سرطان سینه در تصاویر ماموگرافی ۷.۶۲٪ افزایش یابد. همچنین

^۱ Food Drug Administration


افزایش کم اما قابل قبول نرخ بازخوانی به میزان ۰.۹۳٪ و کمترین افزایش در میزان نمونه‌برداری در موارد خوش‌خیم از مزایای استفاده از سیستم‌های CAD است. همچنین Brem et al. در مرجع [۱۴] نشان داده‌اند که CAD ها تشخیص درست سرطان سینه را با افزایش میزان حساسیت رادیولوژیست‌ها به مقدار ۲۱.۲٪ بهبود می‌بخشند.

۲-۲-۲ نماهای چندگانه تکنیک‌های سیستم‌های CAD

به طور کلی حساسیت سیستم‌های CAD در تشخیص توده‌های سرطانی نسبتاً بالا است. برای کاهش نرخ مثبت تشخیص‌های غلط تلاش‌های زیادی برای گسترش تکنیک‌های CAD ای که از اطلاعات زمینه و تقارن و نماهای چندگانه استفاده می‌کنند، وجود دارد [۲].

اکثر سیستم‌های CAD تنها از اطلاعات یک نمای تصویر در زمان استفاده می‌کنند. در مواردی که بهبود کارایی CAD ها مورد نظر است نتایج همه نماها در پایان به طور مستقل ترکیب می‌شوند. به عبارت دیگر رادیولوژیست از اطلاعات تمام نماها در تفسیر خود استفاده می‌کند. آن‌ها اینگونه آموزش داده شده‌اند که از مقایسه تقارن میان تصویر سینه چپ و راست نواحی مشکوک را تشخیص دهند. (شکل ۲-۳)

مقایسه زودگذر هر دو جفت ماموگرام سبب می‌شود که نواحی جدید و یا در حال رشد سرطان در ماموگرام تشخیص داده شود. این حقیقت که استفاده از اطلاعات تصاویر MLO و CC به طور همزمان دقت تشخیص سرطان را بهبود می‌بخشد، امروزه برای همه شناخته شده است.



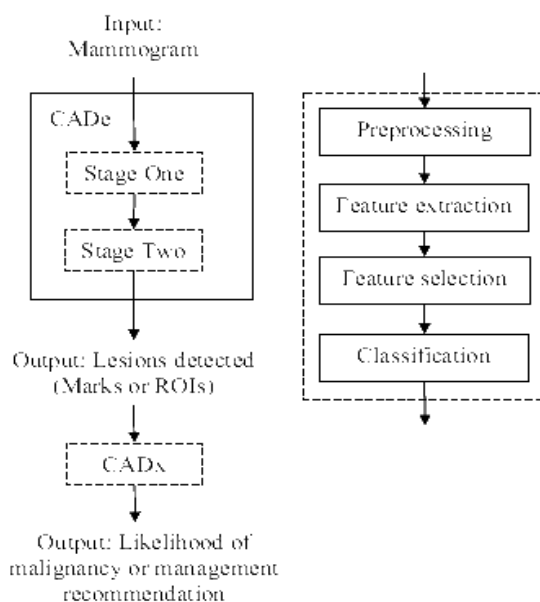
شکل ۲-۳: تصاویر (a) و (b) نمونه ای از *asymmetry bilateral* را نشان می‌دهد و تصاویر (c) و (d) روشی برای یافتن این نامتقارن بودن است [۲].

۲-۲-۳ شمای کلی یک سیستم CAD

در بیشتر سیستم‌های CAD پیشرفته، چند قدم اساسی و متداول وجود دارد که باید به منظور یافتن نواحی سرطانی انجام شود. مراحل فوق در شکل ۲-۴ آورده شده است [۱۵].

بیشتر الگوریتم‌های تشخیص سرطان دو مرحله اساسی دارند. در مرحله اول، هدف یافتن Lesion‌های مشکوک در یک حساسیت بالا است. در مرحله بعدی هدف کاهش نرخ *false positive* است بدون اینکه حساسیت تغییر چشمگیری داشته باشد. نرخ *false positive* درصد نمونه‌های نرمال و فاقد بیماری که توسط سیستم CAD به عنوان بیماری تشخیص داده شده است. مراحل که در بخش طراحی درگیر آن‌ها هستیم در قسمت خاکستری شکل ۲-۴ آورده شده است [۱۵].

در بعضی از دیدگاه‌ها، ممکن است بعضی از مراحل شامل روش‌های خیلی ساده‌ای شوند و یا به کلی حذف گردند. بیشتر الگوریتم‌های CADها با نواحی مورد علاقه (ROI)^۱ شروع می‌شوند. مراحل طراحی چنین سیستمی هم در شکل ۲-۴ آورده شده است [۱۵].



شکل ۲-۴: شمای کلی الگوریتم طراحی یک سیستم CAD [۱۵]

۳-۲ بهبود کیفیت تصاویر (Image Enhancement)

مقدمه

تصاویر ماموگرافی معمولاً دارای وضوح و کنتراست ضعیفی هستند. به همین دلیل معمولاً افزایش و بهبود کیفیت تصویر قبل از پیاده سازی سیستم CAD ضروری به نظر می‌رسد.

^۱ Region Of Interest

تصاویر بهبود یافته برای انجام عملیات خاص و همچنین اعمال توابع هدف بهتر از تصویر اولیه است [۱۶].

روش‌های بهبود کیفیت تصاویر را می‌توان به دو نوع متفاوت دسته‌بندی کرد: روش‌های مستقیم بهبود کنتراست تصویر و روش‌های غیرمستقیم بهبود کنتراست تصویر.

۲-۳-۱ روش‌های مستقیم بهبود کنتراست تصویر

در روش‌های مستقیم بهبود کنتراست تصویر، ابتدا اندازه‌گیری کنتراست تعریف می‌شود و سپس بهبود کنتراست مستقیماً با دستکاری کنتراست تصویر صورت می‌پذیرد [۱۷]- [۱۹].

یکی از روش‌های بهبود مستقیم کنتراست تصویر در مرجع [۲۰] معرفی شده است که در آن Dhawan et al. یک کنتراست محلی برای هر پیکسل را به صورت متوسط روشنایی‌های مرکز و اطراف پیکسل تعریف می‌کنند. مرکز و اطراف هر پیکسل هم به طور خاص در این مقاله تعریف شده است. میزان کنتراست هر پیکسل هم با استفاده از یک تابع به کنتراست جدید بهبود می‌یابد.

Tang et al. در مرجع [۲۱] روشی برای بهبود مستقیم کنتراست تصویر ارائه کرده‌اند که در آن یک اندازه‌گیری کنتراست محلی چند مقیاسی در حوزه موجک^۱ تعریف شده است. روش‌های بهبود در حوزه موجک با دستکاری کردن کنتراست اندازه‌گیری شده با استفاده از


^۱ Wavelet

اطلاعات فرکانس بالا و فرکانس پایین انجام می‌شود. مزایای استفاده از این روش در مرجع [۲۱] به صورت زیر دسته‌بندی می‌شود:

(۱) آسانی تنظیم پارامترها

(۲) عملیات بهبود می‌تواند بر روی تصاویر فشرده شده JPEG۲۰۰۰ در مرحله فشرده‌سازی اعمال شود که در این صورت زمان مورد نیاز برای بهبود کیفیت تصویر کاهش می‌یابد. در این روش در واقع ضرایب موجک در مرحله فشرده‌سازی اصلاح می‌شوند.

(۳) روش ارائه شده، اندازه‌گیری چندمقیاسی را اصلاح می‌کند به شکلی که با سیستم بینایی انسان منطبق است، به طوری که تصویر اصلاح شده کیفیت بصری بهتری دارد. شکل ۲-۵ یک نمونه از تصویر بهبودیافته با استفاده از این روش را نشان می‌دهد.



شکل ۲-۵: بهبود کیفیت تصویر به صورت مستقیم (a) تصویر اولیه (b) تصویر بهبود یافته [۲]

۲-۳-۲ روش‌های غیرمستقیم بهبود کنتراست تصویر

مقدمه

بر خلاف روش‌های مستقیم، در روش‌های غیرمستقیم بهبود کنتراست تصویر، کنتراست تصویر بصورت مستقیم دستکاری نمی‌شود. روش‌های غیرمستقیم شامل روش‌های histogram equalization, un-sharp masking و multi-scale/wavelet enhancement می‌شود. در بین این روش‌ها، روش‌های multi-scale/wavelet enhancement به طور گسترده‌ای مورد مطالعه قرار گرفته‌اند. دلیل استفاده از این روش‌ها این است که مشاهده شده است تصاویر ماموگرافی شامل ویژگی‌هایی هستند که خصوصیاتشان در مقیاس‌های مختلف فرق می‌کند [۲۲].

به طور مثال نواحی اشغال شده توسط MCها مساحت کوچکی در تصاویر ماموگرافی می‌باشد، در حالی که اشیاء بزرگ با مرزهای آرام مثل massها عمدتاً مساحت بزرگی دارند [۲۲]. بنابراین ویژگی‌های مختلفی را میتوان از یک تصویر انتخاب کرد و در مقیاس‌های مختلف بهبود بخشید.

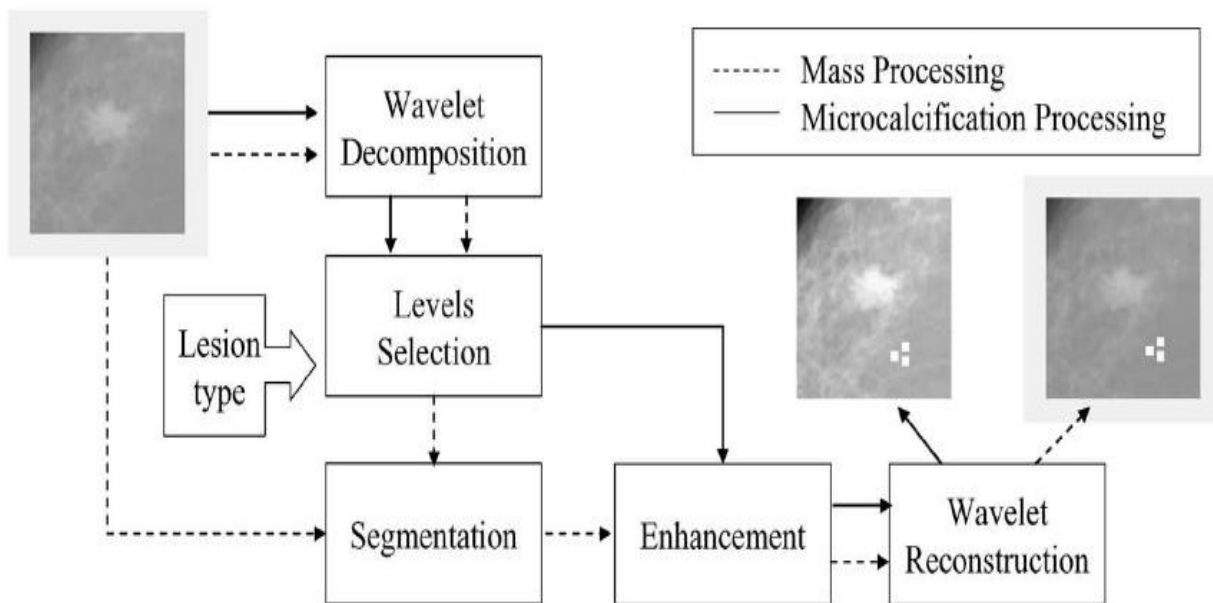
۲-۳-۲-۱ حذف نویز و بهبود کیفیت در تصاویر ماموگرافی برای تشخیص

سرطان سینه بر اساس تبدیل موجک دیادیک^۱ [۲۳]

^۱ Dyadic Wavelet Transform

در مرجع [۲۳] Arianna Mencattin et al یک الگوریتم جدید برای حذف نویز و بهبود کیفیت در تصاویر بر اساس تبدیل موجک دیادیک پیشنهاد داده است. شمای کلی الگوریتم در شکل ۲-۵ نشان داده شده است. همان‌طور که در شکل ۲-۶ دیده می‌شود الگوریتم شامل دو مسیر جداگانه برای بهبود بخشیدن تصاویر شامل MCها و تصاویر شامل massها است.

مرحله حذف نویز که قبل از مرحله بهبود کیفیت بر روی کل تصاویر انجام می‌شود بر اساس تخمین واریانس نویز تکرار شونده محلی انجام می‌شود [۲۴].



شکل ۲-۶: بلوک دیاگرام الگوریتم ارائه شده در مرجع [۲۳]

۲-۴ روش‌های تشخیص MCها

MCها رسوب‌های کوچک کلسیم هستند که به صورت نقاط روشن کوچکی در ماموگرام‌ها دیده می‌شوند. توده‌های MCها می‌توانند نماینده خوبی از سرطان سینه باشند. آن‌ها در ۳۰٪ تا ۵۰٪ از موارد تشخیص داده شده با تصویربرداری ماموگرافی مشاهده می‌شوند [۲۵]. در دو دهه گذشته تحقیقات گسترده‌ای در روش‌های کامپیوتری تشخیص صورت گرفته است، که چندین مقاله این روش‌ها را بررسی کرده‌اند [۲۶].

همان طور که در مرجع [۲] اشاره شده است تشخیص MCها را می‌توان در ۴ گروه کلی دسته‌بندی کرد:

(۱) روش‌های مبتنی بر بهبود کیفیت تصویر

(۲) روش‌های مبتنی بر مدل‌های آماری

(۳) روش‌های تجزیه چند مقیاسی

(۴) روش‌های آموزش ماشین

بعضی از تحقیقات را می‌توان در بیشتر از یکی از این ۴ گروه دسته‌بندی کرد. برای مثال یک کلاسه بند شبکه‌ی عصبی ممکن است از ویژگی‌های حوزه فرکانس به عنوان ورودی استفاده کند.

۲-۴-۱ روش‌های مبتنی بر بهبود کیفیت تصویر

ایده اصلی این روش‌ها با این انگیزه به وجود آمده است که MC ها نقاطی روشن‌تر از محیط اطرافشان هستند. بنابر این این روش‌ها بر روی بهبود کنتراست تصویر کار می‌کنند و سپس با استفاده از یک آستانه، MCها را از اطراف آن جداسازی میکنند. برای مثال در مرجع [۲۷] بهبود کیفیت با استفاده از تکنیک تصویر اختلافی^۱ به همراه اپراتورهای مورفولوژیکی جهت کاهش نرخ false positive انجام می‌گیرد. تصویر اختلافی با استفاده از دو فیلتر به دست می‌آید. فیلتر اول برای بهبود کنتراست MCها و فیلتر دوم برای فشرده سازی آن‌ها به کار می‌روند. یک ایده متداول در روش‌ها، اعمال روش‌های بهبود کیفیت تصویر به عملیات پردازش تصویر در مرحله ی pre-processing یا post-processing است. مزیت این کار راحتی انجام، و پیاده‌سازی و تاثیر آن در عملیات و کاربردهای کلینیکی می‌باشد.

۲-۴-۲ روش‌های مبتنی بر مدل‌های آماری

ایده اصلی این روش‌ها بر اساس تفاوت‌های آماری MCها با محیط اطرافشان است. برای مثال در مرجع [۲۸] تفاوت‌ها در مشخصات آماری مرتبه‌های بالا برای مثال skewness (moment مرتبه سوم) و kurtosis (moment مرتبه چهارم) استفاده شده است. با این فرض که نواحی شامل MC دارای توزیع مشابه گوسی و نواحی شامل MC دارای توزیع مشابه غیر گوسی است، می‌توان MCها را از محیط اطرافشان جداسازی کرد. چرا که توزیع گوسی دارای

^۱ Difference image

skewness و kurtosis برابر با صفر می‌باشد و توزیع غیر گوسی دارای skewness و kurtosis غیر صفر است.

در بعضی از تحقیقات اخیر از مدل پنهان مارکوف (MRF) در تشخیص MCها استفاده شده است. استفاده از مدل MRF برای جداسازی تصویر نسبت به دیگر مدل‌های آماری بسیار ارجحیت دارد زیرا توانایی این مدل در کاراکتر بندی توزیع چگالی حوزه فضایی^۱ تصویر بالا است. به هر حال تخمین یک توزیع اولیه مناسب در این موارد یک موضوع مخاطره‌آمیز محسوب می‌شود.

۲-۴-۳ روش‌های تجزیه چند مقیاسی

در این دسته از روش‌ها تلاش بر این است که تفاوت‌های فرکانسی میان لکه روشن MC و اطرافش را به عنوان ویژگی متمایز کننده، به کار بگیرند. به طور معمول تبدیل موجک به طور بسیار گسترده برای تشخیص MCها مورد استفاده قرار گرفته است. در مرجع [۲۹] از تبدیل un-decimated bi-orthogonal wavelet استفاده شده است که در آن MCها به صورت اشکال گوسی دوار با عرض‌های متغیر در مقیاس‌های متفاوت نمایش داده می‌شوند. سپس با استفاده از اعمال یک تابع جداساز fisher ضرایب وزندهی می‌شود و از زیرباندهای^۲ دوم و سوم برای بهبود تشخیص و جداسازی MCها استفاده می‌شود.

در تحقیقات اخیر در مرجع [۳۰] نشان داده شده است که استفاده از تبدیل موجک Matzinger به جای تبدیل‌های موجک Daubechies برای تشخیص MCها نتایج بهتری

^۱ Spatial
^۲ Sub-band

می‌دهد. در مرجع [۳۱] برای تشخیص MC روش تبدیل موجک با روش درخت پنهان مارکوف در ماکسیمم likelihood ترکیب شده است.

در اینجا به دلیل اهمیت و تاثیر تبدیل موجک و تجزیه چند مقیاسی یک دسته جداگانه از روش‌های تشخیص به آن‌ها اختصاص داده شد. این روش‌ها به طور متداول در مرحله استخراج ویژگی و به عنوان ورودی برای کلاسه بندها استفاده می‌شوند.


۲-۴-۴ روش‌های آموزش ماشین

هدف روش‌های آموزش ماشین یافتن وابستگی‌های متقابل داده‌ها است. در زمینه تشخیص MC، مساله اساسی عمل کردن به صورت یک کلاسه بند باینری است که هدف آن این است که مشخص کند آیا MC در یک پیکسل موجود است یا خیر. برای مثال، در مرجع [۳۲] یک شبکه عصبی دو لایه استفاده شده است. ویژگی‌های این کلاسه بند اجزای فرکانسی موجک، مشخصات آماری (gray-scale) و ویژگی‌های شکل هستند. لایه اول در شبکه عصبی پیکسل‌هایی را که پتانسیل MC بودن را دارند شناسایی می‌کند و لایه دوم MC را به عنوان یک شیء تشخیص می‌دهد.

روش‌های آموزش ماشین سهم زیادی از تحقیقات اخیر را شامل می‌شود. ثابت شده است که کلاسه بندهایی که بر اساس روش‌های آموزش ماشین طراحی شده اند بسیار قدرتمند هستند. پیشرفت‌های اخیر در آموزش ماشین در زمینه الگوریتم‌های شناخته شده SVM^۱ هستند.

^۱ Support Vector Machine

در شکل ۷-۲ یک مثال از اعمال کلاسه بند SVM بر روی تصویر ماموگرافی دیده می‌شود که در آن MCها به صورت مکان‌های روشن در خروجی کلاسه بند مشخص شده است. گزارش شده است که SVMها بالاترین دقت را در تشخیص MCها دارند.




شکل ۷-۲: اعمال کلاسه بند SVM برای تشخیص کلاستر MCها [۲].


۵-۲ تشخیص توده‌ها (mass)

مقدمه


یک توده یا mass معمولاً با شکل و حاشیه‌هایش کاراکتر بندی می‌شود. یک توده با شکل نامنظم احتمال بیشتری برای بدخیم بودن دارد در حالی که خوش خیم بودن توده‌ای با شکل منظم محتملتر است. (شکل ۸-۲)



(الف)



(ج)



(ب)

شکل ۲-۸: الف) دو نمونه توده تشخیص داده شده (a) خوش خیم (b) بد خیم [۲] ب) شکل دو نمونه توده [۳۳]. ج) تفاوت

شکل‌های توده‌های خوش خیم و بدخیم [۳۴]

بیشتر الگوریتم‌های تشخیص توده‌ها از دو مرحله اساسی تشکیل می‌شوند:

(۱) تشخیص نواحی مشکوک در تصاویر ماموگرافی

۲) کلاسه‌بندی نواحی مشکوک به عنوان ناحیه نرمال یا توده سرطانی

الگوریتم‌های مرحله اول تشخیص توده‌ها معمولا Pixel-based یا Region-based هستند [۳۵]-[۳۶].

۲-۵-۱ روش‌های Pixel-based

در دیدگاه‌های pixel-based، ابتدا ویژگی‌ها برای هر پیکسل استخراج می‌شود و سپس پیکسل‌ها به دو دسته مشکوک و یا نرمال کلاسه‌بندی می‌شوند [۳۵]. تحقیقات زیادی در زمینه روش‌های pixel-based تاکنون صورت گرفته است. برای مثال در مرجع [۳۷] ویژگی‌ها و مشخصات لبه‌های نزدیک به هم محلی از نواحی مورد علاقه (ROI) استخراج می‌شوند و یک کلاسه بند درختی با تصمیم‌گیری باینری برای کلاسه‌بندی Spiculated lesion‌ها از نواحی نرمال به کار می‌رود. نویسندگان این مقاله ۱۰۰٪ حساسیت را برای این روش گزارش داده است.

در مرجع [۳۸] یک شماتیک چند-رزولوشن برای تشخیص توده‌ها ارائه شده است. در این روش ابتدا تصویر به نمایش چند رزولوشن تجزیه می‌شود و چهار ویژگی برای هر پیکسل در هر رزولوشن استخراج می‌شود. در آزمایشات نویسنده از ۱۹ عدد تصویر ماموگرافی شامل Spiculated lesion‌ها از بانک تصاویر MIAS استفاده کرده است.

در مرجع [۳۹] روشی برای تشخیص توده‌ها در تصاویر دیجیتال ماموگرافی ارائه شده است. این روش شامل دو مرحله است. در مرحله اول، یک الگوریتم فیلترینگ جهت بهبود بخشیدن ویژگی‌های خاصی استفاده شده است. در مرحله دوم، یک فیلتر

speculation برای تشخیص مکان spatial با استفاده از ویژگی‌های بهبود یافته استفاده می‌شود. این الگوریتم با استفاده از تصاویر ماموگرافی از بانک اطلاعاتی DDSM^۱ تست شده است [۳۳]. نتایج نشان می‌دهد که نواحی شامل توده در ماموگرام‌ها با استفاده از این الگوریتم به طور کامل مکان‌یابی می‌شوند.

۲-۵-۲ روش‌های Region-based

در روش‌های فوق ابتدا ROIها از تصویر اولیه جدا می‌شوند و سپس ویژگی‌ها از هر ناحیه مورد علاقه از تصویر استخراج می‌شود که در نهایت این نواحی هستند که در دو گروه مشکوک و یا غیر مشکوک کلاسه‌بندی می‌شوند.

تاکنون مقالات زیادی در این زمینه ارائه شده است. برای مثال chan et al. در مرجع [۴۰] یک الگوریتم Region-based ارائه کرده‌اند که در آن هشت ویژگی از ماتریس‌های (SGLD) در حوزه فضایی استخراج شده است و از یک جداساز خطی برای تشخیص اهمیت هر ویژگی و در نهایت جداسازی توده‌ها از نواحی سالم استفاده شده است.

^۱ Digital Database for Screening Mammography

فصل ۳

بهبود کیفیت تصاویر ماموگرافی (Image Enhancement)

مقدمه

همان طور که در فصل دوم اشاره شد، تصاویر ماموگرافی معمولاً دارای وضوح و کنتراست پایینی هستند و به همین دلیل معمولاً افزایش و بهبود کیفیت تصویر قبل از پیاده‌سازی سیستم CAD و یا جهت تشخیص توده‌های سرطانی به صورت چشمی، ضروری به نظر می‌رسد. تصاویر بهبود یافته برای انجام عملیات خاص و همچنین اعمال توابع هدف بهتر از تصویر اولیه است [۱۷].

دسته‌بندی روش‌های مختلف بهبود کیفیت در تصاویر ماموگرافی در فصل گذشته مورد بررسی قرار گرفت. در این فصل بهبود کیفیت تصاویر ماموگرافی و عملیات پیش پردازش صورت گرفته بر روی آن‌ها را مورد بررسی قرار می‌دهیم.

در مرجع [۲۳] روشی برای حذف نویز تصاویر ماموگرافی و بهبود کیفیت آن‌ها معرفی شده است. در این روش حذف نویز وابسته به تخمین میزان واریانس نویز تصویر است. در این تحقیق نقطه ضعف این روش بررسی شده و روشی جدید برای تخمین دقیق واریانس نویز در تصاویر ارائه شده است. با توجه به اینکه تصاویر ماموگرافی از بافت‌های پیچیده‌ای تشکیل شده‌اند روش جدید ارائه شده، تخمین دقیق‌تری از واریانس نویز در اینگونه تصاویر را به ما می‌دهد.

عملیات پیش پردازش^۱ که بر روی همه تصاویر ماموگرافی در این تحقیق انجام گرفته است شامل جداسازی بافت سینه از پس زمینه سیاه تصاویر و همچنین اعمال یک فیلتر بالاگذر بر روی این تصاویر است. این فیلتر جهت حذف نویز و یکنواخت‌سازی پیچیدگی‌های

^۱ Pre-processing

تصاویر ماموگرافی قبل از ورود به مرحله استخراج ویژگی بر روی تصاویر اعمال می‌شود. جزئیات مربوط به این عملیات در بخش ۲-۳ مورد بررسی قرار گرفته است.

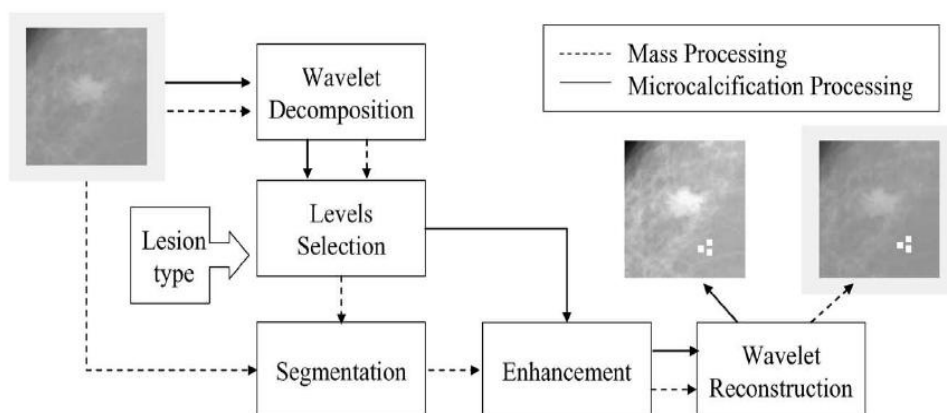
۱-۳ حذف نویز در تصاویر ماموگرافی تبدیل موجک دیادیک^۱

[۲۳]

در مرجع [۲۳] Arianna Mencattin و همکارانش یک الگوریتم جدید برای حذف نویز و بهبود کیفیت در تصاویر بر اساس تبدیل موجک دیاتیک پیشنهاد داده‌اند. شمای کلی الگوریتم در شکل ۱-۳ آورده شده است. همانطور که در این شکل مشاهده می‌شود الگوریتم شامل دو مسیر جداگانه برای بهبود بخشیدن تصاویر شامل MCها و تصاویر شامل massها است.

مرحله حذف نویز که قبل از مرحله بهبود کیفیت بر روی کل تصاویر انجام می‌شود بر اساس تخمین واریانس نویز تکرار شونده محلی به روش ارائه شده در مرجع [۲۴] صورت می‌پذیرد.

^۱ Dyadic wavelet



شکل ۳-۱: بلوک دیاگرام الگوریتم ارائه شده در مرجع [۲۳]

در مرجع [۲۴] تخمین واریانس نویز به وسیله یک الگوریتم تکرار شونده فازی که بر روی بعضی از خواص و ویژگی‌های تصویر اعمال می‌شود صورت می‌پذیرد. در این روش پنجره‌هایی از تصویر که دارای توزیعی مشابه گوسی هستند در تخمین نویز مشارکت بیشتری دارند.

اکثر مقالات الگوریتم‌هایی را جهت تخمین پارامترهای نویز افزایشی در تصاویر دیجیتال ارائه می‌کنند. در بعضی از آن‌ها مانند مراجع [۴۱] و [۴۲] و [۴۳] استخراج پارامترها با شروع از یک پنجره‌ی کوچک تصویر صورت می‌گیرد به طوری که بتوان در آن پنجره توزیع اصلی ارزش پیکسل‌ها را به اندازه کافی یکنواخت فرض کرد. هدف این است که اهمیت بیشتری به پنجره‌هایی داده شود که توزیع طیفی مشابه‌تری نسبت به توزیع گوسی دارند [۲۴]. در واقع با فرض اینکه نویز تصویر دارای چگالی احتمال گوسی باشد، پنجره‌هایی از تصویر با این خاصیت، برای تخمین نویز مناسب‌تر هستند.

جهت اندازه‌گیری تشابه توابع چگالی احتمال، روش‌های متفاوتی پیشنهاد شده است. یکی از روش‌های متداول استفاده از معیار شباهت χ^2 می‌باشد [۴۴] و [۴۵]. این معیار تشابه بین چگالی احتمال روشنایی پیکسل‌های یک پنجره از تصویر را با توزیع گوسی اندازه می‌گیرد. چگالی احتمال گوسی مورد انتظار در اینجا به تعداد N_I فاصله فرعی تقسیم شده است که E_K تعداد نمونه‌های مورد انتظار قرار گرفته در K مین فاصله و O_K تعداد نمونه‌های واقعی قرار گرفته در همان فاصله است [۲۴].

$$\chi^2 = \sum_{K=1}^{N_I} \frac{(E_K - O_K)^2}{E_K} \quad (1 - 3)$$

هر چه اندازه‌ی معیار χ^2 کوچکتر باشد توزیع ارزش پیکسل‌ها در آن پنجره به توزیع گوسی نزدیکتر است. تعداد فاصله‌ها N_I نباید کوچک باشد زیرا در این صورت تفاوت بین دو توزیع مورد مطالعه قابل توجه نخواهد بود. همچنین این تعداد نباید خیلی بزرگ باشد زیرا در غیر این صورت، معیار شباهت بجای اهمیت دادن به توزیع احتمالاتی، اغتشاشات هیستوگرام که در نتیجه ناکافی بودن نمونه‌ها است را مدل می‌کند. تعداد این فاصله‌های فرعی در مرجع [۲۴]، هشت انتخاب شده است و نقاط جداسازی به صورت زیر تعریف می‌شود:


$$\Pi_{1,2,3} = \pm 0.3186\sigma, \pm 0.6745\sigma, \pm 1.1503\sigma \quad (2 - 3)$$

شکل ۲-۳ توزیع احتمالاتی $P(x)$ نویز گوسی و $\phi(x)$ تابع خطا، بر طبق یک تابع $erf(x)$ را نشان می‌دهد.

یکی دیگر از پارامترهایی که در تخمین واریانس نویز استفاده می‌شود درصد پیکسل‌های به اشباع رفته در هیستوگرام تصویر است که این مقدار برای هر پنجره باید تا حد

^۱ Error Function

امکان کوچک باشد. این پارامتر با $P_{0.1}$ نمایش داده شده است [۲۴]. منظور از پیکسل‌های به اشباع رفته در یک پنجره پیکسل‌هایی هستند که دارای سطح روشنایی ماکسیمم و یا مینیمم روشنایی می‌باشند. با توجه به اینکه پنجره‌ای با معیار $P_{0.1}$ پایین برای تخمین نویز مناسب‌تر هستند، در مدل فازی ارائه شده از این پنجره‌ها استفاده می‌شود. پارامترهایی که در تخمین واریانس نویز از هر پنجره استخراج می‌شوند، معیار شباهت هیستوگرام χ^2 ، درصد پیکسل‌های به اشباع رفته $P_{0.1}$ و متوسط روشنایی \bar{x} است. با استفاده از این پارامترها میزان مشارکت واریانس هر پنجره در تخمین واریانس نویز کل تصویر سنجیده می‌شود. این مشارکت به صورت وزندهی به واریانس هر پنجره لحاظ شود.



شکل ۳-۲: گراف توزیع احتمالاتی $P(x)$ نویز گوسی و $\phi(x)$ تابع خطا [۲۴].

در این مقاله از سیستم‌های فازی *Sugeno* برای تعیین وزن هر پنجره استفاده می‌شود. خروجی سیستم فازی وزن پنجره‌ی h_i نام را h_i در نظر می‌گیرد. مقادیری که h_i می‌پذیرد وزن‌های ($H=1$) و یا ($L=0$) می‌باشد.

در مرحله اول تصویر ورودی به پنجره‌هایی با سایز N_W تقسیم‌بندی شده و پارامترهای χ^2 و P_{01} و \bar{x} برای هر پنجره محاسبه می‌شود. سپس ویژگی‌های بدست آمده از پنجره (χ^2 و P_{01} و \bar{x}) به سیستم فازی FS₁ به عنوان ورودی اعمال می‌شود و وزن خروجی h_i توسط سیستم فازی با تعریف قوانین زیر برای آن محاسبه می‌گردد [۲۴].

If (χ^2 is L) and (P_{01} is L) and (\bar{x} is M) then (h_i is H)

If (χ^2 is L) and (P_{01} is L) and (\bar{x} is H) then (h_i is H)

If (χ^2 is L) and (P_{01} is M) and (\bar{x} is L) then (h_i is H)

If (χ^2 is L) and (P_{01} is L) and (\bar{x} is M) then (h_i is H)

If (χ^2 is L) and (P_{01} is M) and (\bar{x} is L) then (h_i is H)

If (χ^2 is L) and (P_{01} is M) and (\bar{x} is M) then (h_i is L)

If (χ^2 is M) and (P_{01} is L) and (\bar{x} is H) then (h_i is L)

If (χ^2 is M) and (P_{01} is M) and (\bar{x} is M) then (h_i is L)

در مرجع [۲۴] واریانس نویز تصویر با استفاده از خروجی سیستم FS₁ به شکل زیر


تعریف می‌شود:

$$\sigma = \frac{\sum_{i=1}^{N_W} h_i \cdot \sigma_i}{\sum_{i=1}^{N_W} h_i} \quad (3-3)$$

که در رابطه (۳-۳)، σ_i میزان انحراف معیار روشنایی پیکسل‌های هر پنجره و σ انحراف

معیار نویز تصویر می‌باشد.

در شکل ۳-۳ بلوک دیاگرام الگوریتم تخمین واریانس نویز با استفاده از سیستم فازی شامل عملیات پیش پردازش و ورودی‌ها و خروجی‌های سیستم‌های فازی FS_1 و FS_2 مشاهده می‌شود. شکل توابع عضویت در سیستم FS_1 مطابق مرجع [۲۴] بصورت مثلثی تعریف شده است.



شکل ۳-۳: بلوک دیاگرام الگوریتم ارائه شده در مرجع [۲۴] جهت تخمین واریانس نویز

نتایج سیستم ارائه شده توسط مرجع [۲۴] برای تصاویر مختلفی از پایگاه داده weizmann^۱ نشان می‌دهد که این الگوریتم در تخمین نویز تصاویر با بافت اصطلاحاً شلوغ، مثل تصاویر ماموگرافی، دقت کمی دارد. از طریق نتایج آزمایشات مشاهده شد که برای این گونه از تصاویر، درصد بالایی از پنجره‌ها وزن h_i برابر با H را به خود اختصاص می‌دهند. با انجام آزمایشاتی بر روی تصاویر شلوغ دریافتیم که تعداد این پنجره‌ها نسبت به کل پنجره‌ها در بازه

^۱Weizmann Database

۰.۹ تا ۰.۹۸ می‌باشد. در واقع در روش ارائه شده در مرجع [۲۴] بسیاری از پنجره‌های دارای بافت شلوغ را در محاسبه نویز تصویر دخالت می‌دهد در حالی که واریانس مربوط به این پنجره-ها مربوط به نویز نمی‌باشد بلکه مربوط به بافت تصویر است. در این تحقیق نسبت پنجره‌های دخالت داده شده در محاسبه واریانس نویز به کل پنجره‌های تصویر را با پارامتر T_{01} نشان می‌دهیم. در شکل (۳-۴) مقدار این پارامتر برای دو دسته از تصاویر نشان داده شده است. خطای نسبی تولید شده در تخمین نویز با استفاده از الگوریتم ارائه شده در [۲۴] برای تصاویر دسته اول (شکل (۳-۴-الف)) از ۰.۸۰ بالاتر و برای تصاویر دسته دوم (شکل (۳-۴-ب)) از این مقدار پایینتر است. همانطور که مشاهده می‌شود برای بیشتر تصاویر شلوغ مقدار T_{01} در بازه فوق قرار گرفته است در حالی که تعداد تصاویری از دسته دوم که مقدار T_{01} آنها در این بازه قرار می‌گیرد مینیمم است.

در ادامه با استفاده از مشاهدات تجربی ارائه شده، در الگوریتم پیشنهادی ابتدا خروجی سیستم FS₁ برای کل تصویر محاسبه می‌شود و معیار T_{01} اندازه گیری می‌شود. در صورتی که این مقدار در بازه فوق قرار گیرد تصویر ورودی با بافت پیچیده تلقی می‌گردد و نویز این تصاویر بصورت دیگری تخمین زده می‌شود. از آنجا که تصاویر ماموگرافی بر اساس این اندازه گیری دارای بافت پیچیده‌ای می‌باشند، ما در این تحقیق روشی را جهت یافتن واریانس نویز در تصاویر دارای بافت پیچیده ارائه کردیم. در این گونه از تصاویر می‌بایست اهمیت بیشتری به پنجره‌هایی داده شود که علاوه بر تشابه توزیع آن‌ها به توزیع گوسی، واریانس پنجره (σ_i) میزان کمتری داشته باشد که نشان دهنده میزان یکنواخت بودن توزیع روشنایی پیکسل‌های پنجره نسبت به دیگر بخش‌های تصویر است. در سیستم پیشنهادی FS₃ قوانین فازی به صورت زیر تعریف می‌شوند.

If (χ^2 is L) and (σ_i is L) then (h_i is H)

If (χ^2 is L) and (σ_i is M) then (h_i is L)

If (χ^2 is M) and (σ_i is L) then (h_i is M)


If (χ^2 is M) and (σ_i is M) then (h_i is L)

همچنین بلوک‌دیگرام الگوریتم معرفی شده در شکل (۳-۵) و شکل توابع عضویت


سیستم FS۳ در شکل (۳-۶) آورده شده است. اگر تصویر ورودی با معیار T۰۱ شلوغ تلقی

نشود، مطابق مرجع [۲۴] تخمین واریانس توسط سیستم FS۱ (بلوک‌دیگرام شکل ۳-۵)

صورت می‌گیرد.



(الف)

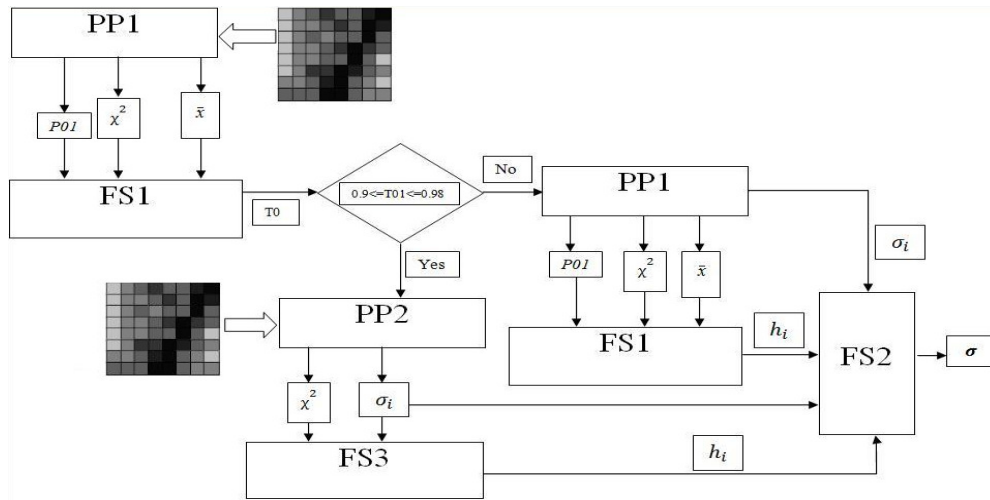


(ب)


شکل ۳-۴: تعداد تصاویر بر حسب T۰۱ (محور افقی مقدار (T۰۱*۱۰۰) و محور عمودی تعداد تصاویر می‌باشد) الف) برای

تصاویر دارای خطای تخمین نویز بالاتر از ۸۰٪ با استفاده از الگوریتم ارائه شده در مرجع [۲۴] ب) برای تصاویر دارای


خطای تخمین نویز پایینتر از ۸۰٪ با استفاده از الگوریتم ارائه شده در مرجع [۲۴]



شکل ۳-۵: بلوک-دیاگرام الگوریتم ارائه شده در این تحقیق



(الف) توابع عضویت برای σ_i



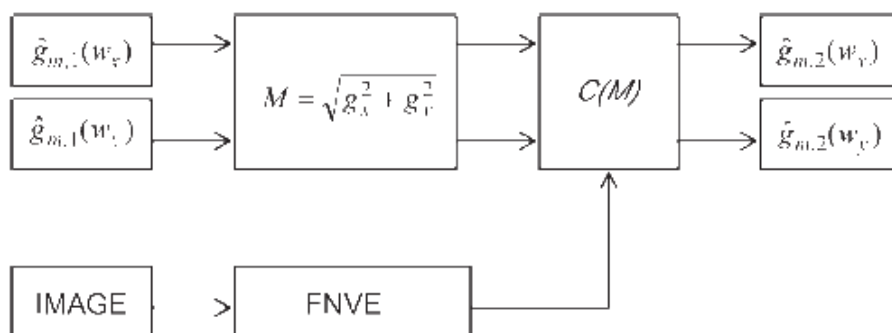
(ب) توابع عضویت برای χ^2

شکل ۳-۶: توابع عضویت برای σ_i و χ^2

پس از یافتن واریانس نویز می توان ضرایب موجک تصویر را با استفاده از فیلتر $C(M)$ اصلاح کرد که در آن میزان آستانه همانگونه که نشان داده شده است با استفاده از واریانس تخمینی نویز به گونه ای که گفته شد محاسبه می شود. در این مرحله عملیات حذف نویز صورت پذیرفته است و از ضرایب جدید می توان جهت بازسازی تصویر بدون نویز شده استفاده کرد (شکل ۷-۳).

$$C(M) = \begin{cases} |M| - T_n, & |M| < T_n \\ 0, & \text{otherwise} \end{cases} \quad (4-3)$$

$$T_n = \sigma \sqrt{-2 \log(1-p)} \quad (5-3)$$



شکل ۷-۳: چگونگی انجام مرحله حذف نویز در مرجع [۲۳]

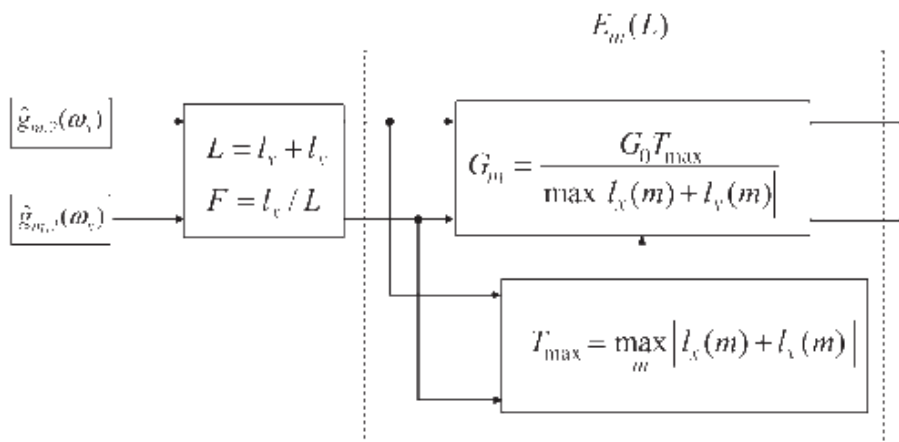
در مرحله بعد کنتراست تصویر اصلاح می شود. در ساختار موجک، بهبود کیفیت تصویر به دو شکل خطی و غیر خطی انجام می شود. بهبود خطی کیفیت تصویر به وسیله اعمال یک تابع خطی بر روی ضرایب موجک به شکل $Em = Gms$ صورت می پذیرد که در آن S ضرایب موجک تصویر و Gm میزان بهره است که عموماً به سطح موجک بستگی دارد. در مرجع [۴۶]، نویسندگان مقاله ثابت کرده اند که بهبود خطی با عملیات unsharp masking در هر مقیاس مطابقت دارد. برای اجتناب از به اشباع رفتن ضرایب سطح بالا، که باعث اتلاف جزئیات بعد از فرایند بازسازی می شود، نیاز به استفاده از بهبود غیرخطی کیفیت تصویر احساس می شود.

متاسفانه، طراحی یک تابع غیرخطی برای بهبود عملیاتی غیربدهی است و شامل نکات زیر می‌شود. ابتدا اینکه، تابع $Em(s)$ باید به طور یکنواخت افزایشی باشد تا در حین فرایند تجزیه و بازسازی تولید اعوجاج نکند. همچنین، نواحی با کنتراست پایین باید بهبود بیشتری یابد تا اثرات اشباع رفتن بعد از فرایند تغییر مقیاس به حداقل برسد. در نهایت، در مرجع [۴۶] یک تابع غیرخطی برای بهبود کیفیت تصویر با استفاده از ضرایب موجک به شکل زیر پیشنهاد شده است.

$$E_m(s) = \begin{cases} s - (G_m - 1)T, & s < -T \\ G_m s, & |s| \leq T \\ s + (G_m - 1)T, & s > T \end{cases} \quad (۶-۳)$$

مقادیر G_m و T_m مرز بین بهبود کیفیت سخت (شیب) و بهبود کیفیت نرم (شیب

واحد) را تعیین می‌کنند که از طریق فرایند جداگانه‌ای تعیین می‌شوند (شکل ۳-۸).



شکل ۳-۸: چگونگی انجام بهبود کیفیت بر روی تصاویر شامل MC در مرجع [۲۳]

تا اینجا بهبود بر روی تصاویر شامل MC انجام شد. اما نسبت به MCها، بهبود تصاویر شامل massها با مسائل پیچیده‌تری روبرو است. نه تنها از لحاظ تصویری تشخیص توده‌ها در ماموگرام‌ها مشکل است، بلکه در حوزه موجک جداسازی ضرایب مربوط به توده‌ها از ضرایب مربوط به پس زمینه تصویر، کار ساده‌ای نیست. بنابراین در این موارد برای انجام عملیات بهبود تصویر ابتدا یک جداسازی صورت می‌پذیرد.

در این مقاله یک روش جدید برای جداسازی با ترکیب اطلاعات مدل‌های گسسته کانتور^۱ و رشد ناحیه‌ای^۲ ارائه شده است.

الگوریتم به وسیله دو بار اعمال اپراتور مورفولوژیکی tophat پیاده شده است، که در زیر ساختار آن مشاهده می‌شود.

$$YB_1 [f(x,y)] = \max [0, f(x, y) - (f \circ B_1)(x, y)] \quad (7-3)$$

$$YB_2 [f(x,y)] = \max [0, f(x, y) - (f \circ B_2)(x, y)] \quad (8-3)$$

$$R(x,y) = \max(0, YB_2 - YB_1) \quad (9-3)$$

که در آن YB_1 خروجی اپراتور tophat بر روی تصویر اولیه $f(x,y)$ با استفاده از المان ساختاری^۳ دایره شکل B_1 است و YB_2 جداسازی توده بهبود یافته را از اطرافش با اعمال اپراتور tophat دوم با استفاده از المان ساختاری دایره شکل B_2 انجام می‌دهد.

ابعاد B_1 از کوچکترین توده موجود کوچکتر و ابعاد B_2 از بزرگترین توده موجود بزرگتر است.


^۱ Discrete contour models

^۲ Region growing


^۳ Structure element

تصویر نهایی که توده‌ها در آن جداسازی شده‌اند با $R(x, y)$ بدست آمده است. پس از جداسازی توده‌ها وارد مرحله بهبود کیفیت برای این تصاویر شده و در این مرحله، از تصویر باینری خروجی مرحله قبل یعنی $R(x, y)$ استفاده کرده و با اعمال تابع Em به صورت زیر بر روی ضرایب موجک توده جداسازی شده، کیفیت تصویر را بهبود بخشیده است. بهره G_0 توسط کاربر تعریف می‌شود. نتایج این روش بر روی تصویر شامل MC در شکل ۳-۹ آورده شده است. شکل ۳-۱۰ مراحل جداسازی و شکل ۳-۱۱ عملکرد این روش بر روی تصاویر ماموگرافی شامل توده‌ها را در مقایسه با تشخیص رادیولوژیست نشان می‌دهد.

$$E_m[s(x, y)] = \begin{cases} G \cdot s(x, y) & , \\ s(x, y) & \end{cases} \quad \begin{matrix} S(x, y) = 1 \\ S(x, y) = 0 \end{matrix} \quad (10-3)$$




شکل ۳-۹: نتایج بهبود کیفیت تصویر در مرجع [۲۳]. (a) تصویر اولیه (b) انجام عملیات بهبود کیفیت قبل از حذف نویز (c) انجام عملیات حذف نویز بر روی تصویر اولیه (d) انجام عملیات بهبود کیفیت بر روی تصویر (c)



شکل ۳-۱۰: (a) انجام مراحل جداسازی بر روی تصویر شامل mass (b) انجام عملیات فیلترینگ (c) انجام عملیات

مورفولوژیکال (d) توده جدا شده [۲۳]



شکل ۳-۱۱: تشخیص توده‌ها در ۴ نمونه تصویر. سطر اول تصاویر ماموگرافی شامل توده و در سطر دوم خطوط سفید رنگ


تشخیص توسط رادیولوژیست و خطوط مشکی تشخیص بعد از انجام عملیات حذف نویز و بهبود کیفیت است [۲۳]

عملیات پیش پرداز ۲-۳


در این بخش قصد داریم عملیات پیش پردازش انجام شده در این تحقیق را مورد بررسی قرار دهیم. تصاویر انتخاب شده‌ی ماموگرافی دارای یک پس زمینه سیاه با مقدار قابل توجهی نویز است. بنابراین نیاز است که قبل از ورود به مرحله استخراج ویژگی و انجام عملیات کلاسه‌بندی، بخش حاشیه بافت که در تصویر به صورت ناحیه سیاه دیده می‌شود را حذف کنیم.

۲-۳-۱ حذف پس زمینه تصاویر ماموگرافی


جهت جداسازی بافت سینه از بخش حاشیه خارج بافت در تصاویر ماموگرافی ابتدا هیستوگرام تصاویر ماموگرافی استخراج می‌شود. سپس با اعمال یک آستانه مناسب بر روی هیستوگرام تصاویر بخش غیر بافت بدن حذف می‌گردد. مقدار این آستانه برابر با مکانی از هیستوگرام است که اولین مینیمم محلی اتفاق می‌افتد. نمونه‌ای از این عملیات در شکل ۳-۱۲ مشاهده می‌شود. با توجه به هیستوگرام تصویر ماموگرافی در این شکل مشاهده می‌شود که اولین مینیمم محلی در مکان $(x = 6939 * 10^4)$ اتفاق می‌افتد. در نتیجه با حذف مکان‌هایی از تصویر که روشنایی کمتر از این مقدار دارند می‌توان بافت سینه را از ناحیه خارج آن جدا کرد.



(الف)



(ب)



(ج)

شکل ۳-۱۲: الف) تصویر اولیه ماموگرافی قبل از جداسازی بافت سینه از پس زمینه. ب) هیستوگرام تصویر (الف). ج) بافت

جدا شده‌ی سینه از پس زمینه‌ی نویزی و سیاه تصویر (الف)

فصل ۴

تشخیص MCها در تصاویر ماموگرافی

مقدمه

همان طور که در فصل دوم بررسی شد، تاکنون روش‌های مختلفی برای تشخیص MCها در تصاویر ماموگرافی پیشنهاد شده است. این روش‌ها بطور خلاصه در فصل دوم دسته بندی و معرفی شدند. این فصل شامل بررسی چند سیستم CAD و معرفی روش‌های تشخیص MC است که در این سیستم‌ها پیشنهاد، پیاده‌سازی و در نهایت تحلیل و مقایسه شده است. همانطور که در فصل دوم اشاره شد شبیه سازی و طراحی یک سیستم CAD شامل سه مرحله اساسی پیش پردازش تصاویر، استخراج ویژگی و کلاسه‌بندی است. پیش پردازش انجام گرفته بر روی تصاویر ماموگرافی در این تحقیق در انتهای فصل سوم بررسی شد.

تفاوت اصلی سیستم‌های CAD طراحی شده و شبیه‌سازی شده در این تحقیق در مرحله استخراج ویژگی از تصاویر ماموگرافی و همچنین کلاسه بند استفاده شده جهت تشخیص MC می‌باشد. این فصل شامل چهار بخش کلی است. در بخش اول روش‌های مختلف استفاده شده برای استخراج ویژگی از تصاویر ماموگرافی در سیستم‌های CAD پیشنهادی، معرفی می‌شود. سپس در بخش دوم به معرفی و بررسی کلاسه بندهای به کار گرفته شده در این سیستم‌ها پرداخته‌ایم و در پایان فلوچارت مربوط به طراحی این سیستم‌ها آورده شده است.

۴-۱ ویژگی‌های استخراج شده از تصاویر ماموگرافی

استخراج ویژگی و انتخاب ویژگی یکی از مراحل اساسی در طراحی یک سیستم CAD می‌باشد. هدف عمده استخراج ویژگی در واقع توصیف نمودن یک شیء به گونه‌ای است که

بتوان آن را با اندازه‌گیری یک شاخص مشخص کرد. این شاخص باید به گونه‌ای انتخاب شود که مقدار آن در دسته اشیاء مشابه آن شیء، اندازه یکسانی داشته باشد و مقدار آن در دسته‌های دیگر اشیاء کاملاً متفاوت باشد. بنابراین به طور مثال در یک تصویر باید به دنبال ویژگی‌های تمییزدهنده‌ای بود که به خوبی خواص نامتغیر اشیاء درون تصویر را توصیف کند. برای مثال شکل، رنگ و بافت اشیاء در تصویر ویژگی‌هایی هستند که همیشه با حرکت انتقالی تصویر، چرخش و مقیاس بندی آن، ثابت باقی می‌مانند.

در این تحقیق از آنجا که هدف تشخیص MCها در تصاویر ماموگرافی است، باید به دنبال ویژگی‌هایی بود که بخوبی بتواند خواص MCها را توصیف کند و از طرفی باید این ویژگی‌ها در مناطق سالم و نرمال تصویر ماموگرافی مقدراری متفاوت از مناطق شامل MC داشته باشند.


در ادامه این بخش، سه روش متفاوت برای استخراج بردار ویژگی از تصاویر ماموگرافی معرفی شده است.

۴-۱-۱ استخراج ویژگی روشنایی تصویر


از آنجایی که هر کدام از MCها به تنهایی یک شیء متمرکز و واحد می‌باشد، می‌توان جهت تشخیص اینکه آیا در یک مکان از تصویر ماموگرافی MC موجود می‌باشد یا خیر، از بردار ویژگی روشنایی تصویر در یک همسایگی اطراف همان مکان بهره برد. بنابراین برای آشکارسازی وجود رسوبات کلسیمی، هر مکان تصویر را با یک همسایگی کوچک در اطرافش تست می‌کنیم. به این ترتیب بردار ویژگی ورودی برای کلاسه بند را یک پنجره کوچک $M \times M$

در نظر می‌گیریم که مرکز آن درست در وسط مکان MC قرار می‌گیرد. این پنجره باید به اندازه کافی بزرگ باشد که به طور کامل یک MC را شامل شود، و به اندازه کافی کوچک باشد تا از تداخل MC با همسایگی‌های مجاور جلوگیری شود. در این تحقیق مقدار $M=9$ در نظر گرفته شده است.

تصاویر انتخاب شده ماموگرافی دارای مقدار قابل توجهی نویز است. بنابراین پس از انجام عملیات پیش پردازش توصیف شده در فصل سوم و برش بخش‌های ناخواسته، با اعمال یک فیلتر تیز بالاگذر FIR فاز خطی، پس زمینه تصویر را یکنواخت می‌کنیم. فرکانس ۳-dB فیلتر دو-بعدی مورد نظر $0/125$ و طول آن $n=41$ در نظر گرفته شده است [۴۷]. تصویر این فیلتر در شکل ۱-۴ و نتایج بعد از برش بافت سینه و اعمال فیلتر بر روی یک تصویر ماموگرافی در شکل ۲-۴ نشان داده شده است. اعمال این فیلتر سبب می‌شود که پس زمینه تصویر فرونشانده شود و جداسازی میان داده‌های آموزشی و داده‌های تست در کلاسه بند افزایش یابد.



شکل ۴-۱: فیلتر تیز بالاگذر FIR فاز خطی با فرکانس ۳-dB، برابر ۰.۱۲۵ و طول $n=۴۱$



(ب)

(الف)

شکل ۴-۲: الف) بخشی از یک تصویر ماموگرافی شامل کلاستر MC. ب) نتیجه اعمال فیلتر شکل (۴-۱) بر روی تصویر الف.

۴-۱-۲ استخراج ویژگی‌های فرکانسی

نکته‌ای که در تصاویر ماموگرافی مشاهده می‌شود این است که MCها اجزاء فرکانس بالایی هستند که در یک پس‌زمینه شامل اجزاء فرکانس پایین و نویز فرکانس بالا دفن شده‌اند. با توجه به اینکه تبدیل موجک دارای خواص چند رزولوشنی می‌باشد و تصویر را در حوزه فرکانس تجزیه می‌کند، می‌توان از آن برای استخراج MCها از پس‌زمینه فرکانس پایین و نویز فرکانس بالا استفاده کرد. در واقع تبدیل موجک تصویر را در هر باند به سیگنالی در رنج فرکانسی متفاوت تجزیه می‌کند. این ویژگی کمک می‌کند که بتوان اطلاعات مفید مربوط به MCها را یافت و همچنین باندهای فرکانسی که سهم کمی در تشخیص MCها دارند را نادیده گرفت. در اینجا ابتدا تبدیل موجک و خواص آن معرفی شده است و سپس استخراج ویژگی با استفاده از این تبدیل شرح داده شده است.

۴-۱-۲-۱ تبدیل موجک و خواص آن

در آنالیز موجک، سیگنال مورد نظر در یک تابع موجک ضرب می‌شود. تبدیل موجک به طور جداگانه بر روی قطعه‌های زمانی مختلف سیگنال انجام می‌شود. در این بخش، ایده اصلی تبدیل موجک در قالب روابط ریاضی پایه‌ای بیان می‌شود.

یک پایه از فضای برداری V مجموعه‌ای از بردارهای مستقل خطی است به نحوی که بتوان هر بردار v در فضای V را برحسب یک ترکیب خطی از این بردارهای پایه نوشت. در حالت کلی برای هر فضای برداری می‌توان بیش از یک پایه یافت، اما همگی آن‌ها دارای تعداد

یکسانی بردار پایه خواهند بود که این تعداد را بعد آن فضای برداری می‌نامند. به این ترتیب، توصیف هر بردار دلخواه فضا چنین نشان داده می‌شود:

$$v = \sum_{k=1}^N \alpha_k b_k \quad (1-4)$$

که در آن بردارهای پایه فضا هستند، α_k ضرایب ترکیب خطی بوده و N بعد فضا است. این مفهوم که در فضای برداری بیان شد را می‌توان به سادگی به توابع تعمیم داد با این تغییر که بردارهای پایه جای خود را به توابع پایه (ϕ_k) می‌دهند. بنابراین هر تابع دلخواه $f(t)$ را می‌توان به صورت زیر تعریف نمود.

$$f(t) = \sum_{k=1}^N \alpha_k \phi_k(t) \quad (2-4)$$

توابع نمایی مختلط، توابع پایه برای محاسبه تبدیل فوریه یک سیگنال هستند. به علاوه، این توابع متعامد بوده و لذا این قابلیت را به تبدیل فوریه می‌دهند که بتوان سیگنال اولیه را از روی تبدیل یافته بازسازی نمود.

فرض می‌کنیم $f(t)$ و $g(t)$ دو تابع در فضای دوبعدی باشند. ضرب داخلی این دو تابع به صورت زیر نشان داده می‌شود:

$$f(t) \cdot g(t) = \int f(t) g^*(t) dt \quad (3-4)$$

بر این اساس، رابطه تبدیل موجک پیوسته را می‌توان به صورت ضرب داخلی سیگنال و یک تابع پایه به فرم زیر نوشت:

$$CWT_x^\Psi(\tau, s) = \psi_x^\psi(\tau, s) = \frac{1}{\sqrt{|s|}} \int_{-\infty}^{+\infty} x(t) \Psi^*\left(\frac{t-\tau}{s}\right) dt = \langle x(t), \Psi_{\tau,s}(t) \rangle \quad (4-4)$$

که در آن:

$$\Psi_{\tau,s}(t) = \frac{1}{\sqrt{|s|}} \Psi\left(\frac{t-\tau}{s}\right) \quad (5-4)$$

با تعریف ارائه شده در رابطه (4-4) که به صورت ضرب داخلی بیان شده است، می‌توان اینگونه برداشت کرد که تبدیل موجک در حقیقت اندازه‌گیری شباهت بین سیگنال و توابع پایه (موجک‌ها) است. منظور از شباهت در این بحث، شباهت‌سنجی بین محتوای فرکانسی است. به بیان دیگر، ضرایب تبدیل موجک بیانگر میزان نزدیکی سیگنال به موجک در مقیاس مورد نظر است.

بدین ترتیب، اگر سیگنال موردنظر یک مؤلفه برجسته در فرکانس متناظر با مقیاس مورد تحلیل داشته باشد، در این صورت موجک مقیاس شده، شبیه سیگنال موردنظر خواهد بود. بنابراین ضریبی از تبدیل موجک پیوسته که در این مقیاس محاسبه می‌شود مقداری نسبتاً بزرگ خواهد داشت. همان‌گونه که پیش از این بیان شد، در هر فضا بیش از یک مجموعه از توابع پایه وجود دارد که از بین آن‌ها، توابع پایه متعامد از اهمیت ویژه‌ای برخوردارند، چرا که خواص بسیار خوب و تسهیل‌کننده‌ای به ویژه در یافتن ضرایب تبدیل خواهند داشت. به این ترتیب، با استفاده از خاصیت تعامد توابع پایه، ضرایب تبدیل در رابطه (4-2) به صورت زیر محاسبه می‌شوند:

$$\alpha_k = \langle f(t), \phi_k(t) \rangle = \int f(t), \phi_k^*(t) dt \quad (۶ - ۴)$$

با داشتن این ضرایب، می‌توان تابع را به صورت زیر بازسازی نمود:

$$f(t) = \sum_{k=1}^N \alpha_k \phi_k(t) = f(t) = \sum_{k=1}^N \langle f(t), \phi_k(t) \rangle \phi_k(t) \quad (۷ - ۴)$$

در کنار این خواص تسهیل‌کننده، ممکن است بسته به کاربرد، توابع پایه متعامد در دسترس نباشد. در این مواقع می‌توان از پایه‌های دومتعامد^۱ استفاده نمود. واژه دومتعامد به دو پایه مختلف که عمود بر یکدیگر هستند اما هرکدام به تنهایی یک پایه متعامد تشکیل نمی‌دهند گفته می‌شود.

در هر سیگنال دو-بعدی که از آن عموماً به تصویر یاد می‌شود، یک ماتریس از المان‌ها موجود است که در سطر و ستون‌های مختلف چیده شده‌اند. هر ستون یا هر سطر از یک تصویر را می‌توان به عنوان یک سیگنال یک بعدی تصور کرد که مقادیر دامنه آن، میزان روشنایی نقاط (پیکسل‌های) موجود در آن ستون یا سطر خاص را نشان می‌دهد. شکل ۳-۴ چند نمونه سیگنال متناظر با سطر یا ستون‌های مختلف یک تصویر را نشان می‌دهد.

به این ترتیب، می‌توان تبدیل موجک را بر روی هر سطر و یا ستون از تصویر، به طور جداگانه اعمال کرد. در حقیقت، نحوه پیاده‌سازی تبدیل ویولت دو-بعدی نیز همانند تبدیل موجک یک-بعدی است. به عبارت دیگر، به منظور اعمال تبدیل موجک دو-بعدی به تصویر، ابتدا تبدیل موجک یک-بعدی به سطرها اعمال می‌شود و سپس ستون‌ها با نرخ ۲، downsample می‌شوند تا فقط نمونه‌های واقع در محل‌های زوج باقی بمانند. در این حالت، مجدداً تبدیل موجک یک-بعدی بر ستون‌ها اعمال می‌گردد و در نهایت سطرها با نرخ ۲،

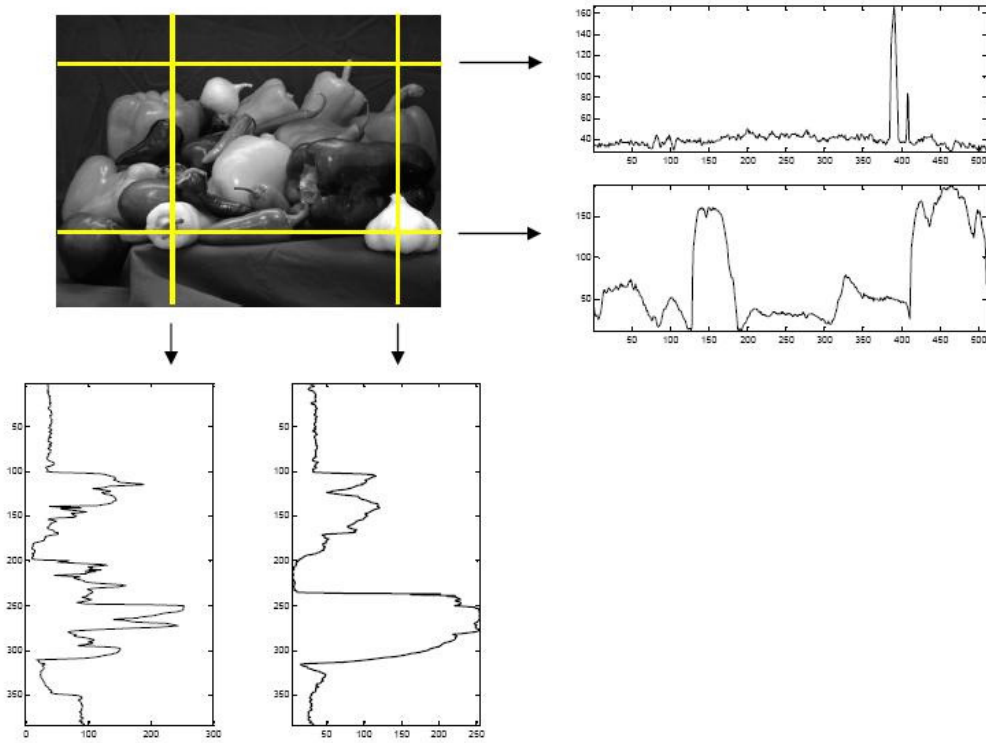
^۱ Biorthogonal

downsample می‌شوند. بدین ترتیب، چهار زیرباند مختلف به عنوان ضرایب تبدیل موجک تصویر، بدست می‌آید.


مشابه با حالت یک-بعدی، اولین زیرباند از ضرایب تبدیل موجک مربوط به ضرایب تقریب است که از لحاظ مقدار و شکل ظاهری، مشابه با تصویر اولیه است. جدای از زیر باند تقریب، سه زیر باند جزئیات خواهیم داشت که یکی از آن‌ها مربوط به جزئیات افقی موجود در تصویر، یکی از آن‌ها مربوط به جزئیات عمودی موجود در تصویر و آخرین زیرباند مربوط به سایر جزئیات موجود در تصویر است که گاهی به آن جزئیات قطری نیز گفته می‌شود. شکل ۴-۴ دو مرحله تبدیل موجک دو-بعدی را بر روی یک نمونه تصویر نشان می‌دهد.

همانطور که در این شکل دیده می‌شود، در زیرباند تقریب (که بالا، سمت چپ واقع است) شکل اولیه حفظ شده است. همچنین، در زیرباند جزئیات افقی (بالا، سمت راست) بخش‌های دارای رفتار افقی موجود در تصویر به نمایش درمی‌آید. به طور مشابه، در زیرباند جزئیات عمودی (پائین، سمت چپ) بخش‌های دارای رفتار عمودی موجود در تصویر نمایش داده می‌شود. آخرین زیرباند نیز مربوط به جزئیات قطری است که در پائین، سمت راست قرار دارد.

در این تحقیق جهت تولید ویژگی‌های فرکانسی، هر تصویر ماموگرافی با استفاده از تبدیل موجک دو-بعدی به چهار سطح تجزیه می‌شود. تبدیل موجکی که در این تحقیق استفاده می‌شود، تبدیل موجک اورتوگونال Daubechies با طول ۴ می‌باشد. دلیلی که از این تبدیل استفاده می‌شود این است که این تبدیل دارای زمان محاسبه کمتری نسبت به دیگر تبدیل‌های موجک از خانواده‌ی Daubechies است در حالی که کارایی تشخیص MC در این نوع نسبت به دیگر تبدیل‌ها قابل مقایسه است [۳۲].



شکل ۴-۳: سیگنال‌های یک-بعدی به دست آمده از چند سطر و ستون دلخواه از یک سیگنال دو-بعدی (تصویر).



(ب)

(الف)

شکل ۴-۴: الف) یک نمونه تصویر شامل انواع جزئیات. ب) یک نمونه تبدیل موجک تصویر و ۴ زیر باند ایجاد شده.

همچنین مشاهده می‌شود که ادامه تجزیه در سطوح بالاتر تنها به پس زمینه فرکانس پایین تصاویر ماموگرافی حساس است [۴۸]. حتی اگر این تصاویر در سطوح بالاتر دارای اطلاعات مفیدی برای تشخیص MCها باشند باز هم به دو دلیل توسط کامپیوترها قابل خوانش نیستند:

(۱) زیر تصاویر تجزیه موجک کوچک کوچکتر از تصویر اصلی هستند به طوری که ابعاد هر یک از تصاویر تجزیه در سطح k ام، یک چهارم ابعاد تصویر در سطح $(k-1)$ ام می‌باشد. بنابراین برای سیستم کامپیوتر، یافتن پیکسل متناظر با تصویر اصلی اولیه از روی تصاویر تجزیه موجک مشکل است.


(۲) تصاویر تجزیه موجک نسبت به تغییر جهت حساس هستند، در حالی که MCها اینگونه نیستند.

با توجه به این دلایل، بازسازی تصویر به این صورت انجام می‌گیرد که برای بازسازی تصویر از هر سطحی، ضرایب موجک مربوط به دیگر سطوح (جزئیات) و ضرایب موجک مربوط به تقریب در همان سطح را صفر قرار می‌دهیم. یعنی تنها ضرایب مربوط به جزئیات هر سطح را بدون تغییر باقی می‌گذاریم. به این ترتیب، چهار تصویر بازسازی شده از چهار سطح مختلف بدست می‌آوریم. بنابر این می‌توان مطمئن شد که همه اطلاعات مربوط به MCها حفظ شده است و از طرفی به طور همزمان پس زمینه فرکانس پایین حذف گردیده و ابعاد تصویر بازسازی شده هم کاملاً با تصویر اصلی اولیه یکسان است. در شکل ۴-۵ تصاویر بازسازی شده از سطوح یک تا چهار تبدیل موجک برای یک نمونه کلاستر MC آورده شده است.

با مشاهده تصاویر بازسازی شده از سطوح اول تا چهارم نتیجه می‌شود که، تصویر بازسازی شده از سطح اول به نوبت پس زمینه حساس است و تصویر بازسازی شده از سطح


چهارم به پس زمینه فرکانس پایین تصویر ماموگرافی وابسته است. تنها تصاویر بازسازی شده از سطوح دوم و سوم دارای اطلاعات مفیدی درباره MCها می باشند. بنابراین ما تنها ویژگی های مربوط به این دو سطح را استخراج کرده و اطلاعات مربوط به سطوح اول و چهارم را در نظر نمی گیریم. ویژگی های فرکانسی برای هر پیکسل از تصویر ماموگرافی به صورت دو مقدار $w^2(i, j)$ و $w^3(i, j)$ تعریف می شوند که به ترتیب مقادیر تصاویر بازسازی شده از سطوح دوم و سوم تبدیل موجک در موقعیت پیکسل (i, j) می باشند. در نهایت بردار ویژگی برای هر پیکسل به صورت زیر تعریف شده است:

$$f(i, j) = \{w^2(i, j), w^3(i, j)\} \quad (۸ - ۴)$$




(الف)

(ب)



(ج)

(د)



(ه)

(ی)

شکل ۴-۵: الف) تصویر ماموگرافی. ب) مکان کلاستر MC. ج-ی) تصاویر بازسازی شده از سطوح یک تا چهار

تبدیل موجک

۳-۱-۴ استخراج ویژگی‌های آماری و ترکیب آن‌ها با ویژگی‌های

فرکانسی

در اینجا هدف گسترش بردار ویژگی‌های فرکانسی با استفاده از افزودن ویژگی‌هایی از حوزه آماری است. ویژگی‌های آماری که می‌تواند در کنار ویژگی‌های فرکانسی قرار گرفته و اطلاعات مفیدی از MCها داشته باشد بسیار زیاد است. در اینجا جهت کاهش حجم محاسبات غیر ضروری و افزایش بازدهی تنها از دو ویژگی استفاده شده است. این دو ویژگی به صورت تجربی موثرتر از دیگر ویژگی‌ها تشخیص داده شده‌اند. این دو ویژگی عبارتند از "کنتراست میانه"^۱ $c(i, j)$ [۴۹] و "ارزش سطح خاکستری هنجار شده"^۲ $s(i, j)$ [۵۰] که به صورت زیر تعریف می‌شوند:

$$c(i, j) = p(i, j) - \text{medium}(y(l, m), l, m \in \text{Window}) \quad (۹ - ۴)$$

^۱ Median contrast

^۲ Normalized gray level value (contrast-to-noise ratio)

$$s(i, j) = \frac{p(i, j) - \text{mean}(y(l, m), l, m \in \text{Window})}{\text{std}(y(l, m), l, m \in \text{Window})} \quad (10 - \epsilon)$$

در رابطه بالا $p(i, j)$ مقدار روشنایی پیکسل در موقعیت (i, j) و Window یک پنجره $n \times n$ است که مرکز آن بر روی پیکسل (i, j) واقع شده است. mean و std به ترتیب تصاویر میانه، میانگین و انحراف معیار در این پنجره می‌باشند. در این تحقیق $n=9$ در نظر گرفته شده است.

با اضافه کردن این دو ویژگی آماری به ویژگی‌های فرکانسی معرفی شده در بخش قبل، بردار ویژگی برای هر پیکسل از تصویر به صورت زیر نمایش داده می‌شود:

$$f(i, j) = \{w_2(i, j), w_3(i, j), c(i, j), s(i, j)\} \quad (11 - \epsilon)$$

۲-۴ کلاسه‌بندی در تصاویر ماموگرافی

در این تحقیق از دو نوع کلاسه بند جهت تشخیص MCها در تصاویر ماموگرافی استفاده شده است. در این بخش اصول اولیه طراحی و مشخصات این دو نوع کلاسه بند و پیاده‌سازی آنها مورد بررسی قرار گرفته است. هر دو کلاسه بند استفاده شده در دسته روش‌های آموزش ماشین بحث شده در فصل ۲ قرار می‌گیرند. همانطور که گفته شد هدف روش‌های آموزش ماشین یافتن وابستگی‌های متقابل داده‌ها است. در زمینه تشخیص MC، مساله اساسی عمل کردن به صورت یک کلاسه بند باینری است که هدف آن این است که مشخص کند آیا MC در یک پیکسل موجود است یا خیر. در اینجا در ابتدا کلاسه بند شبکه

عصبی (NN)^۱ و مشخصات کلاسه بندی از این نوع که در این تحقیق استفاده شده است معرفی می‌شود و سپس کلاسه بند ماشین بردار پشتیبان (SVM)^۲ و پارامترهای طراحی این کلاسه بند که در این تحقیق استفاده شده است، بررسی شده است.

۴-۲-۱ کلاسه بند شبکه عصبی (NN)

شبکه‌های عصبی نوعی مدلسازی از سیستم‌های عصبی واقعی هستند که کاربرد فراوانی در حل مسائل مختلف در علوم دارند. در حقیقت یک شبکه، مجموعه‌ای از ساختارهای ساده است که در کنار یکدیگر سیستم پیچیده نهایی را توصیف می‌کنند. شبکه‌ها انواع مختلفی دارند اما همگی آنها از دو مؤلفه تشکیل می‌شوند:

۱. مجموعه‌ای از گره‌ها: هر گره در حقیقت واحد محاسباتی شبکه است که ورودی‌ها را گرفته و بر روی آن پردازش انجام می‌دهد تا خروجی بدست آید. پردازش انجام شده توسط گره می‌تواند از ساده‌ترین نوع پردازش‌ها نظیر جمع کردن ورودی‌ها تا پیچیده‌ترین محاسبات را شامل شود.


۲. اتصالات بین گره‌ها: این اتصالات نحوه گذر اطلاعات بین گره‌ها را مشخص می‌کند. در حالت کلی اتصالات می‌توانند تک سویه^۳ یا دوسویه^۴ باشند.

^۱ Neural Network
^۲ Support Vector Machine
^۳ Unidirectional
^۴ Bidirectional

۴-۲-۱-۱ شبکه عصبی مصنوعی:

آنچنان که بیان شد انواع مختلفی از شبکه‌ها وجود دارد. در این بین شبکه‌ای وجود دارد که گره را به عنوان یک نرون مصنوعی^۱ در نظر می‌گیرد. در اصطلاح، این چنین شبکه‌هایی را شبکه عصبی مصنوعی یا به اختصار (ANN Network) می‌نامند.

یک نرون مصنوعی در حقیقت مدلی محاسباتی است که از نرون‌های عصبی واقعی انسان، الهام گرفته شده است. شکل ۴-۶ یک نمونه عصب واقعی را نشان می‌دهد.



شکل ۴-۶: یک نمونه عصب واقعی.


به هنگام مدل کردن اعصاب، از پیچیدگی‌های آن‌ها صرف نظر می‌شود و تنها به مفاهیم پایه‌ای بها داده می‌شود، چرا که در غیر این صورت مدلسازی بسیار دشوار خواهد شد.

^۱ Artificial Neural

به طور کلی، مدل یک عصب باید شامل ورودی‌هایی باشند. این ورودی‌ها در وزن‌هایی ضرب می‌شوند تا قدرت سیگنال را تعیین کنند. در نهایت یک عملگر ریاضی تصمیم‌گیری می‌کند که آیا نرون فعال شود یا خیر و اگر جواب مثبت باشد، میزان خروجی را مشخص می‌سازد.

در مدل ارائه شده در شکل ۴-۷، تنوع‌های بسیاری وجود دارد. از جمله این که وزن‌های یک شبکه عصبی، که مقدار خروجی را منتقل می‌کنند، می‌توانند مثبت یا منفی باشند. از طرفی، توابع مورد استفاده برای آستانه‌گذاری می‌توانند بسیار متنوع باشند. از جمله مشهورترین این توابع می‌توان به تابع‌هایی نظیر \arcsin ، \arctan و sigmoid اشاره کرد. این توابع باید پیوسته و هموار بوده و مشتق‌پذیر باشند.

همچنین تعداد گره‌های ورودی شبکه می‌تواند متغیر باشد. البته با زیاد شدن تعداد این گره‌ها، به وضوح تعیین وزن‌ها دشوار می‌شود. تحقیقات زیادی برای حل این موضوع صورت گرفته است. روند تعیین وزن‌های بهینه و تنظیم مقادیر آن‌ها به طور عمده به صورت بازگشتی انجام می‌شود. بدین منظور شبکه را با استفاده از قواعد و داده‌ها آموزش داده و با استفاده از قابلیت یادگیری شبکه، الگوریتم‌های متنوعی پیشنهاد می‌گردد که همگی سعی در نزدیک کردن خروجی تولید شده توسط شبکه به خروجی ایده‌آل و مورد انتظار دارند.



شکل ۴-۷: مدل ریاضی ساده شده عصب واقعی.

یکی از ساده‌ترین و در عین حال کارآمدترین چیده‌مان‌های پیشنهادی برای استفاده در مدلسازی عصب‌های واقعی، مدل پرسپترون چندلایه یا به اختصار MLP^۱ می‌باشد که از یک لایه ورودی، یک یا چند لایه پنهان و یک لایه خروجی تشکیل شده است. در این ساختار، تمام نرون‌های یک لایه به تمام نرون‌های لایه بعد متصل‌اند. این چیده‌مان به اصطلاح یک شبکه با اتصالات کامل را تشکیل می‌دهد. شکل ۴-۸ شمای یک شبکه پرسپترون سه لایه را نشان می‌دهد.

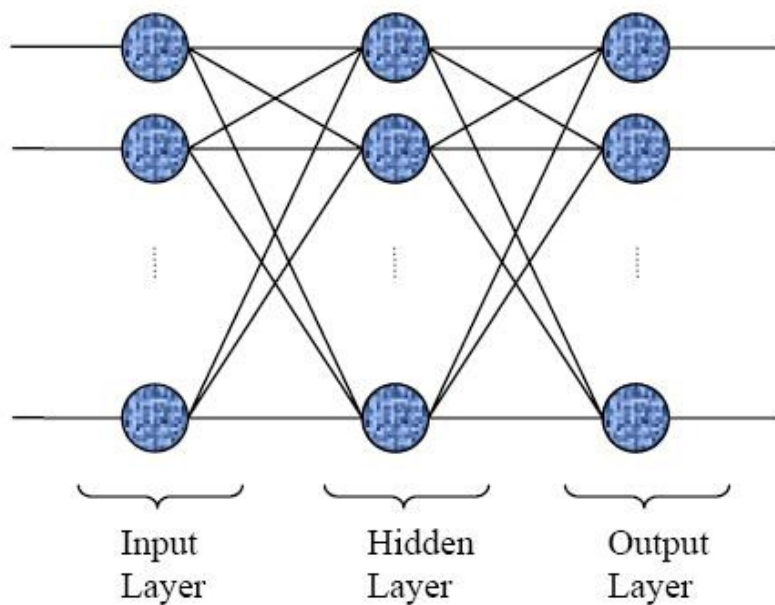
به سادگی می‌توان استنباط نمود که تعداد نرون‌های هر لایه، مستقل از تعداد نرون‌های دیگر لایه‌ها می‌باشد. توجه به این نکته حائز اهمیت است که در شکل ۴-۸، هر دایره تجمیع شده‌ی عمل جمع و آستانه‌گذاری (عبور از تابع غیرخطی سیگموئید) است. در حقیقت هر دایره توپر در شکل ۴-۸، مدلی است از جمع‌کننده و بلوک آستانه‌گذاری نشان داده شده در شکل ۴-۷، که به منظور سهولت نمایش به این فرم نشان داده شده است. با توجه به شکل خروجی عصب نام (در لایه آخر) را می‌توان به صورت زیر نشان داد.

$$o_i = \text{sgm} \left(\sum_m \text{sgm} \left(\sum_l x_l w_{lm}^h \right) w_{mi}^o \right) \quad (۴-۱۲)$$

که در آن h و o به ترتیب نشان دهنده‌ی لایه پنهان و لایه خروجی بوده و منظور از w همان وزن‌های لایه‌ها می‌باشد. sgm نیز تابع فعال‌ساز سیگموئید است که به صورت زیر تعریف می‌شود:

$$\text{sgm}(x) = \frac{1}{1 + e^x} \quad (۴-۱۳)$$


^۱ Multi layer perceptron



شکل ۴-۸: پرسپترون ۳ لایه با اتصالات کامل.

شکل ۴-۹ تابع سیگموئید را نشان می‌دهد. می‌توان دید که این تابع رفتاری هموار

بین ۰ و ۱ دارد.



شکل ۴-۹: رفتار تابع سیگموئید

۴-۲-۱-۲ آموزش شبکه به روش پس انتشار خطا

به طور کلی شبکه‌های عصبی مصنوعی از لحاظ یادگیری دو دسته‌اند: شبکه‌های با وزن ثابت و شبکه‌های با وزن متغیر (شبکه‌های یادگیرنده). خود شبکه‌های یادگیرنده نیز به دو دسته با سرپرست^۱ و بدون سرپرست^۲ تقسیم می‌شوند. در شبکه‌های با سرپرست، در فاز آموزش از نمونه‌هایی استفاده می‌گردد که خروجی ایده‌آل متناظر با آن‌ها از پیش دانسته است. به عبارت دیگر در این گونه شبکه‌ها، نمونه‌های داده ورودی، برچسب دارند. در شبکه‌های بی‌سرپرست، بر اساس یک معیار (مثلاً فاصله) و بر اساس نوعی رقابت، خروجی مورد نظر در کلاس جداگانه قرار می‌گیرد.

با توجه به این که شبکه عصبی، مدل ساده شده اعصاب بدن است، درست به مانند آن‌ها قابلیت یادگیری دارد. به عبارت دیگر، شبکه با استفاده از اطلاعاتی که از ورودی و توسط سرپرست خود دریافت می‌کند، قادر به فراگیری روند موجود در الگوهاست. لذا به طور مشابه با انسان، روند یادگیری در شبکه عصبی نیز از مدل‌های انسانی الهام گرفته است بدین صورت که مثال‌های بسیاری را به دفعات بایستی به شبکه ارائه نمود تا بتواند با تغییر وزن‌های شبکه، خروجی مورد نظر را دنبال کند.

ارائه نمونه داده‌های ورودی به شبکه عصبی به دو روش امکان‌پذیر است:

۱. روش ارائه یک جا^۳: در این روش، تمام نمونه‌ها به شبکه ارائه می‌گردند و در آخر، خطای شبکه نسبت به کل نمونه‌ها محاسبه گشته و وزن‌ها بر اساس آن خطا تغییر می‌کنند. در مرحله بعد، به طور مجدد تمام داده‌ها یک بار دیگر به شبکه ارائه شده و روند فوق نظیر به نظیر انجام می‌پذیرد تا در نهایت خطا به سطح

^۱ Supervised

^۲ Unsupervised

^۳ Batch mode

قابل قبولی برسد. واضح است که این روش پیچیده و زمان‌بر بوده و نیاز به حافظه زیادی دارد. همچنین امکان گیر کردن الگوریتم در مینیمم‌های محلی نیز وجود دارد.

۲. روش ارائه الگو^۱: در این روش، در هر گام نمونه‌ها به صورت تک تک به شبکه داده شده و خطای متناظر با همان داده بلافاصله محاسبه شده و بر اساس آن، وزن‌های شبکه تغییر می‌کنند. سپس نمونه بعدی به شبکه ارائه شده و روند بالا به طور مشابه انجام می‌پذیرد. چون در این روش، در هر گام، اصلاح وزن‌ها بر اساس هر نمونه انجام می‌پذیرد، الگوریتم همگرایی خوبی داشته و با توجه به ماهیت تصادفی موجود در ارائه تکی داده‌ها، خطر مینیمم‌های محلی منتفی است.

الگوریتم پس‌انتشار خطا:

این الگوریتم که در سال ۱۹۸۶ توسط روملهارت و مک کلیلاند پیشنهاد گردید، در شبکه‌های عصبی پیش‌سو^۲ مورد استفاده قرار می‌گیرد. پیش‌سو بودن به این معناست که نرون‌های مصنوعی در لایه‌های متوالی قرار گرفته‌اند و خروجی (سیگنال) خود را رو به جلو می‌فرستند. واژه‌ی "پس‌انتشار" نیز به معنای این است که خطاها به سمت عقب در شبکه تغذیه می‌شوند تا وزن‌ها را اصلاح کنند و پس از آن، به طور مجدد ورودی مسیر پیش‌سوی خود تا خروجی را تکرار کند. روش پس‌انتشار خطا از روش‌های باسرپرست است به این مفهوم که نمونه‌های ورودی برچسب خورده‌اند و خروجی مورد انتظار هر یک از آن‌ها از پیش دانسته است. لذا خروجی شبکه با این خروجی‌های ایده‌آل مقایسه شده و خطای شبکه محاسبه می‌گردد. در این الگوریتم ابتدا فرض بر این است که وزن‌های شبکه

^۱ Pattern mode

^۲ Feed forward

به طور تصادفی انتخاب شده‌اند. در هر گام خروجی شبکه محاسبه شده و بر حسب میزان اختلاف آن با خروجی مطلوب، وزن‌ها تصحیح می‌گردند تا در نهایت این خطا، مینیمم شود. در الگوریتم پسانتشار خطا، تابع تحریک هر عصب به صورت جمع وزن‌دار ورودی‌های مربوط به آن عصب در نظر گرفته می‌شود. بدین ترتیب با فرض این که w وزن‌های متناظر بین لایه ورودی و لایه بعد باشد می‌توان نوشت:

$$A_j(\bar{x}, \bar{w}) = \sum_{i=1}^n x_i w_{ji} \quad (14-4)$$

به وضوح می‌توان دید که خروجی تابع تحریک عصب فقط به ورودی و وزن‌های متناظر بستگی دارد. با فرض این که تابع خروجی، سیگموئید باشد می‌توان خروجی عصب j ام را به صورت زیر نوشت:

$$O_j(\bar{x}, \bar{w}) = \text{sgm}(A_j(\bar{x}, \bar{w})) = \frac{1}{1 + e^{-A_j(\bar{x}, \bar{w})}} \quad (15-4)$$

همان گونه که در شکل ۴-۹ دیده شد، تابع سیگموئید به ازای اعداد منفی بزرگ، بسیار نزدیک به صفر است و برای اعداد مثبت بزرگ، مقداری بسیار نزدیک به ۱ دارد و در این بین به طور هموار تغییر می‌کند به نحوی که در $x=0$ دقیقاً از حد واسط بازه [۰،۱] یعنی ۰.۵ عبور می‌کند. همچنین با دقت در رابطه (۴-۱۵) درمی‌یابیم که خروجی فقط به مقدار تابع تحریک بستگی دارد که به نوبه خود به ورودی و وزن‌ها مرتبط می‌شود. لذا برای تغییر خروجی باید وزن‌ها تغییر کنند. آن چنان که پیش از این نیز بیان شد، هدف فرآیند آموزش، رسیدن به خروجی مطلوب (یا نزدیک به مطلوب) است. بدین ترتیب

ابتدا باید تابع خطای هر نرون را تعریف کنیم. این خطا از اختلاف خروجی واقعی شبکه و خروجی مورد انتظار به صورت زیر بدست می‌آید:

$$E_j(\bar{x}, \bar{w}, d_j) = (O_j(\bar{x}, \bar{w}) - d_j) \quad (۴ - ۱۶)$$

انتخاب مربع تفاضل بین خروجی واقعی (O_j) و خروجی مطلوب (d_j) از چندین جنبه قابل بحث است؛ اولاً با استفاده از توان دوم، مقدار خطا همواره مثبت خواهد بود، ثانیاً اگر اختلاف بین خروجی واقعی و مطلوب زیاد باشد، توان دوم منجر به بزرگتر شدن این عدد می‌شود و بالعکس اگر اختلاف بین خروجی واقعی و مطلوب کم باشد، توان دوم منجر به کوچکتر شدن آن می‌گردد. بر این اساس می‌توان خطای کلی شبکه را به فرم مجموع خطای تک تک عصب‌های لایه خروجی نوشت. لذا داریم:

$$E(\bar{x}, \bar{w}, \bar{d}) = \sum_j E_j(\bar{x}, \bar{w}, d_j) = \sum_j (O_j(\bar{x}, \bar{w}) - d_j)^2 \quad (۴ - ۱۷)$$

حال بایستی به بررسی ارتباط خطا با ورودی‌ها، وزن‌ها و خروجی‌ها پردازیم. برای

این کار روش‌های متفاوتی وجود دارد که برخی از مهم‌ترین آن‌ها عبارتند از:

۱. روش گرادیان شیب^۱
۲. روش نیوتن
۳. روش اندازه حرکت^۲
۴. روش آنتروپی متقابل^۳
۵. روش مارکوآرلت-لونبرگ^۴

^۱ Gradient descent

^۲ Momentum

^۳ Cross entropy

^۴ Marquardt-Levenberg

در اینجا، از روش گرادیان شیب به دلیل این که ساده‌ترین و درعین حال پرکاربردترین روش است، استفاده کرده‌ایم که در ادامه روابط آن بیان خواهد شد. در روش گرادیان شیب، ابتدا یک تابع هزینه درجه دوم تعریف می‌گردد که عبارت است از:

$$J(w) = \frac{1}{N} \sum_{i=1}^N J(w, i) = \frac{1}{N} \sum_{i=1}^N \left(\sum_{j=1}^L (O_j - d_j)^2 \right) \quad (۱۸ - ۴)$$

که در آن L بعد خروجی (تعداد نرون‌های لایه خروجی) است. هدف نهایی الگوریتم پس‌انتشار خطا، مینیمم کردن این تابع هزینه است. بر اساس روش گرادیان شیب، با توجه به درجه ۲ و مثبت بودن تابع هزینه، فرض می‌شود این تابع رفتاری سهموی دارد. لذا برای رسیدن به مینیمم کلی آن بایستی در خلاف جهت شیب تابع حرکت کنیم. بنابراین با فرض این که وزن‌ها در ابتدای کار به صورت تصادفی انتخاب شده باشند، باید شیب تابع خطا را نسبت به وزن‌ها محاسبه نموده و در جهت خلاف آن، وزن‌ها را تغییر دهیم و این روند را تا آن جا ادامه دهیم که به مینیمم کلی یا یک خطای قابل قبول برسیم. بنابراین میزان تغییر وزن‌ها در هر گام عبارت است از:

$$\Delta w_{ji} = -\eta \frac{\partial E}{\partial w_{ji}} \quad (۱۹ - ۴)$$

که در آن η ثابت اصلاح وزن‌هاست و توسط کاربر انتخاب می‌شود. این ثابت نرخ همگرایی الگوریتم را تعیین می‌کند. لذا به وضوح هر چه مقدار این ثابت بیشتر باشد، میزان تغییرات در هر گام بیشتر خواهد بود و بالعکس.

طبق رابطه (۱۹-۴) به منظور یافتن میزان اصلاح وزن‌ها در هر گام، باید مشتق خطا را برحسب وزن‌ها بدست آوریم. بدین منظور با استفاده از قاعده زنجیره‌ای می‌توان نوشت:

$$\frac{\partial E}{\partial w_{ji}} = \frac{\partial E}{\partial O_j} \cdot \frac{\partial O_j}{\partial w_{ji}} \quad (۲۰ - ۴)$$

با توجه به رابطه (۱۷-۴) می‌توان نوشت:

$$\frac{\partial E}{\partial O_j} = \tau(O_j - d_j) \quad (۲۱ - ۴)$$

همچنین با استفاده مجدد از قاعده زنجیره‌ای و با توجه به روابط (۱۴-۴) و (۴-۴)

(۱۵) می‌توان نوشت:

$$\frac{\partial O_j}{\partial w_{ji}} = \frac{\partial O}{\partial A_j} \cdot \frac{\partial A_j}{\partial w_{ji}} = (O_j(1 - O_j)) \cdot x_i \quad (۲۲ - ۴)$$

در رابطه بالا برای محاسبه $\frac{\partial O}{\partial A_j}$ با توجه به رابطه (۱۴-۴) و با استناد به خاصیت

زیر برای تابع سیگموئید استفاده شده است که در آن می‌توان مشتق تابع سیگموئید را

برحسب خود تابع نوشت:

$$\frac{d}{dx} \text{sgm}(x) = \frac{d}{dx} \left(\frac{1}{1 + e^{-x}} \right) = \frac{e^{-x}}{(1 + e^{-x})^2} = (1 - \text{sgm}(x)) \text{sgm}(x) \quad (۲۳ - ۴)$$

با قرار دادن (۲۱-۴) و (۲۲-۴) در رابطه (۲۰-۴) خواهیم داشت:

$$\frac{\partial O_j}{\partial w_{ji}} = \frac{\partial E}{\partial O_j} \cdot \frac{\partial O_j}{\partial w_{ji}} = \tau(O_j - d_j)O_j(1 - O_j)x_i \quad (24 - 4)$$

اکنون با جایگزینی (۲۴-۴) در (۱۹-۴)، رابطه نهایی میزان اصلاح وزن‌ها در هر

گام از الگوریتم پس‌انتشار خطا به صورت زیر بدست می‌آید:

$$\Delta w_{ji} = -\eta \frac{\partial E}{\partial w_{ji}} = -\tau\eta(O_j - d_j)O_j(1 - O_j)x_i \quad (25 - 4)$$

از رابطه بالا در اصلاح وزن‌های یک شبکه عصبی دو لایه (ورودی-خروجی) که فقط یک دسته وزن دارند می‌توان استفاده نمود. با فرض وجود لایه پنهان بایستی دو دسته وزن در هر گام از اجرای الگوریتم پس‌انتشار خطا، اصلاح در این (w) و وزن‌های اتصالات لایه پنهان به لایه خروجی (v) شوند: وزن‌های اتصالات لایه ورودی به لایه پنهان حالت، خطا علاوه بر وابستگی به وزن‌های اتصالات لایه پنهان به لایه خروجی یا همان وابسته است. مجدداً با استفاده از ایده گرادیان شیب می‌توان نوشت:

$$\Delta v_{ik} = -\eta \frac{\partial E}{\partial v_{ik}} = -\eta \frac{\partial E}{\partial x_i} \cdot \frac{\partial x_i}{\partial v_{ik}} = -\eta \frac{\partial E}{\partial x_i} \cdot (x_i(1 - x_i)v_{ik}) \quad (26 - 4)$$

همچنین با توجه به این که در حالتی که شبکه عصبی دارای ۳ لایه است،

ورودی لایه خروجی در حقیقت خروجی لایه پنهان است، رابطه (۲۴-۴) به صورت زیر

تغییر می‌یابد:

$$\frac{\partial E}{\partial w_{ji}} = \tau(O_j - d_j)O_j(1 - O_j)w_{ji} \quad (4 - 27)$$

اگر شبکه عصبی دارای تعداد لایه‌های بیشتری باشد، با استفاده از روندی مشابه می‌توان میزان وزن‌های هر لایه را اصلاح نمود. در عمل می‌توان نشان داد که یک شبکه عصبی با ۳ لایه می‌تواند راندمانی مشابه با شبکه‌های با لایه‌های بیشتر داشته باشد، بنابراین از آنجا که افزایش تعداد لایه‌ها، الگوریتم یادگیری را پیچیده‌تر می‌کند، مرسوم است که از شبکه‌های عصبی با ۳ لایه (ورودی، نهان و خروجی) استفاده گردد.

۴-۲-۱-۳ تشخیص MCها در تصاویر ماموگرافی با استفاده از شبکه عصبی

در این بخش هدف این است که با استفاده از ویژگی‌هایی که در بخش ۴-۱ بدست آمده است و کلاسه بند شبکه عصبی مکان‌هایی از تصویر ماموگرافی را که پتانسیل MC بودن را دارا هستند تشخیص دهیم. برای این کار در این تحقیق یک کلاسه بند شبکه عصبی پیش-سو انتخاب شده است. مهم‌ترین دلیل برای انتخاب این کلاسه بند خواص آماری غیرپارامتری آن است. برخلاف روش‌های کلاسه‌بندی آماری کلاسیک مثل کلاسه بند بیزین^۱، در شبکه عصبی به هیچگونه اطلاعاتی درباره توزیع احتمالاتی اصلی نیازی نیست. از آنجا که شبکه عصبی می‌تواند پارامترهای خود را در مرحله آموزش با استفاده از مثال‌هایی آموزش دهد، می‌توان در موارد عملی و کاربردی مثل تشخیص MCها که داده‌ها غیر خطی، نایستان و غیر گوسی هستند از آن استفاده کرد. شبکه عصبی در اینجا برای تولید یک نقشه احتمالاتی^۲ در خروجی برای هر تصویر ماموگرافی و با استفاده از ویژگی‌های توصیف شده به عنوان ورودی،


^۱ Bayes classifier

^۲ Likelihood map

استفاده می‌شود. ارزش هر پیکسل در این نقشه احتمالاتی بیانگر احتمال MC بودن آن پیکسل است. هرچه ارزش پیکسل، مقدار بالاتری داشته باشد، احتمال MC بودن آن پیکسل بیشتر است. شبکه عصبی پیش‌سوی چند لایه استفاده شده در این تحقیق یک شبکه سه لایه است: یک لایه ورودی، یک لایه خروجی و یک لایه پنهان که شامل شش واحد^۱ است. تعداد واحدهای لایه ورودی برابر با تعداد المان‌های بردار ویژگی است که بنابراین برای بردار ویژگی‌های روشنایی تصویر این تعداد ۸۱، برای بردار ویژگی‌های فرکانسی تعداد آن ۲ و برای بردار ویژگی‌های فرکانسی و آماری تعداد این واحدها ۴ می‌باشد. تعداد واحدهای بردار خروجی هم ۲ عدد متناظر با پیکسل‌های شامل MC و پیکسل‌های نرمال می‌باشد.

۲-۲-۴ کلاسه بند ماشین بردار پشتیبان (SVM)

ماشین بردار پشتیبان یا SVM در واقع یک کلاسه بند دودویی است که دو کلاس را با استفاده از یک مرز خطی از هم جدا می‌کند. ایده اصلی یک کلاسه بند SVM در شکل ۴-۱۰ نمایش داده شده است.



شکل ۴-۱۰: اساس کار SVM

^۱ Unit


این شکل ساده‌ترین حالت را نشان می‌دهد که در آن بردارهای ویژگی با یک ابرصفحه مجزاساز خطی به صورت:

$$f(x) = W^T \cdot x + b \quad (4 - 28)$$

جدا می‌شود. با انتخاب W و b های مختلف، صفحه‌های مختلفی می‌تواند به عنوان صفحه مجزاساز انتخاب شود.

در این روش با استفاده از تمامی باندها و یک الگوریتم بهینه‌سازی، نمونه‌هایی را که مرزهای دو کلاس را تشکیل می‌دهند، به دست می‌آورند. به این نمونه‌ها بردارهای پشتیبان می‌گویند. در واقع تعدادی از نقاط آموزشی که کمترین فاصله را تا مرز تصمیم‌گیری دارند به عنوان زیر مجموعه‌ای برای تعریف مرزهای تصمیم‌گیری و به عنوان بردار پشتیبان در نظر گرفته می‌شوند.

در شکل ۴-۱۱ دو کلاس مختلف از چند نمونه داده و بردارهای پشتیبان مربوط به آنها نشان داده شده است.



شکل ۴-۱۱: دو کلاس مختلف از چند نمونه داده و بردارهای پشتیبان مربوط به آنها.

فرض کنید داده‌ها از دو کلاس تشکیل شده و کلاس‌ها در مجموع دارای L نقطه آموزشی (x_i) $i=1, \dots, L$ باشند. بردار ویژگی نمونه آموزشی i ام را نشان می‌دهد. خروجی این دو کلاس با $y_i = \pm 1$ برچسب زده می‌شوند. محاسبه مرز تصمیم‌گیری دو کلاس کاملاً جدا از هم، از روش حاشیه بهینه استفاده می‌شود [۵۱]. در این روش مرز خطی بین دو کلاس به گونه‌ای محاسبه می‌شود که:

۱- تمام نمونه‌های کلاس +۱ در یک طرف مرز و تمام نمونه‌های کلاس -۱ در طرف دیگر مرز واقع شوند.

۲- مرز تصمیم‌گیری به گونه‌ای باشد که فاصله نزدیکترین نمونه‌های آموزشی هر دو کلاس از یکدیگر در راستای عمود بر مرز تصمیم‌گیری تا جایی که ممکن است حداکثر شود.

یک مرز تصمیم‌گیری خطی را در حالت کلی می‌توان به صورت زیر نوشت:

$$w \cdot x + b = 0 \quad (4-29)$$

x یک نقطه روی مرز تصمیم‌گیری و w یک بردار n بعدی عمود بر مرز تصمیم‌گیری است. $\frac{b}{\|w\|}$ فاصله مبدأ تا مرز تصمیم‌گیری و $w \cdot x$ بیانگر ضرب داخلی دو بردار است. از آنجا که با ضرب یک ثابت در دو طرف رابطه (۴-۲۹) باز هم تساوی برقرار خواهد بود برای تعریف یکتای مقدار b و w شرایط زیر بر روی آن‌ها اعمال می‌شود:

$$y_i(w \cdot x_i + b) = 1 \quad \leftarrow \text{اگر } x_i \text{ یک بردار پشتیبان باشد}$$

(۴-۳۰)

$$y_i(w \cdot x_i + b) > 1 \quad \leftarrow \text{اگر } x_i \text{ یک بردار پشتیبان نباشد}$$

اولین مرحله برای محاسبه مرز تصمیم‌گیری بهینه، پیدا کردن نزدیکترین نمونه‌های آموزشی دو کلاس است. در مرحله بعد فاصله آن نقاط از هم در راستای عمود بر مرزهایی که دو کلاس را از هم به طور کامل جدا می‌کنند محاسبه می‌شود. مرز تصمیم‌گیری بهینه، مرزی

است که حداکثر حاشیه را داشته باشد. مرز تصمیم‌گیری بهینه با حل مسئله بهینه‌سازی زیر محاسبه می‌شود.

$$\max_{w,b} \min_{i=1,\dots,L} \left[y_i \frac{(w \cdot x_i + b)}{|w|} \right] \quad (31 - 4)$$

با توجه به (۲۳-۴) و انجام یک سری عملیات ریاضی، رابطه بالا به رابطه زیر تبدیل

می‌شود.

$$\min_{w,b} \frac{1}{\gamma} |w|^2, \quad y_i(w \cdot x_i + b) - 1 \geq 0, \quad i = 1, \dots, L \quad (32 - 4)$$

حل کردن مسئله بهینه‌سازی (۳۲-۴) کار مشکلی است. برای ساده‌تر کردن آن با

استفاده از روش ضرایب نامعین لاگرانژ این مسئله بهینه‌سازی را می‌توان به فرم زیر تبدیل

کرد که λ_i ها ضرایب لاگرانژ می‌باشند.

$$\max_{\lambda_1, \dots, \lambda_L} \left[-\frac{1}{\gamma} \sum_{i=1}^L \sum_{j=1}^L \lambda_i y_i (x_i \cdot x_j) \lambda_j y_j + \sum_{i=1}^L \lambda_i \right] \quad (33 - 4)$$

$$\lambda_i \geq 0 \quad i = 1, \dots, L$$

$$\sum_{i=1}^L \lambda_i y_i = 0$$

پس از حل مسئله بهینه‌سازی بالا و یافتن ضرایب لاگرانژ w با استفاده از رابطه زیر

محاسبه می‌شود.

$$w = \sum_{i=1}^L \lambda_i y_i x_i \quad (34 - 4)$$

λ_i برای بردارهای پشتیبان، بزرگتر از صفر و برای نقاط دیگر صفر خواهد بود.

بنابراین با توجه به رابطه (۴-۳۴) و صفر بودن λ_i مربوط به x_i هایی که بردار پشتیبان نیستند، برای به دست آوردن مرز تصمیم‌گیری فقط نیاز به تعداد محدودی از نقاط آموزشی، که همان بردارهای پشتیبان هستند، می‌باشد و همه آن‌ها لازم نیستند. در نتیجه طبقه‌بندی تصاویر ابرطیفی با استفاده از ماشین بردار پشتیبان به تعداد محدودی نقطه آموزشی نیاز خواهد داشت. پس از یافتن w با استفاده از رابطه زیر مقدار b به ازاء بردارهای پشتیبان مختلف محاسبه شده و b نهایی با میانگین‌گیری از b های حاصل به دست می‌آید.

$$\lambda_i [y_i (wx_i + b)] = 0 \quad i = 1, \dots, L \quad (۴-۳۵)$$

طبقه‌بند کننده نهایی از رابطه (۸) به دست می‌آید.

$$f(x, w, b) = \text{sgn}(w \cdot x + b) \quad (۴-۳۶)$$

الگوریتم بالا مرز خطی دو کلاس کاملاً جدا از هم را به دست می‌دهد، اما در حالتی که کلاس‌ها با هم همپوشانی داشته باشند جدا کردن کلاس‌ها بوسیله مرز تصمیم‌گیری خطی همواره با خطا همراه بود. برای حل این مشکل می‌توان ابتدا داده‌ها را از فضای اولیه R^n با استفاده از یک تبدیل غیرخطی ϕ ، به فضای با ابعاد بیشتر R^m منتقل کرد که در فضای جدید کلاس‌ها تداخل کمتری با یکدیگر داشته باشند. سپس در فضای جدید با استفاده از معادلات قبلی و جایگزینی x_i با $\phi(x_i)$ و در نظر گرفتن مقداری خطا، مرز تصمیم‌گیری بهینه محاسبه می‌شود. با توجه به این نکته و در نظر گرفتن رابطه (۴-۳۳) می‌توان نتیجه گرفت که یافتن مرز تصمیم‌گیری بهینه به حل مسئله بهینه‌سازی (۴-۳۷) تبدیل می‌شود.

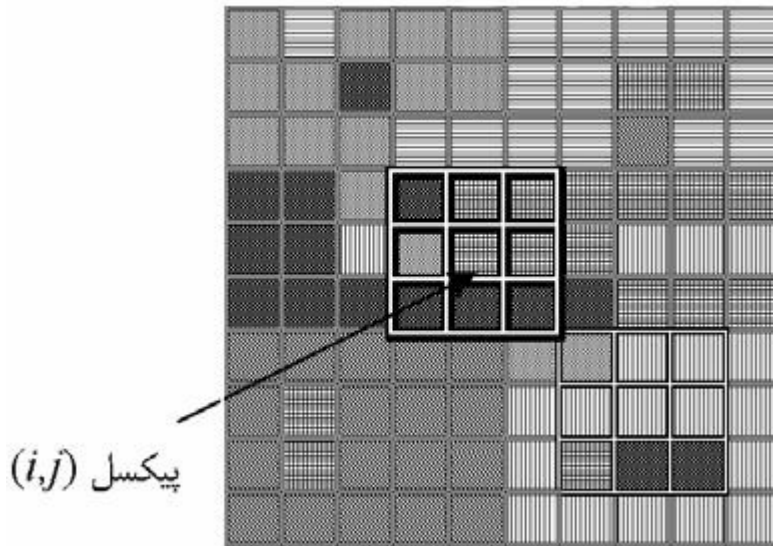
$$\max_{\lambda_1, \dots, \lambda_L} \left[-\frac{1}{2} \sum_{i=1}^L \sum_{j=1}^L \lambda_i y_i (\phi(x_i) \cdot \phi(x_j)) y_j \lambda_j + \sum_{i=1}^L \lambda_i \right] \quad (۴-۳۷)$$

$$C \geq \lambda_i \geq 0 \quad i = 1, \dots, L$$

$$\sum_{i=1}^L \lambda_i y_i = .$$

در این مسئله بهینه‌سازی C یک عدد ثابت است. اگر $C \rightarrow \infty$ مسئله بهینه‌سازی به سمت یافتن یک مرز بهینه برای کلاس‌هایی با تداخل بسیار زیاد پیش می‌رود. از طرفی اگر $C \rightarrow 0$ مسئله بهینه‌سازی به سمت یافتن مرز بهینه جداکننده دو کلاس که تداخل بسیار کمی دارند پیش خواهد رفت. در رابطه (۴-۳۷) معمولاً به جای استفاده از ϕ ، از یک تابع هسته که به صورت زیر تعریف می‌گردد استفاده می‌شود:

$$k(x_i, x_j) = \phi(x_i)\phi(x_j) \quad (4 - 38)$$



شکل ۴-۱۲: پیکسل‌های همسایه پیکسل (i, j)

پس از تعیین یک کرنل مناسب $k(x_i, x_j)$ به جای $\phi(x_i)\phi(x_j)$ ، در رابطه (۴-۳۷)، مسئله بهینه‌سازی حل می‌شود. $k(x_i, x_j)$ در واقع یک تابع در فضای اولیه می‌باشد که برابر با

ضرب داخلی دو بردار در فضای ویژگی است. برای معادل بودن تابع $k(x_i, x_j)$ با ضرب داخلی دو بردار در فضای ویژگی، باید $k(x_i, x_j)$ یک تابع معین مثبت متقارن بوده و در شرط مرسر^۱ صدق کند [۵۱]. از مهمترین کرنل‌ها که در این شرط صدق می‌کنند، کرنل چندجمله‌ای، هیپربولیک و تانژانت هستند که به صورت زیر تعریف می‌شوند:

$$k(x, y) = (x \cdot y + 1)^p \quad (39 - 4)$$

$$k(x, y) = e^{-\|x-y\|^2 / 2\sigma^2} \quad (40 - 4)$$

$$k(x, y) = \tanh(kx \cdot y - \delta) \quad (41 - 4)$$

۴-۲-۱- تشخیص MCها در تصاویر ماموگرافی با استفاده از کلاسه بند

ماشین بردار پشتیبان

در این بخش هدف این است که با استفاده از ویژگی‌هایی که در بخش ۴-۱ بدست آورده شده است و کلاسه بند ماشین بردار پشتیبان مکان‌هایی از تصویر ماموگرافی را که پتانسیل MC بودن را دارا هستند تشخیص دهیم. همانطور که در بخش ۴-۲-۴ گفته شد، گزارش شده است که SVMها بالاترین دقت را در تشخیص MCها دارند. در این تحقیق می‌توان به مزیت استفاده از SVM در تشخیص اشیاء در تصاویر پزشکی پی برد. جهت تعیین ساختار SVM استفاده شده در این تحقیق ابتدا باید تابع کرنل مورد استفاده را مشخص کرد. در این تحقیق از کرنل گوسی (رابطه ۴-۴۰) استفاده شده است. طبقه‌بندی کننده‌ی نهایی را می‌توان با استفاده از رابطه زیر به دست آورد.

^۱ Mrrcer

$$f(x, \lambda_1, \dots, \lambda_L) = \text{sgn}(\sum_{i=1}^L \lambda_i y_i k(x_i, x) + b) \quad (42 - 4)$$

برای بدست آوردن پارامترهای بهینه از الگوریتم "m-fold cross validation" استفاده شده است. این الگوریتم شامل چند مرحله است. در مرحله اول، مجموعه داده‌های آموزشی به صورت مساوی به تعداد m مجموعه با اندازه‌های یکسان تقسیم می‌شود. سپس برای محاسبه پارامتر بهینه σ ، به ازای هر مقدار پارامتر، کلاسه بند SVM، m مرتبه آموزش داده می‌شود. در هر یک از این m مرتبه یکی از m مجموعه را بیرون نگه داشته و SVM را با استفاده از بقیه مجموعه‌ها آموزش می‌دهیم. پس از آموزش SVM، از همان مجموعه بیرون نگه داشته شده برای تست SVM استفاده می‌شود و خطای بدست آمده از تست این مجموعه را ذخیره می‌گردد. سپس در مرحله بعدی از خطاهای ذخیره شده در مرحله قبل میانگین گرفته تا خطای تعمیم^۱ SVM زده شود. در نهایت پارامتری که به ازای آن کمترین خطای تعمیم ایجاد شود به عنوان پارامتر بهینه انتخاب می‌شود.

در اینجا هم مشابه کلاسه‌بندی به روش شبکه عصبی، خروجی کلاسه بند SVM یک نقشه احتمالاتی است که ابعادی مشابه تصویر اولیه دارد و ارزش هر پیکسل در آن بیانگر میزان MC بودن آن مکان است [۴۷].

۳-۴ نتیجه‌گیری

در این فصل تعداد شش روش تشخیص MC در تصاویر ماموگرافی معرفی شد. این شش روش به طور خلاصه از حیث روش‌های استخراج ویژگی و کلاسه بند استفاده شده به صورت زیر دسته بندی می‌شوند:

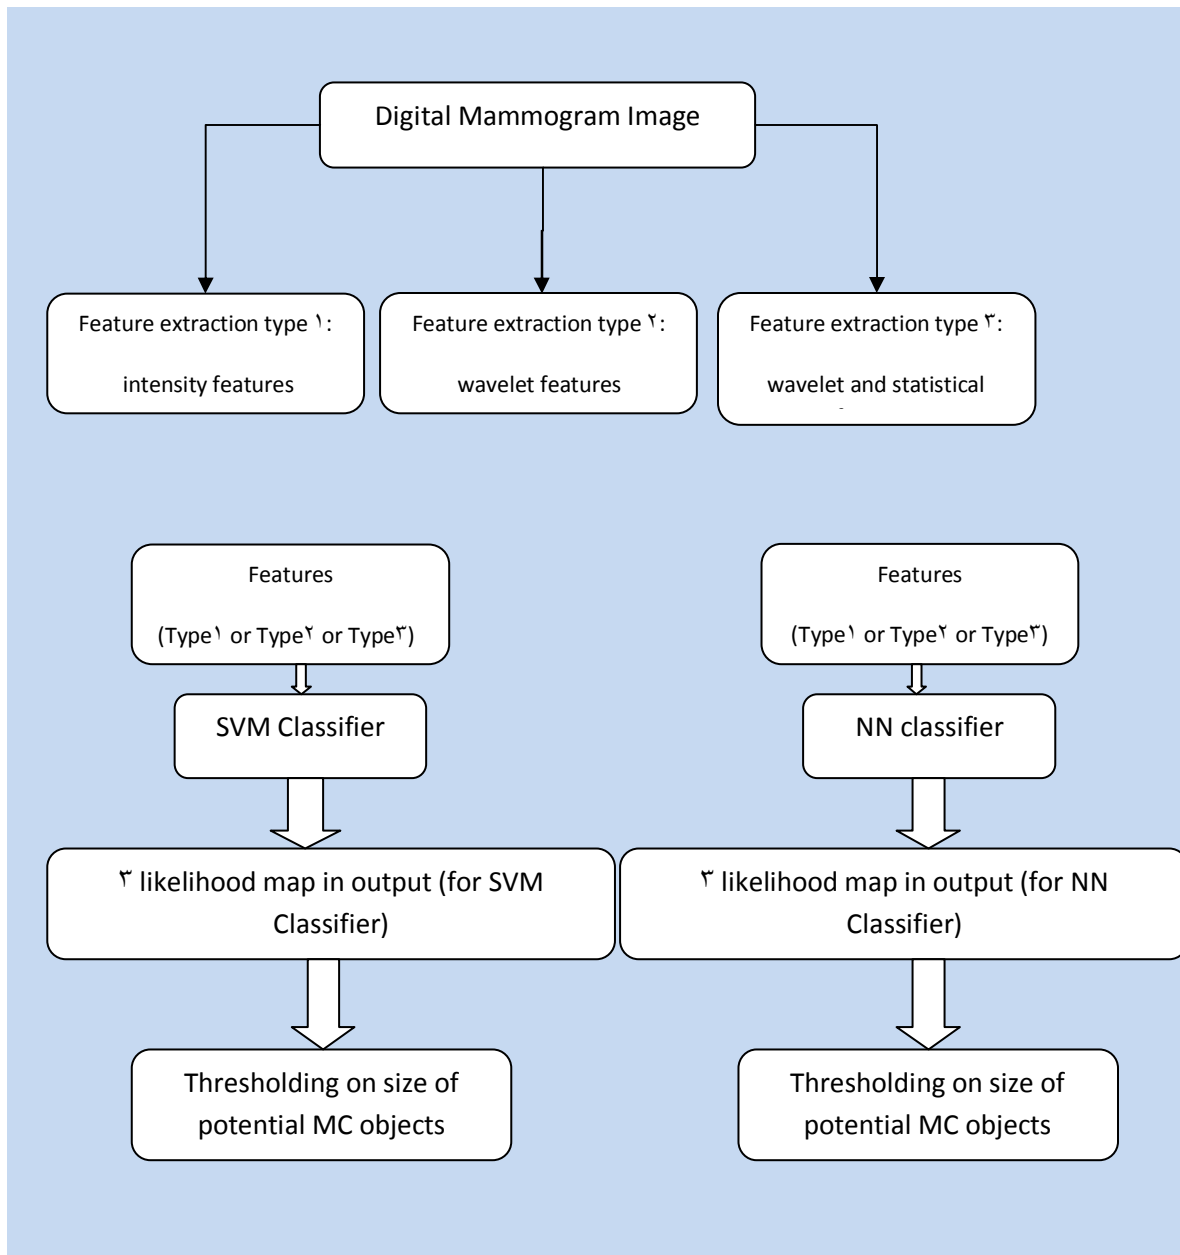
^۱ Generalization

- (۱) استخراج ویژگی شدت روشنایی پیکسل‌های تصویر و کلاسه بند شبکه عصبی
- (۲) استخراج ویژگی‌های فرکانسی پیکسل‌های تصویر و کلاسه بند شبکه عصبی
- (۳) استخراج ویژگی‌های فرکانسی و آماری پیکسل‌های تصویر و کلاسه بند شبکه

عصبی

- (۴) استخراج ویژگی شدت روشنایی پیکسل‌های تصویر و کلاسه بند SVM
- (۵) استخراج ویژگی‌های فرکانسی پیکسل‌های تصویر و کلاسه بند SVM
- (۶) استخراج ویژگی‌های فرکانسی و آماری پیکسل‌های تصویر و کلاسه بند SVM

جزئیات مربوط به روش‌های استخراج ویژگی و همچنین کلاسه بندهای شبکه عصبی و در این فصل مورد بررسی قرار گرفت. از میان این شش روش، روش شماره ۳ و ۴ به ترتیب در مراجع [۳۲] و [۴۷] بررسی شده است. در اینجا با توجه به اینکه نتایج کلاسه بند SVM نسبت به نتایج کلاسه بند شبکه عصبی بهتر گزارش شده است، هدف بررسی اثر این کلاسه بندها و همچنین بررسی اثر روش‌های مختلف استخراج ویژگی در تشخیص MCها در تصاویر ماموگرافی است. نتایج مربوط به اعمال این شش روش بر روی تصاویر ماموگرافی در فصل آینده تحلیل و مقایسه شده است. فلوچارت مربوط به کار انجام شده در این فصل در شکل ۴-۱۳ نمایش داده شده است.



شکل ۴-۱۳: فلوچارت مربوط به روش‌های تشخیص استفاده شده در این تحقیق.

فصل ۵

نتایج روش پیشنهادی در تشخیص MC در تصاویر ماموگرافی

مقدمه

این فصل به مقایسه، بررسی و تحلیل روش‌های ارائه شده جهت تشخیص MCها، که در فصل چهارم مورد بحث قرار گرفتند، می‌پردازد. در ابتدا پایگاه داده‌ی استفاده شده در این تحقیق معرفی شده است. در ادامه اعمال روش‌های تشخیص MC بر روی تصاویر این پایگاه داده و جزئیات مربوط به اعمال هر روش مورد بررسی قرار گرفته شده است. این جزئیات شامل تعداد و اندازه داده‌های بدست آمده از اعمال مرحله استخراج ویژگی در هر روش و نتایج مربوط به اعمال کلاسه بند هر روش بر روی داده‌های استخراج شده از تصاویر و همچنین دقت هر روش می‌باشد. در نهایت هم با رسم نمودارهای ROC^۱ مربوط به این روش‌ها، مقایسه‌ای بین این شش روش از حیث نوع استخراج ویژگی و کلاسه بند مورد استفاده، صورت گرفته است.

۵-۱ پایگاه داده تصاویر ماموگرافی

در این تحقیق از تصاویر پایگاه داده دیجیتال برای تصاویر ماموگرافی یا DDSM^۲ استفاده شده است. این پایگاه داده منبعی است که جهت استفاده در انجام تحقیقات بر روی تصاویر ماموگرافی تهیه شده است. برای اولین بار بخش تحقیقات پزشکی ارتش آمریکا از این پروژه حمایت کرد. پایگاه داده‌ی DDSM با همکاری بیمارستان عمومی ماساچوست^۳ (D.Kopans, R. Moore)، دانشگاه فلوریدای جنوبی^۴ (K. Bowyer) و آزمایشگاه ملی سندیا^۵ (P. Kegelmeyer) تهیه شده است. هدف‌های اصلی این پروژه یکی تسهیل انجام تحقیقاتی

^۱ Receive Operating Characteristic

^۲ Digital Database for Screening Mammography

^۳ Massachusetts General Hospital

^۴ University of South Florida

^۵ Sandia National Laboratories

برای توسعه الگوریتم‌های کامپیوتری که به تصویربرداری کمک می‌کنند و دیگری توسعه الگوریتم‌های تشخیص بیماری و همچنین کمک‌های آموزشی و تحصیلی می‌باشند.

این پروژه شامل ۲۵۰۰ نمونه مطالعه شده است. هر نمونه شامل دو تصویر از هر سینه، به همراه اطلاعاتی در مورد بیمار (شامل سن بیمار در زمان مطالعه، شدت بیماری و نوع بیماری و ...) و اطلاعاتی راجع به تصویر (نوع اسکنر، رزولوشن تصویر و ...) می‌باشد.

تصاویر شامل اطلاعات "ground-truth" می‌باشد که اطلاعات مربوط به مکان نواحی مشکوک به بیماری و نوع بیماری در آن مشخص می‌شود.

در این تحقیق از ۱۴۰ تصویر ماموگرافی این پایگاه داده، که شامل توده‌های سرطانی MC می‌باشند، استفاده شده است. این تصاویر متعلق به ۷۰ بیمار است. در اینجا از هر دو پروجکشن تصویر ماموگرافی، یعنی تصویر MLO و تصویر CC سینه سرطانی بیمار استفاده شده است. همه تصاویر استفاده شده شامل یک یا دو کلاستر MC می‌باشند.

۵-۲ داده‌های آموزشی و داده‌های آزمایشی

مجموعه داده‌های آموزشی و آزمایشی که در کلاسه بندها مورد استفاده قرار گرفته است از تعداد ۱۵۰ عدد ROI، شامل کلاستر MC برگزیده شده است. به ازای هر MC در ناحیه ROI، یک بردار ویژگی از آن MC به عنوان نمونه شامل بیماری و یک بردار ویژگی از نواحی نرمال همان ROI به طور تصادفی به عنوان نمونه نرمال استخراج می‌شود. به این ترتیب، تعداد بردارهای ویژگی شامل بیماری و بردارهای ویژگی فاقد بیماری در مجموعه آموزشی و مجموعه آزمایشی، برابر خواهند بود.

تعداد MCها در این ۱۵۰ ناحیه مورد بررسی، ۹۹۶ عدد است که از این تعداد، ۵۲۸ عدد در مجموعه آموزشی در مرحله آموزش کلاسه بندها و ۴۶۸ عدد در مجموعه آزمایشی و جهت تست کلاسه بندها استفاده شده است. در استخراج این ویژگی‌ها از سه روش توصیف شده در فصل چهارم استفاده شده است. اندازه مجموعه آموزشی و مجموعه آزمایشی با استفاده از هر یک از این سه روش در جدول ۵-۱ گزارش شده است.

جدول ۵-۱: اندازه مجموعه آموزشی و مجموعه آزمایشی برای سه روش استفاده شده در استخراج ویژگی

ویژگی‌های آماری و فرکانسی (Type ۳)	ویژگی‌های فرکانسی (Type ۲)	ویژگی‌های روشنایی تصویر (Type ۱)	استخراج ویژگی
۵۲۸×۲×۴	۵۲۸×۲×۲	۵۲۸×۲×۸۱	اندازه مجموعه آموزشی
۴۶۸×۲×۴	۴۶۸×۲×۲	۴۶۸×۲×۸۱	اندازه مجموعه آزمایشی

در این جدول، برای هر پیکسل، ویژگی‌های Type ۱ شامل پنجره ۹*۹ حول آن پیکسل و در نتیجه اندازه ۸۱ است که این اندازه، برای ویژگی‌های Type ۲ و Type ۳ به ترتیب ۲ و ۴ می‌باشد.

۵-۳ نتایج آزمایش بر روی سیستم‌های CAD

پس از استخراج ویژگی، سیستم‌های CAD معرفی شده در فصل قبل توسط مجموعه داده‌های آموزشی، آموزش داده شده و از مجموعه‌های آزمایشی به دست آمده برای تست این

شش سیستم CAD استفاده شده است. میزان دقت^۱ این شش سیستم در جدول ۵-۲ به تفکیک روش استخراج ویژگی و کلاسه بند استفاده شده، آورده شده است. این نتایج نشان می‌دهد که نرخ دقت بدست آمده از این سیستم‌ها بین ۸۵٪ تا ۹۴٪ می‌باشد. همچنین در مقایسه با کلاسه بند شبکه عصبی، نتایج کلاسه بند SVM زمانی که از ویژگی‌های فرکانسی استفاده می‌کنیم دقیق‌تر است.

با مقایسه روش‌های استخراج ویژگی دیده می‌شود که استفاده از ویژگی‌های روشنایی تصویر هم در کلاسه بند NN و هم کلاسه بند SVM نتایج دقیق‌تری را نسبت به دیگر روش‌ها ارائه می‌دهد. دلیل این امر می‌تواند اطلاعات بیشتری باشد که داده‌های بدست آمده از این روش برای کلاسه بندها در مرحله آموزش فراهم می‌کند. استفاده از این نوع ویژگی‌ها به دلیل اندازه بزرگتر بردارهای ویژگی، در حالی دقت را افزایش می‌دهد که سرعت کلاسه‌بندی در هر دو مرحله آموزش و آزمایش کاهش می‌یابد.

جدول ۵-۲: دقت تشخیص در مرحله آزمایش در شش سیستم CAD مورد بررسی در این تحقیق.

Classifier Feature extraction	Neural Network (NN)	Support Vector Machine (SVM)
Type ۱	۹۳.۵%	۹۴%
Type ۲	۸۵.۰۴%	۹۱%
Type ۳	۹۰.۲۸%	۸۸%

^۱ Accuracy rate

۴-۵ نتایج آزمایش بر روی تصاویر ماموگرافی

در اینجا هدف آزمایش سیستم‌های CAD مورد بررسی بر روی چند نمونه تصویر ماموگرافی و مشاهده نتایج آن است. از آن جایی که آزمایش اولیه جهت یافتن دقت تشخیص هر کدام از سیستم‌ها بر روی مجموعه داده‌هایی صورت گرفته است که به طور تصادفی انتخاب شده‌اند و همچنین داده‌های شامل MC و نرمال در مرحله آموزش و آزمایش کاملاً متمایز هستند، نتایج تست بر روی تصاویر، دقت تشخیص هر سیستم را در تشخیص MC در یک تصویر ماموگرافی دقیق‌تر نشان می‌دهد. به عبارت دیگر در اینجا ابتدا استخراج ویژگی‌ها با روش‌های گفته شده از تمامی سطح یک تصویر ماموگرافی انجام می‌شود. برای این کار یک پنجره ۹*۹ را با جابه‌جایی یک پیکسل در جهت افقی و عمودی بر روی تصویر می‌لغزانیم و ویژگی‌ها را از هر پنجره استخراج می‌کنیم. سپس این بردارهای ویژگی را در مرحله آزمایش به هر یک از کلاسه بندهای NN و SVM می‌دهیم. کلاسه بندهای SVM و NN در اینجا توسط همان داده‌های آموزشی که در بخش قبل استفاده شد آموزش داده شده‌اند. در اینجا به این ترتیب در خروجی هر کلاسه بند یک نقشه likelihood^۱ بدست می‌آوریم که در آن نقاط روشن به عنوان نقاط شامل MC و نقاط تیره نمایانگر نواحی نرمال تصویر ماموگرافی می‌باشد.

۵-۵ مقایسه سیستم‌های CAD مورد بررسی با رسم

نمودارهای ROC

با توجه به اینکه نتایج عملی تست شش سیستم CAD مورد بررسی بر روی تصاویر ماموگرافی تفاوت‌های این سیستم‌ها را دقیق‌تر مشخص می‌کند در اینجا با رسم نمودارهای

^۱ Likelihood map

ROC به تحلیل این نتایج پرداخته شده است. نمودار ROC و خواص آن در ادامه معرفی شده است.

۵-۵-۱ رسم نمودار ROC

واژه ROC مخفف Receiver Operating Characteristics می‌باشد. نمودار ROC یک ابزار مدل‌سازی قوی است که در تصمیم‌گیری‌های پزشکی، روانشناسی، مخبرات و در زمانی که نیاز به ارزش‌های آستانه‌ای مد نظر است استفاده می‌شود. منحنی ROC یک نمودار پراکندگی از حساسیت^۱ برای یک سیستم طبقه‌بندی کننده باینری است که آستانه‌ی تمییز آن متغییر است. برای تشکیل نمودارهای ROC به دو طبقه‌بندی نیاز است. یکی طبقه‌بندی واقعی و دیگری طبقه‌بندی پیش‌بینی شده بر اساس مدل. مثلاً در مورد تشخیص بیماری، طبقه‌بندی‌ها عبارتند از یکی نظر متخصصان و رادیولوژیست‌ها در جداسازی نواحی بیماری و نواحی نرمال و دوم طبقه‌بندی نواحی بر اساس خروجی سیستم CAD.

پارامترهایی بر اساس این اطلاعات بدست آمده از مدل، تعریف می‌شود. این پارامترها در تشخیص MCها در تصاویر ماموگرافی عبارتند از:

TP^۲: تعداد پیکسل‌های شامل MC، که توسط سیستم CAD به عنوان MC تشخیص داده شده است.

TN^۱: تعداد پیکسل‌های نرمال و فاقد بیماری که توسط سیستم CAD به عنوان پیکسل نرمال تشخیص داده شده است.

^۱ Sensitivity
^۲ True Positive

^۲FP: تعداد پیکسل‌های نرمال و فاقد بیماری که توسط سیستم CAD به عنوان MC تشخیص داده شده است.

^۳FN: تعداد پیکسل‌های شامل MC، که توسط سیستم CAD به عنوان پیکسل نرمال تشخیص داده شده است.

$$TPR = TP / P = TP / (TP + FN) \quad (۱-۵)$$

$$FPR = FP / N = FP / (FP + TN) \quad (۲-۵)$$


$$ACC = (TP + TN) / (P + N) \quad (۳-۵)$$

$$SPC = TN / N = TN / (FP + TN) = ۱ - FPR \quad (۴-۵)$$

نام پارامترهای روابط ۱-۵ تا ۴-۵ به ترتیب عبارتند از: حساسیت یا فراخواننده یا نرخ موفقیت، فرونشست، صحت و اختصاصی بودن.

برای ترسیم نمودار ROC باید محورهای افقی و عمودی تعریف شوند. محور x در این نمودار عبارت است از فرونشست و محور عمودی عبارت است از حساسیت. نمودار ROC برای مثال دارای شکل زیر است:

^۱ True Negative
^۲ False Positive
^۳ False Negative



شکل ۵-۱: نمودار ROC

هر چه نقاط روی نمودار ROC به محور عمودی و یا محور افقی هم‌تراز $sensitivity=1$ نزدیک‌تر باشد سیستم تشخیص دهنده به حالت ایده‌آل خود نزدیک‌تر است. مختصات نقطه (۰ و ۱) حالت ایده‌آل است. این نقطه نشان می‌دهد که آنچه مدل پیش‌بینی ارائه می‌دهد انطباق کامل بر مدل واقعی دارد. نقطه‌ی مقابل آن دارای مختصات (۱ و ۰) است و به این معنا است که هر چه مدل پیش‌بینی ارائه داده عکس مدل واقعی است. این قسمت از فضای نمودار ROC نیز جالب توجه است و باید نتیجه‌ی سوالاتی که منجر به این حالت شده را عکس کرد. اما در صورتی که مدل به صورت تصادفی عمل کند منحنی ROC در راستای خط $y=x$

قرار می‌گیرد. سیستم تشخیص دهنده MC نیاز به تعیین یک نقطه آستانه برای ارزیابی بافت‌ها دارد. این آستانه نقطه‌ای را بر روی نمودار ROC مشخص می‌کند که به ازای آن درجه‌ای از sensitivity و specificity مشخص می‌شود. مساحت زیر منحنی‌های ROC معیاری برای عملکرد خوب پارامتر در تمایز بین دو گروه تشخیص است مثل دو گروه نرمال و بیمار.


۵-۵-۲ اعمال آستانه بر نقشه احتمالاتی خروجی کلاسه بندها و

رسم نمودار ROC

خروجی کلاسه بندهای SVM و NN به شکل یک تصویر باینری است. این خروجی‌ها شامل تعداد زیادی نواحی روشن است که اندازه‌ای بسیار بزرگتر و یا بسیار کوچکتر از یک MC دارند و به غلط به دلیل خطای موجود در تشخیص سیستم‌ها، MC تشخیص داده شده‌اند. بنابراین در ادامه با استفاده از یک الگوریتم قصد داریم نقاط روشن به دست آمده به عنوان MC را از حیث اندازه و تعداد پیکسل‌ها مورد بررسی قرار دهیم. در این الگوریتم با اندازه‌گیری تعداد پیکسل‌های هر شیء مجزا در تصویر نقشه احتمالاتی خروجی سیستم CAD و اعمال ترشولد بر روی آن‌ها، شیء‌های بزرگتر از اندازه در نظر گرفته برای یک MC یعنی یک پنجره 9×9 شامل ۸۱ پیکسل را حذف می‌کنیم. سپس با اعمال آستانه دیگری، اشیاء کوچکتر از یک آستانه را که به طور غلط MC تشخیص داده شده‌اند حذف می‌گردند. این آستانه دوم مقداری متغیر بین ۱۰ تا ۶۰ پیکسل را داراست. در واقع با تغییر این آستانه می‌توان نمودار ROC را به شیوه‌ای که در بخش قبل توضیح داده شد، برای هر تصویر رسم نمود و مناسب‌ترین میزان آستانه را برای هر سیستم CAD از روی این نمودار محاسبه کرد.

در شکل ۲-۵ تصویر خروجی سیستم CAD با روش استخراج ویژگی نوع ۱ و کلاسه بند SVM به ازای آستانه‌های $T=10, 14, 18, \dots, 58$ نشان داده شده است.

در شکل‌های ۳-۵ و ۴-۵ خروجی سیستم‌های CAD برای یک نمونه تصویر ماموگرافی، پس از اعمال ترشولدی معادل $T=30$ بر روی تصویر خروجی آن‌ها، نمایش داده شده است.




(الف) یک کلاستر از MCها




(ب) خروجی سیستم CAD با روش استخراج ویژگی نوع ۱ و کلاسه بند SVM بر روی تصویر الف به ازای

آستانه $T=10$




(پ) خروجی سیستم CAD با روش استخراج ویژگی نوع ۱ و کلاسه بند SVM بر روی تصویر الف به ازای

آستانه $T=14$




(ت) خروجی سیستم CAD با روش استخراج ویژگی نوع ۱ و کلاسه بند SVM بر روی تصویر الف به ازای

آستانه $T=18$




(ث) خروجی سیستم CAD با روش استخراج ویژگی نوع ۱ و کلاسه بند SVM بر روی تصویر الف به ازای

آستانه $T=22$




(ج) خروجی سیستم CAD با روش استخراج ویژگی نوع ۱ و کلاسه بند SVM بر روی تصویر الف به ازای

آستانه $T=26$




(چ) خروجی سیستم CAD با روش استخراج ویژگی نوع ۱ و کلاسه بند SVM بر روی تصویر الف به ازای

آستانه $T=30$




(ح) خروجی سیستم CAD با روش استخراج ویژگی نوع ۱ و کلاسه بند SVM بر روی تصویر الف به ازای

آستانه $T=34$




(خ) خروجی سیستم CAD با روش استخراج ویژگی نوع ۱ و کلاسه بند SVM بر روی تصویر الف به ازای

آستانه $T=۳۸$




(د) خروجی سیستم CAD با روش استخراج ویژگی نوع ۱ و کلاسه بند SVM بر روی تصویر الف به ازای

آستانه $T=۴۲$




(ذ) خروجی سیستم CAD با روش استخراج ویژگی نوع ۱ و کلاسه بند SVM بر روی تصویر الف به ازای

آستانه $T=46$




(ر) خروجی سیستم CAD با روش استخراج ویژگی نوع ۱ و کلاسه بند SVM بر روی تصویر الف به ازای

آستانه $T=50$



(ز) خروجی سیستم CAD با روش استخراج ویژگی نوع ۱ و کلاسه بند SVM بر روی تصویر الف به ازای


آستانه $T=۵۴$



(ژ) خروجی سیستم CAD با روش استخراج ویژگی نوع ۱ و کلاسه بند SVM بر روی تصویر الف به ازای آستانه $T=۵۸$


شکل ۵-۲: الف) یک کلاستر از MCها و تصویر خروجی سیستم CAD با روش استخراج ویژگی نوع ۱ و کلاسه

بند SVM بر روی تصویر الف به ازای آستانه‌ای (ب) $T=10$ ، (پ) $T=14$... و (ژ) $T=58$



(a)

(b)




(c)

(d)

شکل ۵-۳: (a) کلاستر MC در تصویر ماموگرافی. خروجی کلاسیفایر NN پس از اعمال آستانه‌ای معادل $T=30$ برای


روش‌های استخراج ویژگی (ب) نوع ۱، (c) نوع ۲ و (d) نوع ۳




(a)



(b)



(c)



(d)

شکل ۴-۵: (a) کلاستر MC در تصویر ماموگرافی. خروجی کلاسیفایر SVM پس از اعمال آستانه‌ای معادل $T=30$ برای

روش‌های استخراج ویژگی (b) نوع ۱، (c) نوع ۲ و (d) نوع ۳

در ادامه برای رسم نمودار ROC در هر یک از تصاویر ماموگرافی، همان طور که گفته شد، مقدار آستانه اعمال شده بر روی تصویر نقشه احتمالاتی خروجی هر سیستم CAD را در بازه $T=10$ تا $T=60$ تغییر داده‌ایم. سپس در تصاویر خروجی بدست آمده پس از اعمال آستانه‌های مورد نظر، میزان حساسیت و فرونشست را با توجه به روابط ۵-۱ و ۵-۲ محاسبه می‌کنیم. نمودار ROC بدست آمده از این محاسبه، برای ۵ تصویر ماموگرافی میانگین‌گیری شده و در شکل ۵-۵ نمایش داده شده است. نمودار ROC مربوط به هر روش به طور مشخص در شکل نمایش داده شده است.

با توجه به آنچه که درباره نمودارهای ROC گفته شد می‌توان با مشاهده شکل ۵-۵ این‌گونه نتیجه‌گیری کرد که از میان روش‌های مورد بحث در این تحقیق، استفاده از روش استخراج ویژگی‌های آماری و فرکانسی تصویر در کنار کلاسه بند SVM بهینه‌ترین روش در تشخیص MCها در تصاویر ماموگرافی است. تغییرات قابل توجه MCها در حوزه فرکانس و استفاده از ویژگی‌های آماری به شکلی که اطلاعات مربوط به ویژگی‌های روشنایی تصویر را شامل شود می‌تواند دلیل برتری این روش به دیگر روش‌ها باشد. در این نمودار، منحنی‌های SVM، SVMf، SVMfs، NN، NNf، NNfs و NNfs به ترتیب مربوط به سیستم‌های CAD زیر می‌باشند:

۱. استخراج ویژگی شدت روشنایی پیکسل‌های تصویر و کلاسه بند SVM

۲. استخراج ویژگی‌های فرکانسی پیکسل‌های تصویر و کلاسه بند SVM


۳. استخراج ویژگی‌های فرکانسی و آماری پیکسل‌های تصویر و کلاسه بند SVM

۴. استخراج ویژگی شدت روشنایی پیکسل‌های تصویر و کلاسه بند شبکه عصبی

۵. استخراج ویژگی‌های فرکانسی پیکسل‌های تصویر و کلاسه بند شبکه عصبی

۶. استخراج ویژگی‌های فرکانسی و آماری پیکسل‌های تصویر و کلاسه بند شبکه

عصبی



شکل ۵-۵: نمودار ROC مربوط به شش روش مورد بحث در این تحقیق.

فصل ۶

جداسازی مرز MCها در تصاویر ماموگرافی

مقدمه

در این فصل هدف جداسازی^۱ مرز هر یک از MCها در تصاویر ماموگرافی است. به طور متداول فرایندهای تشخیص MC در تصاویر ماموگرافی، با جداسازی MCها از پس‌زمینه نرمال بافت سینه شروع می‌شوند. سپس با اعمال روش‌های استخراج ویژگی و همچنین تکنیک‌های تشخیص الگو بر روی این اشیاء کاندید می‌توان آن‌ها را در گروه‌های MC و یا نرمال دسته‌بندی کرد [۵۲]-[۵۷]. به طور کلی جداسازی در این فرایند نقش مهمی را ایفا می‌کند زیرا ویژگی‌هایی مثل اندازه، کنتراست و تیزی که بیانگر این اشیاء جدا شده‌ی کاندید در تصویر هستند، کاملاً به ناحیه‌ای که جدا شده است، بستگی دارند [۵۸].

در این فصل پس از پرداختن به اهمیت موضوع جداسازی، روشی جدید مبتنی بر ساختار توپوگرافیک^۲ تصاویر ماموگرافی و همچنین استخراج ناحیه‌ای روشنایی^۳ تصاویر را برای جداسازی MCها ارائه و بررسی می‌کنیم.

۶-۱ جداسازی مرز MCها در تصاویر ماموگرافی

بیشتر روش‌های تشخیص MC با الگوریتمی آغاز می‌شوند که در آن مکان‌های کاندیدی به عنوان MC از تصاویر ماموگرافی جدا می‌شود. اغلب الگوریتم‌هایی که برای جداسازی این MCها استفاده می‌شوند دارای جنبه‌هایی هستند که مشکلاتی عملیاتی و کاربردی مثل: انتخاب آستانه، انتخاب پنجره و یا مدل‌های پارامتریک داده‌ها را ایجاد می‌کنند.

^۱ Segmentation

^۲ Topographic

^۳ Intensity region extraction

در مرجع [۵۸]، Isaak N. Bankman و همکارانش یک الگوریتم جداسازی جدید را ارائه کرده و آن را با دو الگوریتم دیگر مقایسه کرده‌اند: الگوریتم منطقه در حال رشد^۱ چندرزولوشن که جنبه‌هایی که در بالا اشاره شد را دارا نمی‌باشد و مدل کانتور فعال^۲ که قبلاً جهت جداسازی MCها استفاده نشده است. الگوریتم جدید به گونه‌ای عمل می‌کند که در آن نیازی به انتخاب آستانه و پنجره و مدل‌های داده پارامتریک نیست و از الگوریتم‌های مقایسه شده در این مرجع سریع‌تر است.

در این تحقیق، ما الگوریتمی را جهت جداسازی MCها پیشنهاد کرده‌ایم که بر اساس استخراج ناحیه مبتنی بر روشنایی است که یک توصیف‌گر ناحیه‌ی یکنواخت می‌باشد. در اینجا فرض بر این است که ناحیه شامل MC در یک تصویر ماموگرافی از نظر روشنایی، در مقایسه با محیط اطرافش که ناحیه نرمال است، دارای تغییرات کمی است. این فرض سبب می‌شود که نتیجه بگیریم مرزی به ضخامت یک پیکسل برای جداسازی MC از محیط نرمال اطرافش وجود دارد.

این الگوریتم جداسازی بر اساس این واقعیت است که لبه‌های یک MC در یک تصویر ماموگرافی یک کانتور بسته در اطراف پیکسل ماکزیمم روشنایی محلی است. برای بدست آوردن این پیکسل در تصاویر ماموگرافی از ساختار توپوگرافیکی تصاویر استفاده کرده‌ایم که در بخش ۶-۲ به تفصیل مورد بحث قرار گرفته است. همچنین در بخش ۶-۳ یافتن لبه‌های MC با استفاده از استخراج ناحیه مبتنی بر روشنایی^۳ مورد بررسی قرار می‌گیرد.

^۱ Region growing

^۲ Active contour model

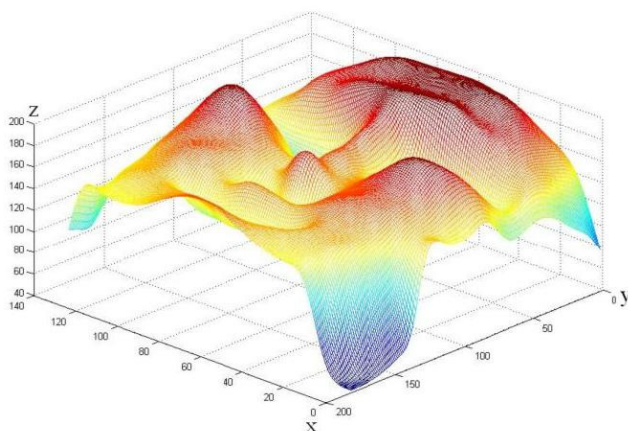
^۳ Intensity-based region extraction

۲-۶ تعیین ساختار توپوگرافیک تصاویر ماموگرافی

در صورتی که تصویر سطح خاکستری ماموگرافی با یک رویه‌ی سه بعدی نشان داده شود، به طوری که جهت‌های x و y بیانگر راستای ابعاد تصویر و جهت Z سطح روشنایی نقاط تصویر باشند، هر کدام از اجزای چهره با توجه به مشخصات توپوگرافیکی (پستی و بلندی‌ها) در رویه‌ی متناظر با آن، قابل تشخیص می‌باشند. برای مثال تصویر سطح خاکستری یک چهره و رویه‌ی متناظر با آن در شکل ۱-۶ نمایش داده شده است.



(الف)



(ب)

شکل ۱-۶: الف) تصویر چهره. ب) نمایش تصویر چهره به صورت یک رویه‌ی سه بعدی

برای استخراج ویژگی‌های توپوگرافیکی از یک تصویر، به هر پیکسل از تصویر یکی از دوازده برجسب توپوگرافیکی را نسبت می‌دهیم. این برجسب‌ها وضعیت رویه را در نقطه‌ی مورد نظر مشخص می‌کنند، نظیر قله، چاله، سراشیبی و

دلایل قابل توجهی برای استفاده از تصویر نگاشت یافته به حوزه‌ی توپوگرافیک به منظور یافتن به طور مثال ماکزیمم و یا مینیمم‌های محلی تصویر ماموگرافی وجود دارد. مهمترین آن این است که تصویر نگاشت یافته در مقایسه با تصویر سطح خاکستری نسبت به شرایط نورپردازی مقاوم‌تر است. در تصویر سطح خاکستری سطح روشنایی پیکسل‌ها در ۲۵۶ سطح (۰-۲۵۵) کوانتیزه شده است، این مقادیر در اثر تغییر شرایط تصویر برداری و نورپردازی تغییر می‌کنند در حالی که در تصویر برجسب خورده‌ی توپوگرافیکی ارزش پیکسل‌ها به ۱۲ برجسب (سطح) خلاصه می‌شود. این مقادیر بیانگر خاصیت رویه در محل پیکسل می‌باشند و مقاومت بیشتری در مقابل شرایط تصویر برداری و نورپردازی دارند.


۶-۲-۱ حذف نویز از تصویر ورودی

استخراج برجسب‌های توپوگرافیک تصویر نیازمند محاسباتی است که از مشتقات مرتبه اول و دوم در هر نقطه از رویه‌ی تصویر استفاده می‌کند. در صورتی که تصویر نویزی باشد، مقادیر محاسبه شده برای مشتقات به نحو قابل توجهی تحت تاثیر نویز قرار گرفته و منجر به تولید نتایج متفاوت در ساختار توپوگرافیک تصویر می‌شود.


روشی که برای مقابله با اثرات ناخواسته نویز وارد شده در تصاویر به کار گرفته می‌شود، هموارسازی^۱ رویه قبل از محاسبه مشتق می‌باشد. پروسه‌ی هموارسازی با استفاده از یک فیلتر

^۱ Smoothing

گوسی دو بعدی^۱ امکان پذیر می باشد. شکل ۶-۲ رویه یک تصویر نمونه را قبل و بعد از هموارسازی نشان می دهد.



(الف)



(ب)

شکل ۶-۲: (الف) رویه یک تصویر سطح خاکستری. (ب) رویه تصویر الف پس از اعمال فیلتر گوسی بر روی تصویر

سطح خاکستری

^۱Gaussian filter

۶-۲-۲ استخراج برچسب‌های توپوگرافیک

همان طور که قبلاً نیز بیان شد، برای دستیابی به ساختار توپوگرافیک تصویر باید هر یک از پیکسل‌های تصویر بر اساس حالت رویه در آن نقطه برچسب گذاری شود.

الگوریتم‌های متفاوتی برای استخراج ساختار توپوگرافیک یک تصویر دیجیتال در تاریخچه بینایی ماشین گزارش شده است [۵۹]. این الگوریتم‌ها به دو دسته‌ی اصلی تقسیم می‌شوند. دسته‌ی اول به تکنیک‌هایی اشاره می‌کند که به طور مستقیم از تصویر دیجیتال (گسسته) برای طبقه‌بندی پیکسل‌ها استفاده می‌کنند در حالی که در دسته دوم ابتدا یک سطح پیوسته به طور محلی در هر نقطه از رویه با شرط ایجاد مینیمم خطا، برازش شده و سپس طبقه‌بندی پیکسل‌ها بر اساس رویه‌ی تخمین زده شده انجام می‌شود [۵۹].

این تحقیق مشابه روش Wang [۵۹] چند جمله‌ای گسسته چبی‌چف^۱ به عنوان اساس گسترش فضای برداری این توابع پیوسته انتخاب شد. مشتق جزئی مرتبه (p,q) تابع f در نقطه (x,y)، (p در راستای محور x و q در راستای محور y) توسط رابطه ۶-۱ محاسبه می‌شود:

$$f^{(p,q)}(x,y) = \sum_{i=-N}^N \sum_{j=-N}^N f(x,y) h(i,p) h(j,q) \quad (۱-۶)$$

در این رابطه $f(x,y)$ تصویر سطح خاکستری ورودی است و $h(i,p)$ و $h(j,q)$ فیلترهای متمایز هموار شده به ترتیب با درجه‌های p و q از چندجمله‌ای‌های چبی‌چف هستند. روابط ۶-۲، ۶-۳ و ۶-۴ به ترتیب $h(i,0)$ ، $h(i,1)$ و $h(i,2)$ را نشان می‌دهند.

$$h(i,0) = -\frac{33[\Delta i^2 - (3N^2 + 3N - 1)]}{(2N-1)(2N+1)(2N+3)} \quad i = -N, \dots, N \quad (۲-۶)$$

^۱ Discrete Chebyshev polynomials

$$h(i, 1) = \frac{\delta[\gamma(\gamma N^2 + \gamma N - 1)i^2 - \delta(\gamma N^2 + \epsilon N^2 - \gamma N + 1)]}{(N-1)N(N+1)(N+2)(2N-1)(2N+1)(2N+3)} \quad i = -N, \dots, N \quad (3-6)$$

$$h(i, 2) = \frac{\gamma \cdot [\gamma i^2 - N(N+1)]}{N(N+1)(2N-1)(2N+1)(2N+3)} \quad i = -N, \dots, N \quad (4-6)$$

با توجه به اینکه فیلتر h مستقل از تصویر ورودی می باشد، می تواند به طور مستقل برای ابعاد همسایگی (N) انتخاب شده، محاسبه گردد سپس مشتق جزئی مرتبه $(p+q)$ که توسط رابطه ی ۶-۱ تخمین زده می شود بصورت یک فیلتر گسسته دوبعدی با تصویر کانالو می شود (رابطه ۶-۵)

$$f^{(p,q)}(x, y) = conv(f(x, y), H(p, q)) \quad (5-6)$$

در این رابطه $H(p, q)$ فیلتر مشتق گیر با درجه های p و q را نشان می دهد. P درجه ی مشتق در راستای محور X و Q درجه ی مشتق در راستای محور Y می باشد. فیلتر H از ضرب بردارهای h ساخته می شود و ابعاد آن نیز $N \times N$ می باشد.

روابط ۶-۶ تا ۶-۱۰ فیلترهای مورد استفاده در الگوریتم پیشنهادی را نشان می دهند.

$$H(1, \cdot) = h'(i, 1) \cdot h(i, \cdot) \quad (6-6)$$


$$H(\cdot, 1) = h'(i, \cdot) \cdot h(i, 1) \quad (7-6)$$

$$H(1, 1) = h'(i, 1) \cdot h(i, 1) \quad (8-6)$$


$$H(2, \cdot) = h'(i, 2) \cdot h(i, \cdot) \quad (9-6)$$

$$H(\cdot, \tau) = h'(i, \cdot) \cdot h(i, \tau) \quad (10 - 6)$$


شکل ۳-۶ فیلترهای بدست آمده برای $N=20$ را نشان می‌دهد.




$H(1,0)$ (الف)




$H(0,1)$ (ب)



$H(1,1)(\varphi)$



$H(2,0)(\tau)$



ش(۰,۲) H(۰,۲)

شکل ۶-۳: فیلترهای گسسته دوبعدی برای $N=20$

بردار گرادیان^۱ و اندازه‌ی آن در نقطه‌ای به مختصات (x,y) ، توسط روابط ۶-۱۱ و ۶-۱۲ بیان

می‌شوند. در این روابط $\frac{\partial f(x,y)}{\partial x}$ و $\frac{\partial f(x,y)}{\partial y}$ مشتق جزئی تابع f نسبت به x و y می‌باشند.

$$\vec{\nabla}f = \left(\frac{\partial f(x,y)}{\partial x}, \frac{\partial f(x,y)}{\partial y} \right) \quad (۱۱-۶)$$

$$\|\vec{\nabla}f\| = \sqrt{\left(\frac{\partial f(x,y)}{\partial x} \right)^2 + \left(\frac{\partial f(x,y)}{\partial y} \right)^2} \quad (۱۲-۶)$$

ماتریس Hessian نیز برای نقطه‌ی (x,y) از تصویر به صورت زیر تعریف می‌گردد.

$$H = \begin{bmatrix} \frac{\partial^2 f(x,y)}{\partial x^2} & \frac{\partial^2 f(x,y)}{\partial x \partial y} \\ \frac{\partial^2 f(x,y)}{\partial x \partial y} & \frac{\partial^2 f(x,y)}{\partial y^2} \end{bmatrix} = \begin{bmatrix} f^{(2,0)}(x,y) & f^{(1,1)}(x,y) \\ f^{(1,1)}(x,y) & f^{(0,2)}(x,y) \end{bmatrix} \quad (۱۳-۶)$$

^۱ Gradient vector

بردارهای ویژه^۱ این ماتریس \vec{u}_1, \vec{u}_2 و مقادیر ویژه^۲ متناظر با این بردارها λ_1, λ_2 هستند و شرط $|\lambda_1| \geq |\lambda_2|$ برقرار می‌باشد.

دو نکته مفید در رابطه با $\vec{u}_1, \vec{u}_2, \lambda_1, \lambda_2$ وجود دارد:

۱. H یک ماتریس متقارن است بنابراین λ_1, λ_2 حقیقی هستند و \vec{u}_1, \vec{u}_2 بر هم عمودند.


۲. مشتق دوم \vec{u} به صورت $f_u^{(2)} = \vec{u}^T H \vec{u}$ بیان می‌شود. بردارهای ویژه‌ی ماتریس H, \vec{u}_1, \vec{u}_2 جهت‌هایی هستند که مشتق دوم در آن‌ها ماکزیمم است. λ_1, λ_2 نیز بیانگر مقادیر مشتق دوم هستند.

۳. \vec{u}_1, \vec{u}_2 تصویر بردار گرادیان در جهت \vec{u}_1 و \vec{u}_2 تصویر بردار گرادیان در جهت \vec{u}_1 است.


مقادیر محاسبه شده برای $\|\vec{\nabla} f\|, \vec{u}_1, \vec{u}_2, \lambda_1, \lambda_2$ نوع برجسب توپوگرافیکی که به هر پیکسل اختصاص می‌یابد را مشخص می‌کند.

۱۲ برجسب توپوگرافیک در شکل ۴-۶ نشان داده شده است.


^۱ Eigen vectors
^۲ Eigen values




(الف): قلّه




(ب): چاله




(ج): ناودانی بیرون




(د): ناودانی داخل




(ه): زین اسبی از خارج




(ز): زین اسبی از داخل




(ح): سرایشی با انحناء به داخل




(ط): سرایشی با انحناء به خارج




(ی): سرایشی زین اسبی با انحناء
به خارج



(ک): سرایشی زین اسبی با
انحناء به داخل



(ل): سرایشی بدون انحناء



(م): سطح تراز

شکل ۴-۶: برجسب‌های توپوگرافیک

در این تحقیق برای شروع الگوریتم جداسازی MCها نیاز به یافتن نقاط ماکزیمم محلی در تصاویر ماموگرافی است. این پیکسل‌ها متناظر با نقاطی از تصویر هستند که برچسب توپوگرافیک قله^۱ دارند که به صورت زیر تعریف شده و به دست می‌آیند.

قله: اولین برچسب از برچسب‌های دوازده‌گانه می‌باشد و زمانی اتفاق می‌افتد که یک ماکزیمم محلی^۲ در تمام جهات وجود داشته باشند. شرایط بیان شده در رابطه ۶-۱۴ نقطه‌ای به مختصات (x,y) از تصویر را در گروه قله قرار می‌دهد.

$$\|\vec{\nabla}f\| = 0, \quad \lambda_1 < 0, \lambda_2 < 0. \quad (14-6)$$

۳-۶ جداسازی MC بر اساس استخراج ناحیه مبتنی بر روشنایی

برای هر پیکسل بدست آمده به عنوان قله توسط ساختار توپوگرافیک در بخش ۶-۲، یک کانتور به عنوان مرز جداسازی MC از محیط اطرافش بدست می‌آید. این قله‌های بدست آمده در یک ROI در واقع ماکزیمم‌های محلی هستند که به نوعی بیانگر مرکز هر MC می‌باشند. در این بخش روشی برای استخراج نواحی شامل MC ارائه شده است که به طور مستقیم بر اساس روشنایی تصویر عمل می‌کند و در آن نیازی به استخراج ویژگی‌هایی نظیر لبه‌ها و گوشه‌ها نیست. به همین دلیل این روش را استخراج ناحیه بر اساس روشنایی می‌نامند [۶۰].


^۱ Peak

^۲ Local maximum

این الگوریتم به جای شروع از نقاط گوشه یک شیء مثل MC، از ماکزیمم محلی آن (قله‌های تصویر) آغاز به کار می‌کند. به ازای هر پیکسل قله، تابع $S(x,y)$ بر روی خطوط منتشر شده در جهات مختلف در اطراف آن پیکسل به شکل زیر تعریف می‌شود.

$$S(x,y) = \frac{abs(|f(x,y) - f(x.,y.)|)}{\max(\frac{\int_0^t abs(|f(x,y) - f(x.,y.)|)dt}{t}, d)} \quad (6-10)$$

این الگوریتم جداسازی بر اساس این واقعیت عمل می‌کند که در یک تصویر مانند $f(x,y)$ لبه‌های یک MC جدا شده، یک کانتر بسته را در اطراف پیکسل شناخته شده $(x.,y.)$ که همان ماکزیمم محلی است تشکیل می‌دهد.



شکل ۶-۵: یافتن نقاط مرز در اطراف یک پیکسل قله $(x.,y.)$ در ۸ جهت با استفاده از روشنایی تصویر و معیار

$$S(x,y)$$


در رابطه‌ی ۱۵-۶ $f(x, y)$ ، روشنایی در مکان (x, y) از تصویر و t فاصله پیکسل (x, y) از پیکسل قله در روی یک راستای k می‌باشند. d یک عدد مثبت بسیار کوچک است که برای جلوگیری از صفر شدن مخرج در آنجا قرار داده شده است.

فرض می‌کنیم که $n=0, \dots, N-1$ $p(n)$ نمایانگر N پیکسل باشد که از نقطه ماکزیمم محلی ($n=0$) شروع شده و در راستای k قرار گرفته‌اند. اندازه N از شعاع یک MC بزرگتر باشد. در این تحقیق N برابر ۱۶ در نظر گرفته شده است.

همچنین راستاهایی که به عنوان k در نظر گرفته شده‌اند λ راستا هستند که با فاصله برابر از هم به صورت شعاعی در اطراف پیکسل قله قرار گرفته‌اند. این λ راستا در شکل ۵-۶ نمایش داده شده‌اند. برای هر یک از این λ راستا مقادیر $S(x, y)$ را بدست آورده و در نموداری بر حسب t رسم می‌کنیم. در جایی که مقدار $S(x, y)$ در این نمودار شامل یک پیک قابل توجه باشد آن پیکسل به عنوان مرز MC در آن راستا در نظر گرفته می‌شود. در انتها با اتصال λ پیکسل بدست آمده به عنوان مرز MC در λ راستای تعریف شده می‌توان کانتور بسته شده‌ی مورد نظر را که شامل یک MC است، بدست آورد.

در شکل ۶-۶ ابتدا با استفاده از ساختار توپوگرافیکی تصویر نقاط قله را در یک نمونه تصویر ماموگرافی یافته‌ایم. در این تصویر یک کلاستر از MC ها انتخاب شده و با استفاده از خواص توپوگرافیکی قله‌های پیک در این کلاستر یافت شده است. همان‌گونه که مشاهده می‌شود قله‌های بدست آمده بر روی مرکز MC ها منطبق است. سپس برای قله‌هایی که مشخص کننده یک MC می‌باشد با استفاده از الگوریتم بحث شده در این فصل مرز MC

مشخص شده است. مرز یک MC با استفاده از روش فوق در شکل ۶-۶ ب نمایش داده شده است.



(الف)



(ب)

شکل ۶-۶: الف) یک کلاستر از MCها و نقاط روشن تشخیص داده شده به عنوان مراکز MC با استفاده از خواص توپوگرافیکی تصویر. ب) جداسازی مرز یک MC با روش پیشنهادی در این تحقیق

فصل ۷

نتیجه‌گیری و ارائه پیشنهادات

نتیجه گیری:

در این تحقیق هدف مطالعه سیستم‌های CAD جهت تشخیص MCها در بافت‌های سینه بود. در این رابطه راهکارهایی جهت بهبود کیفیت تصویر ماموگرافی و بهبود تشخیص MCها داده شده و در آخر روشی برای جداسازی هر MC از بافت‌های مجاور ارائه گردید. پس از بررسی روش‌های متداول در طراحی سیستم‌های CAD و روش‌های موجود در تشخیص MCها در تصاویر ماموگرافی به طراحی و شبیه‌سازی شش سیستم CAD پرداختیم. این سیستم‌ها در دو بخش استخراج ویژگی و کلاسه بند مورد استفاده با هم تفاوت داشتند. برای طراحی این سیستم‌ها از ویژگی‌های روشنایی تصویر، ویژگی‌های فرکانسی و ترکیب ویژگی‌های آماری و فرکانسی استفاده شد. همچنین از کلاسه بندهای SVM و NN جهت کلاسه‌بندی استفاده کردیم. همه سیستم‌ها با مجموعه‌های یکسانی از داده‌ها آموزش داده شده و تست شدند. همچنین نتایج تست این شش روش در تشخیص MC با اعمال بر روی تصاویر ماموگرافی مورد بررسی قرار گرفت. به طور کلی این شش روش را می‌توان به صورت زیر دسته بندی کرد:

این شش روش به طور خلاصه از حیث روش‌های استخراج ویژگی و کلاسه بند استفاده شده به صورت زیر دسته بندی می‌شوند:

۱. استخراج ویژگی شدت روشنایی پیکسل‌های تصویر و کلاسه بند شبکه عصبی
۲. استخراج ویژگی‌های فرکانسی پیکسل‌های تصویر و کلاسه بند شبکه عصبی
۳. استخراج ویژگی‌های فرکانسی و آماری پیکسل‌های تصویر و کلاسه بند شبکه عصبی
۴. استخراج ویژگی شدت روشنایی پیکسل‌های تصویر و کلاسه بند SVM

۵. استخراج ویژگی‌های فرکانسی پیکسل‌های تصویر و کلاسه بند SVM

۶. استخراج ویژگی‌های فرکانسی و آماری پیکسل‌های تصویر و کلاسه بند SVM

از میان این شش روش، روش شماره ۳ و ۴ به ترتیب در مراجع [۳۲] و [۴۷] بررسی شده است. با مقایسه روش‌های استخراج ویژگی دیده می‌شود که استفاده از ویژگی‌های روشنایی تصویر هم در کلاسه بند NN و هم کلاسه بند SVM نتایج دقیق‌تری را نسبت به دیگر روش‌ها ارائه می‌دهد. دلیل این امر می‌تواند اطلاعات بیشتری باشد که داده‌های بدست آمده از این روش برای کلاسه بندها در مرحله آموزش فراهم می‌کند. استفاده از این نوع ویژگی‌ها به دلیل اندازه بزرگتر بردارهای ویژگی، در حالی دقت را افزایش می‌دهد که سرعت کلاسه‌بندی در هر دو مرحله آموزش و آزمایش کاهش می‌یابد.

همچنین با اعمال این روش‌ها بر روی تصاویر ماموگرافی و رسم نمودارهای ROC نتیجه شد که از میان روش‌های مورد بحث در این تحقیق، استفاده از روش استخراج ویژگی‌های آماری و فرکانسی تصویر در کنار کلاسه بند SVM بهینه‌ترین روش در تشخیص MCها در تصاویر ماموگرافی است. تغییرات قابل توجه MCها در حوزه فرکانس و استفاده از ویژگی‌های آماری به شکلی که اطلاعات مربوط به ویژگی‌های روشنایی تصویر را شامل شود می‌تواند دلیل برتری این روش به دیگر روش‌ها باشد.

پیشنهاداتی برای ادامه تحقیق:

- در این تحقیق هدف بررسی و مقایسه قدرت ویژگی‌های فرکانسی و آماری و روشنایی تصویر در تشخیص MCها با استفاده از دو کلاسه بند پرکاربرد SVM و NN بود. می‌توان برای

بهبود روش‌های بررسی شده در این تحقیق، اثر ترکیب این روش‌ها به شکل‌های مختلف را در تشخیص MCها بررسی کرد. به این شکل می‌توان نقاط ضعف یک روش را با استفاده از روش‌های دیگر کاهش داد و همچنان از نقاط قوت آن بهره جست.

- در تشخیص MCها با روش‌های فوق می‌توان با افزودن ویژگی‌های آماری و یا فرکانسی دیگری به مجموعه ویژگی‌ها، اثر آن‌ها را بررسی و دقت تشخیص را بهبود بخشید.

- با توجه به اینکه MCها در یک تصویر ماموگرافی معمولاً به صورت خوشه‌های متمرکز ظاهر می‌شوند، پس از ناحیه‌بندی هر MC می‌توان محدوده قرار گرفتن خوشه‌ها را به دست آورد. این موضوع می‌تواند در تشخیص میزان توسعه MCها و جراحی بافت سرطانی موثر باشد.

- در بخش استخراج ویژگی از تصاویر ماموگرافی، استفاده از تابع گابور با توجه به خاصیت چند جهتی بودن و چند مقیاسی بودن می‌تواند مطرح گردد. استفاده از ویژگی‌های گابور به تنهایی در کنار سایر ویژگی‌ها می‌تواند نرخ تشخیص MCها را افزایش دهد که نیاز به بررسی و مطالعه دارد.

مراجع:

- [1] www. Wikipedia.com
- [2] Jinshan Tang, Senior Member, IEEE, Rangaraj,(2009) "**Computer-Aided Detection and Diagnosis of Breast Cancer With Mammography: Recent Advances**", IEEE TRANSACTIONS ON INFORMATION TECHNOLOGY IN BIOMEDICINE, VOL. 13, NO. 2.
- [3] K. H. Ng and M. Muttarak,(2003) "**Advances in mammography have improved early detection of breast cancer**" J. Hong Kong College Radiol., vol. 6, no. 3, pp. 126–131.
- [4] Saskia van Engeland,(2006) PHD. Thesis, "**Detection Of mass lesions in mammograms by using multiple views**".
- [5] R. Bird, T. Wallace, and B. Yankaskas,(1992) "**Analysis of cancers missed at screening mammography**" Radiology, vol. 184, no. 3, pp. 613–617.
- [6] K. Kerlikowske, P. Carney, B. Geller, M. Mandelson, S. Taplin, K. Malvin, V. Ernster, N. Urban, G. Cutter, R. Rosenberg, and R. Ballard- Barbash,(2000) "**Performance of screening mammography among women with and without a first-degree relative with breast cancer**" Ann. Internal Med., vol. 133, no. 11, pp. 855–863.
- [7] J. Brown, S. Bryan, and R. Warren,(1996) "**Mammography screening: An incremental cost effectiveness analysis of double versus single reading of mammograms**" Br. Med. J., vol. 312, no. 7034, pp. 809–812.
- [8] R. Warren and S. Duffy,(1995)"**Comparison of single and double reading of mammograms, and change in effectiveness with experience**" Br. J. Radiol., vol. 68, no. 813, pp. 958–962.
- [9] M. L. Giger,(2000) "**Computer-aided diagnosis of breast lesions in medical images**" Comput. Sci. Eng., vol. 2, no. 5, pp. 39–45.
- [10] N. Karssemeijer and J.H.Hendriks,(1997) "**Computer-assisted reading of mammograms**" Eur. Radiol., vol. 7, no. 5, pp. 743–748.
- [11] L. Zhang, R. Sankar, and W. Qian,(2000) "**Advances in micro-calcification clusters detection in mammography**" Comput. Biol. Med., vol. 32, no. 6, pp. 515–528.
- [12] I. El Naqa and Y. Yang,(2005) "**Techniques in the detection of microcalcification(MC) clusters in digital mammograms**" in Medical Imaging Systems:Technology and Applications, vol. 4, T. Leondes, Ed. Singapore:World Scientific, pp. 15–36.
- [13] M. Morton, D. Whaley, K. Brandt, and K. Amrami,(2006) "**Screening mammograms: Interpretation with computer-aided detection—Prospective evaluation**" Radiology, vol. 239, no. 2, pp. 375–383.
- [14] R. Brem, J. Baum, M. Lechner, S. Kaplan, S. Souders, L. Naul, and J. Hoffmeister,(2003) "**Improvement in sensitivity of screening mammography with computer-aided detection: A multiinstitutional trial**" Amer. J. Roentgenol., vol. 181, no. 3, pp. 687–693.
- [15] Jelena Bozek, Kresimir Delac, Mislav Grgic,(2008) "**Computer-Aided Detection and Diagnosis of Breast Abnormalities in Digital Mammography**", 50th International Symposium ELMAR, 10-12, Zadar, Croatia, pp. 2-3.
- [16] J. Tang, K. Jeonghoon, and E. Peli,(2004) "**An image enhancement algorithm in JPEG domain for low-vision patient**" IEEE Trans. Biomed. Eng., vol. 51, no. 11, pp. 2013–2023, Nov.
- [17] R. M. Nishikawa, M. L. Giger, K. Doi, C. J. Vyborny, and R. A. Schmidt,(1985) "**Computer-aided detection of clustered microcalcifications on digital mammograms**" Med. Biol. Eng. Comput., vol. 33, no. 2, pp. 174–178.

- [18] Q. Sun and J. Tang,(2003) **“A new contrast measure based image enhancement algorithm in the DCT domain”** in Proc. IEEE Int. Conf. Syst., Man Cybern., Washington, DC, Oct. 5–8 , pp. 2055–2058.
- [19] J. Tang, E. Peli, and S. Acton,(2003) **“Image enhancement using a contrast measure in the compressed domain”** IEEE Signal Process. Lett., vol. 10, no. 10, pp. 289–292, Oct.
- [20] A. P. Dhawan, G. Buelloni, and R. Gordon,(1986) **“Enhancement of mammographic features by optimal adaptive neighborhood image processing”** IEEE Trans. Med. Imag., vol. MI-5, no. 1, pp. 8–15.
- [21] J. Tang, Q. Sun, and K. Agyepong,(2007) **“An image enhancement algorithm based on new contrast measure in the wavelet domain for screening mammograms”** in Proc. IEEE Int. Conf. Image Process.(ICIP2007), vol 5, pp. 29_32.
- [22] P. Sakellaropoulos, L.Costaridou, andG. Panayiotakis,(2003) **“A wavelet-based spatially adaptive method for mammographic contrast enhancement”** Phys. Med. Biol., vol. 48, no. 6, pp. 787–803.
- [23] Arianna Mencattini, Marcello Salmeri,(2008) **“Mammographic Images Enhancement and Denoising for Breast Cancer Detection Using Dyadic Wavelet Processing”**, IEEE TRANSACTIONS ON INSTRUMENTATION AND MEASUREMENT, VOL. 57, NO. 7.
- [24] A. Mencattini, M. Salmeri, S. Bertazzoni, and A. Salsano,(2003) **“Noise variance estimation in digital images using iterative fuzzy procedure”** WSEAS Trans. Syst., vol. 4, no. 2, pp. 1048–1056.
- [25] D. B. Kopans,(2007) **“Breast Imaging”**, 3rd ed. Baltimore, MD: Williams & Wilkins.
- [26] H. D. Cheng, X. Cai, X. Chen, L. Hu, and X. Lou,(2003) **“Computer-aided detection and classification of microcalcifications in mammograms: A survey”** Pattern Recognit., vol. 36, no. 12, pp. 2967–2991.
- [27] R. M. Nishikawa, M. L. Giger, K. Doi, C. J. Vyborny, and R. A. Schmidt,(1995) **“Computer-aided detection of clustered microcalcifications on digital mammograms”** Med. Biol. Eng. Comput., vol. 33, no. 2, pp. 174–178.
- [28] M. N. Gurcan, Y. Yardimci, A. E. Cetin, and R. Ansari,(1997) **“Detection of microcalcifications in mammograms using higher order statistics”** IEEE Signal Process. Lett., vol. 4, no. 8, pp. 213–216.
- [29] R. N. Strickland and H. Hahn,(1996) **“Wavelet transforms for detecting microcalcifications in mammograms”** IEEE Trans.Med. Imag., vol. 15, no. 2, pp. 218–229.
- [30] G. Lemaur, K. Drouiche, and J. DeConinck,(2003) **“Highly regular wavelets for the detection of clustered microcalcifications in mammograms”** IEEE Trans. Med. Imag., vol. 22, no. 3, pp. 393–401.
- [31] E. Regentova, L. Zhang, J. Zheng, and G. Veni,(2007) **“Microcalcification detection based on wavelet domain hiddenMarkov tree model: Study for inclusion to computer aided diagnostic prompting system”** Med. Phys., vol. 34, no. 6, pp. 2206–2219.
- [32] S. Yu and L. Guan,(2000) **“A CAD system for the automatic detection of clustered microcalcifications in digitized mammogram films”** IEEE Trans. Med. Imag., vol. 19, no. 2, pp. 115–126.
- [33] M. Heath, et al.(2000) **“The Digital Database for Screening Mammography”**, Proceedings of the 5th International Workshop on Digital Mammography, Toronto, Canada, pp. 212-218
- [34] L.M. Bruce, R.R. Adhami,(1999) **“Classifying Mammographic Mass Shapes Using the Wavelet Transform Modulus-Maxima Method”**, IEEE Transactions on Medical Imaging, Vol. 18, Issue 12, pp. 1170-1177.
- [35] M. P. Sampat, M. K. Markey, and A. C. Bovik,(2005) **“Computer-aided detection and diagnosis in mammography”** in Handbook of Image and Video Processing, A.C. Bovik, Ed., 2nd ed. New York: Academic, pp. 1195–1217.
- [36] H. D. Li, M. Kallergi, L. P. Clarke, V. K. Jain, and R. A. Clark,(1995) **“Markov random field for tumor detection in digital mammography”** IEEE Trans. Med. Imag., vol. 14, no. 3, pp. 565–576.
- [37] W. P. Kegelmeyer, Jr., J. M. Pruneda, P. D. Bourland, A. Hillis, M. W. Riggs, and M. L. Nipper,(1994) **“Computer-aided mammographic screening for speculated lesions”** Radiology, vol. 191, no. 2, pp. 331–337.

- [38] S. Liu, C. F. Babbs, and E. J. Delp,(2001) “**Multiresolution detection of spiculated lesions in digital mammograms**” IEEE Trans. Image Process., vol. 10, no. 6, pp. 874–884.
- [39] M. P. Sampat and A. C. Bovik,(2003) “**Detection of spiculated lesions in mammograms**” in Proc. 25th Annu. Int. Conf. IEEE Eng. Med. Biol. Soc. vol. 1, pp. 810–813.
- [40] H. P. Chan, D. Wei, M. A. Helvie, B. Sahiner, D. D. Adler, M. M. Goodsitt, and N. Petrick,(1995) “**Computer-aided classification of mammographic masses and normal tissue: Linear discriminant analysis in texture feature space**” Phys. Med. Biol., vol. 40, no. 5, pp. 857–876.
- [41] B. Aiazzi, L. Alparone, and S. Baronti,(1997) “**A robust method for parameters estimation of signal-dependent noise models in digital images**” in Proc. of the IEEE 13th International Conference on Digital Signal Processing, vol. 2, pp. 601 – 604.
- [42] J.-M. Jolion P. Meer and A. Rosenfeld,(1990) “**A fast parallel algorithm for blind estimation of noise variance**” Trans. on IEEE Pattern analysis and machine intelligence, vol. 12, no. 2, pp. 216 – 223.
- [43] M. Rank, M. Lendl, and R. Unbehauen,(1999) “**Estimation of image noise variance**” in Proc. of the IEEE Visual Signal Process, vol. 146, pp. 80 – 84.
- [44] B. R. Frieden,(1983) “**Probability, Statistical Optics, and data Testing, Information Sciences**”, Springer-Verlag, Berlin.
- [45] J. R. Taylor,(1982) “**An introduction to Error Analysis, The study of uncertainties in physical measurements**”, University Science Books.
- [46] J. Fan and A. Laine,(1996) “**Contrast enhancement by multi-scale and nonlinear operators**” Wavelets in Medicine and Biology. Boca Raton, FL: CRC, pp. 163–192.
- [47] Issam El-Naqa. Yongyi Yang,(2002) “**A Support Vector Machine Approach for Detection of Microcalcifications**”, IEEE TRANSACTIONS ON MEDICAL IMAGING, VOL. 21, NO. 12.
- [48] S. Yu, S. Brown, Y. Xue, and L. Guan,(1996) “**Enhancement and identification of microcalcifications in mammogram images using wavelets**” in IEEE SMC Conf. Proc. pp. 1166–1171.
- [49] H. Kong,(1998) “**Self-organizing tree map and its applications in digital image processing**” Ph.D. thesis, Dept. Elect. Eng., Univ. of Sydney, Sydney, Australia.
- [50] P. F. Stetson, F. G. Sommer, and A. Macovski,(1997) “**Lesion contrast enhancement in medical ultrasound imaging**” IEEE Trans. Med. Imag., vol. 16, pp. 416–425.
- [51] احمد کشاورز و حسن قاسمیان یزدی، (۱۳۸۴) “**یک الگوریتم سریع مبتنی بر ماشین بردار پشتیبان برای طبقه بندی تصاویر ابرطیفی با استفاده از همبستگی مکانی**”، نشریه مهندسی برق و مهندسی کامپیوتر ایران، سال 3، شماره 1، بهار و تابستان ۱۳۸۴. ص ۲-۳.
- [52] H. P. Chan, K. Doi, C. J. Vyborny, K. L. Lam and R. A. Schmidt,(1998) “**Computer-aided detection of microcalcifications in mammograms**” Investigative Radiology, vol 9, pp. 664–671.
- [53] Y. Wu, K. Doi, M. L. Giger, and R. M. Nishikawa,(1992) “**Computerized detection of clustered microcalcifications in digital mammograms: Applications of artificial neural networks**” Med. Phys., vol. 19, pp. 555–560.
- [54] D. H. Davies and D. R. Dance,(1990) “**Automated computer detection of clustered microcalcifications in digital mammograms**” Phys. Med. Biol., vol. 35, pp. 1111–1118.
- [55] D. H. Davies and D. R. Dance,(1992) “**The automatic computer detection of subtle calcifications in radiographically dense breasts**” Phys. Med. Biol., vol. 37, pp. 1385–1390.
- [56] M. Kallergi, K. Woods, L. P. Clarke, W. Qian, and R. Clark,(1992) “**Image segmentation in digital mammography: Comparison of local thresholding and region growing algorithms**” Comput. Med. Imag. Graph., vol. 16, pp. 323–331.
- [57] K. S. Woods, C. C. Doss, K. W. Bowyer, J. L. Solka, C. E. Priebe, W. P. Kegelmeyer,(1993) “**Comparative evaluation of pattern recognition techniques for detection of microcalcifications in mammography**” Int. J. Pattern Recognit. Artif. Intell., vol. 7, pp. 1417–1436.
- [58] Isaac N. Bankman, Member, IEEE, Tanya Nizialek, Student Member, IEEE, Inpakala Simon,(1997) “**Segmentation Algorithms for Detecting Microcalcifications in Mammograms**”,

IEEE TRANSACTIONS ON INFORMATION TECHNOLOGY IN BIOMEDICINE, VOL. 1,
NO.2.

[۵۹] فردوسی،(۱۳۸۶)، پایان‌نامه کارشناسی ارشد، "پیدا کردن محل چشم در تصویر صورت و ردیابی آن"، دانشگاه صنعتی شاهرود.

[60] Tinne,(2000), PhD thesis, "**local invariant features for registration and recongnition**"
TUYTELAARS. Katholieke university

Abstract:

This years, early detection and diagnosis of breast cancer is one of the most important issues for radiologists. Early detection of breast cancer can increase the life expectancy of patients. Using mammograms is currently the most popular method for detection of breast cancer.

Micro Calcifications or MCs are tiny deposits of calcium that appear as clusters of bright spots in mammograms. Clustered MCs can be an important indicator of breast cancer. They appear in 3.0%–5.0% of cases diagnosed by mammographic screenings.

Computer aided detection or diagnosis (CAD) systems, which use computer technologies to detect abnormalities in mammograms such as calcifications, masses, and architectural distortion, and the use of these results by radiologists for diagnosis can play a key role in the early detection of breast cancer and help to reduce the death rate among women with breast cancer.

In this research we analyzed and compared six methods for detecting the position of MCs in mammograms and proposed a intensity-region based method for segmentation of detected MCs in a mammogram. The methods for MC detection differ in the two main steps of designing a CAD system. These two steps are feature extraction and classification. We used three different feature vectors for MC detection. We design CAD systems using the proposed feature vectors and compare the power of these methods. The first feature vector is consisted of the raw intensity of pixels within a window centered at the location of interest. The second and third feature vectors are consist of frequency and statistical features.

We used the two classifiers SVM (support vector machine) and NN (neural network) for classifying the pixels in a mammogram using each of three feature vectors. Accordingly six CAD systems using and three feature vectors and two classifiers are constructed. Our experiments on these CAD systems shows that using frequency and statistical features with SVM classifier provides the best recognition rate among these CAD systems.

Key words: Mammograms- Micro Calcifications- CAD systems- Wavelet transform- SVM classifier- NN classifier.