

بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ



دانشکده: برق و رباتیک
گروه: الکترونیک

مدل‌سازی بافت‌های تصادفی در تصاویر جهت تشخیص نواحی معیوب

دانشجو: سید عبدالله میرمهدوی چابک

اساتید راهنما:

دکتر علیرضا احمدی فرد
دکتر سید علی سلیمانی

استاد مشاور:

دکتر امیدرضا معروضی

پایان‌نامه ارشد جهت اخذ درجه کارشناسی ارشد

بهمن ۱۳۹۰

تقدیم به

پدر و مادر عزیز

و همچنین خانواده‌ام که همواره مشوق و حامی بنده در طی

مراحل زندگی بوده‌اند و تقدیم به روح خواهر گرانقدرم

زینب پورقاسمی.

سپاس بی کران خداوند متعال که مرا فرصت اندیشیدن داد.

برخود لازم می دانم از استاد گرانقدرم جناب آقای دکتر علیرضا احمدی فرد

و

تمامی اساتید گرامی که مرا راهنمای زندگی بودند

کمال تشکر و قدردانی را داشته باشم.

چکیده:

امروزه کنترل کیفیت تولیدات یکی از مسائل مهم در صنعت بشمار می‌رود. یکی از اهداف کنترل کیفی محصولات نظیر کاشی، استیل، چوب و پارچه، بازرسی سطوح این محصولات به منظور تشخیص نواحی معیوب احتمالی می‌باشد. در این صورت کیفیت تولیدات را با توجه به استانداردها و نیازهای کاربر کنترل می‌نمایند. تمامی این سیستم‌ها از لحاظ کارایی دارای مشترکاتی هستند که از میان آن می‌توان به مواردی همچون، خصوصیات بصری یا ویژگی‌های یک شیء که آنرا از دیگر اشیاء متمایز می‌سازد اشاره نمود. یکی از این خصوصیات مهم در بازرسی سطوح، بررسی بافت در تصاویر سطوح می‌باشد. در این پایان‌نامه مسأله تشخیص عیب در بافت‌های تصادفی را مورد بررسی قرار می‌دهیم. بدین منظور روش‌هایی جهت تشخیص عیوب بر روی سطوح بافت‌های تصادفی ارائه می‌گردد. تاکنون بیشتر کارهای انجام شده، جهت آنالیز بافت‌های منظم پیشنهاد شده است اما به دلیل ماهیت بافت‌های تصادفی، متأسفانه نمی‌توان اکثر این روش‌ها را مستقیماً بر روی بافت‌های تصادفی اعمال نمود. بدیهی است که طراحی و ارائه روش‌های جدیدی در این زمینه از اهمیت بسزایی برخوردار می‌باشد.

دو روش جهت آنالیز بافت‌های تصادفی پیشنهاد می‌گردد. روش اول مبتنی بر تبدیل موجک بوده و در روش دوم از بانک فیلتر گابور استفاده می‌شود. الگوریتم‌های پیشنهادی در این پایان‌نامه شامل دو مرحله آموزش و آزمون هستند. در مرحله آموزش، از یک یا چند تصویر بافت سالم برای استخراج بردارهای ویژگی و مدل کردن این بافت‌ها استفاده می‌شود. چگالی احتمال بردارهای ویژگی استخراج شده توسط مدل مخلوط گوسی، مدل شده و پارامترهای توابع گوسی مربوطه تخمین زده می‌شوند. در مرحله آزمون، بطور مشابه بردارهای ویژگی از پنجره‌های کوچک تصویر تحت بازرسی استخراج می‌گردند، و بافت هر پنجره مورد ارزیابی قرار می‌گیرد. بطوریکه مقدار تعلق بردار ویژگی هر پنجره تصویر آزمون به مدل استخراج شده محاسبه شده، و با یک مقدار آستانه جهت تشخیص ناحیه معیوب مقایسه می‌شود. تعیین مقدار مطلوب آستانه در راستای رویکرد تشخیص تمایزها می‌باشد.

نتایج تجربی نشان می‌دهند که دو الگوریتم پیشنهادی در مقایسه با روش‌های ارائه شده از حجم محاسباتی و دقت قابل قبولی برخوردار است.

کلمات کلیدی: بافت تصادفی، تشخیص عیب، مدل مخلوط گوسی، تبدیل موجک، بانک فیلتر

گابور

فهرست شکل‌ها

صفحه

عنوان

۱	فصل اول - مقدمه
۲	۱-۱ مقدمه
۳	۲-۱ انگیزش و هدف اصلی پروژه
۸	۳-۱ اهداف پروژه
۹	۴-۱ طرح‌بندی پروژه
۱۰	۵-۱ نتیجه‌گیری
۱۱	فصل دوم - مروری بر کارهای گذشته
۱۲	۱-۲ مقدمه
۱۲	۲-۲ روش‌های تشخیص عیوب بافت‌های منظم
۱۳	۱-۲-۲ روش‌های آماری
۱۹	۲-۲-۲ روش‌های ساختاری
۲۲	۳-۲-۲ روش‌های مبتنی بر پردازش سیگنال
۲۵	۴-۲-۲ روش‌های مبتنی بر مدل
۲۹	۳-۲ روش‌های تشخیص عیوب بافت‌های تصادفی
۳۴	فصل سوم - مبانی نظری
۳۵	۱-۳ تبدیل موجک
۳۵	۱-۱-۳ مقدمه
۳۶	۲-۱-۳ تبدیل فوریه و تبدیل موجک
۳۷	۳-۱-۳ تبدیل موجک پیوسته
۳۸	۴-۱-۳ تبدیل موجک گسسته
۴۵	۲-۳ فیلتر گابور
۵۲	۳-۳ مدل مخلوط گوسی
۵۸	۱-۳-۳ الگوریتم K-means
۵۹	فصل چهارم - روش‌های پیشنهادی
۶۰	۱-۴ مقدمه
۶۲	۲-۴ روش پیشنهادی اول
۶۳	۱-۲-۴ مرحله آموزش
۷۲	۲-۲-۴ مرحله آزمون
۷۵	۳-۴ روش پیشنهادی دوم

۷۶.....	مرحله آموزش ۱-۳-۴
۸۱.....	مرحله آزمون ۲-۳-۴
۸۲.....	نتیجه‌گیری ۴-۴
۸۴.....	فصل پنجم - نتایج و ارزیابی روش‌های پیشنهادی
۸۵.....	مقدمه ۱-۵
۸۵.....	بانک تصاویر و تهیه نقشه صحت ۲-۵
۸۷.....	انتخاب پارامترهای آزاد روش‌های پیشنهادی ۳-۵
۹۰.....	ارزیابی کیفی روش‌های پیشنهادی ۴-۵
۹۲.....	ارزیابی کمی روش‌های پیشنهادی ۵-۵
۹۴.....	ارزیابی محاسباتی روش‌های پیشنهادی ۶-۵
۹۶.....	فصل ششم - نتیجه‌گیری و ارائه پیشنهادات
۹۷.....	نتیجه‌گیری ۱-۶
۹۸.....	پیشنهادات و تحقیقات آینده ۲-۶
۱۰۰.....	مراجع

فهرست شکل‌ها

صفحه

عنوان

- شکل (۱-۱): نمایی از یک سیستم کنترل کیفیت خط تولید کاشی [۱۲۳] ۴
- شکل (۲-۱): نمونه‌هایی از یک نوع کاشی با بافت‌های تصادفی [۱۷] ۵
- شکل (۳-۱): نمونه‌هایی از بافت‌های تصادفی سالم و بافت‌های معیوب متناظر با آنها [۳۳] ۶
- شکل (۴-۱): نمونه‌ای از یک بافت منظم سالم و نمونه‌ی معیوب مرتبط با آن [۳۳] ۷
- شکل (۵-۱): نمونه‌ای از یک بافت تصادفی سالم و نمونه‌ی معیوب آن [۱۸] ۷
- شکل (۶-۱): شمای کلی روش‌های پیشنهادی ۹
- شکل (۱-۲): نمونه‌ای از ماتریس هم‌رخداد یک تصویر فرضی ۱۶
- شکل (۲-۲): نمایش LBP پایه بافت تصویر یک کاشی ۱۸
- شکل (۳-۲): نمایش تکستونی یک مدل تولیدی سه لایه [۴۰] ۲۱
- شکل (۴-۲): نحوه تولید یک شکل تکستونی ستاره مانند [۴۰] ۲۲
- شکل (۵-۲): تصویر رنگی به همراه دو اپیتوم در اندازه‌های مختلف [۶۸] ۲۹
- شکل (۶-۲): توصیفی تصویری از فرآیند تولیدی دو لایه تگزم‌ها، از روی مجموعه‌ای از تصاویر آموزشی [۱۷] ۳۳
- شکل (۱-۳): فرآیند تجزیه سیگنال به ضرایب موجک با استفاده از فیلترهای تجزیه پایین‌گذر و بالاگذر ۴۰
- شکل (۲-۳): فرآیند بازسازی سیگنال بر اساس ضرایب موجک ۴۱
- شکل (۳-۳): فیلتر بانک تبدیل موجک یک تصویر در مقیاس اول ۴۲
- شکل (۴-۳): بلوک دیاگرام تجزیه دو بعدی تبدیل موجک گسسته یک تصویر در دو مقیاس ۴۳
- شکل (۵-۳): فرآیند بازسازی سیگنال دو بعدی، از ضرایب تبدیل موجک ۴۳
- شکل (۶-۳): تبدیل موجک تصویر یک کاشی در یک و دو مقیاس ۴۴
- شکل (۷-۳): قسمت حقیقی و قسمت موهومی تابع گابور دو بعدی ۴۶
- شکل (۸-۳): موجک‌های گابور یک بانک فیلتر ۲۴ تایی، در مختصات فرکانسی [۱۱۱] و مختصات مکانی ۴۹
- شکل (۹-۳): اعمال بانک فیلتر موجک گابور به تصویر کاشی در چهار مقیاس ($M = 4$) و شش جهت ($N = 6$) ۵۱
- شکل (۱۰-۳): بلوک دیاگرام تشکیل مدل مخلوط گوسی ۵۳
- شکل (۱۱-۳): مدل مخلوط گوسی ابعادی همراه با ۳ جزء مخلوط [۱۰۳] ۵۴
- شکل (۱۲-۳): تخمین پارامترهای مدل مخلوط گوسی همراه با ۳ جزء مخلوط، برای داده آموزشی ۲ بعدی ۵۷
- شکل (۱-۴): فلوجارت روش پیشنهادی اول در دو مرحله آموزش و آزمون ۶۲
- شکل (۲-۴): تابع مقیاس، تابع موجک، فیلترهای تجزیه پایین‌گذر و بالاگذر و فیلترهای بازسازی پایین‌گذر و بالاگذر موجک دایبچز-۱ ۶۴
- شکل (۳-۴): مراحل استخراج ضرایب تبدیل موجک بافت یک کاشی و درون‌یابی آنها بصورت شماتیک ۶۵
- شکل (۴-۴): یک همسایگی 5×5 برای ضریب تبدیل موجک در راستای عمودی بافت یک کاشی ۶۶
- شکل (۵-۴): نمایش توصیفی از استخراج تکه‌های ضرایب تبدیل موجک ۶۷

- شکل (۴-۶): بلوک دیاگرام روش پیشنهادی دوم در دو فاز آموزش و آزمون ۷۶
- شکل (۴-۷): فلوجارت بخش استخراج ویژگی در روش پیشنهادی دوم ۷۹
- شکل (۵-۱): نمونه ای از یک نقشه صحت برای یک بافت معیوب ۸۶
- شکل (۵-۲): تأثیر تعداد مخلوط های گوسی در دقت نهایی تشخیص عیوب، در روش پیشنهادی اول ۸۸
- شکل (۵-۳): تصویر هر خانواده از بافت سالم که در آزمایشات مورد استفاده قرار گرفته است ۹۰
- شکل (۵-۴): مثال هایی از فرآیند تشخیص عیوب بر روی بافت های مختلف از چهار خانواده ۹۱

فهرست جدول‌ها

صفحه

عنوان

- جدول (۱-۲): تعدادی از معیارهای اندازه‌گیری شباهت بین هیستوگرام‌ها [۲۲] ۱۴
- جدول (۱-۵): ارزیابی کمی روش‌های پیشنهادی و مقایسه آن با روش TEXEM، از لحاظ کارایی توسط سه معیار "میزان حساسیت"، "میزان اختصاصی بودن"، "میزان صحت" ۹۳
- جدول (۲-۵): ارزیابی روش‌های پیشنهادی و روش TEXEM از لحاظ زمان پردازش در مراحل آموزش و آزمون.... ۹۵

فصل اول

مقدمه

۱-۱ مقدمه

بینایی از حس‌های پیشرفته انسان است. بنابراین شگفت آور نیست که تصاویر نقش بسیار مهم و منحصر به فردی را در ادراک انسان بازی می‌کنند. برخلاف انسان‌ها که منحصر به باند مرئی طیف الکترومغناطیسی هستند، ماشین‌های تصویربرداری تقریباً تمامی طیف الکترومغناطیسی که از اشعه گاما تا امواج رادیویی گسترده است را می‌پوشانند و می‌توانند روی تصاویری همچون تصاویر مافوق صوت، میکروسکوپ الکترونی، و... عمل کنند که منبع ایجاد آن‌ها برای انسان نامأنوس است. بنابراین پردازش تصویر دیجیتالی کاربردهای گسترده و متنوعی را در بر می‌گیرد که بینایی ماشین^۱ یکی از این کاربردها در این حوزه می‌باشد. یکی از مزیت‌های استفاده از بینایی ماشین، کاهش دخالت و یا جایگزینی اپراتور انسانی در صنایع مختلف است. از دهه هشتاد میلادی، در میان تعداد بسیار زیادی از روش‌های خودکار مبتنی بر بینایی ماشین، بازبینی اتوماتیک^۲ بصری سطوح جهت کاهش و یا حذف انجام فرآیندهای تکراری توسط نیروی انسانی، یکی از بارزترین و مهمترین کارها در حوزه بینایی ماشین بوده است.

در این فصل ابتدا در بخش ۱-۲، به شرح انگیزه و هدف اصلی پروژه جاری پرداخته و سپس ویژگی‌های پروژه و همچنین شمای کلی روش پیشنهادی را در بخش ۱-۳ به طور خلاصه شرح می‌دهیم. پس از آن در بخش ۱-۴، طرح‌بندی پروژه را ارائه داده و بصورت خلاصه، مفاد و محتوای موجود در هر فصل را توضیح می‌دهیم. سرانجام در بخش ۱-۵، نتیجه‌گیری این فصل را ارائه خواهیم نمود.

^۱ Machine Vision

^۲ Automatic Visual Surface Inspection

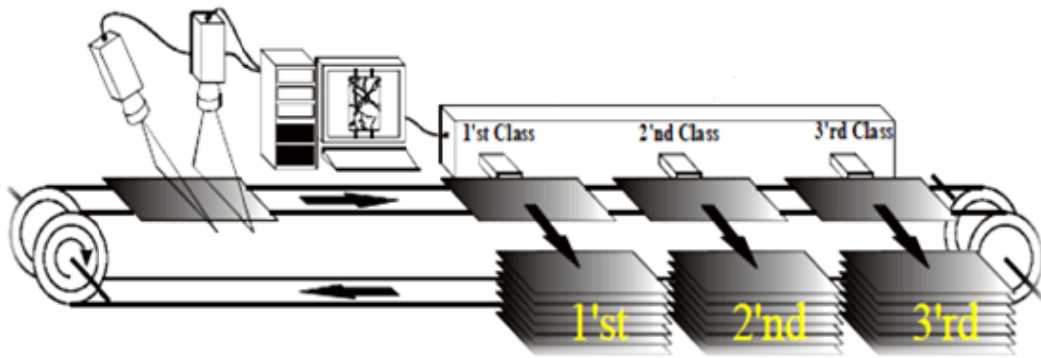
۱-۲ انگیزش و هدف اصلی پروژه

هدف اولیه از انجام روش‌های خودکار بازبینی بصری سطوح، یافتن مناطقی از سطح موردنظر است که خصوصیات ظاهری و یا فیزیکی آنها بر اساس معیارهای خاصی نظیر رنگ و یا نظم در الگو، از خصوصیات نرمال مناطق متناظر در نمونه‌های آموزشی و سالم، انحراف دارد. به طور معمول، اغلب خطوط تولید دارای بازرسان یا اپراتورهایی هستند که کار بازرسی سطوح را انجام می‌دهند. درمقایسه با این روش، بازرسی اتوماتیک سطوح، فوائد زیادی را دارد. با یک سیستم بازرسی اتوماتیک می‌توانیم بازبینی دقیق‌تری داشته باشیم و مواردی نظیر خستگی نیروی انسانی و هزینه‌های بازبینی بر نیروی انسانی را کاهش دهیم. روش کار به اینصورت است که، اجناس تولید شده در کارخانه که بر روی یک نوار نقاله قرار گرفته‌اند، توسط یک دوربین CCD^۱ برای آزمایش دیده می‌شوند و محصولات با کیفیت مناسب، اجازه عبور پیدا خواهند کرد. چنانچه محصولی دارای استانداردهای مناسب نباشد از ادامه مسیر حذف می‌گردد. معیار این استانداردها می‌تواند لبه‌های زائد، خراشیدگی و بادکردگی و تورم روی فلزات و یا عیب‌های موجود در کاشی، پارچه، و محصولات کشاورزی باشد. بطور خلاصه فوایدی که توسط یک سیستم بازرسی اتوماتیک بدست می‌آید عبارتند از:

- افزایش سرعت بازرسی و نتیجتاً سرعت خط تولید.
- فراهم کردن سطح بازرسی مورد قبول.
- افزایش کنترل بر فرآیند تولید.
- سهولت درجه‌بندی کیفیت تولیدات.
- امکان استخراج و تحلیل آماری خرابی‌ها برای افزایش کیفیت.
- بازرسی پیشگیری کننده بقصد اجتناب یا جبران خرابی به محض وقوع.

شکل (۱-۱) مثال بسیار ساده‌ای از چنین سیستمی را نشان می‌دهد.

^۱ Charge Coupled Device




شکل (۱-۱): نمایی از یک سیستم کنترل کیفیت خط تولید کاشی [۱].

امروزه روش‌های مبتنی بر بینایی ماشین بطور عمده‌ای در تشخیص و موقعیت‌یابی چنین عیوب و یا نواقصی، در کاربردهای گوناگون نظیر بازرسی و کنترل کیفی سطح کاشی [۲،۳،۴]، پارچه [۵،۶]، چوب [۷،۸]، فولاد [۹]، و یا ویفر سلیکون [۱۰] مورد استفاده قرار می‌گیرند. بطور کلی، چنین فرآیندهای تشخیصی، در حوزه آنالیز بافت^۱ رده‌بندی می‌گردند.

بافت یک خصوصیت ذاتی اشیاء تصویر است و در میان خاصیت‌های مختلفی که اشیای یک تصویر دارند مثل رنگ یا شکل، بافت یکی از خاصیت‌های بارز اشیای تصویر هم از دیدگاه چشم انسان و هم از دیدگاه آنالیزهای اتوماتیک تصویر می‌باشد. تعریف مشخصی از بافت وجود ندارد، ولی به لحاظ ادراکی ساختارهایی در تصویر که به لحاظ آماری خصوصیات مشابهی دارند، یک نوع بافت خواهند داشت. مثلاً نقش روی سنگ‌های مرمر، نقش رگه‌ای چوب، سطح آسفالت و غیره، مثالی از بافت‌های مختلف می‌باشند. تحلیل بافت، یک حوزه مفید و مهم در مطالعات بینایی ماشین می‌باشد و شاخه مهمی از پردازش تصویر به شمار می‌رود که دارای کاربردهای فراوانی نظیر سنجش از راه دور، بازرسی کیفیت و تصویربرداری پزشکی، ناحیه بندی تصاویر ماهواره‌ای، بینایی روبات‌ها و... می‌باشد. در تحلیل بافت، مشکلترین مسئله عبارتست از تعریف مجموعه‌ای از ویژگی‌ها بطوریکه مشخصات یک بافت را توصیف نموده تا بتوان آن بافت را از سایر بافت‌ها متفاوت دانست.

^۱ Texture Analysis

بافت‌ها از نظر الگوی ظاهری بطور کلی به دو دسته بافت‌های منظم^۱ و تصادفی^۲ تقسیم‌بندی می‌گردند [۱۱]. اکثر روش‌های موجود، مسئله تشخیص عیوب بافت^۳ را برای بافت‌های منظم که دارای الگوهای مشخص و یا تکراری هستند، مورد بررسی قرار داده‌اند، در مقایسه روش‌های اندکی نیز به منظور تشخیص عیوب بافت‌های تصادفی که از نظر محلی فاقد هرگونه نظم مشخصی هستند، گزارش شده‌اند [۱۲،۱۳،۱۴،۱۵]. این در حالیست که در سالیان اخیر، تقاضای روزافزونی به منظور تشخیص عیوب بافت‌های پیچیده و نوعاً تصادفی از سوی صنایع مختلفی نظیر صنایع تولید کاشی و سرامیک مطرح شده است. بعنوان مثال، شکل (۱-۲) نمونه‌ای از تصویرهای یک نوع کاشی با بافت تصادفی را نشان می‌دهد. اگرچه بافت این سه کاشی با یکدیگر متفاوت است اما آنها از دید ظاهری چشم بسیار شبیه و نزدیک به هم تصور می‌شوند. این مسئله در بسیاری از بافت‌های تصادفی به چشم می‌خورد.




شکل (۱-۲): نمونه‌هایی از یک نوع کاشی با بافت‌های تصادفی [۱۲].

در شکل (۱-۳) نیز تصویر تعدادی از کاشی‌های گرانیته با بافت‌های تصادفی سالم و معیوب نشان داده شده است. همانطور که از این شکل مشاهده می‌گردد، بافت موجود در تصویر کاشی‌های سالم و معیوب، از لحاظ مکانی با یکدیگر متفاوت بوده، اما از لحاظ دیداری، مشابه هم ادراک می‌شوند. در این شکل، عیوب مورد نظر با رسم یک بیضی حول آنها مشخص گردیده‌اند.

^۱ Regular

^۲ Random


^۳ Texture Defect Detection



شکل (۳-۱): (الف و ج) نمونه‌هایی از بافت‌های تصادفی سالم و (ب و د) بافت‌های معیوب متناظر با آنها. در هر یک از بافت‌های معیوب، حول هر عیب یک بیضی کشیده شده است [۱۶].

به منظور مقایسه، در شکل (۴-۱)، تصویر یک بافت منظم سالم و همچنین تصویر بافت معیوب مرتبط با آن نمایش داده شده است. در این تصویر، از آنجاییکه بافت مورد نظر منظم و پررودیک می‌باشد، یافتن عیب مورد نظر نسبت به نمونه‌هایی که در شکل (۳-۱) نشان داده شده‌اند، به مراتب آسان‌تر می‌باشد. به منظور مشخص نمودن هر چه بیشتر پیچیدگی‌های موجود در فرآیند تشخیص عیوب در بافت‌های تصادفی، در شکل (۵-۱) نمونه دیگری از یک کاشی گرانیته سالم و همچنین معیوب نمایش داده شده است. همانطور که از این شکل مشخص است، عیب مورد نظر رگه سفید رنگی است که در پایین و سمت راست کاشی قرار گرفته است و خال تیره رنگی که در وسط و بالای کاشی بوده، عیب محسوب نمی‌گردد و در حقیقت جزو الگوی اصلی بافت سالم به حساب می‌آید. لذا در چنین مواردی، تشخیص دادن عیب از الگوی اصلی بافت، بسیار مهم و حیاتی می‌باشد. واضح است که این مسئله، فرآیند تشخیص عیوب بافت‌های تصادفی را پیچیده‌تر می‌سازد.

در بخش‌های بعدی خواهیم دید که متأسفانه نمی‌توان روش‌های تشخیص عیوب در بافت‌های منظم را به طور مستقیم بر روی بافت‌های تصادفی اعمال نماییم و در نتیجه نیاز به طراحی روش‌های مختص به بافت‌های تصادفی داریم. بنابراین همانطور که از مباحث بالا بر می‌آید، انگیزه و هدف اصلی در این پایان نامه، یافتن روش نوینی برای تشخیص عیوب در بافت‌های تصادفی می‌باشد که در ادامه به تفصیل به بحث در مورد آن خواهیم پرداخت.



شکل (۱-۴) : نمونه‌ای از یک بافت منظم سالم (سمت چپ) و نمونه‌ی معیوب مرتبط با آن (وسط و سمت راست) [۱۶].



شکل (۱-۵) : نمونه‌ای از یک بافت تصادفی سالم (سمت چپ) و نمونه‌ی معیوب آن (وسط و سمت راست) [۱۷].

۳-۱ اهداف پروژه

در این پایان‌نامه، سعی بر آن است تا روش جدیدی را به منظور تشخیص عیوب بافت‌های تصادفی به کمک تبدیل موجک^۱، فیلتر گابور^۲ و مدل مخلوط گوسی^۳، ارائه نماییم. همانطور که اشاره گردید، یکی از کاربردهای تشخیص عیوب بافت، در فرآیندهای بازبینی سطوح در صنایع مختلف می‌باشد که اینگونه فرآیندها عمدتاً بصورت برخط^۴ و بلادرنگ^۵ بوده و لذا زمان پردازش نقش بسیار مهمی را در قابل استفاده بودن یک روش بازبینی ایفا می‌نماید. بنابراین سرعت اجرای روش پیشنهادی باید تا حد امکان بالا بوده تا قابلیت پیاده‌سازی آن بصورت بلادرنگ فراهم گردد.

همچنین باید توجه داشت که در بسیاری از کاربردهای واقعی، عیوب محتمل واقع بر سطوح، غیر قابل پیش‌بینی بوده و امکان آموزش^۶ یک سیستم تشخیص عیب با در دست داشتن تمام عیوب ممکن عملاً غیرممکن است. لذا سیستم پیشنهادی می‌بایست تا حد امکان خودکار بوده و در آن نیازی به آموزش کلاس معیوب وجود نداشته باشد. بنابراین سیستم موردنظر را می‌توان در یک فرآیند آموزش، توسط نمونه‌هایی از کلاس و یا دسته‌ای سالم، آموزش داده و در مرحله^۷ آزمون^۷ به صورت خودکار عیوب ممکن را آشکارسازی و موقعیت‌یابی نمود. لازم به ذکر است که در بسیاری از کاربردها، صرف تعیین سالم و یا معیوب بودن یک بافت کفایت نمی‌کند و تشخیص موقعیت و همچنین اندازه عیوب ضروری می‌باشد. این عیوب می‌توانند از اندازه‌های بسیار کوچک تا اندازه‌های خیلی بزرگ باشند و لذا روش پیشنهادی می‌بایست قابلیت تشخیص و موقعیت‌یابی انواع عیوب در اندازه‌های مختلف را دارا باشد. در شکل (۱-۶) شمای کلی سیستم پیشنهادی نشان داده شده است. همانطور که

^۱ Wavelet Transform

^۲ Gabor Filter

^۳ Gaussian Mixture Model

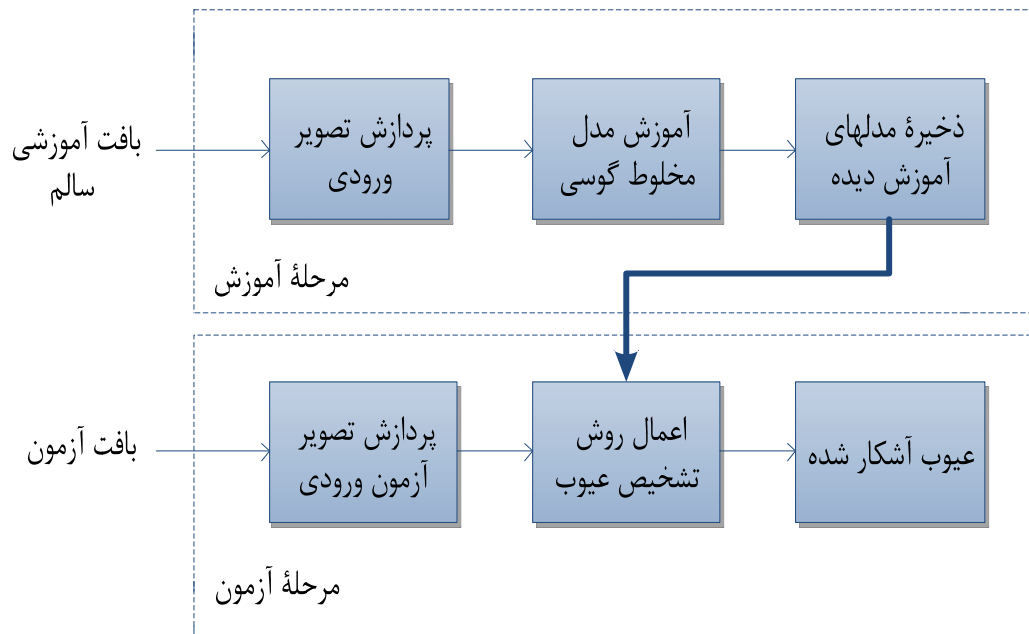
^۴ Online

^۵ Real Time

^۶ Train

^۷ Test

از این شکل بر می آید، روش پیشنهادی دارای دو مرحله آموزش و آزمون می باشد که قسمت پردازش تصاویر، در روش پیشنهادی اول، شامل اعمال تبدیل موجک، و در روش پیشنهادی دوم، شامل اعمال فیلتر گابور به تصاویر می باشد. در فصول بعدی به تفصیل در مورد جزئیات هر یک از این مراحل، بحث خواهیم نمود.



شکل (۱-۶): شمای کلی روش های پیشنهادی.

۴-۱ طرح بندی پروژه

همانطور که اشاره گردید، هدف این پایان نامه ارائه روشی نوین به منظور تشخیص عیوب بافت-های تصادفی به کمک مدل مخلوط گوسی می باشد که شامل دو روش پیشنهادی؛ ابتدا با استفاده از تبدیل موجک و سپس استفاده از فیلترهای گابور می باشد. لذا در فصل سوم، به معرفی مدل مخلوط گوسی می پردازیم. در این فصل خواهیم دید که مدل مخلوط گوسی ابزار بسیار قدرتمندی جهت تحلیل و مدل سازی فرآیندهای اتفاقی و تصادفی است و لذا به نظر می رسد که در کاربرد جاری نیز می تواند مؤثر واقع شوند. همچنین خواهیم دید که یکی دیگر از ملزومات روش پیشنهادی این پایان-

نامه، استفاده از روش‌های دیگر آنالیز بافت موسوم به تبدیل موجک و فیلترهای گابور می‌باشد و لذا در فصل سوم به معرفی اجمالی این روش‌ها هم می‌پردازیم. سپس در فصل چهارم، روش پیشنهادی اول که شامل استفاده از تبدیل موجک جهت مدل‌سازی ویژگی‌های بافت در حوزه فرکانس است، به تفصیل ارائه می‌گردد و در ادامه روش پیشنهادی دوم که در آن از فیلترهای گابور جهت استخراج بردارهای ویژگی استفاده شده است را ارائه خواهیم نمود. در فصل پنجم، به شرح نتایج حاصل از شبیه‌سازی و آزمایشات تجربی و همچنین مقایسه کمی و کیفی روش‌های مذکور با یکدیگر و همچنین با روش اخیر صورت گرفته در بافت‌های تصادفی، می‌پردازیم. و در نهایت در فصل ششم به ارائه پیشنهادات و تحقیقاتی که می‌تواند در راستای این امر مفید واقع شود، می‌پردازیم و نتیجه‌گیری می‌نماییم.

۱-۵ نتیجه‌گیری

در این فصل، به شرح هدف اصلی این پایان‌نامه پرداختیم. همانطور که مشاهده گردید، برخلاف تعداد بسیار زیاد روش‌های تشخیص عیوب در بافت‌های منظم، تاکنون روش‌های اندکی جهت تشخیص عیوب بافت‌های تصادفی ارائه شده است. همچنین مشاهده گردید که تشخیص عیوب در بافت‌های تصادفی به مراتب پیچیده‌تر از تشخیص عیوب در بافت‌های منظم بوده و لذا تمییز دادن یک عیب مفروض از الگوی بافتی اصلی از حساسیت و اهمیت بالایی برخوردار است. متأسفانه بسیاری از روش‌های تشخیص عیوب در بافت‌های منظم را نمی‌توان به راحتی بر روی بافت‌های تصادفی اعمال نمود، چرا که در بسیاری از این روش‌ها، از خاصیت تناوبی و یا منظم بودن ذاتی بافت‌های داده شده جهت آشکارسازی عیوب استفاده می‌شود و این در حالیست که عمدتاً در بافت‌های تصادفی، هیچگونه الگوی منظم و یا تناوبی به صورت آشکار وجود ندارد. بدیهی است که طراحی و ارائه روش‌های جدید در این زمینه از اهمیت بسزایی برخوردار می‌باشد.

فصل دوم

مروری بر کارهای گذشته

۱-۲ مقدمه

همانطور که اشاره گردید، بافت‌ها از نظر کلی به دو دسته بافت‌های منظم و تصادفی تقسیم‌بندی می‌گردند. البته لازم به یادآوری است که دسته دیگری از بافت‌ها موسوم به بافت‌های شبه تصادفی^۱ نیز وجود دارند که در این پایان نامه، به منظور سادگی آنها را در زمره بافت‌های تصادفی در نظر می‌گیریم. با توجه به این طبقه بندی، واضح است که دو دسته کلی از روش‌های تشخیص عیوب بافتی موجود است. دسته اول روش‌های تشخیص عیوب بافت‌های منظم، و دسته دوم روش‌های تشخیص عیوب بافت‌های تصادفی خواهند بود. در ادامه به بررسی اجمالی بعضی از روش‌های پیشین تشخیص عیوب، چه در بافت‌های منظم و چه در بافت‌های تصادفی می‌پردازیم.

۲-۲ روش‌های تشخیص عیوب بافت‌های منظم

تاکنون روش‌های بسیار زیاد و متعددی در زمینه تشخیص عیوب بافت‌های منظم و شبه‌منظم در کاربردهای مختلف، مطرح گردیده‌اند. این روش‌ها را می‌توان بطور کلی به چهار دسته زیر تقسیم‌بندی نمود [۱۱]:

۱- روش‌های آماری

۲- روش‌های ساختاری

۳- روش‌های مبتنی بر پردازش سیگنال

۴- روش‌های مبتنی بر مدل

^۱ Pseudo-Random

۲-۲-۱ روش‌های آماری^۱

روش‌های آماری آنالیز بافت، توزیع مکانی^۲ سطح خاکستری پیکسل‌ها را اندازه‌گیری می‌نماید. این روش‌ها در بسیاری از زمینه‌های بینایی رایانه^۳ و پردازش تصویر، بطور گسترده‌ای مورد استفاده قرار گرفته‌اند. تاکنون روش‌های آماری زیادی از آماره‌های مرتبه اول^۴ تا آماره‌های مرتبه بالاتر، پیشنهاد گردیده‌اند. از میان آنها می‌توان به آماره‌های هیستوگرامی^۵، ماتریس‌های هم‌رخداد^۶، توابع خود همبستگی^۷، و الگوهای باینری محلی^۸، اشاره نمود. در ادامه به شرح مختصر تعدادی از این روش‌ها می‌پردازیم.

الف - خصوصیات هیستوگرام

در این روش‌ها، جهت تشخیص عیب تصویر بافت مفروض، خصوصیات هیستوگرام بافت داده شده با خصوصیات متناظر هیستوگرام یک بافت سالم (مدل) مقایسه می‌گردد. از میان آماره‌های هیستوگرامی مشهوری که در مقالات به کرات مورد استفاده قرار گرفته‌اند، می‌توان به آماره‌هایی نظیر میانگین حسابی، میانگین هندسی، انحراف معیار، واریانس و میانه اشاره نمود. در جدول (۲-۱)، معیارهای اندازه‌گیری تشابه دو هیستوگرام و یا بطور کلی دو توزیع آماری بطور خلاصه نمایش داده شده است [۲۰، ۱۹، ۱۸]. در این جدول، r_i و s_i به ترتیب تعداد رخدادها در انباره^۹ i برای توزیع اول و دوم می‌باشد، \bar{r} و \bar{s} مقادیر میانگین هستند و n تعداد کل انباره‌ها بوده و $r_{(i)}$ و $s_{(i)}$ اندیس‌های مرتب

^۱ Statistical Approaches

^۲ Spatial Distribution

^۳ Computer Vision

^۴ First Order Statistics

^۵ Histogram Statistics

^۶ Co-occurrence Matrices

^۷ Autocorrelation Function

^۸ Local Binary Pattern

شده (به شکل صعودی) را نشان می‌دهند. توجه کنید که EMD فاصله $Earth Mover$ را نشان می‌دهد [۱۹].

علی‌رغم سادگی و حجم محاسباتی بسیار پایین، اینگونه روش‌ها از کارایی نسبتاً خوبی برخوردار هستند [۲۲، ۲۱، ۱۹]. اینگونه روش‌ها نسبت به چرخش، جابجایی و موقعیت مکانی دقیق پیکسل‌های رنگی نامتغیر می‌باشند. این خصوصیات، آنها را در کاربردهای تشخیص عیوب رنگی نظیر تمایز بین طیف و غلظت رنگ بسیار مؤثر ساخته‌اند [۱۸]. همچنین دقت چنین روش‌هایی را می‌توان با استفاده از آماره‌های استخراج شده از نواحی محلی، افزایش داد [۲۳]. بعنوان مثال در [۲۴] از ممان‌های هیستوگرامی ساده نظیر میانگین و انحراف معیار که از بلوک‌های کوچک تصویر استخراج شده‌اند، جهت طبقه‌بندی و تشخیص عیوب استفاده شده است.

جدول (۱-۲) : تعدادی از معیارهای اندازه‌گیری شباهت بین هیستوگرام‌ها [۱۸].

Measurement	Formula
L_1 norm	$L_1 = \sum_{i=1}^n r_i - s_i $
L_2 norm	$L_2 = \sqrt{\sum_{i=1}^n (r_i - s_i)^2}$
Mallows or EMD distance	$M_p = \left(\frac{1}{n} \sum_{i=1}^n r_{(i)} - s_{(i)} ^p \right)^{1/p}$
Bhattacharyya distance	$B = -\ln \sum_{i=1}^n \sqrt{r_i s_i}$
Matusita distance	$M = \sqrt{\sum_{i=1}^n (\sqrt{r_i} - \sqrt{s_i})^2}$
Divergence	$D = \sum_{i=1}^n \left((r_i - s_i) \ln \frac{r_i}{s_i} \right)$
Histogram intersection	$H = \frac{\sum_{i=1}^n \min(r_i, s_i)}{\sum_{i=1}^n r_i}$
Chi-square	$\chi^2 = \sum_{i=1}^n \frac{(r_i - s_i)^2}{r_i + s_i}$
Normalised correlation coefficient	$r = \frac{\sum_{i=1}^n (r_i - \bar{r})(s_i - \bar{s})}{\sqrt{\sum_{i=1}^n (r_i - \bar{r})^2} \sqrt{\sum_{i=1}^n (s_i - \bar{s})^2}}$

ب- ماتریس‌های هم‌رخداد

اندازه‌گیری معیارهای بافت فقط بر اساس هیستوگرام، اطلاعات نسبی مکان پیکسل‌ها نسبت به یکدیگر را در اختیار قرار نمی‌دهد. این نکته در هنگام توصیف بافت مهم است و یک روش برای گنجاندن این نوع اطلاعات در فرآیند تحلیل بافت، در نظر گرفتن نه تنها توزیع شدت‌ها، بلکه موقعیت‌های نسبی پیکسل‌ها در تصویر می‌باشد. ماتریس‌های هم‌رخداد سطح خاکستری مکانی^۱ (GLCM) [۲۵]، یکی از مشهورترین و پرستفاده‌ترین ویژگی‌های بافتی می‌باشد. این آماره‌های مرتبه دوم در مجموعه‌ای از ماتریس‌های ۲-بُعدی $\Phi_{d,\theta}(i, j)$ انباشته می‌شوند که هر یک از آنها، وابستگی مکانی دو سطح خاکستری i و j را با داشتن یک بردار جابجایی d اندازه‌گیری می‌کند. تعداد رخدادها یا دفعاتی که دو سطح خاکستری i و j در یک فاصله d از یکدیگر قرار می‌گیرند، درایه (i, j) ماتریس $\Phi_{d,\theta}(i, j)$ را تشکیل می‌دهد. فرض نمایید I یک تصویر با ابعاد $U \times V$ را نمایش دهد. آنگاه ماتریس هم‌رخداد تصویر I با N سطح شدت، بصورت رابطه (۱-۲) بدست می‌آید:

$$\Phi_{d,\theta}(i, j) = \sum_{u=1}^U \sum_{v=1}^V p(I(u, v), I(u', v'), i, j) \quad (1-2)$$

که در آن d و θ به ترتیب فاصله و زاویه بین جفت پیکسل‌های $\langle x(u, v), x(u', v') \rangle$ می‌باشند. عملگر p هم بصورت رابطه (۲-۲) تعریف می‌گردد:

$$p(x(u, v), x(u', v'), i, j) = \begin{cases} 1 & \text{if } x(u, v) = i \text{ and } x(u', v') = j \\ 0 & \text{other wise} \end{cases} \quad (2-2)$$

بطور کلی مقادیر بهینه‌ای برای d و θ وجود ندارد. ولی در بیشتر کاربردها $d=1$ و $\theta = \{0^\circ, 45^\circ, 90^\circ, 135^\circ\}$ برای تحلیل بافت‌ها در نظر گرفته می‌شوند.


بعنوان نمونه ماتریس هم‌رخداد یک تصویر 6×6 در شکل (۱-۲) آورده شده است. پس از یافتن ماتریس‌های هم‌رخداد، ویژگی‌های بافتی نظیر انرژی، آنترپی، کنتراست، همگنی^۲ و همبستگی^۳ از

^۱ Spatial Grayscale Co-occurrence Matrices

^۲ Homogeneity

^۳ Correlation

این ماتریس‌ها استخراج می‌گردند. مقالات متعددی، از ماتریس‌های هم‌رخداد به منظور تشخیص عیوب بافتی استفاده نموده‌اند [۲۷،۲۶،۲۴]. یکی از معایب ماتریس‌های هم‌رخداد، نبود راه حل مناسبی برای انتخاب بهینه مقدار d و θ می‌باشد [۲۸،۱۶]. در کاربردهای عملی، معمولاً تعداد سطوح خاکستری به منظور کنترل نمودن اندازه ماتریس‌های هم‌رخداد و در نتیجه حجم محاسبات، کاهش می‌یابد. البته باید توجه نمود که تعداد عناصر این ماتریس‌ها می‌بایست به اندازه کافی باشد تا ویژگی‌های آماری استخراج شده از آنها از قابلیت اطمینان برخوردار باشند. برای یک بردار جابجایی داده شده، تعداد زیادی از ویژگی‌های بافتی را می‌توان محاسبه نمود که این امر نیازمند استفاده از روش‌های انتخاب بهترین ویژگی‌ها جهت افزایش کارایی می‌باشد. در مرجع [۲۹]، نشان داده شده است که ماتریس‌های هم‌رخداد و اپراتور الگوهای باینری محلی (LBP) دارای کارایی نزدیک به هم در تشخیص عیوب هستند ولی روش LBP مؤثرتر است.



شکل (۲-۱): نمونه‌ای از ماتریس هم‌رخداد یک تصویر فرضی. (الف) ماتریس هم‌رخداد تصویر اصلی و (ب) تصویر اصلی.

ج - تابع خود همبستگی^۱

مشاهده شده است که بسیاری از بافت‌ها همانند بافت پارچه بصورت طبیعی دارای المان‌های تکراری هستند. بر این اساس، ویژگی خودهمبستگی در بسیاری از کاربردها تعریف و مورد استفاده قرار گرفته است. این ویژگی، همبستگی بین یک تصویر با نمونه جابجا شده خود توسط بردار جابجایی d را اندازه‌گیری می‌نماید. این تابع بصورت رابطه (۳-۲) تعریف می‌گردد:

$$\rho(d) = \frac{\sum_{x=0}^w \sum_{y=0}^h I(x, y)I(x + dx, y + dy)}{\sum_{x=0}^w \sum_{y=0}^h I^2(x, y)} \quad (3-2)$$

تابع خودهمبستگی بافت‌های با نظم بسیار بالا، دارای قله‌ها و دره‌های مشخصی می‌باشد. همچنین لازم به تذکر است که این آماره مرتبه دوم به طور واضح نسبت به نویز حساس می‌باشد. همچنین از آماره‌های مرتبه بالاتر هم بدین منظور استفاده می‌شود [۳۰، ۳۱]. برای مثال در [۳۲]، از آماره‌های مرتبه چهارم تابع خودهمبستگی در بلوک‌های مختلف تصویر اصلی جهت تشخیص عیوب در تصاویر پارچه و چوب استفاده شده است. باید توجه داشت که اکثر بافت‌های تصادفی از نظم مشخصی برخوردار نیستند و لذا تابع خودهمبستگی جهت آنالیز آنها مناسب نمی‌باشد.

د - الگوهای باینری محلی

الگوهای باینری محلی (LBP) توسط اجالا^۲ به عنوان توصیف کننده بافت مستقل از دوران، مبتنی بر طیف واحد بافت^۳ معرفی شد [۳۳] و در دهه اخیر از LBP در زمینه‌های مختلف آنالیز بافت استفاده شده است که از مهمترین آنها می‌توان به مرجع‌های [۳۳، ۳۴، ۳۵] اشاره نمود. LBP پایه، یک همسایگی ۳×۳ را برای هر پیکسل در نظر می‌گیرد. این هشت پیکسل همسایه، اگر مقدار آنها از مقدار پیکسل مرکزی بزرگتر یا مساوی باشد با ارزش یک جایگزین می‌شوند. در غیر اینصورت ارزش آنها صفر خواهد بود. در پایان، پیکسل مرکزی با جمع وزندار باینری پیکسل‌های همسایه جایگزین شده و

^۱ Autocorrelation Function

^۲ Ojala

^۳ Texture Unit Spectrum

پنجره 3×3 به پیکسل بعدی منتقل می‌شود. همچنین می‌توان LBP پایه را با اندازه همسایگی‌های

مختلف توسعه داد. تعریف ریاضی LBP با اندازه همسایگی‌های مختلف بصورت رابطه (۴-۲) است:

$$LBP_{P,R} = \sum_{p=0}^{p-1} S(g_p - g_c) 2^p \quad (4-2)$$

که $S(\cdot)$ معرف تابع علامت^۱ است که بصورت رابطه (۵-۲) تعریف می‌شود:


$$S(x) = \begin{cases} 1 & , x \geq 0 \\ 0 & , x < 0 \end{cases} \quad (5-2)$$

g_c و g_p مقادیر سطوح خاکستری پیکسل‌های مرکز و همسایه می‌باشند و p تعداد پیکسل‌های

همسایگی و R شعاع همسایگی‌ها را مشخص می‌کنند. بعنوان نمونه شکل (۲-۲) نشان دهنده بافت

یک کاشی و تصویر LBP پایه با $P=8$ و $R=1$ متناظر با بافت کاشی می‌باشد. جهت مقایسه،

هیستوگرام‌های متناظر با هر یک از این دو تصویر نیز در زیر هر تصویر آورده شده است.



شکل (۲-۲): نمایش LBP پایه بافت تصویر یک کاشی. (الف) کاشی سرامیکی و هیستوگرام متناظر با آن، (ب) نگاشت LBP کاشی و هیستوگرام متناظر با آن.

^۱ Sign function

۲-۲-۲ روش‌های ساختاری^۱

در روش‌های ساختاری، یک بافت توسط عناصر اصلی بافتی^۲ و نحوه چیدمان یا موقعیت مکانی این عناصر توصیف می‌گردد. بنابراین، هدف اصلی روش‌های ساختاری، ابتدا استخراج این عناصر بافتی و سپس مدل‌سازی و یا تعمیم موقعیت و قواعد جابجایی این عناصر نسبت به یکدیگر می‌باشد. این عناصر بافتی می‌توانند به سادگی یک پیکسل، یک ناحیه با سطوح خاکستری یکنواخت و یا قطعه‌های خطی باشد.

در مرجع [۳۶]، پیشنهاد شده است که بافت‌های طبیعی را می‌توان به صورت الگوهای ایده‌آلی در نظر گرفت که تحت تأثیر تبدیلات و تحولات مشخصی قرار گرفته‌اند که قواعد جابجایی این الگوها توسط گراف خاصی تعریف می‌گردد. در مرجع [۳۷]، مفهوم تکستون^۳ها بعنوان ساختارهای تصویری اساسی^۴ نظیر اشکال میله‌ای^۵، ضربدری^۶، حباب‌های کشیده^۷، و امثال آن مطرح شده است. در این مقاله، تکستون‌ها بعنوان کوچکترین ساختار قابل درک سیستم بینایی انسان در نظر گرفته شده‌اند. در ادامه این بخش به معرفی روش آنالیز بافت بر مبنای تکستون‌ها بعنوان یک روش تحلیل ساختاری بافت می‌پردازیم.

الف - تکستون

در این بخش به معرفی مدل تکستون که در سال‌های اخیر مورد توجه بسیاری از محققان قرار گرفته، می‌پردازیم. تکستون‌ها بصورت رسمی در مرجع [۳۷] به عنوان ساختارهای تصویری اساسی معرفی شده‌اند. در [۳۸]، نویسندگان یک مدل تمایزی^۸ را برای توصیف تکستون‌ها ارائه نمودند. در

^۱ Structural Approaches

^۲ Texture Primitives or Texture Elements

^۳ Textons

^۴ Fundamental Image Structures

^۵ Bars

^۶ Crosses

^۷ Elongated Blobs

^۸ Discriminative Model

روش آنها، ابتدا تصویر هر بافت، توسط یک بانک از فیلترهای گوسی مشتمل بر ۴۸ فیلتر در جهت‌ها و مقیاس‌های متفاوت آنالیز می‌شود. بدین صورت یک بردار ویژگی با ابعاد بسیار بالا در هر موقعیت پیکسل از تصویر مورد مطالعه استخراج می‌شود. سپس از الگوریتم K-means برای خوشه‌بندی بردارهای ویژگی استخراج شده استفاده می‌شود. پس از عملیات خوشه‌بندی، مرکز هر خوشه بعنوان یک تکستون در نظر گرفته می‌شود.

در مرجع [۳۹]، نشان داده شده است که از تکستون‌ها می‌توان بعنوان ساختارهای پایه تشکیل دهنده یک تصویر در مدل کردن آنها استفاده نمود. آنها یک مدل تولیدی سه لایه را پیشنهاد کردند که در این مدل، یک تصویر I را می‌توان بصورت یک برهم نهی^۱ از تعدادی از توابع پایه^۲ که از یک دیکشنری خیلی کامل^۳ Ψ انتخاب شده‌اند، بدست آورد. این پایه‌های تصویری، در حقیقت خروجی فیلترهای گابور و یا لاپلاسین گوسی در مقیاس‌ها و جهت‌های مختلفی هستند که خود از تعداد کمتری از عنصرهای تکستونی^۴ که از یک دیکشنری تکستون Π انتخاب شده‌اند، تولید می‌شوند. این سه لایه تولیدی در شکل (۳-۲) نشان داده شده است.

یک تصویر I از یک نقشه پایه B که خود از یک نقشه تکستونی^۵ T تولید می‌گردد، مطابق رابطه (۶-۲) ساخته می‌شود.

$$T \xrightarrow{\Pi} B \xrightarrow{\Psi} I \quad (۶-۲)$$

که در آن $\Pi = \{\pi_i, i = 1, 2, \dots\}$ و $\Psi = \{\psi_i, i = 1, 2, \dots\}$ می‌باشد. هر تکستون یک نمونه در نقشه تکستونی T می‌باشد که بصورت ترکیبی از تعداد مشخصی از توابع پایه که بصورت اشکال هندسی

^۱ Superposition

^۲ Base Function

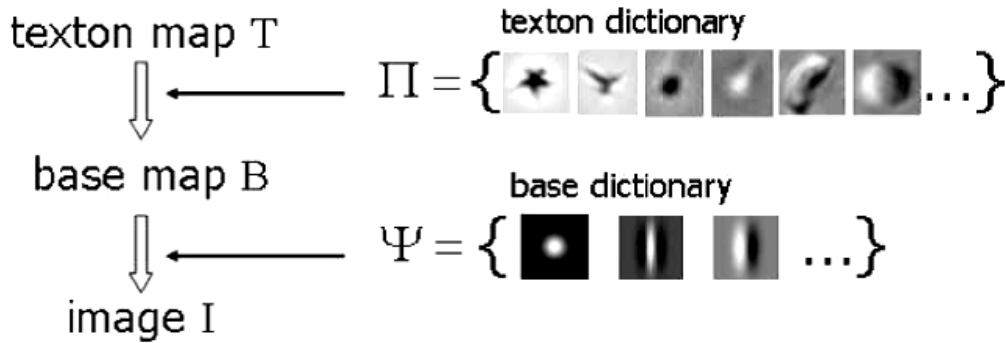
^۳ Over-complete dictionary

^۴ Texton Elements

^۵ Texton Map

شکل پذیر یا تغییرپذیر^۱ همانند ستاره، پرنده، دانه برف و امثال آن هستند، در نظر گرفته می‌شود (شکل ۲-۴).

یک نمایش یا شکل تکستونی^۲ ستاره مانند در شکل (۲-۴) نشان داده شده است. برای ساخت این تکستون، دو تابع پایه از یک دیکشنری پایه انتخاب می‌شوند. یکی از آنها دایره شکل بوده که می‌تواند یک تابع لاپلاسیین گوسی باشد و دیگری میله ای شکل است که می‌تواند یک تابع متقارن گابور باشد. این پایه‌ها، جابجا شده و بر روی هم برهم نهی می‌شوند تا یک تکستون ستاره شکل را تولید نمایند. با اعمال این مدل تولیدی بر روی تصاویر مشاهده شده، دیکشنری تکستونی بر اساس پارامترهای این مدل تولیدی ساخته می‌شود. حال می‌توان با مقایسه دیکشنری حاصل از یک تصویر با دیکشنری‌های متناظر با سایر تصاویر، تصاویر را با یکدیگر مقایسه نمود. به عنوان مثال در مرجع [۴۰]، نویسندگان از مدل تکستون به منظور بازیابی تصویر بر اساس محتوا^۳ استفاده نموده‌اند. در نهایت باید توجه داشت که انتخاب و طراحی توابع پایه، نقش بسیار مهمی در دقت و کارایی روش‌های مبتنی بر تکستون دارند.

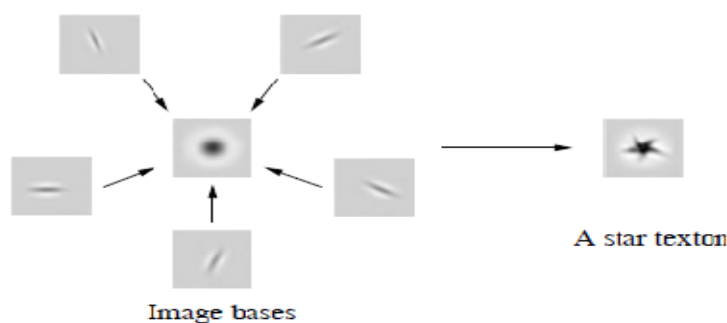


شکل (۲-۳): نمایش تکستونی یک مدل تولیدی سه لایه: یک تصویر I ترکیب خطی از تعدادی پایه تصویری است که از یک دیکشنری پایه Ψ که شامل خروجی فیلترهای گابور و لاپلاسیین می‌باشد. هر نقشه پایه خود از تعداد کمتری از تکستون‌ها تولید می‌شود که آنها از یک دیکشنری تکستون Π انتخاب می‌شوند [۳۹].

^۱ Deformable Geometric Configurations

^۲ Texton Configuration

^۳ Content Based Image Retrieval



شکل (۲-۴) : نحوه تولید یک شکل تکستونی ستاره مانند [۳۹].

۲-۲-۳ روش‌های مبتنی بر پردازش سیگنال^۱

در این بخش به معرفی بعضی از تکنیک‌های مبتنی بر پردازش سیگنال، جهت تشخیص عیوب می‌پردازیم. بعنوان یک مشخصه مشترک، اکثر روش‌های پردازش سیگنالی، یک بانک فیلتری^۲ را بر روی تصویر مورد نظر اعمال نموده و انرژی پاسخ‌های فیلترها را محاسبه می‌نمایند. این روش‌ها به سه دسته کلی حوزه مکانی^۳، حوزه فرکانسی^۴ و حوزه مکانی-فرکانسی^۵ تقسیم‌بندی می‌گردند. در ادامه به بررسی اجمالی هر یک از این دسته‌ها می‌پردازیم.

الف - حوزه مکانی و حوزه فرکانسی

اندازه‌گیری قدرت لبه^۶ یکی از اولین تلاش‌ها به منظور تمایز بین بافت‌های مختلف بوده است. در حوزه ابعادی یا مکانی، معمولاً تصاویر با فیلترهای گرادیان جهت استخراج لبه‌ها، خطوط، نقاط منفرد و غیره، فیلتر می‌شوند. از جمله این فیلترها می‌توان به فیلترهای سوبل^۷، روبرت^۸، و

^۱ Signal Processing Approaches

^۲ Filter Bank

^۳ Spatial Domain

^۴ Frequency Domain

^۵ Spatial-Frequency Domain

^۶ Edge Strength

^۷ Sobel

^۸ Robert

فیلترهای لاپلاسیان^۱، اشاره نمود. در مرجع [۴۱]، نویسندگان بانکی از تفاضلات آفست‌های توابع گوسی را برای مدل‌سازی بافت ارائه نموده‌اند. به اینصورت که هسته اصلی هر یک از این فیلترها توسط تفاضل دو تابع گوسی بدست می‌آید و مرکز هر یک از این دو تابع گوسی بوسیله بردار (dx, dy) ، جابه‌جا می‌گردد. در مرجع [۴۲]، فیلترهای ویژه^۲ جهت نمایش و توصیف بافت مطرح شدند شدند که این فیلترها از یک مجموعه از ماسک‌های بدست آمده از اعمال تبدیل KL [۴۳] بر روی پنجره‌های محلی تصویر^۴، ساخته می‌شوند.

در مرجع [۴۴]، از فیلترهای با پاسخ ضربه محدود (FIR) خطی جهت تشخیص عیوب در پارچه استفاده شده است. پاسخ‌های فیلتری نواحی سالم و همچنین معیوب، بدست آمده و سپس فیلترهای بهینه بر اساس آنالیز تمایزی^۵ توسط معیارهایی نظیر معیار فیشر^۶، انتخاب می‌گردند. در مرجع [۴۵]، از فیلترهای FIR با ابعاد 5×5 استفاده شده است و عملیات طبقه‌بندی عیوب بر اساس هیستوگرامی از ویژگی‌های استخراج شده از نواحی‌ای با ابعاد 10×10 ، انجام می‌گیرد.

در مرجع [۴۶] و اخیراً در مرجع [۱۵]، از فیلترهای ویژه جهت تشخیص عیوب استفاده شده است. نویسندگان در این دو مقاله نشان داده‌اند که برخلاف سایر اپراتورهای مکانی، فیلترهای ویژه، وابسته به تصویر هستند و تصاویر حاصله از فیلتر شدن توسط فیلترهای ویژه با یکدیگر عمود می‌باشند.

بسیاری از روش‌های دیگر، فیلترهای مورد نظر را در حوزه فرکانس اعمال نموده‌اند، بخصوص هنگامی که پیدا کردن یک هسته سر راست^۷ در حوزه مکان مشکل بوده است. در چنین مواردی، تصاویر به حوزه فوریه انتقال داده می‌شوند و سپس با توابع فیلتری ضرب می‌گردند و در نهایت نتیجه حاصله به

^۱ Laplacian

^۲ Eigenfilters

^۳ Karhunen-Loeve(KL)

^۴ Local Image Patches

^۵ Discriminant Analysis

^۶ Fisher

^۷ Straightforward Kernel

حوزه مکان بازگردانده می‌شود. بدین ترتیب از حجم محاسبات سنگین جهت انجام عملیات کانولوشن در حوزه مکان اجتناب می‌گردد. در مرجع [۴۷]، از ویژگی‌های توزیع توان^۱ همانند مقادیر ویژه طیف توان بمنظور تمایز بین بافت‌های مختلف استفاده شده است. در مرجع [۴۸]، نویسندگان از تبدیل فوریه به منظور تشخیص عیوب پارچه استفاده کرده‌اند. در این مقاله، الگوهای خطی در تصویر پارچه، بعنوان عیب در نظر گرفته شده است که با حذف مؤلفه‌های فرکانس بالا در حوزه فوریه با استفاده از تبدیل هاف^۲ یک بعدی، این عیوب حذف می‌گردند. سپس تفاضل بین تصویر اصلی و تصویر جدید، عیوب محتمل را آشکار می‌سازد. در مرجع [۴۹]، از ایده‌ای مشابه استفاده شده است. در این مقاله، از یک فیلتر پایین‌گذر برای حذف اطلاعات پریودیک و متناوب استفاده شده است. متأسفانه این روش‌ها از کارایی مناسب جهت بافت‌های تصادفی که فاقد نظم مشخصی می‌باشند برخوردار نیستند.

ب - حوزه توأم مکانی-فرکانسی

یک مشکل تبدیل فوریه، پایین بودن قدرت تحلیل مکانی^۳ آن می‌باشد، چرا که ضرایب فوریه بستگی به کل تصویر دارند. این در حالیست که در بسیاری از کاربردها نیاز است تا آنالیز مربوطه در حوزه مکان، محدود به یک ناحیه مشخص و خاص شود. بعبارت دیگر نتیجه آنالیز در هر موقعیت مکانی دلخواه حائز اهمیت می‌باشد. بعنوان مثال در کاربردهای تشخیص عیوب نیاز داریم تا موقعیت و مکان عیوب کاملاً مشخص گردند.

روش کلاسیک جهت وارد کردن اطلاعات مکانی به آنالیز فوریه، استفاده از تبدیل فوریه در پنجره‌های تصویر می‌باشد. اگر این پنجره گوسی باشد، آنگاه چنین تبدیل فوریه پنجره شده‌ای، تبدیل به فیلتر مشهور گابور می‌گردد که به طور قابل ملاحظه‌ای قابلیت موقعیت‌یابی^۴ به صورت بهینه، هم در حوزه مکان و هم در حوزه فرکانس را دارد [۵۰]. همانند روش‌های مبتنی بر فیلترهای گابور،

^۱ Power Distribution

^۲ Hough Transform

^۳ Spatial Resolution

^۴ Localization

روش‌های مبتنی بر تبدیل موجک نیز بطور وسیعی در مقالات مختلف مورد بررسی قرار گرفته‌اند [۵۱،۵۲،۵۳].

در این پایان‌نامه بنابر اهمیت استفاده از فیلترهای گابور و تبدیل موجک، در فصل ۳ به تفصیل به بحث در مورد آنها خواهیم پرداخت.

۲-۲-۴ روش‌های مبتنی بر مدل^۱

از میان بسیاری از روش‌های مبتنی بر مدل می‌توان به مدل‌های فرکتالی^۲ [۵۴]، مدل‌های میدان تصادفی^۳ [۵۵] و مدل اپیتومی^۴ [۵۶] اشاره نمود. در این بخش به معرفی مختصر این روش‌ها می‌پردازیم.

الف - مدل فرکتالی

با ملاحظه اشکال موجود در طبیعت، مشخص می‌شود که هندسه اقلیدسی قادر به تبیین و تشریح اشکال پیچیده و ظاهراً بی‌نظم طبیعی نیست. فرکتال‌ها که اولین بار توسط ماندلبرت^۵ [۵۴] معرفی شدند، شکل‌هایی هستند که بر خلاف شکل‌های هندسی اقلیدسی، به هیچ وجه منظم نمی‌باشند. این شکل‌ها اولاً سرتاسر نامنظم‌اند، ثانیاً میزان بی‌نظمی آنها در همه مقیاس‌ها یکسان است. جسم فرکتال از دور و نزدیک یکسان دیده می‌شود. به تعبیر دیگر خودمتمشابه^۶ است. وقتیکه به یک جسم فرکتال نزدیک می‌شویم، می‌بینیم که تکه‌های کوچکی از آن که از دور همچون دانه‌های بی‌شکلی به نظر می‌رسید، بصورت جسم مشخص در می‌آید که شکلش کم و بیش مثل همان شکلی است که از دور دیده می‌شود. در طبیعت نمونه‌های فراوانی از فرکتال‌ها دیده می‌شود. درختان، ابرها،

^۱ Model Based Approaches

^۲ Fractal Models

^۳ Random Field Methods

^۴ Epitome Model

^۵ Mandelbrot

^۶ Self-Similarity

کوه‌ها، رودها، لبه سواحل دریا، و گل‌کلم‌ها اجسام فرکتال هستند. اصل هندسه فرکتالی خود متشابه بودن است، بدین معنا که یک شیء خاص با اندازه‌های گوناگون، تکرار می‌شود.

بُعد فرکتالی، یکی از مهمترین ویژگی‌هایی است که بعنوان معیاری جهت اندازه‌گیری پیچیدگی و نامنظم بودن، در مدل فرکتالی مطرح می‌شود. یکی از روش‌های پر کاربرد در محاسبه بُعد فرکتالی، روش شمارش جعبه^۱ می‌باشد. در این روش سعی می‌شود که نمودار فرکتال توسط شبکه‌ای^۲ پوشش داده شود. این شبکه معمولاً از بهم پیوستن مربع‌هایی در فضای دو بعدی و ابر مکعب‌هایی در فضایی با ابعاد بیشتر بوجود می‌آید. این شبکه، $N \times N$ بوده که N نیز توانی از دو است. این روش بصورت بازگشتی عمل کرده و جعبه‌هایی که دارای نمودار هستند به چهار جعبه دیگر (در فضای دو بعدی) تقسیم می‌شوند. در نهایت نمودار لگاریتمی تعداد جعبه‌ها بر حسب طول جعبه‌ها رسم می‌شود. عکس شیب نمودار بدست آمده نشان دهنده ابعاد فرکتالی تصویر مورد مطالعه است. در مراجع [۵۷، ۵۸]، نویسندگان از مدل فرکتالی جهت بازبینی سطوح پارچه استفاده نموده‌اند.

ب- مدل میدان تصادفی

تئوری MRF^3 یک راه مناسب برای مدل‌سازی کمیت‌های وابسته به محیط اطراف خود^۴، نظیر پیکسل‌ها را از طریق تأثیرات متقابل بین آنها با استفاده از توزیعات شرطی^۵ MRF فراهم می‌سازد [۵۵]. در مرجع [۵۹] بین توزیع گیبس^۶ و MRF یک تناظر برقرار شده است و از آنجاییکه محاسبات محاسبات و آنالیز آماری توسط توزیعات گیبس به سادگی انجام می‌شود، لذا با استفاده از این تناظر می‌توان روش مناسبی جهت اعمال مدل‌های MRF بر روی تصاویر را پیدا نمود. از MRF ‌ها در

^۱ Box-Counting

^۲ Grid

^۳ Markov Random Field

^۴ Context Dependent Entities

^۵ Conditional Distribution

^۶ Gibbs Distributions

کاربردهای مختلفی نظیر ناحیه‌بندی تصاویر، ساخت مصنوعی بافت^۱، طبقه‌بندی بافت و بازیابی تصاویر استفاده شده است.

در مدل‌های MRF، یک تصویر بصورت یک شبکه^۲ مستطیلی محدود در نظر گرفته می‌شود که در آن هر پیکسل یک گره یا سایت را نشان می‌دهد. سایت‌های مجاور و همسایه، یک گروهک یا کلیک^۳ را تشکیل می‌دهند و روابط بین آنها در یک سیستم همسایگی^۴ مدل می‌شود. بر روی این کلیک‌ها یک تابع پتانسیل تعریف می‌گردد و از مجموع تک‌تک پتانسیل‌ها یک تابع انرژی برای کل تصویر حاصل می‌آید که با کمینه‌سازی آن قادر به رسیدن اهداف مورد نظر می‌باشیم. تئوری تناظر و برابری^۵ بین MRF و میدان‌های تصادفی گیبس (GRF) یک پایه‌ی اساسی را برای مشخص نمودن توزیعات توأم^۶ MRF فراهم می‌سازد. توزیعات مختلف دیگری را نیز می‌توان با استفاده از توابع پتانسیل گوناگون بدست آورد. توزیعاتی چون MRF گوسی (GMRF) [۶۰] و مدل فریم (FRAME) [۶۱] از دیگر گونه‌های مدل‌های میدان تصادفی می‌باشند.

در روش پیشنهادی در [۶۲]، تصاویر آزمون به تعدادی بلوک‌های غیرهمپوشان تقسیم‌بندی شده و هر بلوک بر اساس آماره‌های استخراج شده از نمونه‌های سالم با استفاده از GMRF جهت پیدا نمودن عیوب ممکن بازبینی می‌شود. در مرجع [۶۳]، نویسندگان نشان داده‌اند که روش‌های مبتنی بر MRF در مقایسه با سایر روش‌های آماری و طیفی در آشکارسازی عیوب، از کارایی نسبی برخوردار هستند.

^۱ Texture Synthesis

^۲ Lattice

^۳ Clique

^۴ Neighborhood System

^۵ Equivalence Theorem

^۶ Joint Distribution Function

ج - مدل اپیتومی^۱

اخیراً در مرجع [۵۶]، روشی جدیدی به نام مدل اپیتومی برای توصیف یک تصویر ارائه شده است. اپیتوم یک نمایش کوچک و فشرده از یک تصویر است که حاوی اشکال ابتدایی^۲ و عنصرهای بافتی^۳ می‌باشد. نگاشت از یک اپیتوم به پیکسل‌های اصلی (تصویر اصلی) بصورت مخفی می‌باشد و تصاویر متعددی می‌توانند با تغییر این نگاشت مخفی^۴ دارای یک اپیتوم مشترک باشند. در این مدل، مقادیر خام پیکسل‌ها جهت توصیف خصوصیات بافتی و رنگی تصاویر استفاده می‌شود و این در حالی است که در اکثر روش‌های کلاسیک از پاسخ فیلترها بدین منظور استفاده می‌گردد. اپیتوم‌ها توسط یک مدل تولیدی^۵ ساخته می‌شوند. در این مدل فرض می‌شود که پنجره‌های تصویر^۶، توسط ترکیب تعدادی از اپیتوم‌ها با کپی کردن مقادیر پیکسل‌های درون آنها به اضافه یک نویز گوسی تولید می‌شوند. بنابراین لازم است تا در فرآیند تولید اپیتوم‌ها، در یک مرحله آموزش، پنجره‌های تصویر در ابعاد مختلف آموزش داده شوند. شکل (۲-۵)، یک تصویر رنگی به همراه دو اپیتوم مربوط به آن از دو اندازه مختلف را نشان می‌دهد. با توجه به این شکل مشاهده می‌گردد که اپیتوم‌ها نمایش فشرده‌تری از محتوای تصویر می‌باشند. همچنین همانطور که از این شکل مشخص است، روابط مکانی بین پیکسل‌ها در نمایش اپیتومی در مقیاس‌های کوچکتر حفظ می‌گردد. بعنوان مثال، نواحی قرمز و آبی که در تصویر اصلی در مجاورت یکدیگر هستند، در نمایش اپیتومی نیز در کنار یکدیگر قرار می‌گیرند. هرچند که در مقیاس‌های کوچکتر، آنچه که در اپیتوم ۱۶×۱۶ این تصویر مشاهده می‌گردد، این نواحی تا حدی از یکدیگر جدا می‌شوند.

^۱ Epitome Model

^۲ Primitive Shapes

^۳ Texture Elements


^۴ Hidden Mapping

^۵ Generative


^۶ Image Patches



(ج)



(ب)



(الف)

شکل (۲-۵) : تصویر رنگی به همراه دو اپیتوم در اندازه‌های مختلف. (الف) تصویر اصلی، (ب) اپیتوم 32×32 و (ج) اپیتوم 16×16 آن [۵۶].

در مرجع [۵۶]، از مدل اپیتوم در ناحیه‌بندی بافت^۱، رفع نویز تصویر و پر کردن تصویر^۲ استفاده شده است. همچنین در مرجع [۶۴]، از اپیتوم‌ها جهت اندازه‌گیری میزان شباهت بین پیکسل‌ها و پنجره‌ها به منظور ناحیه‌بندی تصویر استفاده گردیده است.

۲-۳ روش‌های تشخیص عیوب بافت‌های تصادفی

همانطور که اشاره گردید، برخلاف بافت‌های منظم، تاکنون روش‌های اندکی جهت تشخیص عیوب در بافت‌های تصادفی ارائه گردیده است. در این بخش به بررسی جدیدترین و مهمترین روش‌های موجود در این زمینه می‌پردازیم.

در مرجع [۱۵]، روشی بر مبنای فیلترهای ویژه به منظور تمیز دادن بافت‌های تصادفی سالم از معیوب، بدون قابلیت موقعیت‌یابی دقیق عیوب، ارائه گردیده است. فیلترهای ویژه با اعمال آنالیز PCA^۳ [۴۳] بر روی همسایگی‌های با اندازه مختلف موجود در یک تصویر داده شده، بدست می‌آیند. عبارت دیگر، هر فیلتر ویژه یک بردار ویژه از مجموعه همسایگی‌های پیکسلی تشکیل دهنده تصویر اصلی می‌باشند. تعداد این فیلترها بر اساس نوع بافت به صورت تجربی تعیین می‌گردد. ایده حاکم بر

^۱ Texture Segmentation

^۲ Image Inpainting

^۳ Principle Component Analysis

این روش، بر اساس دو بار بازسازی^۱ تصویر آزمون می‌باشد: یکبار توسط فیلترهای ویژه تصویر آزمون و یکبار توسط فیلترهای ویژه مجموعه‌ای از تصاویر آموزشی سالم. میزان خطا و یا اختلاف بین این دو بازسازی، بعنوان معیاری جهت تشخیص معیوب بودن بافت استفاده می‌گردد. این روش بر روی بافت-های سطح خاکستری پیاده شده است [۱۵] و همانطور که اشاره گردید، فقط قادر به تشخیص معیوب بودن یک بافت بوده و اطلاعات دقیقی در مورد موقعیت و اندازه عیوب در اختیار قرار نمی‌دهد.

در مرجع [۱۴]، روشی جهت تشخیص عیوب بافت‌های تصادفی بر اساس آماره^۲ T^2 ارائه می‌گردد که این آماره از استراتژی آنالیز چند متغیره تصویر یا MIA^3 اقتباس شده است که در سال‌های اخیر در حوزه آمار کاربردی، توسعه بسیاری یافته است. در مرحله آموزش این روش، از آنالیز PCA برای استخراج یک فضای ویژه^۴ مرجع از یک ماتریس خاص موسوم به ماتریس داده استفاده می‌شود که عناصر این ماتریس، از آرایش و چیدمان خاصی از مقادیر سطح خاکستری پیکسل‌های موجود در همسایگی‌های درون مجموعه‌ای از تصاویر بدون عیب در سه کانال رنگی (R,G,B) به دست می‌آیند. این چیدمان، هم اطلاعات رنگی و هم اطلاعات مکانی پیکسل‌ها را به صورت توأم در نظر می‌گیرد. همچنین تعداد سطرهای این ماتریس برابر با تعداد همسایگی‌های بکار رفته بوده و تعداد ستون‌های آن سه برابر تعداد پیکسل‌های موجود در هر همسایگی می‌باشد. بعنوان مثال برای یک تصویر که شامل ۱۰ همسایگی 3×3 می‌باشد، اندازه این ماتریس برابر $10 \times (3 \times 9)$ خواهد بود. بدیهی است که برای همسایگی‌ها و همچنین تصاویر با ابعاد بالا، اندازه این ماتریس بسیار بزرگ بوده و در نتیجه حجم محاسبات بطور قابل ملاحظه‌ای افزایش می‌یابد. همچنین مقادیر کانال‌های رنگی هر یک از اعضای یک همسایگی به ترتیب ساعتگرد در یک سطر از ماتریس داده نگاشته می‌گردند.

با اعمال آنالیز PCA بر روی این ماتریس، یک فضای ویژه مرجع ساخته می‌شود. این فضای ویژه مرجع، در حقیقت رفتار نرمال پیکسل‌های موجود درون همسایگی بافت‌های سالم آموزش داده

^۱ Reconstruction

^۲ Statistics

^۳ Multivariate Image Analysis

^۴ Eigenspace

شده را مشخص می‌سازد. سپس به کمک این فضای ویژه، ماتریسی موسوم به ماتریس امتیاز^۱ ساخته می‌شود. با استفاده از عناصر این ماتریس، فاصله^۲ T^2 برای هر پیکسل محاسبه می‌گردد که این فاصله در حقیقت فاصله ماهالونوبیس^۲ بین تصویر^۳ هر پیکسل دلخواه در امتداد یکی از مؤلفه‌های اصلی این فضای ویژه و مرکز ثقل این مدل می‌باشد. در نهایت، هیستوگرام انباشته‌ای^۴ از این مقادیر T^2 ، ساخته شده و یک صدک^۵ ۹۰٪ یا ۹۵٪ بعنوان حد آستانه مجاز برای فواصل T^2 بافت‌های سالم محاسبه و ذخیره می‌شود. در مرحله آزمون نیز، ماتریس داده مذکور به شیوه‌ای مشابه با مرحله آموزش، از روی تصویر آزمون ساخته شده و سپس به فضای ویژه بدست آمده در مرحله آموزش، نگاشته می‌گردد. سپس برای هر پیکسل، فاصله^۲ T^2 محاسبه شده و با حد آستانه به دست آمده در مرحله آزمون مقایسه می‌شود. پیکسل‌هایی که فاصله^۲ T^2 آنها از این حد مجاز بیشتر باشد بعنوان پیکسل‌های معیوب علامت‌گذاری می‌گردند. متأسفانه حجم محاسبات این روش بسیار بالا گزارش شده است.

در مرجع [۱۳]، نویسندگان روش آماره^۲ T^2 را به منظور افزایش سرعت و کارایی، به کمک هیستوگرام فشرده‌ای از الگوهای باینری محلی تغییر داده‌اند. در این روش، تصویر اصلی به تعدادی بلوک با ابعاد مناسب تقسیم شده، سپس هیستوگرام فشرده^۶ الگوهای باینری محلی (LBP) آن بعنوان بعنوان ویژگی‌های بافتی آن بلوک، به همراه آماره‌های رنگی در هر سه کانال رنگی نظیر میانگین و واریانس بعنوان ویژگی‌های رنگی، استخراج شده و هر سطر از یک ماتریس داده^۴ X ، را تشکیل می‌دهند. تعداد سطرهای این ماتریس داده برابر تعداد همسایگی‌ها یا بلوک‌های موجود در تصویر می‌باشد. این بلوک‌ها می‌توانند با یکدیگر همپوشانی نیز داشته باشند. سپس روش آماره^۲ T^2 بر روی این ماتریس اعمال می‌گردد با این تفاوت که در این حالت، ماتریس داده به مراتب کوچکتر از ماتریس مورد استفاده در روش اصلی^۲ T^2 می‌باشد و لذا روش مذکور سریعتر خواهد بود. همچنین در این مقاله،

^۱ Score Matrix

^۲ Mahalanobis

^۳ Projection

^۴ Cumulative Histogram

^۵ Percentile

^۶ Compressed Histogram

روش خودکاری برای پیدا نمودن بهینه اندازه بلوک‌های تصویر، صدک مناسب و همچنین تعداد بهینه انباره‌های هیستوگرام LBP ارائه شده است.

روش پیشنهادی در مرجع [۱۷]، یک مدل تولیدی دو لایه است که توسط آن پایه‌های بافتی^۱ یک تصویر و یا مجموعه‌ای از تصاویر مرجع در قالب نماینده‌هایی از آن پیدا خواهند شد که به کمک آنها عملیات تشخیص عیوب در بافت‌های خصوصاً تصادفی، ساده‌تر خواهد شد. در این مدل فرض می‌گردد که تصاویر بافت‌های تصادفی و یا منظم در لایه اول، از مجموعه‌ای از پایه‌ها و نماینده‌های بافتی^۲ موسوم به TEXEMS ها در لایه دوم ساخته شده‌اند. سپس یک فرآیند تولیدی و پایین به بالا^۳ جهت تولید TEXEM ها بر اساس همسایگی پیکسل‌ها پیشنهاد می‌گردد. بدین طریق که تمامی همسایگی‌های موجود در تصویر از یک اندازه مشخص به یک فضای با ابعاد بالا نگاشته می‌شوند. سپس هر یک از این فضاها به چند کلاس محدود خوشه‌بندی می‌شوند که هر یک از این کلاس‌ها توسط یک مدل مخلوط گوسی مدل شده و پارامترهای این مدل توسط الگوریتم EM^۴ در چهارچوب قاعده بیز^۵ بدست می‌آیند. در نهایت میانگین و واریانس این مدل‌های مخلوط گوسی، بعنوان TEXEM در نظر گرفته می‌شود. بدین ترتیب، با فرض اینکه در مرحله ساخت و آموزش TEXEM ها، فقط از سه ابعاد همسایگی استفاده شده باشد، لذا در مجموع تعداد سه فضای با ابعاد بالا خواهیم داشت که هر فضا دارای TEXEM های مربوط به خود، با اندازه‌ای برابر با ابعاد همسایگی‌های آن فضا خواهد بود.

این آنالیز محلی تصویر با استفاده از TEXEM ها، به مجموعه‌ای از تصاویر خاکستری کاشی‌های سرامیکی اعمال می‌شود که در آن، اطلاعات سطح خاکستری به منظور تشخیص صحیح عیوب کفایت می‌کند. سپس این طرح به منظور اعمال بر تصویر رنگی نیز گسترش می‌یابد [۱۲]، که این امر منجر

^۱ Textural Primitive


^۲ Texture Exemplars (TEXEMS)

^۳ Bottom-Up

^۴ Expectation Maximization

^۵ Bayesian

به قاعده‌سازی‌ها^۱ و رویه‌های استنتاج مختلف و پیچیدگی‌های محاسباتی متفاوت می‌گردد. در این روش، تشخیص مکانی و همچنین دقت مکان‌یابی عیوب، بر روی دسته‌ای از تصاویر رنگی و خاکستری ارائه شده و با یکدیگر مقایسه می‌گردند. همچنین مدل TEXEMS، با مدل‌هایی نظیر آنالیزهای چند مقیاسی^۲ و فیلترهای گابور دو بعدی، جهت تشخیص عیوب بافت با یکدیگر مقایسه می‌شوند. در نهایت، روش پیشنهادی در قالب استراتژی تشخیص تمایزها^۳ پیاده‌سازی می‌گردد تا جهت تشخیص عیوب گوناگون که عمدتاً غیر قابل پیش‌بینی نیز هستند، از انعطاف‌پذیری برخوردار باشد. این مسئله، روش پیشنهادی را به منظور پیاده‌سازی صنعتی آماده می‌سازد. لازم به ذکر است که این روش، بسیار شبیه به روش مدل اپیتومی است که در بخش قبل به معرفی آن پرداختیم. همچنین این روش نسبت به روش آماره T^2 از سطح ریاضیاتی بالاتری برخوردار است. شکل (۲-۶)، نحوه تولید TEXEMها را برای تعدادی از تصاویر بافت‌های کاشی نشان می‌دهد.



شکل (۲-۶): توصیفی تصویری از فرآیند تولیدی دو لایه تگزم‌ها، از روی مجموعه‌ای از تصاویر آموزشی. تصاویر I به پنجره‌های Z شکسته شده که از روی آنها تگزم‌های M ساخته می‌شوند. بطور بالعکس، تصاویر I را می‌توان از برهم نهی و ترکیب تعدادی از تگزم‌های M بازتولید نمود [۱۲].

^۱ Formulation

^۲ Multiscale

^۳ Novelty Detection

فصل سوم

مبانی نظری

۳-۱ تبدیل موجک^۱

در این بخش ابتدا تاریخچه مختصری را در مورد پیدایش تبدیل موجک عنوان خواهیم نمود و سپس در بخش بعدی مقایسه بین تبدیل فوریه و تبدیل موجک و لزوم استفاده از این تبدیل را مورد بررسی قرار خواهیم داد. در نهایت هم به تحلیل آنالیز موجک در دو حوزه پیوسته و گسسته خواهیم پرداخت.

۳-۱-۱ مقدمه

ایده نمایش یک تابع برحسب مجموعه کاملی از توابع، اولین بار توسط ژوزف فوریه، ریاضیدان و فیزیکدان بین سال‌های ۱۸۰۲-۱۸۰۶ میلادی طی رساله‌ای در آکادمی علوم راجع به انتشار حرارت، برای نمایش توابع بکار گرفته شد. در واقع برای آنکه یک تابع $f(x)$ به شیوه‌ای ساده و فشرده نمایش داده شود، فوریه اساساً ثابت کرد که می‌توان از محورهای استفاده کرد که به کمک مجموعه‌ای نامتناهی از توابع سینوس وار ساخته می‌شوند. بعبارت دیگر فوریه نشان داد که یک تابع $f(x)$ را می‌توان بوسیله حاصل جمع بی‌نهایت تابع سینوسی و کسینوسی به شکل $\sin(ax)$ و $\cos(ax)$ نمایش داد. با گذشت زمان ضعف پایه‌های فوریه نمایان گردید، مثلاً دانشمندان پی بردند که پایه‌های فوریه و نمایش توابع سینوس‌وار در مورد سیگنال‌های پیچیده‌تری نظیر تصاویر، نه تنها ایده‌آل نیستند بلکه از شرایط مطلوب دورند. بعنوان مثال به شکل کارآمدی قادر به نمایش ساختارهای گذرا نظیر مرزهای موجود در تصاویر نمی‌باشند.

در سال ۱۹۰۹ هار اولین کسی بود که به موجک‌ها اشاره کرد. در سال ۱۹۸۰ ایومیر، ریاضیدان فرانسوی نخستین پایه‌های موجکی متعامد را کشف کرد (تعامد نوعی از ویژگی‌ها را بیان می‌کند که موجب تسهیلات فراوانی در استدلال و محاسبه می‌شود، پایه‌های فوریه نیز متعامدند). در سال ۱۹۷۶ میرو و مالت از پایه‌های موجک متعامد توانستند آنالیز چند تفکیکی را بسازند و مالت تجزیه

^۱ Wavelet Transform

موجک‌ها و الگوریتم‌های بازسازی را با بکار بردن آنالیز چند تفکیکی بوجود آورد. در سال ۱۹۹۰ مورنزی همراه با آنتوان موجک‌ها را به دو بعد و سپس به فضاهایی با ابعاد دیگر گسترش دادند و بدین ترتیب بود که آنالیز موجک پایه‌گذاری گردید.

۳-۱-۲ تبدیل فوریه و تبدیل موجک

بطور کلی می‌توان گفت که اگرچه تبدیل فوریه بعنوان قدیمی‌ترین ابزار تبدیل سیگنال‌ها، قادر به انتقال سیگنال دریافتی از حوزه زمان به حوزه فرکانس می‌باشد و رفتار سیگنال را بر حسب تغییرات فرکانس بیان می‌کند، ولی این تبدیل فاقد هر گونه اطلاعاتی در مورد زمان وقوع هر مؤلفه فرکانسی است. عبارتی، اطلاعات وابسته به زمان، به طور کامل حذف شده است. برای تصحیح این اشکال، فردی بنام دنیس گابور روشی را ابداع کرد که در آن تبدیل فوریه را فقط برای محدوده زمانی کوچکی از سیگنال به کار برد و آن را تبدیل فوریه^۱ زمان کوتاه نامید. این محدوده، پنجره زمانی نامیده شده است [۶۵]. در حقیقت تبدیل فوریه زمان کوتاه، همان تبدیل فوریه سیگنال پنجره شده است، به اینصورت که با شروع از ابتدای سیگنال، تابع پنجره در سیگنال ضرب شده و سپس تبدیل فوریه این سیگنال پنجره شده محاسبه می‌گردد و در مرحله بعد با حرکت پنجره مزبور در طول زمان سیگنال، تبدیل فوریه هر قسمت بطور جداگانه مورد محاسبه قرار می‌گیرد. در عین حال این تبدیل دارای محدودیتی چون ثابت بودن عرض پنجره است که منجر به عدم توانایی آن در طبقه‌بندی فرکانس‌هایی با طول زمانی متفاوت می‌شود.

تبدیل ویولت پیوسته^۲ بعنوان روشی جایگزین برای تبدیل فوریه زمان کوتاه ارائه گردید و هدف آن، فائق آمدن بر مشکلات مربوط به رزولوشن در تبدیل فوریه زمان کوتاه است. در آنالیز موجک، مشابه با تبدیل فوریه زمان کوتاه، سیگنال موردنظر در یک تابع موجک^۳ ضرب می‌شود که در حقیقت

^۱ Short Fourier Transform

^۲ Continuous Wavelet Transform

^۳ Wavelet Function

نقش همان تابع پنجره را دارد. همچنین به طور مشابه با قبل، تبدیل موجک نیز به طور جداگانه بر روی قطعه‌های زمانی مختلف سیگنال انجام می‌شود. اما ماهیتاً دو اختلاف عمده با تبدیل فوریه زمان-کوتاه دارد که عبارتند از:

۱. در تبدیل ویولت، از سیگنال پنجره شده، تبدیل فوریه گرفته نمی‌شود و بنابراین پیک‌های

منفرد متناظر با یک سینوسی، یا بعبارت دیگر فرکانس‌های منفی محاسبه نمی‌شود.

۲. در تبدیل موجک، عرض پنجره به موازات تغییر مؤلفه‌های فرکانسی تغییر می‌کند که به طور

حتم مهم‌ترین ویژگی موجک است.

بطور کلی در تبدیل موجک، امکان مشاهده اطلاعات فرکانسی و زمانی بطور توأم برقرار است.

همچنین در مقایسه با تبدیل فوریه می‌توان چنین عنوان کرد که، اگرچه تبدیل فوریه با تبدیل

سیگنال اولیه به مجموعه‌ای از سیگنال‌های سینوسی با فرکانس‌های مختلف خواص سیگنال را در یک

دوره زمانی به خوبی نشان می‌دهد، ولی در مورد سیگنال‌های غیرایستا^۱ که در یک دوره زمانی

تغییرات زیادی دارند، کاربردی ندارد. در حالی که تبدیل موجک برای این سیگنال‌ها هم پاسخ

مناسبی ارائه می‌دهد. از این رو تبدیل موجک بعنوان ابزاری نیرومندی در بیان خواص سیگنال‌ها، از

اهمیت ویژه‌ای برخوردار است.

۳-۱-۳ تبدیل موجک پیوسته

در آنالیز موجک همانند آنالیز فوریه با بسط توابع سروکار داریم، ولی این بسط برحسب

موجک‌ها انجام می‌شود. موجک تابع مشخص مفروضی با میانگین صفر است و بسط برحسب انتقال‌ها

و اتساع‌های این تابع انجام می‌گیرد. بر خلاف چند جمله‌ای‌های مثلثاتی، موجک‌ها در فضا بصورت

موضعی بررسی می‌شوند و به این ترتیب ارتباط نزدیکی بین بعضی توابع و ضرایب آن‌ها امکان‌پذیر

می‌شود و پایداری عددی بیشتری در بازسازی و محاسبات فراهم می‌گردد.

^۱ Non-Stationary

بر این اساس، تبدیل موجک پیوسته به صورت رابطه (۱-۳) تعریف می‌گردد:

$$CWT_x^\psi(a, b) = \int_{-\infty}^{\infty} f(x) \psi_{a,b}(x) dx \quad (1-3)$$

که با توجه به این معادله، موجک مادر^۱ که در حقیقت نقش همان تابع پنجره را ایفا می‌کند،

بصورت رابطه (۲-۳) تعریف می‌گردد:

$$\psi_{a,b}(t) = |a|^{-\frac{1}{2}} \psi\left(\frac{t-b}{a}\right) \quad (2-3)$$

که در آن a و b به ترتیب پارامترهای مقیاس^۲ و انتقال^۳ می‌باشند. مفهوم انتقال دقیقاً مشابه با مفهوم انتقال زمانی در تبدیل فوریه زمان کوتاه است که میزان جابجایی پنجره را معلوم می‌کند و به وضوح، اطلاعات زمانی تبدیل را در بردارد. اما برخلاف تبدیل فوریه زمان کوتاه، در تبدیل موجک به طور مستقیم پارامتر فرکانس نداریم. در عوض، پارامتر مقیاس را داریم که به طور معکوس با فرکانس ارتباط دارد. به عبارت دیگر $a = 1/f$. واژه ویولت به معنای موج کوچک است که در برخی ترجمه‌ها، ترجمه موجک برای آن آورده شده است. علت استفاده از واژه موج نیز به دلیل ماهیت نوسانی این تابع است. واژه مادر نیز به این منظور به کار برده می‌شود که تمامی نسخه‌های انتقال یافته و مقیاس شده، همگی از روی یک تابع اولیه بدست می‌آیند که اصطلاحاً موجک مادر نامیده می‌شود. به بیان علمی، موجک مادر یک تابع الگو^۴ جهت تولید سایر پنجره‌ها می‌باشد.

۳-۱-۴ تبدیل موجک گسسته^۵

به دلیل وجود اطلاعات زائد و اضافه‌ای که در تبدیل موجک پیوسته وجود دارد و منجر به افزایش بی دلیل بار محاسباتی می‌شود، لذا از تبدیل موجک گسسته که از لحاظ پیاده‌سازی بسیار ساده‌تر و بهینه‌تر است، استفاده می‌گردد. در حقیقت نسخه گسسته شده تبدیل موجک، یک سری

^۱ Mother Wavelet

^۲ Scaling

^۳ Translation

^۴ Prototype

^۵ Discrete Wavelet Transform

موجک است که از تبدیل موجک پیوسته نمونه برداری شده است. ایده اصلی این روش نیز مشابه تبدیل موجک پیوسته است که در آن نوعی توصیف زمان-مقیاس از سیگنال گسسته با استفاده از فیلترهای دیجیتال ارائه می‌گردد. همانطور که در بخش قبل مشاهده کردیم، برای محاسبه تبدیل موجک پیوسته، پنجره مورد نظر منقبض یا منبسط شده و شیفت می‌یابد و در هر موقعیت، از حاصلضرب آن در سیگنال، انتگرال زمانی گرفته می‌شود. در حالت گسسته، فیلترهایی با فرکانس قطع-های مختلف برای تحلیل سیگنال در مقیاس‌های متفاوت به کار برده می‌شود. با عبور سیگنال از فیلترهای بالاگذر و پائین‌گذر، فرکانس‌های مختلف آن تحلیل می‌گردد و رزولوشن سیگنال توسط عملکردهای فیلترها کنترل می‌شود و مقیاس‌ها از طریق انجام عملیات نمونه برداری کاهشی^۱ یا نمونه-برداری افزایشی^۲ تغییر می‌کنند.

در کاربردهای عملی، مستقیماً از روابط تبدیل موجک گسسته استفاده نمی‌شود، بلکه همانند تبدیل فوریه از الگوریتم تبدیل موجک سریع^۳ (FWT) به منظور پیاده‌سازی سریع و مؤثر تبدیل موجک گسسته (DWT)، استفاده می‌گردد. به همین منظور در ادامه به معرفی تبدیل موجک سریع خواهیم پرداخت. در حقیقت تبدیل موجک عبارتست از تجزیه یک سیگنال $f(t)$ به مجموعه‌ای از توابع موجک $\psi_{mn}(t)$ ، که از انتقال و تغییر مقیاس تابع $\psi(t)$ ، که تابع موجک مادر نامیده می‌شود بدست آمده‌اند (رابطه (۳-۳)).

$$\psi_{mn}(t) = 2^{-m/2} \psi(2^{-m}t - n) \quad (3-3)$$

که در آن m و n به ترتیب شاخص‌های مربوط به تغییر مقیاس و انتقال می‌باشند. تابع موجک

مادر از توابع مقیاس^۴ $\phi(t)$ طبق روابط (۳-۴) و (۳-۵) بدست می‌آید:

$$\phi(t) = \sum_{k=-\infty}^{+\infty} h_0(k) \sqrt{2} \phi(2t - k) \quad (4-3)$$

^۱ Downsampling

^۲ Upsampling

^۳ Fast Wavelet Transform

^۴ Scaling


$$\psi(t) = \sum_{k=-\infty}^{+\infty} h_1(k) \sqrt{2} \phi(2t-k) \quad (5-3)$$

که طبق آن $\phi(t)$ تابع مقیاس^۱، $\psi(t)$ تابع موجک^۲ و h_0 و h_1 به ترتیب فیلترهای پایین‌گذر و بالاگذر می‌باشند. بدین ترتیب بسط تابع $f(t)$ بر حسب توابع $\phi(t)$ و $\psi(t)$ بصورت رابطه (۶-۳) است.

$$f(t) = \sum_k c_j(k) 2^{j/2} \phi(2^j t - k) + \sum_k d_j(k) 2^{j/2} \psi(2^j t - k) \quad (6-3)$$

که در آن c_j و d_j به ترتیب ضرایب تخمین^۳ و ضرایب جزئیات^۴، در مقیاس j ام می‌باشند. بسط فوق را تبدیل موجک تابع $f(t)$ نامیده می‌شود.

برای تجزیه یک سیگنال به مولفه‌های تبدیل موجک، یعنی ضرایب تخمین و جزئیات، از بانک فیلتر شکل (۱-۳) استفاده می‌شود.



شکل (۱-۳): فرآیند تجزیه سیگنال به ضرایب موجک با استفاده از فیلترهای تجزیه h_0 و h_1 .

علامت $\downarrow 2$ نشان دهنده فرآیند نمونه‌برداری کاهش^۵ می‌باشد که در ضمن آن تعداد نمونه‌های موجود در سیگنال، به نصف کاهش می‌یابد. و h_0 و h_1 به ترتیب بیانگر فیلترهای تجزیه پایین‌گذر^۶ و بالاگذر^۷ می‌باشند. همانگونه که مشاهده می‌شود، خروجی این بانک فیلتر شامل دو مولفه است:

^۱ Scaling Function

^۲ Wavelet Function

^۳ Approximation Coefficient


^۴ Detail Coefficient

^۵ Down sampling

^۶ Decomposition low-pass filter

^۷ Decomposition high-pass filter

- مولفه c_j در برگیرنده اطلاعات با فرکانس پایین (خروجی فیلتر پایین گذر) یا ضریب تخمین.
 - مولفه d_j در برگیرنده اطلاعات با فرکانس بالا (خروجی فیلتر بالاگذر) یا ضریب جزئیات.
- همچنین عکس فرآیند ذکر شده را می‌توان با در دست داشتن ضرایب جزئیات و تخمین، بصورت شکل (۲-۳) نمایش داد که خروجی آن، همان سیگنال اولیه است. h_0 و h_1 به ترتیب بیانگر فیلترهای بازسازی پایین‌گذر^۱ و بالاگذر^۲ می‌باشند و همچنین علامت $\uparrow 2$ نشان‌دهنده عملیات نمونه-برداری افزایشی^۳ است.



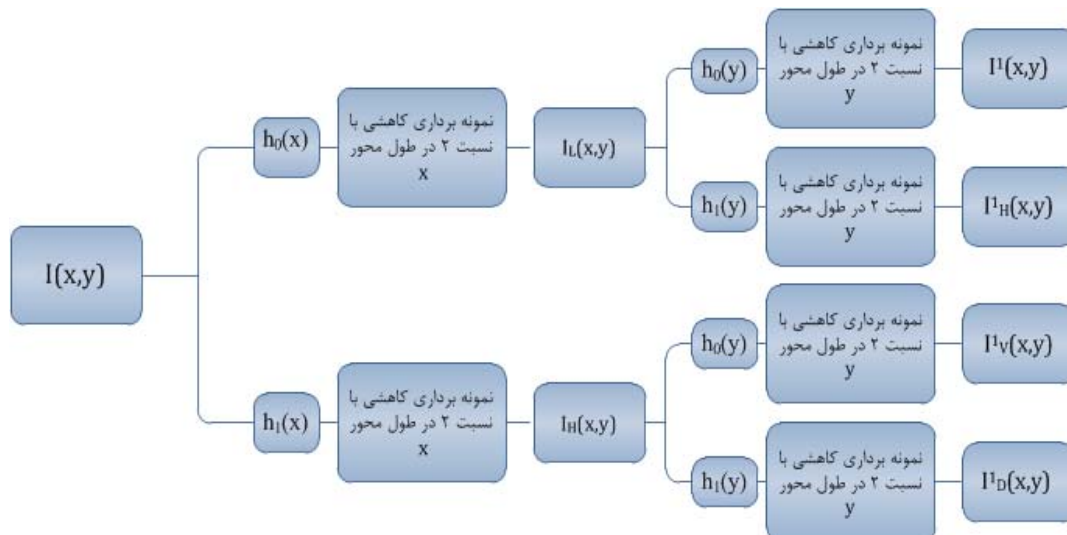
شکل (۲-۳): فرآیند بازسازی سیگنال بر اساس ضرایب موجک.

برای اعمال تبدیل موجک بر تصاویر، از تبدیل موجک دو بعدی استفاده می‌گردد. بدین منظور تبدیل موجک یک بعدی به ترتیب یکبار بر روی سطرها و بار دیگر بر روی ستون‌های ماتریس تصویر اعمال می‌شود تا از ترکیب مولفه‌های این دو تبدیل، ضرایب تبدیل موجک دو بعدی بدست آید. این فرآیند در شکل (۳-۳) نشان داده شده است.

^۱ Reconstruction low-pass filter

^۲ Reconstruction high-pass filter

^۳ Upsampling




شکل (۳-۳): فیلتر بانک تبدیل موجک یک تصویر در مقیاس اول.

در این شکل، تصویر اولیه در راستای x (سطرها) از یک فیلتر پایین‌گذر و یک فیلتر بالاگذر عبور نموده و نمونه‌برداری کاهشی می‌شود. در پایان این مرحله، دو تصویر حاصل می‌شود که یکی شامل فرکانس‌های پایین تصویر $I_L(x,y)$ و دیگری شامل فرکانس‌های بالای تصویر $I_H(x,y)$ می‌باشد. در مرحله بعدی، هر یک از این دو تصویر در راستای y (ستون‌ها) از یک فیلتر پایین‌گذر و یک فیلتر بالاگذر عبور نموده و نمونه‌برداری کاهشی می‌شوند. در نتیجه چهار زیر تصویر حاصل می‌شود که عبارتند از:


- مولفه $I^1(x,y)$ متناظر است با مولفه فرکانس پایین تصویر (ضریب تخمین).
- مولفه $I^H(x,y)$ شامل جزئیات در راستای افقی تصویر است.
- مولفه $I^V(x,y)$ شامل جزئیات در راستای عمودی تصویر است.
- مولفه $I^D(x,y)$ نیز جزئیات در راستای قطری را شامل می‌شود.

به این ترتیب امکان آنالیز تصویر در سه راستای مختلف بدست می‌آید. همچنین می‌توان این فیلتر بانک را در مقیاس‌های بالاتر و سطوح مختلف هم بکار برد، به اینصورت که با هر بار عبور از این فیلتر بانک، یک مقیاس بالاتر از تبدیل موجک گسسته دو بعدی ایجاد می‌گردد. بعنوان مثال بلوک دیاگرام تجزیه دو بعدی تبدیل موجک گسسته در دو سطح، در شکل (۴-۳) نشان داده شده است.



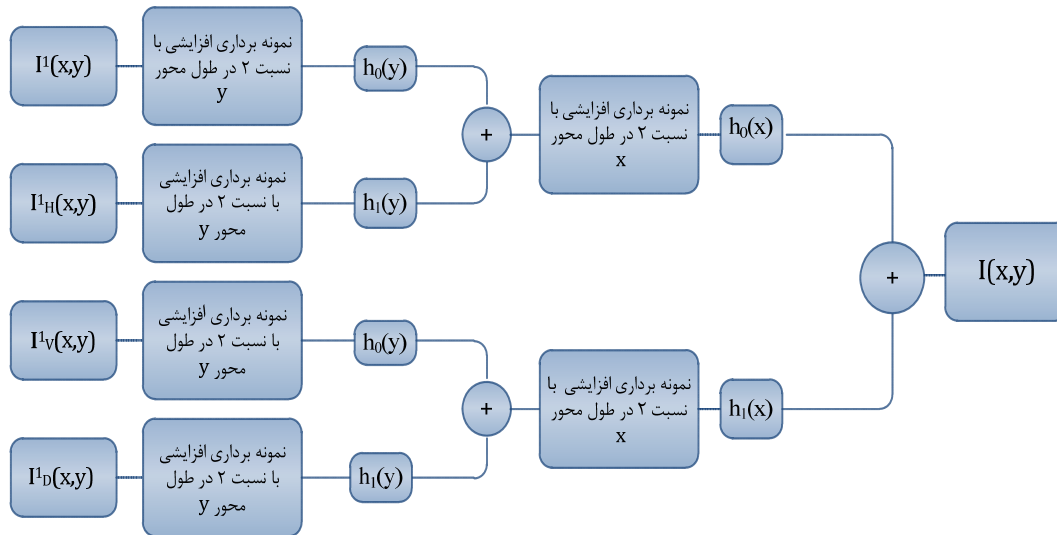
شکل (۳-۴): بلوک دیاگرام تجزیه دو بعدی تبدیل موجک گسسته یک تصویر در دو سطح.

مؤلفه‌های تبدیل موجک بافت یک کاشی، در یک و دو سطح مقیاس همانند الگوریتم شکل (۳-۴)، در شکل (۳-۵) نشان داده شده است.



شکل (۳-۵): تبدیل موجک تصویر یک کاشی در یک و دو مقیاس. (الف) تصویر اصلی، (ب) مؤلفه‌های تبدیل موجک در مقیاس اول، (ج) مؤلفه‌های تبدیل موجک در مقیاس دوم.

علاوه بر فرآیند نمایش داده شده در شکل (۳-۳)، یعنی تجزیه یک سیگنال دو بعدی همچون تصویر دیجیتال، به ضرایب تبدیل موجک در سطوح مختلف، می‌توان عکس فرآیند ذکر شده یعنی بازسازی یک سیگنال دو بعدی را از ضرایب تبدیل موجک آن بصورت شکل (۳-۶) نشان داد.



شکل (۳-۶): فرآیند بازسازی سیگنال دو بعدی، از ضرایب تبدیل موجک.

همانطور که اشاره شد، یکی از کاربردهای متداول تبدیل موجک، پردازش اطلاعات تصاویر دودویی است. در همین راستا استفاده از تبدیل موجک بعنوان یک روش تحلیل چند تفکیکه برای توصیف بافت، نخستین بار توسط ملات^۱ پیشنهاد شد [۶۶]. مزیت استفاده از روش‌های چندتفکیکه از دیدگاه مکان-فرکانس، در حداکثرسازی تمرکز همزمان انرژی در هر دو حوزه مکان و فرکانس می-باشد [۶۷].

همانطور که از شکل (۳-۵) مشخص است، ناحیه آلوده در تصویر اصلی که در شکل (۱-۵) نشان داده شده است، در مقیاس‌های اول و دوم، در قسمت مؤلفه‌های عمودی، به خوبی از سایر نقاط متمایز گردیده است، که این خود مبین آن است که تبدیل موجک می‌تواند ابزار مناسبی جهت تشخیص نواحی آلوده در بافت یک تصویر باشد.

^۱ Mallat

۳-۲ فیلتر گابور^۱

در آغاز دهه ۱۹۶۰ مشاهده شد که بیشتر سلول‌های گیرنده سیستم بینایی میمون‌ها و گربه‌ها به لبه‌ها و خطوطی با جهت خاص، و موقعیت مشخصی از میدان بینایی، پاسخ می‌دهند [۶۸]. بعد از آن بود که مدل‌های محاسباتی به کمک شبیه‌سازی عملکرد این سلول‌ها توسعه یافتند. این مدل‌های محاسباتی، اصول لازم برای الگوریتم‌های آشکارسازی لبه و آنالیز بافت‌نشأت گرفته از بیولوژیک، در پردازش تصویر را مهیا می‌کنند. بویژه، خانواده‌ای از توابع گابور دو بعدی، بعنوان مدلی از خواص فیلترسازی خطی این سلول‌ها، پیشنهاد شده است [۶۸]. در رابطه با آنالیز بافت، اینطور می‌توان عنوان کرد که، چون دوره تناوب، جهت و پیچیدگی سه ویژگی مهم بافت‌ها هستند که باعث می‌شود انسان بتواند با چشم خود بافت‌های مختلف را از یکدیگر تفکیک کند، لذا برای طراحی الگوریتم‌های تفکیک بافت در تصاویر، ایده‌هایی مبنی بر سیستم ادراک بصری انسان، که بر پایه تمیز ویژگی‌های یاد شده استوار می‌باشد، ارائه شده است. یکی از مدل‌های مبتنی بر آنالیز بافت توسط انسان، براساس فیلتر کردن تصویر، از چند کانال مجزا بوسیله فیلترهای میان‌گذر می‌باشد. زیرا سلول‌های قشری بینایی^۲ به چند کانال، مرکب از فرکانس‌های متفاوت در جهات مختلف حساس می‌باشند. از آنجا که پیوند و جهت بافت‌ها را می‌توان به ترتیب با فرکانس و زاویه چرخش توصیف نمود، می‌توان سیستم ادراک انسان را با یک عملیات فیلتر کردن چند کاناله در باندهای مختلف فرکانسی و جهات مختلف برای تمیز بافت‌های مختلف از یکدیگر پیاده‌سازی نمود. برای این منظور می‌توان از تابع گابور استفاده نمود که در آن انتخاب باند فرکانسی و انتخاب زاویه، بطور دلخواه امکان‌پذیر می‌باشد.

بنابراین در کاربردهای مختلف بینایی کامپیوتر^۳ از قبیل آنالیز بافت و آشکارسازی لبه^۴، توابع گابور بطور وسیعی مورد استفاده قرار گرفته‌اند. فیلترهای گابور در صورتیکه به طور مناسب و دقیق

^۱ Gabor Filter

^۲ Simple cell in the visual cortex

^۳ Computer Vision

^۴ Edge Detection

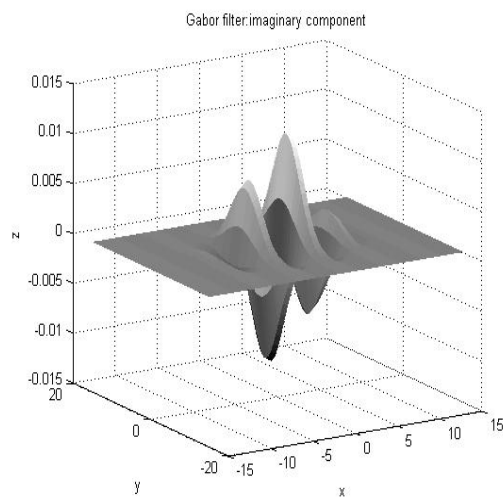
تنظیم شوند، عملکرد بسیار مناسبی در تشخیص ویژگی‌ها و لبه‌بافت‌ها دارند. از آنجا که پیوند و جهت بافت را می‌توان به ترتیب با فرکانس و زاویه چرخش فیلترهای میان‌گذر توصیف نمود، برای استخراج ویژگی‌های بافت از فیلترهای گابور استفاده می‌شود که در آن انتخاب فرکانس و زاویه امکان‌پذیر است. ویژگی دیگر فیلترهای گابور درجه تفکیک مشترک بالای آنهاست. این بدان معنی است که پاسخ آنها هم در حوزه مکان و هم در حوزه فرکانس کاملاً محلی و قابل تنظیم کردن می‌باشد. در واقع نقطه قوت فیلترهای گابور در این است که امکان فیلتر کردن تصویر ورودی را در باندهای فرکانسی مختلف و در جهت‌های گوناگون بخوبی فراهم می‌کند.

تابع گابور دو بعدی در حوزه مکان، عبارتست از یک تابع گوسی مدوله شده با یک تابع سینوسی

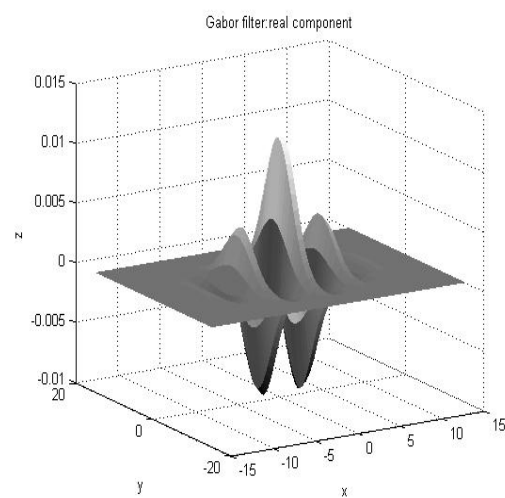
مختلط، که بصورت رابطه (۷-۳) تعریف می‌شود [۴۴]:

$$g(x, y) = \frac{1}{2\pi\delta_x\delta_y} \exp\left[-\frac{1}{2}\left(\frac{x^2}{\delta_x^2} + \frac{y^2}{\delta_y^2}\right)\right] \cdot \exp[j2\pi(Wx)] \quad (7-3)$$

که در آن W فرکانس تابع سینوسی در مختصات کارتیزین، و δ_x و δ_y به ترتیب انحراف معیارهای پوش تابع گوسی در راستای x و y می‌باشند. شکل (۷-۳) نشان‌دهنده قسمت حقیقی و موهومی تابع گابور دو بعدی، در نمای سه بعدی می‌باشد.



(ب)



(الف)

شکل (۷-۳): قسمت حقیقی (الف) و قسمت موهومی (ب) تابع گابور دو بعدی.

همچنین می‌توان پاسخ فرکانسی تابع گابور را بصورت معادله (۸-۳) بیان نمود:

$$G(u, v) = \exp \left[-\frac{1}{2} \left(\frac{(u - W)^2}{\delta_u^2} + \frac{v^2}{\delta_v^2} \right) \right] , \quad \delta_u = \frac{1}{2\pi\delta_x} , \quad \delta_v = \frac{1}{2\pi\delta_y} \quad (۸-۳)$$

در این پایان‌نامه از گونه‌ای از فیلترهای گابور موسوم به موجک گابور^۱ استفاده می‌شود که در ادامه به معرفی آن خواهیم پرداخت. در این بررسی منظور از موجک گابور، بانکی از فیلترهای گابور نرمالیزه شده است که بگونه‌ای طراحی شده‌اند که نمایش آنها، درجهٔ افزونگی^۲ پایینی را شامل شود. فیلتر موجک گابور در زمینه‌های مختلف برای پردازش تصاویر بکار گرفته می‌شود. از جمله کاربردهای آن می‌توان به آشکارسازی عیب‌های موجود در میوه، عیب‌های موجود در کاشی، بخش‌بندی تصاویر، کلاسه‌بندی تصاویر و غیره اشاره کرد. نکته قابل توجه اینست که برای کاربردهای متفاوت، تعاریف متعددی نیز از این فیلتر برای برآورده کردن هدف مورد نظر انجام شده است، اما تقریباً اساس همگی آنها ثابت است. این فیلتر با ترکیب دو روش فیلترهای گابور و آنالیز ویولت بدست می‌آید.

هر گاه $g(x, y)$ را بتو ان یک موجک گابور مادر در نظر گرفت، آنگاه خانوادهٔ موجک‌های گابور یا بانکی از فیلترهای گابور^۳، از طریق انبساط^۴ و چرخش^۵ موجک گابور مادر $g(x, y)$ ، مطابق رابطه (۹-۳) بدست می‌آیند:

$$\begin{aligned} g_{mn}(x, y) &= \alpha^{-m} g(\tilde{x}, \tilde{y}) \\ \tilde{x} &= \alpha^{-m} (x \cos \theta + y \sin \theta) \\ \tilde{y} &= \alpha^{-m} (-x \sin \theta + y \cos \theta) \\ m &= 0, 1, 2, \dots, M-1 \quad , \quad n = 0, 1, 2, \dots, N-1 \\ \theta &= \frac{n\pi}{N} \end{aligned} \quad (۹-۳)$$

که در آن g_{mn} ، فیلتر انبساط و چرخش یافته از فیلتر مادر $g(x, y)$ است. m و n به ترتیب اشاره‌گرهای مربوط به مقیاس و چرخش می‌باشند. همچنین M بیانگر تعداد کل مقیاس‌ها و N تعداد کل جهت‌ها

^۱ Gabor Wavelet

^۲ Redundancy

^۳ Bank Filter

^۴ Scale

^۵ Orientation

را نشان می‌دهد. تعداد جهت‌ها و مقیاس‌ها در کاربردهای متفاوت، متغیر است و انتخاب دقیق آنها برای رسیدن به هدف مورد نظر بسیار مهم است. تاکنون روش منظم و قانونمندی برای انتخاب تعداد جهت‌ها و مقیاس‌ها ارائه نشده است و تقریباً تمامی انتخاب‌ها با روش آزمون و خطا و بصورت تجربی انجام می‌شود. ضریب α^{-m} به این منظور بکار رفته است که از مستقل بودن انرژی $g_{mn}(x,y)$ نسبت به m اطمینان حاصل شود. بنابراین تمامی فیلترها در بانک فیلتر گابور دارای انرژی یکسانی هستند.

عدم تعامد موجک‌های گابور موجب افزونگی می‌شود. بنابراین برای اینکه خروجی فیلترها دارای حداکثر اطلاعات مفید و حداقل اطلاعات زائد باشند، از روشی که در ادامه به معرفی آن خواهیم پرداخت برای طراحی استفاده می‌شود [۶۹].

فرض می‌کنیم U_l و U_h به ترتیب پایین‌ترین و بالاترین فرکانس‌های مرکزی بانک فیلتر مورد نظر باشند و W_{mn} ، فرکانس مرکزی هر کدام از فیلترهای بانک فیلتر، با مقیاس m و جهت n باشد. در اینصورت ساختار ایجاد فیلتر بانک بصورت روابط (۱۰-۳) خواهد بود:

$$W_{mn} = \alpha^m U_l$$

$$\alpha = \left(\frac{U_h}{U_l} \right)^{\frac{1}{M-1}}$$


$$\delta_{x, mn} = \frac{(\alpha + 1)\sqrt{2 \ln 2}}{2\pi\alpha^m (\alpha - 1)U_l} \quad (10-3)$$

$$\delta_{y, mn} = \frac{1}{2\pi \tan\left(\frac{2\pi}{N}\right) \sqrt{\frac{U_h^2}{2 \ln 2} - \left(\frac{1}{2\pi\delta_{x, mn}}\right)^2}}$$


که با توجه به ساختار بالا، می‌توان با تنظیم پارامترهای U_l و U_h و M و N ، بانک فیلتر مورد نظر را طراحی نمود. بعنوان نمونه شکل (۸-۳)، مجموعه‌ای از موجک‌های گابور یک بانک فیلتر را در مختصات فرکانسی^۱ و مکانی^۲ نشان می‌دهد.

^۱ Frequency Domain

^۲ Spatial Domain



(الف)



(ب)

شکل (۳-۸): موجک‌های گابور یک بانک فیلتر، با ۴ مقیاس و ۶ جهت، (الف) در مختصات فرکانسی $[70]$ و (ب) مختصات مکانی.

با توجه به شکل (۸-۳) مشخص است که در مجموع از ۲۴ فیلتر برای طراحی بانک فیلتر استفاده شده است که پارامترهای تنظیم آن عبارت اند از: $U_l = 0/05$ ، $U_h = 0/4$ ، $M = 4$ و $N = 6$. همچنین لازم به ذکر است که هر کدام از بیضی‌ها در مختصات فرکانسی بیانگر دامنه نیم پیک پاسخ فیلترها با جهت و مقیاس مشخصی در بانک فیلترهای گابور می‌باشند.

در نهایت، نتیجه اعمال فیلتر $g_{mn}(x,y)$ به تصویر $T(x,y)$ ، بصورت رابطه (۱۱-۳) می باشد.

$$h^T_{mn}(x,y) = \sum_s \sum_t T(x-s, y-t) g^*_{mn}(s,t) \quad (11-3)$$

طبق این فرآیند، هر کدام از تصاویر بدست آمده از اعمال بانک فیلتر، بصورت مجموعه‌ای از پاسخ‌ها که به فرم $H^T = \{h^T_{mn}, m=1,2,\dots,M, n=1,2,\dots,N\}$ نشان داده می‌شوند، شامل اطلاعات تصویر، در مقیاس و جهت مشخصی می‌باشند.

استفاده از این روش طراحی، برای موجک‌های گابور، بطور گسترده‌ای در ناحیه‌بندی بافت^۱ [۷۱]، شناسایی الگو^۲ [۷۲]، تشخیص چهره^۳ [۷۳]، و تشخیص نواحی معیوب در اجسام دارای بافت [۷۴]، گزارش شده است.

در شکل (۹-۳) نمونه‌ای از اعمال بانک فیلتر گابور، بر روی تصویر یک کاشی آورده شده است. در این شکل، طراحی بانک فیلتر گابوری که به تصویر بافت یک کاشی اعمال می‌شود به اینصورت است که، دارای ۴ مقیاس ($M=4$) و ۶ جهت ($N=6$) می‌باشد و در مجموع متشکل از ۲۴ فیلتر است که پایین‌ترین و بالاترین فرکانس‌های مرکزی این بانک فیلتر به ترتیب با $U_l=0/1$ و $U_h=0/4$ تنظیم شده‌اند. در فصول بعدی از روش طراحی فوق‌الذکر بعنوان یکی از مراحل روش پیشنهادی جهت تشخیص نواحی معیوب، استفاده می‌گردد.

^۱ Texture segmentation

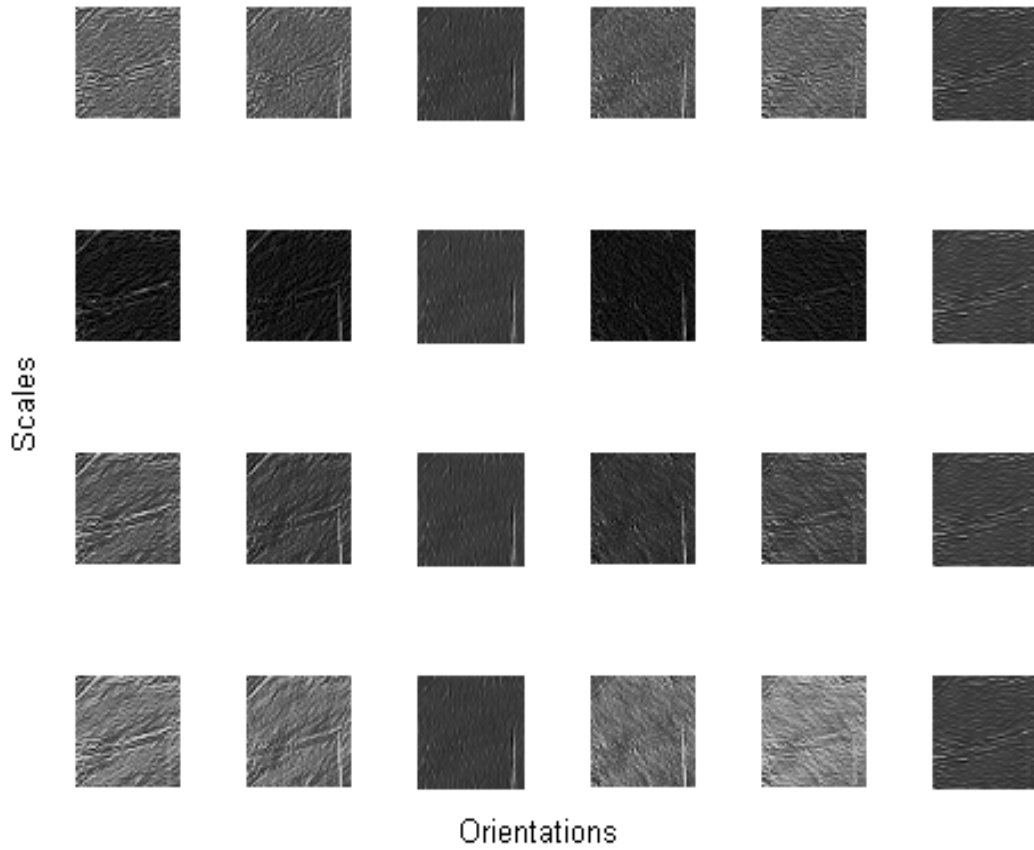
^۲ Pattern recognition

^۳ Face recognition



(الف)

Gabor Wavelet With 4 Scales And 6 Orientations



(ب)

شکل (۳-۹): اعمال بانک فیلتر موجک گابور به تصویر کاشی در چهار مقیاس ($M = 4$) و شش جهت ($N = 6$). (الف) تصویر اصلی، (ب) نتیجه اعمال بانک فیلتر گابور بر روی بافت کاشی.

۳-۳ مدل مخلوط گوسی^۱

مدل مخلوط گوسی (GMM) یک تابع چگالی احتمال پارامتریک می‌باشد که از مجموع وزنی تعدادی تابع چگالی گوسی جزء، بدست می‌آید، و به همین دلیل به آن مدل مخلوط گوسی گفته می‌شود. GMM یک روش خوشه‌بندی بدون نظارت^۲، بر اساس فرض توزیع گوسی داده‌های ورودی^۳، می‌باشد. همچنین لازم به ذکر است که در مسائل مربوط به شناسایی آماری الگو، منظور از خوشه، مجموعه‌ای از داده‌ها است که به علت شباهت زیادی که به هم دارند، در یک دسته قرار گرفته‌اند. در خوشه‌بندی سعی بر آن است مجموعه‌ای از داده‌ها، به صورت بدون ناظر به خوشه‌هایی تقسیم گردند که شباهت داده‌های درون هر خوشه حداکثر، و شباهت بین داده‌های درون خوشه‌های مختلف حداقل گردد. تقریباً همانند تحلیل فوریه که با بسط سیگنال‌های سینوسی، سیگنال را بهتر توصیف می‌کند، مدل مخلوط گوسی نیز می‌تواند با ترکیب چند متغیره گوسین‌ها، تمام اطلاعات را به طور خلاصه در فضا نمایش دهد. مدل مخلوط گوسی توانایی قابل قبولی در مدل کردن داده‌های نامنظم دارد. این ویژگی باعث شده است تا امروزه بعنوان ابزار اصلی در سیستم‌های بازشناسی گوینده مورد استفاده قرار بگیرد و همچنین بعنوان سیستم مبنا در بسیاری از مدل‌های هیبرید و نیز در بسیاری از آزمایشات بیومتریک، بعنوان مدل مرجع جهت مقایسه از آن استفاده می‌شود [۷۵].

همانطور که گفته شد، تابع چگالی مخلوط گوسی از مجموع وزندار K توزیع گوسی مطابق

رابطه (۱۲-۳) بدست می‌آید.


$$p(\bar{x} | \psi) = \sum_{i=1}^K g(\bar{x} | \mu_i, \Sigma_i) \alpha_i \quad (12-3)$$

که می‌توان آنرا بصورت شماتیک مطابق شکل (۱۰-۳) نمایش داد.

^۱ Gaussian Mixture Model

^۲ Unsupervised Clustering

^۳ Input Data




شکل (۳-۱۰): بلوک دیاگرام تشکیل مدل مخلوط گوسی.

با توجه به معادله (۳-۱۲)، \bar{x} بردار ویژگی D بُعدی و α_i ، $(i=1,2,\dots,k)$ ، وزن مخلوط \bar{x} و $g(\bar{x} | \mu_i, \Sigma_i)$ بیانگر یک جزء چگالی مخلوط گوسی با میانگین μ_i و ماتریس کوواریانس Σ_i ، $(i=1,2,\dots,k)$ می باشد. هر جزء چگالی، یک تابع گوسی D بُعدی است که بصورت رابطه (۳-۱۳) تعریف می گردد:

$$g(\bar{x} | \mu_i, \Sigma_i) = \frac{1}{(2\pi)^{D/2} |\Sigma_i|^{1/2}} \exp\left\{-\frac{1}{2}(\bar{x} - \mu_i)^T \Sigma_i^{-1} (\bar{x} - \mu_i)\right\} \quad (۳-۱۳)$$

همچنین وزن مخلوطها باید شرط $\sum_{i=1}^K \alpha_i = 1$ را برآورده نماید تا اینکه چگالی مخلوط گوسیها $p(\bar{X} | \psi)$ ، شرایط تابع چگالی احتمال را دارا باشد. بنابراین مدل GMM را می توان توسط پارامترهای بردار میانگین، ماتریس کوواریانس و وزنهای هر چگالی مخلوط جزء، تعریف نمود و هدف یافتن این پارامترها $(\psi = \{\alpha_i, \mu_i, \Sigma_i\}_{i=1}^K)$ می باشد. مدل مخلوط گوسی بسته به نوع ماتریس کوواریانسش، می تواند چندین نوع داشته باشد. اگر ماتریس کوواریانس کامل باشد، مدل گوسی، کامل نامیده می شود. می توان ماتریس کوواریانس را بصورت یک ماتریس قطری در نظر گرفت و همچنین می توان از یک ماتریس مشترک برای تمام مخلوطها استفاده نمود [۷۶]. همچنین در این مدل، انتخاب تعداد مخلوطهای گوسی (K)، وابسته به تعداد داده های آموزشی است. عبارت دیگر تعداد

مخلوط‌های گوسی بایستی به اندازه‌ای باشد که با تعداد داده‌های آموزشی موجود بتوان پارامترهای آن را تخمین زد. شکل (۱۱-۳) مثالی از مدل مخلوط گوسی ۱ بُعدی با ۳ جزء گوسی را نشان می‌دهد.



شکل (۱۱-۳): مدل مخلوط گوسی ۱ بُعدی همراه با ۳ جزء مخلوط.

جهت تخمین پارامترهای مدل گوسی $(\psi = \{\alpha_i, \mu_i, \Sigma_i\}_{i=1}^K)$ ، روش‌های متعددی وجود دارد. در این میان یکی از متداول‌ترین روش‌ها، تخمین بیشینه درست‌نمایی^۱ (MLE) می‌باشد [۷۷]. هدف از تخمین ML، یافتن پارامترهای مدل بگونه‌ای است که GMM بهترین انطباق را با توزیع بردارهای ویژگی داده آموزش، داشته باشد. بعبارت دیگر باید درست‌نمایی مدل، به شرط داشتن داده‌های آموزش، ماکزیمم گردد. برای یک داده متشکل از T بردار آموزش $X = \{\bar{x}_1; \bar{x}_2; \dots; \bar{x}_T\}$ ، درست‌نمایی مدل GMM طبق رابطه (۱۴-۳) قابل محاسبه می‌باشد:

$$p(X | \psi) = \prod_{i=1}^T p(\bar{x}_i | \psi)$$

$$p(X | \psi) = \prod_{i=1}^T \sum_{i=1}^K g(\bar{x}_i | \mu_i, \Sigma_i) \alpha_i \quad (۱۴-۳)$$

$$\hat{\psi}_{ML} = \arg \max_{\psi} p(X | \psi)$$

^۱ Maximum Likelihood Estimation

متأسفانه چون رابطه فوق یک رابطه غیرخطی از مدل ψ می‌باشد، محاسبه مستقیم پارامترهای مدل امکان پذیر نمی‌باشد. بنابراین می‌توان از الگوریتم بیشینه‌سازی انتظار (EM)^۱، که یکی از بهترین روش‌ها جهت تخمین پارامترها، توسط MLE می‌باشد استفاده نمود [۷۷]. به طور کلی الگوریتم EM در مسائلی به کار می‌رود که هدف، تخمین مجموعه‌ای از پارامترهای ψ مربوط به یک توزیع احتمال می‌باشد، و تنها بخشی از داده‌هایی که توسط این توزیع احتمالی تولید شده‌اند در دسترس می‌باشد. الگوریتم EM یک روش تکراری^۲ است که ایده اصلی آن این است که با شروع از یک مدل اولیه ψ ، یک مدل جدید $\hat{\psi}$ تخمین زده شود بگونه‌ای که $p(X | \hat{\psi}) \geq p(X | \psi)$ باشد. مدل جدید، مدل اولیه برای تکرار بعد می‌شود و این فرآیند تا زمانی که به یک مدل خوب همگرا گردد، تکرار می‌شود.

الگوریتم EM شامل ۳ مرحله جهت تخمین پارامترهای مدل مخلوط گوسی می‌باشد [۷۷]:

- مدل اولیه: شامل مقداردهی اولیه برای پارامترهای $\psi = \{\alpha_i, \mu_i, \sum_{i=1}^K\}$ است، که می‌توان هم بصورت تصادفی و هم از روش k-mean، جهت مقداردهی اولیه استفاده نمود.
- مرحله E: شامل محاسبه احتمال پسین^۳ برای جزء μ می‌باشد که مبنای روش بدست آوردن آن قانون بیزین^۴ است، و طبق معادله (۱۵-۳) قابل محاسبه می‌باشد.

$$\Pr(i | \bar{x}_t, \psi^n) = \frac{g(\bar{x}_t | \mu_i^n, \sum_i^n) \alpha_i}{\sum_{i=1}^K g(\bar{x}_t | \mu_i^n, \sum_i^n) \alpha_i} \quad (15-3)$$

- مرحله M: شامل به روزرسانی^۵ مقادیر پارامترهای وزن، میانگین و ماتریس کوواریانس است که مطابق روابط (۱۶-۳) محاسبه می‌شوند:

^۱ Expectation Maximization Algorithm

^۲ Iteratively

^۳ posteriori probability

^۴ Bayesian Rule

^۵ Update

$$\alpha_i^{n+1} = \frac{1}{T} \sum_{t=1}^T \Pr(i | \bar{x}_t, \psi^n)$$

$$\mu_i^{n+1} = \frac{\sum_{t=1}^T \Pr(i | \bar{x}_t, \psi^n) \bar{x}_t}{\sum_{t=1}^T \Pr(i | \bar{x}_t, \psi^n)} \quad (۱۶-۳)$$

$$\sum_i^{n+1} = \frac{\sum_{t=1}^T (\bar{x}_t - \mu_i^{n+1})(\bar{x}_t - \mu_i^{n+1})^T \Pr(i | \bar{x}_t, \psi^n)}{\sum_{t=1}^T \Pr(i | \bar{x}_t, \psi^n)}$$

که طبق معادله بالا، اندیس n ، بیانگر تعداد دفعات تکرار می‌باشد. مراحل E و M تا زمانی تکرار می‌شوند که تابع لگاریتم درست‌نمایی^۱، مطابق معادله (۱۷-۳) ماکزیمم گردد:

$$\log p(X | \psi) = \sum_{t=1}^T \log \left(\sum_{i=1}^K g(\bar{X} | \mu_i, \Sigma_i) \alpha_i \right) \quad (۱۷-۳)$$

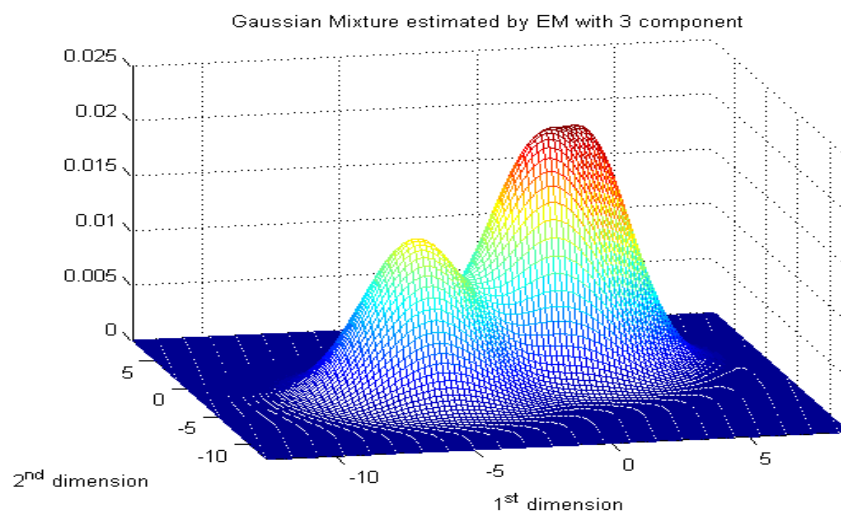
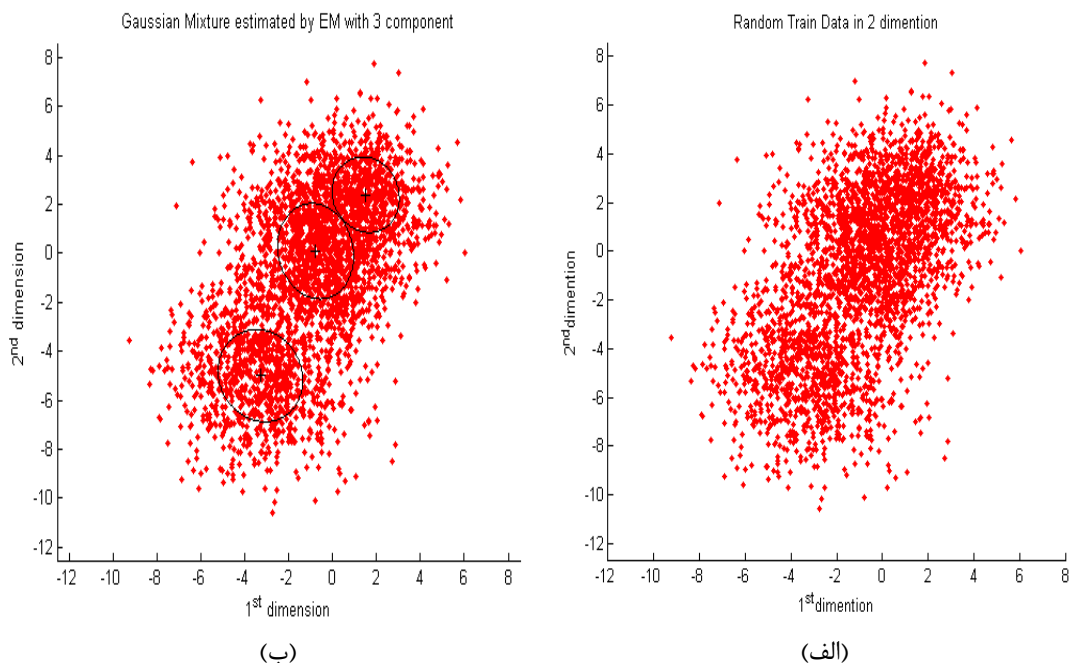
$$\hat{\psi} = \arg \max_{\psi} \log p(X | \psi)$$

لازم به ذکر است که مدل اولیه در آموزش مدل‌های مخلوط گوسی بسیار مهم است. در حالت کلی و مخصوصاً برای آموزش تعداد زیادی از مخلوط‌ها، مقداردهی اولیه صحیح می‌تواند نرخ همگرایی را بالاتر برده و همچنین باعث می‌شود تا الگوریتم EM در ماکزیمم‌های محلی به تله نیفتاده و به ماکزیمم عمومی نزدیکتر گردد [۷۶]. یکی از روش‌های مناسب برای یافتن مراکز اولیه خوشه‌ها، استفاده از الگوریتم خوشه‌بندی K-means می‌باشد. این الگوریتم طی مراحل که در بخش بعد توضیح داده خواهد شد، داده‌ها را در K خوشه، قرار می‌دهد که K همان تعداد مخلوط‌های گوسی در الگوریتم GMM می‌باشد.

در شکل (۱۲-۳) نمونه‌ای از مدل مخلوط گوسی برای یک داده آموزشی ۲ بُعدی نشان داده شده است. همانطور که از این شکل پیداست، داده‌های آموزشی شامل ۱۰۰۰ نمونه از داده‌های تصادفی با ۲ بُعد ویژگی می‌باشند که بصورت شکل (۱۲-۳) (الف) در فضا پراکنده شده‌اند. هدف، مدل کردن این داده‌های آموزشی با مخلوط گوسی می‌باشد که در اینجا ما از ۳ مخلوط ($k=3$)، جهت این

^۱ Log- Likelihood Function

امر استفاده نموده‌ایم. با مدل کردن این داده‌ها، میانگین یا مراکز این ۳ جزء مخلوط گوسی توسط الگوریتم EM تخمین زده می‌شود که بصورت مرکز دواپری در شکل (۲-۱۲ (ب)) نشان داده شده است. همچنین نمای ۳ بُعدی از چگالی مخلوط گوسی‌ها برای این مثال در شکل (۳-۱۲ (ج)) نشان داده شده است.



(ج)

شکل (۳-۱۲): تخمین پارامترهای مدل مخلوط گوسی همراه با ۳ جزء مخلوط، برای داده آموزشی ۲ بُعدی. (الف) داده آموزشی، (ب) میانگین‌های بدست آمده از مدل گوسی، (ج) نمای ۳ بُعدی از مدل مخلوط گوسی حاصله، با ۳ جزء مخلوط.

۳-۳-۱ الگوریتم K-means

این الگوریتم یکی از ساده‌ترین و پرکاربردترین الگوریتم‌های یادگیری بدون نظارت، برای خوشه‌بندی مجموعه‌ای از داده‌های در اختیار، در تعداد مشخصی خوشه (K) است که کاربر آنرا تعیین می‌کند. الگوریتم با انتخاب K نقطه از فضا به عنوان نماینده یا مرکز K خوشه، شروع به کار می‌کند. قدم بعدی تخصیص هر نمونه از داده‌ها به نزدیکترین مرکز می‌باشد. وقتی همه نقاط به مراکز موجود تخصیص داده شدند، مرحله اول تکمیل شده است و یک خوشه‌بندی اولیه انجام می‌شود. در این مرحله نیاز داریم که K مرکز جدید برای خوشه‌های مرحله قبل را محاسبه کنیم. بعد از تعیین K مرکز جدید، مجدداً داده‌ها را به مراکز جدید تخصیص می‌دهیم. این مرحله را آنقدر تکرار می‌کنیم که مراکز خوشه‌ها، جابجا نشوند. این الگوریتم تلاش می‌کند که تابع هدف^۱ که تابع مربع خطا^۲ نیز نامیده می‌شود را مینیمم نماید. تابع هدف بصورت رابطه (۳-۱۸) تعریف می‌گردد:

$$J = \sum_{j=1}^k \sum_{i=1}^k \|x_i^{(j)} - c_j\|^2 \quad (3-18)$$

در رابطه فوق $\|x_i^{(j)} - c_j\|^2$ ، فاصله بین داده i ام متعلق به خوشه j ام $x_i^{(j)}$ ، از مرکز خوشه j ام c_j است.

بطور کلی این الگوریتم از مراحل زیر تشکیل شده است:

- تعیین مراکز اولیه خوشه‌ها (معمولاً بصورت تصادفی صورت می‌گیرد).
- تخصیص هر داده به یکی از خوشه‌ها بر اساس معیار فاصله تا مراکز خوشه‌ها.
- تصحیح مرکز هر خوشه بر اساس متوسط‌گیری بر روی اعضای خوشه.

اگر چه ثابت شده است که الگوریتم همیشه همگرا می‌شود، اما لزوماً جواب بهینه را پیدا نمی‌کند. می‌توان اینطور عنوان کرد که این الگوریتم دارای حساسیت زیادی به مراکز اولیه خوشه‌ها که بصورت تصادفی انتخاب می‌شوند دارد. برای کاهش این تأثیر می‌توان الگوریتم را چندین بار با انتخاب مجدد مراکز اولیه اجرا کرد.

^۱ Objective Function

^۲ Squared error

فصل چهارم

روش‌های پیشنهادی

۴-۱ مقدمه

همانطور که در فصل اول اشاره گردید، هدف از این پایان‌نامه ارائه روش جدیدی به منظور مدل‌سازی بافت‌های تصادفی جهت تشخیص نواحی معیوب موجود در سطح اینگونه از بافت‌ها می‌باشد. در این پایان‌نامه، دو روش جهت تشخیص عیوب بافت‌های تصادفی پیشنهاد شده است. در روش پیشنهادی اول از تبدیل موجک^۱ و مدل مخلوط گوسی^۲، برای مدل کردن ویژگی‌های بافت در حوزه فرکانس استفاده می‌کنیم. و در روش پیشنهادی دوم از ویژگی‌های بدست آمده از پنجره‌های تصویر پاسخ فیلترهای موجک گابور^۳، جهت مدل نمودن و تشخیص نواحی معیوب استفاده شده است. لذا در این فصل ابتدا به شرح روش پیشنهادی اول این پایان‌نامه می‌پردازیم و سپس در بخش بعدی، روش پیشنهادی دوم را مورد بررسی قرار خواهیم داد. در نهایت، در فصل بعدی به مقایسه این دو روش با سایر روش‌های پیشین در زمینه تشخیص عیوب بافت‌های تصادفی خواهیم پرداخت و مزایا و معایب هر کدام از این روش‌های مطرح شده را مورد بررسی قرار خواهیم داد.

همانند بسیاری از روش‌های پیشین در زمینه تشخیص عیوب بافت، روش‌های پیشنهادی در این پایان‌نامه نیز دارای دو مرحله آموزش^۴ و آزمون^۵ می‌باشند (شکل (۱-۶)). در مرحله آموزش، ویژگی‌هایی که در حوزه فرکانس از اعمال تبدیل موجک و موجک‌های گابور به تعدادی از بافت‌های سالم (که همگی از یک خانواده می‌باشند) بدست آمده‌اند، توسط مدل مخلوط گوسی آموزش داده شده و مدل می‌گردند. در مرحله آزمون، با استفاده از پارامترهای مدل آموزش داده شده، عیوب تصویر تحت بازرسی، با استفاده از روش تشخیص تمایزها^۶ [۱۷]، آشکارسازی و موقعیت‌یابی می‌گردند.

^۱ Wavelet Transform

^۲ Gaussian Mixture Model

^۳ Gabor Wavelet Filters

^۴ Train

^۵ Test

^۶ Novelty Detection

همانطور که در مقدمه اشاره گردید، به نظر می‌رسد که الگوی بافتی عمومی^۱ حاضر در بافت‌های تصادفی، از یک فرآیند تصادفی نامشخص پیروی می‌کند. این فرض در بسیاری از کاربردهای مختلف مدل مخلوط گوسی، نظیر پردازش و تشخیص صوت، در نظر گرفته شده می‌شود. از آنجاییکه مدل مخلوط گوسی همچون مدل مخفی مارکوف^۲، ابزار بسیار قدرتمندی برای مدل‌سازی و تحلیل فرآیندهای اتفاقی و تصادفی می‌باشد، لذا در این پایان‌نامه از روش GMM جهت مدل‌سازی بافت‌های تصادفی استفاده می‌نماییم.

در مرجع [۷۸] نشان داده شده است که بسیاری از سیگنال‌های واقعی را می‌توان با مطالعه همسایگی‌های محلی^۳ آن سیگنال، مورد تحلیل و بررسی قرار داد. نتیجه حاصله بیان می‌دارد که بافت‌های با ساختار کلی^۴ را می‌توان با تحلیل و بررسی توزیع ویژگی‌های محلی آن، از یکدیگر تمیز داد. در این پایان‌نامه از این امر بعنوان یک پایه اساسی استفاده خواهیم نمود.

در روش‌های پیشنهادی ارائه شده در این پایان‌نامه، همانطور که اشاره گردید از مدل مخلوط گوسی برای مدل‌سازی مجموعه‌ای از ویژگی‌های بافت در حوزه فرکانس، استفاده می‌شود. نکته مهمی که باید به آن اشاره گردد این است که پارامترهای مدل بدست آمده می‌توانند هیچگونه معنای فیزیکی و خارجی نداشته باشند و ممکن است فقط بر خاصیت خوشه‌بندی بردارهای ویژگی یا مشاهدات دلالت نمایند. این موضوع در روش‌های پیشنهادی مطرح شده در این پایان‌نامه نیز صادق است. در حقیقت می‌توان اینطور تصور نمود که در روش‌های پیشنهادی، از پارامترهای مدل مخلوط گوسی به عنوان توصیف‌گرهای ویژگی‌های بافتی^۵ استفاده خواهیم کرد.

^۱ Global Textural

^۲ Hidden Markov Model

^۳ Local Neighbourhood

^۴ Global Structure

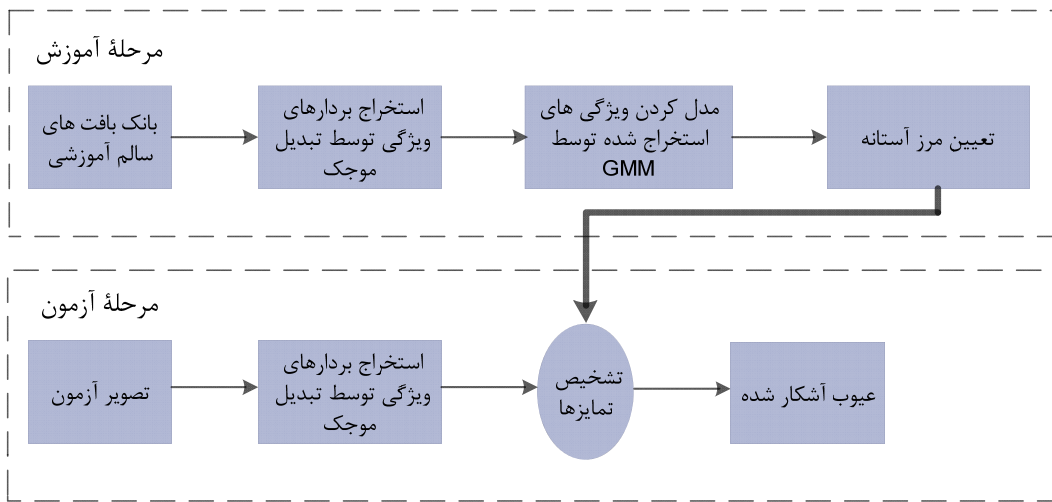
^۵ Texture Feature Descriptor

۲-۴ روش پیشنهادی اول

تشخیص عیوب بافت‌های تصادفی با مدل‌سازی ویژگی‌های مبتنی بر تبدیل موجک، توسط GMM

شکل (۱-۴) بلوک دیاگرام روش پیشنهادی که مبتنی بر تبدیل موجک است را بطور خلاصه

نشان می‌دهد. این الگوریتم شامل دو مرحله آموزش و آزمون می‌باشد.



شکل (۱-۴): فلوچارت روش پیشنهادی اول در دو مرحله آموزش و آزمون.

در مرحله آموزش، بردارهای ویژگی مبتنی بر تبدیل موجک از تصویر یک بافت سالم، استخراج شده، و چگالی احتمال ویژگی‌های بافت توسط مدل مخلوط گوسی تخمین زده می‌شود. پارامترهای بدست آمده از مدل، مجموعه $(\psi = \{\alpha_i, \mu_i, \sum_{i=1}^K\})$ می‌باشد (فصل ۳). سپس در مرحله آزمون، از پارامترهای مدل بدست آمده در مرحله آموزش، به منظور تشخیص عیوب در همسایگی‌های محلی تصویر تحت بازرسی استفاده می‌گردد. در دو بخش بعدی به توضیح جزئیات هر کدام از دو مرحله آموزش و آزمون خواهیم پرداخت.

۴-۲-۱ مرحله آموزش

همانطوریکه در شکل (۴-۱) نشان داده شده است، این مرحله شامل دو بخش اصلی استخراج بردارهای ویژگی و مدل سازی می باشد که به ترتیب هر یک از این بخش ها را مورد بررسی و مطالعه قرار خواهیم داد و به شرح جزئیات بکار رفته در هر یک از این مراحل می پردازیم.

الف - مرحله استخراج بردارهای ویژگی

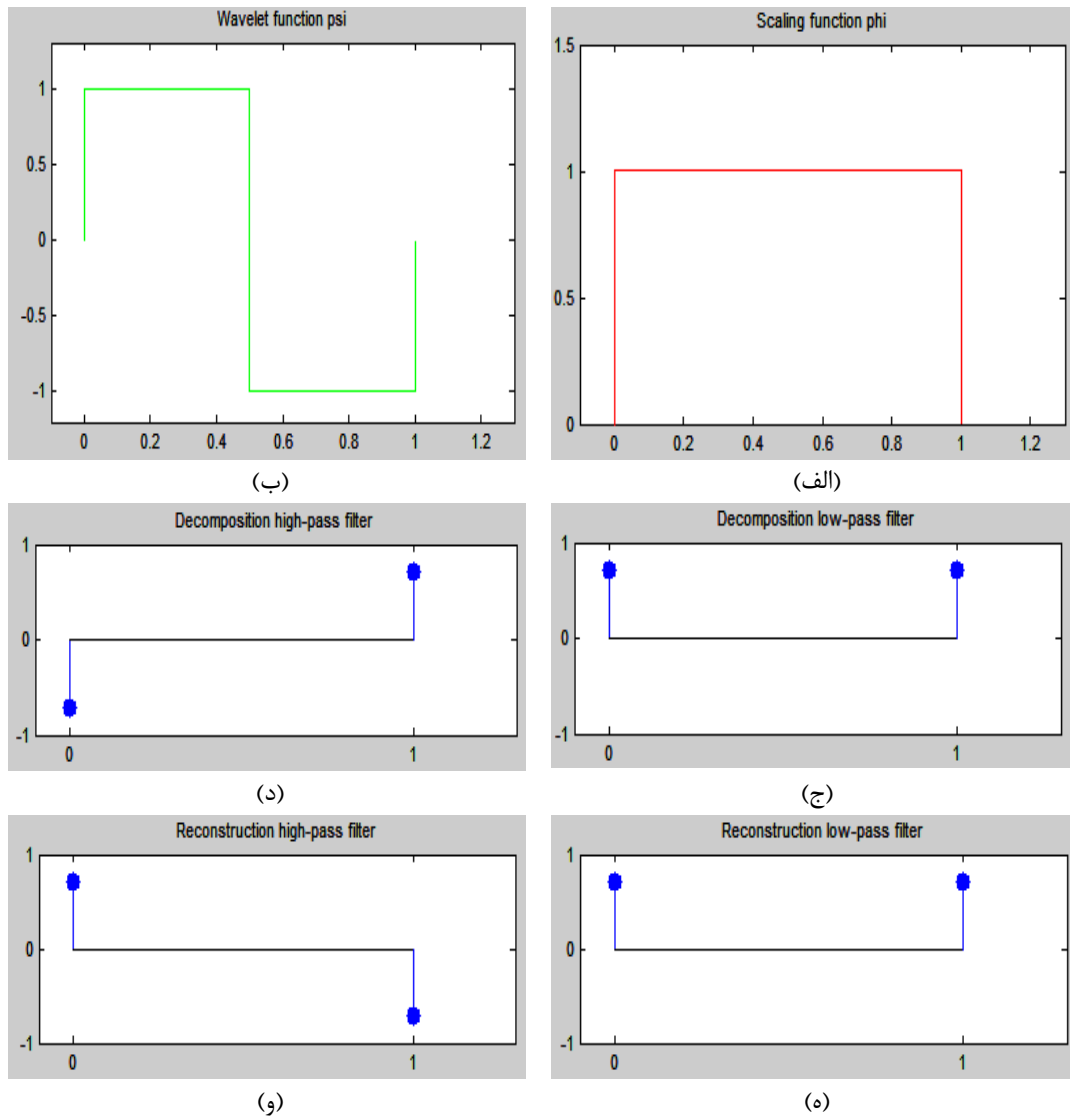
همانطور که در بخش ۳-۲ به آن اشاره گردید، یکی از کاربردهای متداول تبدیل موجک پردازش اطلاعات تصاویر دیجیتال می باشد. در همین راستا، طی سالیان اخیر استفاده از تبدیل موجک بعنوان یک ابزار مفید جهت استخراج ویژگی در حوزه آنالیز بافت مورد توجه قرار گرفته است. این تبدیل کاندیدای مناسبی برای روش های مورد استفاده در فرآیندهای تشخیص عیوب سطوح بافت ها می باشد. شبیه آنچه که در شکل (۳-۶) نشان داده شده است، در واقع اینطور می توان عنوان نمود که تبدیل موجک گسسته می تواند جزئیات واقع بر سطوح بافت های تصادفی را بعنوان مناطق آلوده احتمالی یا عیوب، مشخص و آشکار سازد [۷۹].

روال کار در این مرحله به اینصورت است که ابتدا تصاویر آموزشی دارای بافت تصادفی سالم را بعنوان تصویر ورودی در نظر گرفته و تبدیل موجک را به آن اعمال می کنیم. سپس طبق آنچه که در بخش ۳-۲ به آن اشاره کردیم و در شکل (۳-۳) بصورت شماتیک نشان داده شد، ضرایب تبدیل موجک تصویر ورودی در سطح یک را بدست می آوریم. لذا در نتیجه آن چهار زیر تصویر^۱ که شامل اطلاعات تصویر ورودی در راستای عمودی، افقی، قطری و فرکانس پایین ($I^1_H(x,y)$ ، $I^1_V(x,y)$) می باشد، حاصل می گردد. همچنین لازم به ذکر است که در این پایان نامه، جهت طراحی فیلترهای تجزیه و بازسازی موجک، از توابع موجک دابیچز-۱^۲، به جهت سادگی و پردازش سریع استفاده شده است. در شکل (۴-۲)، توابع مقیاس ($\phi(t)$) و موجک ($\psi(t)$) مربوط به دابیچز-۱

^۱ Subimage

^۲ Daubechies-1

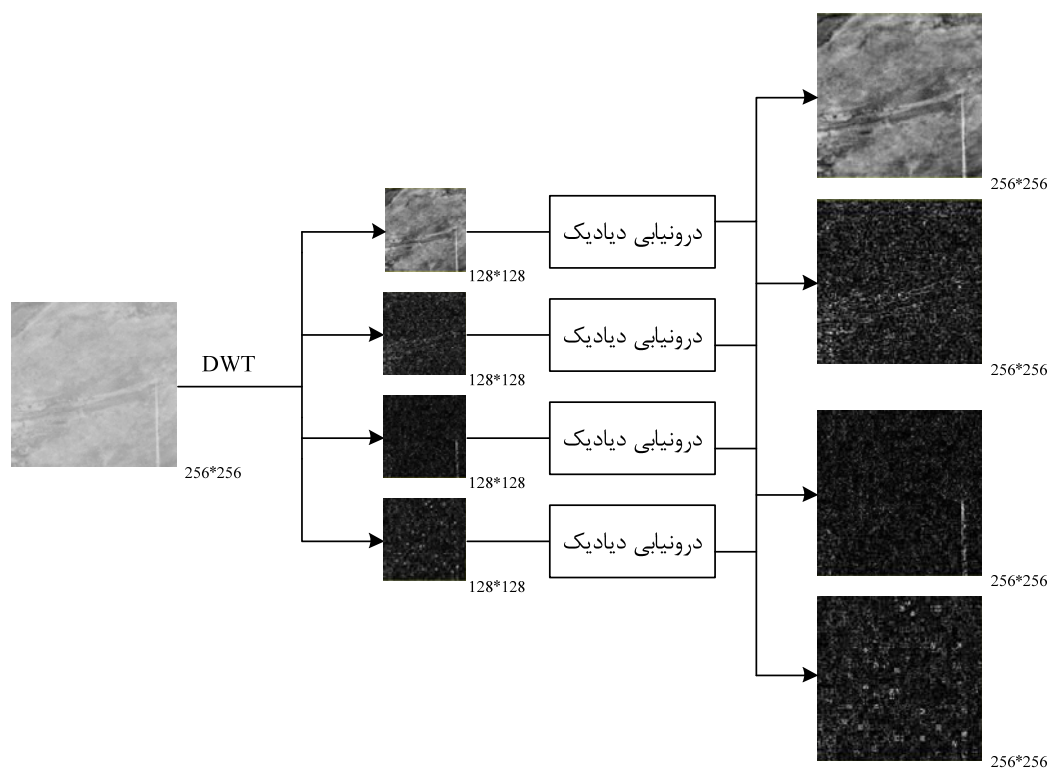
و همچنین فیلترهای پایین‌گذر و بالاگذر مربوط به تجزیه و بازسازی ضرایب تبدیل موجک مورد استفاده در این پایان‌نامه، بعنوان نمونه آورده شده است.



شکل (۴-۲): (الف) تابع مقیاس، (ب) تابع موجک، (ج) فیلترهای تجزیه پایین‌گذر و (د) بالاگذر و (ه) فیلترهای بازسازی پایین‌گذر و (و) بالاگذر، موجک دابیچز-۱.

در پایان این مرحله، به جهت استخراج ویژگی از پیکسل‌ها ورودی، می‌بایست تصاویر مورد مطالعه خروجی تبدیل موجک هم اندازه با تصویر ورودی باشند. لذا با انجام عملیات درون‌یابی

دیادیک^۱ ابعاد تصاویر ضرایب موجک بدست آمده را به ابعاد تصویر اصلی برمی‌گردانیم. لازم به ذکر است که فرآیند درونیابی در این مرحله شامل انجام عملیات نمونه‌برداری افزایشی و کانولوشن ماتریس X با فیلترهای پایین‌گذر و بالاگذر تبدیل موجک، در راستای سطرها و ستون‌های ماتریس ذکر شده می‌باشد. مراحل کار از ابتدا، که شامل استخراج ضرایب تبدیل موجک در راستای عمودی، افقی، قطری و فرکانس پایین بافت یک کاشی در سطح مقیاس اول و تبدیل آنها به ابعاد اصلی تصویر توسط عملیات درونیابی، بصورت شماتیک در شکل (۳-۴) آورده شده است.




شکل (۳-۴): مراحل استخراج ضرایب تبدیل موجک بافت یک کاشی و درونیابی آنها بصورت شماتیک.

همانطور که در مقدمه همین فصل به آن اشاره گردید، برای توصیف هر پیکسل تصویر از همسایگی‌های محلی آن استفاده می‌کنیم. به همین منظور قدم بعدی جهت استخراج بردارهای ویژگی، استخراج همسایگی‌های محلی از هر یک از ضرایب تبدیل موجک بدست آمده در مرحله قبل

^۱ Dyadic Interpolation


می‌باشد. شکل این همسایگی‌های محلی می‌تواند دلخواه باشد، در این تحقیق، از همسایگی‌های محلی به شکل مربع با ابعاد $N=d \times d$ استفاده شده است. شکل (۴-۴) یک همسایگی محلی 5×5 استخراج شده از ضریب موجک بافت کاشی شکل (۵-۱) را که شامل جزئیات در راستای عمودی $(I^1_v(x,y))$ می‌باشد، نشان می‌دهد.




شکل (۴-۴): یک همسایگی 5×5 برای ضریب تبدیل موجک در راستای عمودی بافت یک کاشی.

در این مرحله هر یک از ضرایب تبدیل موجک بدست آمده در مرحله قبل، به مجموعه‌ای از پنجره‌های^۱ کوچکتر که با هم همپوشانی ندارند، شکسته می‌شوند. توصیف تصویری از شکسته شدن هر یک از ضرایب تبدیل موجک به پنجره‌ها، در شکل (۵-۴) نشان داده شده است. با توجه به پنجره‌های استخراج شده، هر کدام از این پنجره‌ها را با علامت $\{P_s^t\}$ نشان می‌دهیم. که در آن $s = \{A, H, V, D\}$ بیانگر یکی از ضرایب تبدیل موجک در مقیاس اول و $t = 1, 2, \dots, T$ نشان‌دهنده شماره پنجره استخراج شده از هر یک از این ضرایب می‌باشد. T ، تعداد کل پنجره‌های استخراج شده از تصویر هر یک از ضرایب تبدیل موجک است. این مقدار در هر چهار تصویر ضرایب موجک، یکسان می‌باشد.


^۱ Patches




(الف)



(ب)



(ج)



(د)

شکل (۴-۵): نمایش توصیفی از استخراج پنجره‌های ضرایب تبدیل موجک. (الف) پنجره‌های تصویری تخمین، (ب) پنجره‌های تصویری ضریب موجک در راستای افقی، (ج) پنجره‌های تصویری ضریب موجک در راستای عمودی، (د) پنجره‌های تصویری ضریب موجک در راستای قطری.

در ادامه ذکر این نکته ضروری است که به دلیل وجود اکستریم‌های محلی (مینیمم و ماکزیمم محلی) در هر یک از پنجره‌های استخراج شده از ضرایب تبدیل موجک، و اینکه این اکستریم‌ها بیانگر تغییرات ناگهانی شدت روشنایی در سطح هر یک از پنجره‌ها می باشند، لذا از قدر مطلق مقادیر این پنجره‌ها جهت استخراج بردارهای ویژگی استفاده می‌نماییم. زیرا این تغییرات ناگهانی می‌تواند بصورت یک قله (ضرایب با انرژی مثبت) و یا یک دره (ضرایب با انرژی منفی) ظاهر شوند، که با اعمال قدر مطلق، این دو رخداد به یک فرم ظاهر می‌گردند. همانطور که قبلاً ذکر شد بنابر مرجع [۷۹]، این اکستریم‌ها می‌توانند بعنوان نقاط احتمالی معیوب بر روی تصاویر بافت در نظر گرفته شوند. با این مقدمه در مرحله بعد به دنبال استخراج بردارهای ویژگی از هر یک از پنجره‌های استخراج شده از ضرایب تبدیل موجک می‌باشیم.

بردار ویژگی‌ای که برای هر کدام از پنجره‌ها در این پایان‌نامه از آن استفاده می‌شود بصورت زیر

$$\bar{x}_i = \left[\text{mean} |p'_A|, \text{mean} |p'_H|, \text{mean} |p'_V|, \text{mean} |p'_D|, \text{energy}_r |p'_A|, \text{energy}_r |w'| \right]$$

هر کدام از اعضای این بردار ویژگی بصورت زیر تعریف می‌گردند:

- $\text{mean} |p'_A|$: متناظر است با میانگین پیکسل‌های پنجره A در ضریب تخمین.
- $\text{mean} |p'_H|$: متناظر است با میانگین پیکسل‌های پنجره H در ضریب شامل راستای افقی.
- $\text{mean} |p'_V|$: متناظر است با میانگین پیکسل‌های پنجره V در ضریب شامل راستای عمودی.
- $\text{mean} |p'_D|$: متناظر است با میانگین پیکسل‌های پنجره D در ضریب شامل راستای قطری.
- $\text{energy}_r |p'_A|$: متناظر است با نسبت انرژی پنجره A در ضریب تخمین، به انرژی کل ضریب تخمین. که بصورت رابطه (۱-۴) بدست می‌آید.

$$\text{energy}_r |p'_A| = \frac{\sum_{i=1}^M \sum_{j=1}^N |p'_A(i, j)|^2}{\sum_{y=1}^Y \sum_{x=1}^X |I^1(x, y)|^2} \quad (1-4)$$

▪ $energy_r|w'$: متناظر است با مجموع نسبت‌های انرژی پنجره‌تأم در ضرایب در راستای افقی، عمودی و قطری، به انرژی کل ضرایب متناظرشان. که بصورت رابطه (۲-۴) قابل محاسبه است.

$$energy_r|w' = energy_r|p'_H + energy_r|p'_V + energy_r|p'_D \quad (2-4)$$

بنابراین به تعداد پنجره‌های استخراج شده در هر ضریب تبدیل موجک، بردار ویژگی خواهیم داشت که تعداد آنها برابر با T ، و ابعاد هر کدام از آنها $1 \times N$ ($N=6$) می‌باشد. دلیل اینکه از این ویژگی‌ها جهت ایجاد بردارهای ویژگی استفاده نمودیم، این بود که با انجام آزمایش و مشاهدات بر روی پنجره‌های استخراج شده از ضرایب تبدیل موجک تعدادی از بافت‌های سالم و معیوب، به این نتیجه رسیدیم که میانگین پنجره‌های استخراج شده از ضرایب تبدیل موجک، در نواحی معیوب بیشتر از سایر نواحی می‌باشد. دلیل این امر هم این است که جزئیات واقع بر ضرایب تبدیل موجک دارای مقادیری بزرگتر از سایر نواحی هستند و همانطور که قبلاً به آن اشاره شد، این جزئیات می‌توانند بعنوان مناطق آلوده احتمالی یا عیب در نظر گرفته شوند [۷۹]. همچنین با استناد به این فرض، مشاهده گردید که نسبت انرژی پنجره‌های استخراج شده از ضرایب تبدیل موجک به انرژی کل ضرایب متناظرشان، در نواحی آلوده بیشتر از سایر نواحی می‌باشد. برای اینکه بتوانیم از اطلاعات بدست آمده از تغییرات انرژی در راستاهای افقی، عمودی و قطری بطور همزمان استفاده نماییم، مطابق رابطه (۲-۴) انرژی‌های پنجره‌های متناظر با این راستاها را با هم جمع می‌کنیم.

چگالی احتمال بردارهای ویژگی متعلق به یک تصویر بافت سالم در مرحله آموزش توسط مدل مخلوط گوس تخمین زده شده و پارامترهای مدل مخلوط گوسی از آن نتیجه می‌شود. بدیهی است که مدل بدست آمده رفتار ویژگی‌های تصاویر بافت بدون عیب را مدل‌سازی می‌کند. همانطور که در بخش ۲-۲-۴-ب خواهیم دید، از این مدل آموزش داده شده در مرحله آزمون، برای تشخیص عیوب احتمالی تصویر تحت بازرسی استفاده می‌شود. چنانچه بردار ویژگی یک پنجره از بافت معیوب در این مدل مورد ارزیابی قرار گیرد، تعلق این پنجره از تصویر به مدل بافت سالم ضعیف خواهد بود.

ب- مدل سازی بردارهای ویژگی استخراج شده، توسط GMM

در این قسمت از مرحله آموزش، بردارهای ویژگی ای که از تصویر یک بافت سالم در قسمت قبل بدست آمده بودند، توسط GMM آموزش داده می شوند و پارامترهای مدل آموزش داده شده، جهت استفاده در مرحله آزمون و یافتن مرز آستانه، ذخیره می گردند.

در سیستم مبتنی بر مدل مخلوط گوسی، توزیع احتمال بردارهای ویژگی بافت یک تصویر $X = \{x_t, 1 \leq t \leq T\}$ ، بصورت یک ترکیب خطی از K مخلوط گوسی مطابق رابطه (۳-۴) بیان می شود.

$$p(\bar{x}_t | \psi) = \sum_{i=1}^K g(\bar{x}_t | \mu_i, \Sigma_i) \alpha_i \quad (۳-۴)$$

همانطور که در بخش ۳-۴ به آن اشاره شد، ψ بیانگر پارامترهای مدل مخلوط گوسی می باشد. در اینصورت فرض می کنیم که هر بردار ویژگی، یک تابع چگالی احتمال D -بُعدی (با توجه به مطالب ذکر شده در بخش قبل، $D=۶$) با بردار میانگین μ_i و ماتریس کوواریانس Σ_i ، مطابق رابطه (۴-۴) می باشد.

$$g(\bar{x}_t | \mu_i, \Sigma_i) = \frac{1}{(2\pi)^{D/2} |\Sigma_i|^{1/2}} \exp \left\{ -\frac{1}{2} (\bar{x}_t - \mu_i)^T \Sigma_i^{-1} (\bar{x}_t - \mu_i) \right\} \quad (۴-۴)$$

با در دست داشتن یک دنباله از مشاهدات $X = \{x_t, 1 \leq t \leq T\}$ ، درست نمایی X ، برای پارامترهای مدل GMM توسط رابطه (۵-۴) بیان می گردد:

$$p(X | \psi) = \prod_{t=1}^T p(\bar{x}_t | \psi) \quad (۵-۴)$$

همانطور که در بخش ۳-۳ توضیح داده شد، توسط الگوریتم EM می توان به بیشینه درست نمایی دست یافت و پارامترهای مدل را تخمین زد. با توجه به مطالب عنوان شده در این بخش و بخش ۳-۳، می توان الگوریتم مدل سازی بردارهای ویژگی را بصورت زیر بیان نمود:

(۱) در نظر گرفتن دنباله مشاهدات بردارهای ویژگی به فرم $X = \{\bar{x}_1; \bar{x}_2; \dots; \bar{x}_T\}$ ، بعنوان

ورودی مدل GMM.

۲) تعیین تعداد مخلوط‌های گوسی (K)، و تخمین اولیه پارامترهای میانگین (μ_i^0)، ماتریس کوواریانس (Σ_i^0) و وزن مخلوط‌ها (α_i^0) که توسط روش k-means بدست می‌آیند.

۳) اعمال مرحله E از الگوریتم EM و محاسبه مقدار احتمال پسین برای جزء مخلوط λ ، مطابق رابطه (۳-۱۵).

۴) اعمال مرحله M از الگوریتم EM، و به‌روزرسانی^۱ مقادیر پارامترهای میانگین، ماتریس کوواریانس و وزن چگالی‌های مخلوط، مطابق رابطه (۳-۱۶).

۵) محاسبه تابع لگاریتم درست‌نمایی $\log p(X | \psi)$ ، با استفاده از پارامترهای به‌روز شده، توسط رابطه (۳-۱۷).

۶) تکرار مراحل ۳ تا ۵، تا اینکه تابع لگاریتم درست‌نمایی همگرا گردد.

۷) ذخیره‌سازی پارامترهای مدل همگرا شده (α, μ, Σ).

بنابراین مطابق با الگوریتم ذکر شده در بالا، در مرحله آموزش، بردارهای ویژگی استخراج شده از یک بافت سالم آموزشی، در قالب همسایگی‌های محلی توسط مدل مخلوط گوسی آموزش داده شده، و پارامترهای مدل $\psi = \{\alpha_i, \mu_i, \Sigma_i\}_{i=1}^K$ ، محاسبه و ذخیره می‌گردند.

در ادامه مطابق با رویکرد تشخیص تمایزها که در بخش بعدی توضیح داده خواهد شد، با استفاده از بردارهای ویژگی استخراج شده از تعدادی نمونه‌های بافت سالم (۳ الی ۴ نمونه) از همان خانواده که آنها را در بخش الف بدست آورده بودیم، مقدار کران پایین^۲ یا مرز آستانه‌گذاری را جهت مقایسه با بردارهای ویژگی بدست آمده از هر پیکسل تصویر تحت بازرسی، بصورت اتوماتیک تعیین می‌نماییم. روال کار در این مرحله به اینصورت است که، ابتدا طبق معادله (۴-۳)، احتمال اینکه هر بردار ویژگی متعلق به پارامترهای مدل مخلوط گوسی باشد را محاسبه می‌نماییم، و آنرا ارزش بردار ویژگی می‌نامیم. به این ترتیب، کمترین مقدار احتمال بردار ویژگی‌ای که متعلق به پارامترهای مدل

^۱ Update

^۲ Minimum Bound

مخلوط گوسی باشد را بعنوان مرز آستانه بین ناحیه معیوب و سالم در نظر گرفته و آنرا با نماد Δ نشان می‌دهیم (رابطه (۴-۶)).

$$\Delta = \min(p(\bar{x}_t | \psi)) \quad \forall \bar{x}_t \in X \quad (۴-۶)$$

۴-۲-۲ مرحله آزمون

همانطور که در شکل (۴-۱) مشاهده می‌شود، این مرحله شامل دو قسمت اصلی است: استخراج بردارهای ویژگی از تصویر تحت بازرسی و قسمت تشخیص تمایزها می‌باشد. در قسمت بعد جزئیات بکار رفته در هر یک از این مراحل را تشریح خواهیم نمود.

الف - مرحله استخراج بردارهای ویژگی

در این مرحله، همانند مرحله آموزش، ابتدا ضرایب تبدیل موجک تصویر تحت بازرسی را بدست آورده و مطابق با آنچه که در بخش ۴-۲-۱-الف، بیان گردید عملیات درون‌یابی را بر روی ضرایب اعمال کرده و آنها را به ابعاد تصویر ورودی بر می‌گردانیم. در مرحله بعد به ازای هر پیکسل از تصویر ورودی، پنجره‌ای به مرکزیت آن نقطه را استخراج نموده و قدر مطلق هر کدام از تصاویر ضرایب موجک متناظر با آنرا جهت استخراج بردارهای ویژگی در نظر می‌گیریم. عملیات استخراج بردارهای ویژگی هم درست همانند آنچه که در مرحله آموزش به آن اشاره شد صورت می‌پذیرد. بنابراین در پایان این مرحله، بردارهای ویژگی مربوط به همسایگی‌های محلی هر کدام از پیکسل‌های ضرایب تبدیل موجک تصویر آزمون، بدست می‌آیند. اکنون مطابق با رویکرد تشخیص تمایزها، ویژگی‌های استخراج شده مورد ارزیابی قرار می‌گیرند تا تعلق هر بردار به بافت سالم یا معیوب تعیین گردد.

ب - مرحله تشخیص تمایزها

تشخیص تمایزها یک دیدگاه متفاوت در میان روش‌های خوشه‌بندی رایج، جهت تشخیص عیوب در سطوح بافت‌ها می‌باشد. در روش استفاده از خوشه‌بندی‌های رایج جهت تشخیص عیوب در تصاویر بافت‌ها، تعبیر مسئله تشخیص عیب، عموماً بعنوان یک مسئله طبقه‌بندی^۱ به یکی از دو کلاس معیوب و سالم مطرح می‌گردد. بدین ترتیب بعد از استخراج ویژگی‌هایی از نمونه‌های آموزشی از هر دو کلاس، آموزش یک طبقه‌بند^۲ جهت تشخیص عیوب انجام می‌شود. اما این روش جهت تشخیص عیوب در بسیاری از موارد دچار مشکل می‌شود. در واقع تعداد ناکافی نمونه‌های معیوب و تنوع عیب مانع از این می‌شود که بتوان کلاس بافت معیوب را بدرستی مدل کرد، لذا مدل‌سازی کلاس معیوب دچار مشکل می‌شود. در بسیاری از کاربردها به دلیل طبیعت متفاوت و غیرقابل پیش‌بینی عیوب، اغلب بدست آوردن تعداد کافی نمونه‌های معیوب و تولید مجموعه‌ای از داده‌های آموزشی معیوب که بتواند همه فضای مشخصه این کلاس را پوشش دهد، دشوار می‌باشد. در حالیکه یک تشخیص‌گر تمایزها، در مرحله آموزش تنها با استفاده از داده‌های نمونه‌های سالم، این داده‌ها را مدل‌سازی می‌کند. در مرحله آزمون، مناطق معیوب از طریق مقایسه با مدلی که در مرحله آموزش بدست آمده، مشخص می‌گردند. با توجه به این، دیگر نیازی به استفاده از نمونه‌های معیوب در مرحله آموزش نمی‌باشد. از دیدگاه هندسی، در فضای N بُعدی ویژگی‌ها، نمونه‌های سالم خوشه‌هایی متمرکز را تشکیل می‌دهند. در حالیکه نمونه‌های معیوب می‌توانند در کل فضا پراکنده باشند و از مراکز خوشه‌های بافت‌های سالم فاصله بگیرند [۸۰]. این دیدگاه متفاوت در تشخیص عیوب، بر مسئله استفاده از روش تشخیص تمایزها تکیه می‌کند.

بنابراین در ادامه، هر بردار ویژگی متعلق به یک پیکسل از تصویر تحت بازرسی، که مقدار احتمال آن طبق معادله (۴-۳) محاسبه می‌شود را با مقدار مرز آستانه‌ای که در مرحله آموزش بدست

^۱ Classification

^۲ Classifier

آمده بود (Δ) مقایسه کرده و مقادیر کمتر از Δ را به عنوان پیکسل معیوب در نظر می‌گیریم. در اینصورت نقشهٔ عیوب^۱ نهایی بصورت باینری مطابق با رابطهٔ (۷-۴) تشکیل شده، و پیکسل‌های معیوب معیوب تصویر تحت بازرسی را نشانه‌گذاری و مشخص می‌نماییم.

$$D(x, y) = \begin{cases} 0 & Q(x, y) \geq \Delta \\ 1 & Q(x, y) < \Delta \end{cases} \quad (7-4)$$

که در آن $Q(x, y)$ ، ارزش بردار ویژگی متعلق به پیکسل تصویر تحت بازرسی در مختصات (x, y) می‌باشد.

^۱ Defect Map

۳-۴ روش پیشنهادی دوم

تشخیص عیوب بافت‌های تصادفی با مدل‌سازی ویژگی‌های فیلترهای موجک گابور، توسط GMM

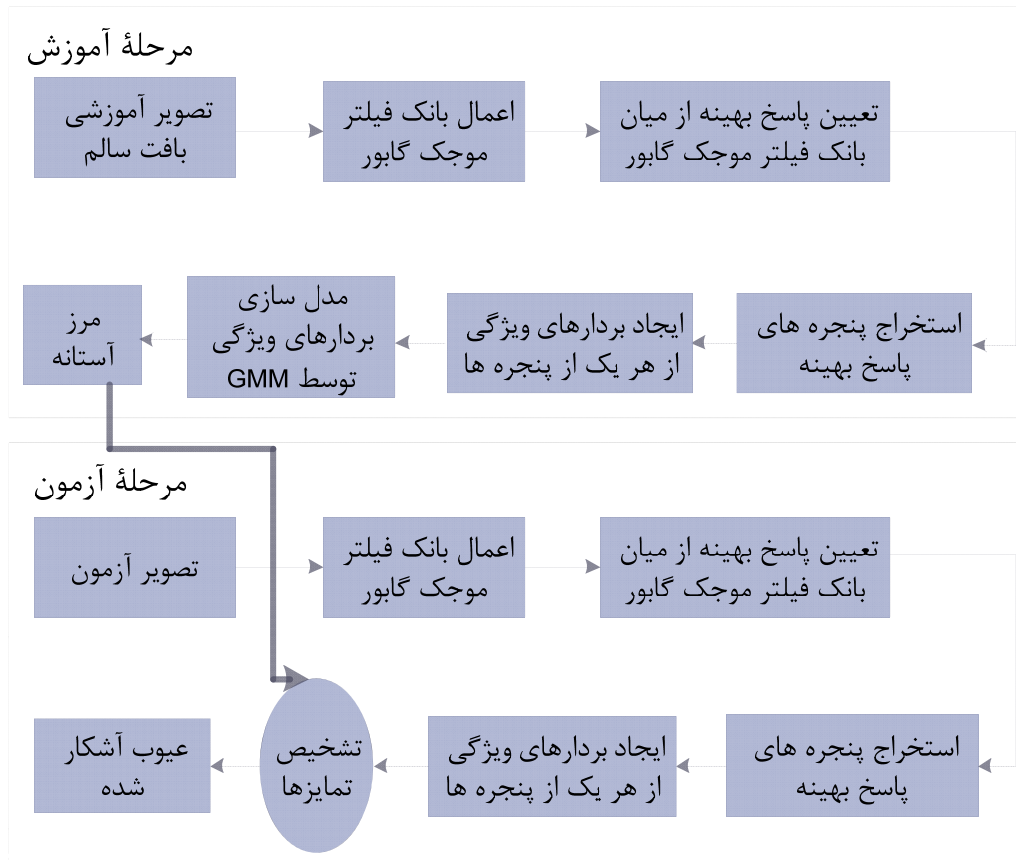
انگیزه ما جهت استفاده از فیلترهای موجک گابور^۱ به جای تبدیل موجک دیادیک برای استخراج بردارهای ویژگی، توانایی بالای این فیلترها در دقت توأم اطلاعات در هر دو حوزه مکانی و فرکانسی بود. همچنین در تبدیل موجک گسسته، در هر سطح تجزیه تنها ناحیه با فرکانس پایین به دو قسمت تجزیه می‌شود و ناحیه با فرکانس بالا مجدداً تجزیه نمی‌گردد. در مقابل تبدیل موجک گابور دارای خواصی است که می‌تواند قسمت اعظم اطلاعات بافت را استخراج نماید. مطالعات چانگ^۲ در [۸۱] نشان داد که بخش عمده‌ای از اطلاعات مربوط به بافت، در نواحی فرکانس میانی قرار دارند. بنابراین موجک گابور نسبت به تبدیل موجک گسسته کارایی بالاتری در آنالیز بافت دارد. یکی از عوامل اصلی این امر، آن است که تبدیل موجک گسسته بخشی از نواحی فرکانس میانی را از دست می‌دهد، درحالی‌که موجک گابور تمام نواحی فرکانس میانی را حفظ می‌نماید.

در این روش همچون روش پیشنهادی اول، مراحل انجام کار در دو فاز آموزش و آزمون صورت می‌پذیرد. شکل (۴-۶) بلوک دیاگرام روش پیشنهادی دوم را بطور خلاصه نشان می‌دهد. در ادامه عملکرد هر بخش را بطور جداگانه مورد تحلیل و بررسی قرار خواهیم داد. در مرحله آموزش، با اعمال فیلترهای موجک گابور به تصویر دارای بافت سالم، بهترین پاسخ از مجموعه پاسخ‌های فیلترهای موجک گابور انتخاب می‌شود. همانطور که بعداً به تفصیل اشاره خواهد شد، فیلتری که خروجی آن بیشترین انرژی را در میان خروجی بانک فیلتر داشته باشد، بعنوان بهترین پاسخ در نظر گرفته می‌شود. سپس بردارهای ویژگی استخراج شده از همسایگی‌های محلی تصویر پاسخ بهینه، توسط مدل مخلوط گوسی آموزش داده می‌شود و پارامترهای بدست آمده از مدل، ذخیره می‌گردند. در مرحله

^۱ Gabor Wavelet Filters

^۲ Chang

آزمون، بردارهای ویژگی از هر پیکسل در تصویر پاسخ بهینه تحت بازرسی (مشابه مرحله آزمون)، استخراج گردیده و از پارامترهای ذخیره شده در مرحله قبل به منظور تشخیص عیوب در هر پیکسل از تصویر آزمون، استفاده می‌گردد. شرح جزئیات هر کدام از مراحل در بخش‌های بعدی آورده شده است.



شکل (۴-۶): بلوک دیاگرام روش پیشنهادی دوم در دو فاز آموزش و آزمون.

۴-۳-۱ مرحله آموزش

همانطور که در شکل (۴-۶) مشاهده می‌شود، این مرحله شامل سه بخش اصلی اعمال بانک فیلترهای موجک گابور، انتخاب پاسخ بهینه از مجموعه پاسخ‌های فیلترهای موجک گابور و مدل‌سازی بردارهای ویژگی می‌باشد، که در ادامه به شرح جزئیات هر کدام از این بخش‌ها می‌پردازیم.

الف - اعمال فیلترهای موجک گابور

در این مرحله نیز همانند روش پیشنهادی اول، تصویر آموزشی دارای بافت تصادفی سالم را بعنوان تصویر ورودی در نظر گرفته و طبق مطالب ذکر شده در بخش ۳-۲ و معادلات (۳-۷)، (۳-۹) و (۳-۱۰)، بانک فیلتر موجک گابور را به آن اعمال می‌کنیم. تعداد فیلترهای مورد استفاده در بانک فیلتر برابر است با $N \times M$ ، که M بیانگر تعداد کل مقیاس‌ها و N تعداد کل جهت‌ها می‌باشد. نمایش توصیفی از اعمال بانک فیلتر موجک گابور به تصاویر بافت یک کاشی در شکل (۳-۹) آورده شده است. در پایان این مرحله، پاسخ‌های بانک فیلتر موجک گابور اعمالی به تصویر بافت سالم، توسط رابطه (۴-۸) محاسبه می‌گردند.

$$h_{mn}^l(x, y) = \sum_s \sum_t I(x-s, y-t) g_{mn}^*(s, t) \quad (۴-۸)$$

که مطابق با آن، تصویر ورودی $I(x, y)$ و فیلتر موجک گابور در مقیاس m و راستای n می‌باشد. به این ترتیب، تمامی پاسخ‌های بانک فیلتر را می‌توان بصورت مجموعه مشاهدات $H^l = \{h_{mn}^l, m=1, 2, \dots, M \quad n=1, 2, \dots, N\}$ در نظر گرفت که تعداد اعضای آن برابر با $N \times M$ می‌باشد.

ب - انتخاب پاسخ بهینه بانک فیلتر موجک گابور

هدف استفاده از بانک فیلتر، استخراج ویژگی‌های بافت در مقیاس‌ها و جهت‌های متفاوت و همچنین انتخاب مناسب‌ترین پاسخ برای توصیف بافت می‌باشد. جهت انتخاب بهترین پاسخ در میان مجموعه مشاهدات H^l ، از تابع ارزش فیشر^۱ [۸۲] مطابق رابطه (۴-۹) استفاده می‌نماییم. که در آن $P \times Q$ ابعاد تصویر ورودی $I(x, y)$ می‌باشد.

$$\begin{aligned} \mu_{mn}^l &= \frac{\sum_x \sum_y |h_{mn}^l(x, y)|}{P \times Q} \\ \sigma_{mn}^l &= \frac{\sum_x \sum_y |h_{mn}^l(x, y) - \mu_{mn}^l|}{P \times Q} \end{aligned} \quad (۴-۹)$$

$$F_{mn}^l = \frac{\mu_{mn}^l}{\sigma_{mn}^l} \quad m = 1, 2, \dots, M \quad n = 1, 2, \dots, N$$

^۱ Fisher Criterion Function

در اینصورت ماتریس خصوصیات بدست آمده (F_{mn}^I) ، پاسخ فرکانسی یا انرژی وابسته به تصویر را مشخص می‌سازد. برای مجموعه‌ای از پاسخ‌های بانک فیلتر موجک گابور، فیلتری بعنوان بهینه انتخاب می‌شود که میانگین انرژی تصویر را ماکزیمم نماید. در اینصورت، فیلتر با بافت مورد بررسی تطبیق یافته و تفکیک کننده خوبی برای بافت از عیوب محسوب می‌گردد. لذا با توجه به مطالب ذکر شده، فیلتر بهینه انتخابی، g_{kl} است بطوریکه بهترین پاسخ را نسبت به تصویر ورودی در بر دارد. همچنین KL توسط رابطه (۴-۱۰) مشخص می‌گردد.

$$F_{kl}^I = \max_{m,n} \{F_{mn}^I\} \quad (۴-۱۰)$$

در نتیجه می‌توان پاسخ بهینه فیلتر انتخابی را از میان مجموعه مشاهدات $H^I = \{h_{mn}^I, m=1,2,\dots,M, n=1,2,\dots,N\}$ بدست آورد، که آنرا با نماد $h_{kl}^I(x,y)$ نشان می‌دهیم. از پاسخ بهینه بدست آمده، جهت استخراج بردارهای ویژگی، استفاده می‌گردد.

ج- استخراج بردارهای ویژگی و مدل‌سازی آنها توسط GMM

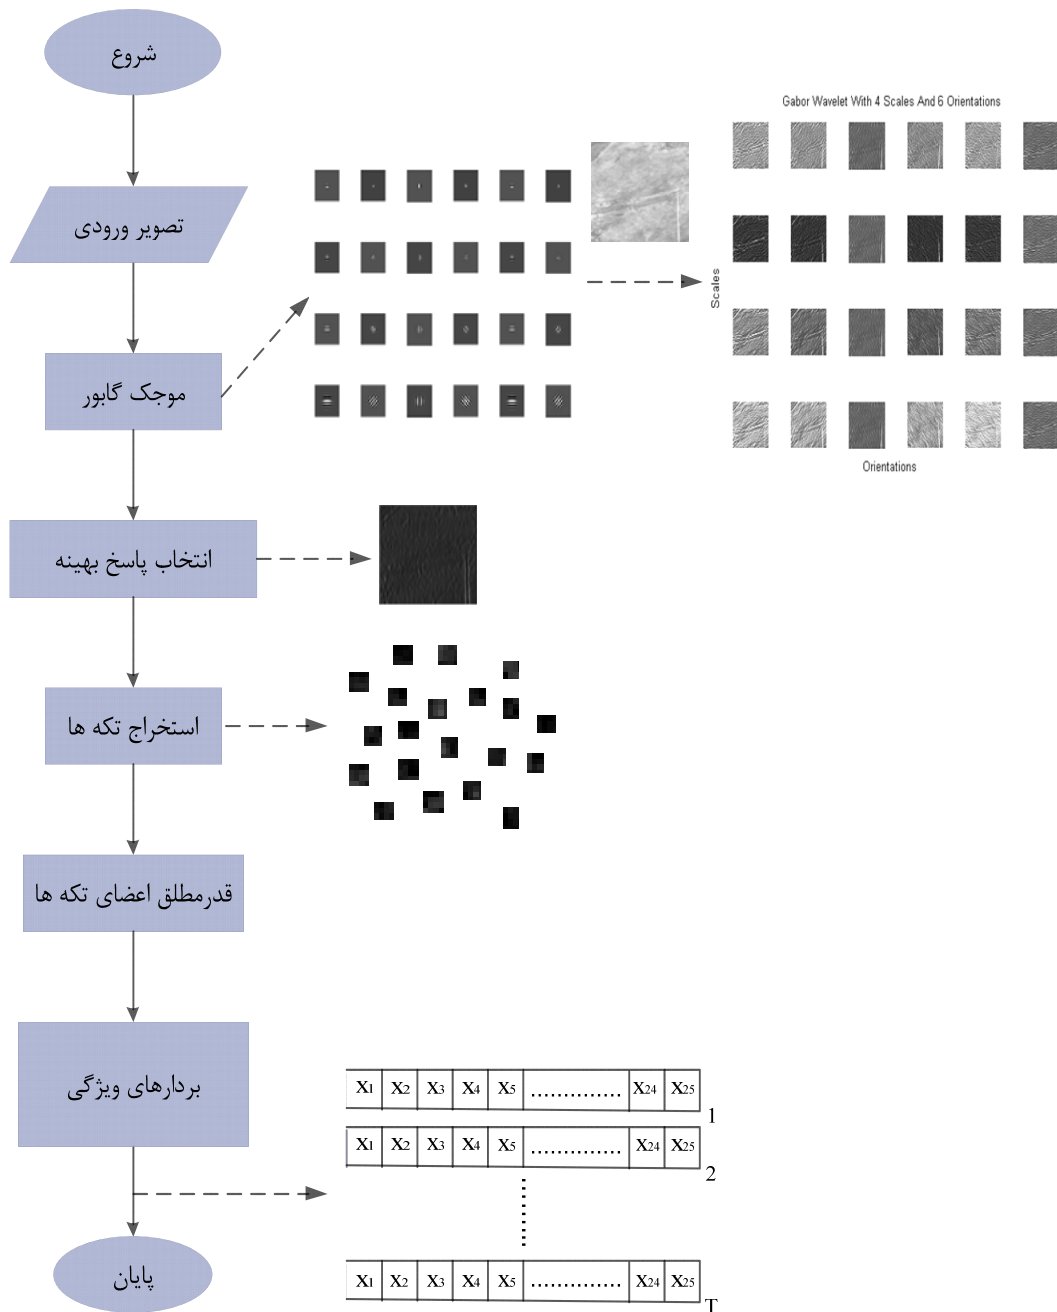
در این روش پیشنهادی، تصویر بافت توسط پنجره‌های استخراج شده از پاسخ بهینه موجک گابور تصویر آموزشی، توصیف می‌گردد. بدین منظور ابتدا تصویر پاسخ بهینه موجک گابور را به پنجره‌های کوچکتری به ابعاد 5×5 که با هم همپوشانی ندارند تقسیم می‌کنیم. برای هر پنجره از تصویر، از اندازه پاسخ بهینه موجک گابور بعنوان بردار ویژگی جهت توصیف بافت پنجره‌های تصویر استفاده می‌نماییم. برای پنجره‌های 5×5 ، یک بردار ویژگی ۲۵ عنصری، توصیف کننده پنجره‌های استخراج شده از پاسخ بهینه موجک گابور می‌باشد.

$$\bar{x}_i = [Q_1, Q_2, \dots, Q_{25}] \quad (۴-۱۱)$$

به ازای هر پنجره تصویر از بافت سالم، یک بردار ویژگی مطابق رابطه (۴-۱۱) استخراج می‌گردد. شکل (۴-۷) روندنمای نحوه استخراج بردارهای ویژگی را نشان می‌دهد. در ادامه، چگالی احتمال بردارهای ویژگی مربوط به تمامی پنجره‌های بافت سالم در $h_{kl}^I(x,y)$ ، توسط مدل مخلوط گوسی

تخمین زده می‌شود. تخمین پارامترهای مدل در این مرحله $(\psi = \{\alpha_i, \mu_i, \sum_{i=1}^K\})$ ، مشابه با الگوریتم

بکار رفته در بخش ۴-۲-۱-ب می‌باشد.



شکل (۴-۷): روندنمای استخراج بردارهای ویژگی در روش پیشنهادی دوم.

در ادامه و با استفاده بردارهای ویژگی استخراج شده از تصویر بافت سالم، مرز آستانه را جهت تعیین معیوب یا سالم بودن پیکسل‌های تصویر آزمون، بطور اتوماتیک محاسبه می‌نماییم. در این مرحله برخلاف روش ارائه شده در روش پیشنهادی اول، از یک تصویر بافت سالم جهت استخراج بردارهای ویژگی و در نتیجه تعیین مقدار مرز آستانه بهره گرفته‌ایم و به منظور تسریع در انجام عملیات، از معیار فاصله اقلیدسی نرمالیزه شده^۱ و همچنین الگوریتم K=means استفاده می‌نماییم. فاصله اقلیدسی نرمالیزه شده بین دو بردار x و y با ابعاد D ، طبق رابطه (۴-۱۲) محاسبه می‌شود [۸۳].

$$d(x, y) = \sqrt{\sum_{n=1}^D \frac{(x_n - y_n)^2}{\delta_{ij}^2}} \quad (۴-۱۲)$$

مراحل انجام کار به اینصورت است که، ابتدا فاصله اقلیدسی وزن‌دار تک‌تک بردارهای ویژگی (ارزش بردار ویژگی) استخراج شده از تصویر بافت سالم را از پارامترهای مدل مخلوط گوسی، مطابق رابطه زیر محاسبه می‌کنیم.

$$dist(\bar{x}_t, \psi) = \sum_{k=1}^K \left(\alpha_k \sqrt{\sum_{n=1}^N \frac{(x_n - \mu_{kn})^2}{\delta_{kn}^2}} \right) \quad (۴-۱۳)$$

که در آن K ، تعداد کل مخلوط‌های گوسی و N تعداد اعضای موجود در بردارهای ویژگی می‌باشد. پس از محاسبه فاصله تمامی بردارهای ویژگی از پارامترهای مدل، اینطور می‌توان عنوان نمود که کمترین مقدار فاصله، بیانگر تعلق بیشتر بردار ویژگی مربوطه به پارامترهای مدل بدست آمده از بردارهای ویژگی بافت‌های سالم می‌باشد. بنابراین بیشترین مقدار از مجموعه مقادیر این فاصله‌ها می‌تواند بعنوان مرز بین ناحیه معیوب و سالم در نظر گرفته شود. جهت یافتن این مقدار از الگوریتم خوشه‌بندی K-means استفاده می‌نماییم. به این ترتیب که، توسط این روش مقادیر فاصله‌های بدست آمده را به L خوشه تقسیم می‌کنیم (بصورت تجربی $L=6$)، و سپس پارامترهای خوشه‌ای که دارای بیشترین

^۱ Normalized Euclidean Distance

میانگین است را محاسبه می‌نماییم. این پارامترها عبارت‌اند از: انحراف معیار خوشه مورد نظر (δ_l) و میانگین خوشه (μ_l). بنابراین مرز ناحیه بین معیوب و ناحیه سالم یا همان مرز آستانه بصورت رابطه (۱۴-۴) قابل محاسبه می‌باشد.

$$\Gamma = \mu_l + \lambda \delta_l \quad (14-4)$$

که مطابق با آن λ ضریب ثابتی است که بصورت تجربی انتخاب می‌گردد و در انجام آزمایشات برابر $(\lambda = 3)$ ، در نظر گرفته شده است.

۴-۳-۲ مرحله آزمون

در این مرحله همچون مرحله آموزش، ابتدا بانک فیلتر موجک گابور را به تصویر تحت بازرسی اعمال نموده و پاسخ بهینه موجک گابور را تعیین می‌نماییم. به ازای هر پیکسل در تصویر ورودی، پنجره‌ای به مرکز پیکسل از اندازه پاسخ بهینه موجک گابور جدا نموده، تا بردار ویژگی توصیف کننده آن پیکسل تشکیل گردد. بعد از استخراج بردارهای ویژگی تصویر تحت بازرسی، فاصله هر یک از این بردارها، از پارامترهای مدل توسط رابطه (۱۳-۴) محاسبه می‌شود.

در مرحله تشخیص تمایزها، اگر فاصله هر بردار ویژگی مربوط به تصویر تحت بازرسی از پارامترهای مدل، بیشتر از مقدار مرز آستانه (Γ) باشد، پیکسل مربوط به بردار ویژگی متناظرش بعنوان ناحیه معیوب شناخته می‌شود. در اینصورت می‌توان یک نقشه عیوب نهایی را بصورت باینری مطابق با رابطه (۱۵-۴) تشکیل داد، و پیکسل‌های معیوب تصویر تحت بازرسی را نشانه‌گذاری و مشخص نمود.

$$D(x, y) = \begin{cases} 1 & dist(x, y) \geq \Gamma \\ 0 & dist(x, y) < \Gamma \end{cases} \quad (15-4)$$

که در آن $dist(x, y)$ مقدار فاصله بردار ویژگی متعلق به پیکسل تصویر تحت بازرسی در مختصات (x, y) می‌باشد.

۴-۴ نتیجه‌گیری

در این فصل به شرح کامل روش‌های پیشنهادی جهت تشخیص عیوب در بافت‌های تصادفی، به کمک مدل مخلوط گوسی پرداختیم. در مرحله آموزش رفتار طبیعی یا نرمال ویژگی‌های محلی تعدادی از بافت‌های سالم، توسط مدل مخلوط گوسی آموزش داده شده و پارامترهای مدل آن تخمین زده می‌شوند. همچنین دو روش جهت استخراج بردارهای ویژگی را ارائه نمودیم. در روش اول، از تبدیل موجک و با استفاده از زیر تصویرهای بدست آمده از آن در مقیاس اول، به استخراج بردارهای ویژگی مطابق با آنچه که در بخش ۴-۲-۱-الف ذکر شد پرداختیم. در روش دوم نیز با استفاده از فیلترهای موجک گابور و انتخاب پاسخ بهینه از مجموعه بانک فیلترها، بردارهای ویژگی را از همسایگی‌های محلی پاسخ بهینه مورد نظر استخراج نمودیم. در این روش از مقادیر سطح خاکستری پیکسل‌های هر همسایگی محلی، بعنوان اعضای بردارهای ویژگی استفاده گردید.

در مرحله آزمون نیز مطابق با رویکرد تشخیص تمایزها، ابتدا مرز آستانه مطابق با آنچه که در این فصل مشاهده کردیم، توسط پارامترهای مدل مخلوط گوسی و بردارهای ویژگی حاصله از تصاویر بافت سالم محاسبه می‌شود. در نهایت هم با مقایسه ارزش بردارهای ویژگی تصویر تحت بازرسی با مرز آستانه، نواحی معیوب را نشانه‌گذاری و مشخص می‌نماییم.

همچنین قابل ذکر است که استخراج بردارهای ویژگی در روش پیشنهادی اول به کمک تبدیل موجک گسسته دیادیک صورت پذیرفت. تبدیل موجک گسسته دیادیک به دلیل آنکه در هر سطح تجزیه فقط نیم باند فرکانس پایین را تجزیه می‌کند و نواحی با فرکانس بالا مجدداً تجزیه نمی‌گردد، لذا نمی‌تواند اطلاعات مربوط به بافت را بخوبی استخراج نماید و در اینصورت بخشی از نواحی فرکانس میانی را از دست می‌دهد. درحالیکه موجک گابور تمام نواحی فرکانسی را حفظ می‌کند. از سوی دیگر در تبدیل موجک گسسته دیادیک صفحه فرکانس فضایی بصورت لگاریتمی تجزیه می‌گردد. درحالیکه با استفاده از تبدیل موجک گابور، باندهای فرکانسی می‌تواند بصورت ترکیبی از تغییرات لگاریتمی و

یکنواخت تجزیه گردد. بنابراین یک روش تجزیه انعطاف پذیرتر در تمام باند فرکانسی قابل دستیابی است که منجر به قابلیت بالایی در جداسازی اطلاعات بافت می گردد. این امر انگیزه‌ای برای معرفی روش دوم برای استخراج بردارهای ویژگی به کمک فیلترهای موجک گابور بود. همچنین در روش پیشنهادی اول مشاهده گردید که زمان پردازش عملیات در آن کمی بالا بنظر می رسد. بنابراین در روش پیشنهادی دوم سعی بر حل این مشکل، با استفاده از در نظر گرفتن مشاهدات خام همسایگی- های محلی بعنوان اعضای بردارهای ویژگی و همچنین استفاده از یک تصویر بافت سالم جهت تعیین مرز آستانه (بدلیل استفاده از روش K-means)، نمودیم. چراکه همانطور که قبلاً هم به آن اشاره شد، زمان پردازش نقش بسیار مهمی را در قابل استفاده بودن یک روش تشخیص عیوب در کاربردهای صنعتی ایفا می کند.

فصل پنجم

نتایج و ارزیابی روش‌های پیشنهادی


۵-۱ مقدمه

در این فصل، روش‌های پیشنهادی مطرح شده در این پایان‌نامه را در عمل توسط مجموعه‌ای از تصاویر بافت‌های واقعی مورد ارزیابی کمی و کیفی قرار می‌دهیم. به همین منظور از تصاویر کاشی‌های سرامیکی که دارای سطوحی با بافت‌های تصادفی می‌باشند استفاده می‌نماییم. ابتدا به معرفی بانک تصاویر مورد استفاده در آزمایشات می‌پردازیم و نحوه تولید نقشه‌هایی موسوم به نقشه‌های صحت را شرح می‌دهیم. از این نقشه‌ها جهت اندازه‌گیری میزان دقت روش پیشنهادی همانند یک کلید استفاده می‌شود. سپس نحوه مقداردهی و انتخاب پارامترهای آزاد روش‌های پیشنهادی نظیر ابعاد همسایگی-های محلی، تعداد مخلوط‌های گوسی و تنظیم پارامترهای بانک فیلتر موجک گابور را شرح خواهیم داد. در ادامه به بررسی کیفی روش‌های مزبور پرداخته، و مثال‌هایی از کیفیت تشخیص عیوب در بافت‌های سطح خاکستری را ارائه می‌نماییم. پس از آن به بررسی کمی روش‌های پیشنهادی می‌پردازیم و آنها را با روش مبتنی بر TEXEM [۱۷] که در فصل دوم به معرفی آن پرداختیم، توسط سه معیار آماری مقایسه می‌نماییم. در نهایت روش‌های مذکور را به لحاظ پیچیدگی محاسباتی مقایسه می‌نماییم. لازم به ذکر است که روش‌های مورد بررسی در محیط نرم‌افزاری MATLAB پیاده‌سازی شده‌اند.

۵-۲ بانک تصاویر و تهیه نقشه صحت

در فصل اول اشاره نمودیم که سطح بسیاری از اشیاء نظیر کاشی‌ها، دارای بافت تصادفی و یا شبه تصادفی می‌باشد و همچنین بازبینی خودکار سطح آنها به منظور تشخیص عیوب سطحی از اهمیت ویژه‌ای برخوردار است. همانطور که در فصل گذشته مشاهده گردید، اساساً روش‌های پیشنهادی برای تشخیص عیوب در بافت‌های سطح خاکستری طراحی شده است و تشخیص عیوب بافت‌های رنگی تعمیمی از حالت سطح خاکستری است، چرا که در مورد بافت‌های رنگی، روش سطح

خاکستری را می‌توان بر روی هر کانال رنگی بصورت مجزا اعمال نمود. بدیهی است که تصویر موجود در هر کانال رنگی را می‌توان همانند یک تصویر سطح خاکستری مجزا در نظر گرفت. بنابراین اندازه-گیری دقت روش‌های پیشنهادی بر روی بافت‌های سطح خاکستری چه از لحاظ کمی و چه از لحاظ کیفی، به‌خوبی می‌تواند بیانگر دقت و کیفیت این روش‌ها در مورد بافت‌های تصادفی رنگی نیز باشد. لذا به منظور ارزیابی کمی و کیفی روش‌های پیشنهادی، این روش‌ها را بر روی مجموعه‌ای از تصاویر سطح خاکستری کاشی‌های سرامیکی اعمال نموده‌ایم. در این مجموعه از تصاویر، هفت خانواده مختلف کاشی با طرح‌های متفاوت، مجموعاً به تعداد ۶۳ عدد تصویر با اندازه 256×256 استفاده شده است که تعداد ۲۸ عدد تصویر سالم و بدون عیب بوده و ۳۵ عدد از آنها نیز دارای عیوب مختلفی در سطح بافت می‌باشند. این عیوب در اندازه‌های مختلف بوده و نوع آنها نیز متفاوت می‌باشد. از جمله این عیوب می‌توان به عیوب فیزیکی و عیوب بافتی اشاره نمود. از این تصاویر معیوب، جهت ساخت تصاویری دودویی موسوم به " نقشه صحت "^۱ استفاده می‌نماییم. بدین ترتیب که، با کمک یک ناظر و یا اپراتور انسانی، مکان‌های معیوب را بطور دستی در یک تصویر جداگانه موسوم به نقشه صحت یا درستی، برچسب‌گذاری می‌کنیم. بنابراین یک نقشه صحت، در حقیقت یک تصویر باینری متناظر با یک تصویر بافت معیوب است که در آن نواحی معیوب برچسب یک گرفته‌اند (شکل ۵-۱). در ادامه نحوه استفاده از این نقشه‌ها را خواهیم دید.



(ب)



(الف)

شکل (۵-۱): (الف) نمونه ای از یک نقشه صحت برای یک بافت معیوب (ب).

^۱ Ground-Truth Maps

۵-۳ انتخاب پارامترهای آزاد روش‌های پیشنهادی

همانطور که در فصل چهارم اشاره نمودیم، در مرحله تعیین مرز آستانه روش پیشنهادی اول، به تعدادی از تصاویر آموزشی بافت سالم نیاز داریم. در این تحقیق، فقط از چهار تصویر آموزشی برای هر خانواده از تصاویر کاشی‌ها استفاده شده است. بدیهی است که با استفاده بیشتر از تصاویر آموزشی جهت تعیین مرز آستانه، می‌توان دقت نهایی روش پیشنهادی را افزایش داد. اما همانطور که در ادامه خواهید دید، افزایش نمونه‌های آموزشی حجم محاسبات را بالا می‌برد. لذا تنها از چهار تصویر آموزشی سالم برای هر خانواده بافتی استفاده نموده‌ایم. در مرحله تعیین مرز آستانه روش پیشنهادی دوم، اینکار را فقط با استفاده از یک تصویر آموزشی انجام دادیم، که دلیل آن هم استفاده از روش خوشه‌بندی K-means به منظور کاهش حجم محاسبات می‌باشد.

علاوه بر تعداد تصاویر آموزشی، پارامتر آزاد دیگری که در روش‌های پیشنهادی می‌بایست تعیین گردد، انتخاب تعداد مخلوط‌های گوسی جهت مدل‌سازی است. همانطور که در ادامه این بخش خواهیم دید، در آزمایشات تجربی خود در روش پیشنهادی اول، به این نتیجه رسیدیم که در اکثر بافت‌ها، تعداد دوازده مخلوط گوسی ($K=12$) جهت مدل‌سازی بافت سالم مناسب است. هر چند که بسته به نوع کاربرد و همچنین نوع بافت مورد بررسی، این تعداد می‌بایست بصورت تجربی و سعی و خطا به شکل مناسب انتخاب گردد که هم دقت روش پیشنهادی در آن لحاظ شود و هم باعث بالا رفتن حجم محاسبات نگردد. بنابراین در کلیه آزمایشات خود در روش پیشنهادی اول از دوازده مخلوط گوسی برای مدل‌سازی استفاده نمودیم. شکل (۵-۲) تأثیر تعداد مخلوط‌های گوسی را بر روی نتیجه تشخیص عیوب به ازای مقادیر مختلف K نشان می‌دهد. همانطور که از این شکل مشخص است، نقشه عیوب حاصله توسط $K=7$ ، نسبت به نقشه عیوب حاصله از $K=12$ ، از دقت پایین‌تری برخوردار است.



(ج)

(ب)

(الف)

شکل (۵-۲): تأثیر تعداد مخلوط‌های گوسی در دقت نهایی تشخیص عیوب، در روش پیشنهادی اول. (الف) تصویر بافت سالم، (ب) تصویر نقشه عیوب نهایی با ۷ مخلوط گوسی، (ج) نقشه نهایی عیوب با ۱۲ مخلوط گوسی.

بر اساس مشاهدات صورت گرفته در روش پیشنهادی دوم، به این نتیجه رسیدیم که بهترین مقدار برای تعداد مخلوط‌های گوسی، $K=5$ می‌باشد. لازم به ذکر است، دلیل اینکه از تعداد مخلوط‌های گوسی کمتری در روش دوم نسبت به روش اول استفاده نمودیم این بود که در روش پیشنهادی اول بردارهای ویژگی از پراکندگی بیشتری نسبت به هم برخوردار بودند، درحالی‌که در روش پیشنهادی دوم این پراکندگی خیلی کمتر بود و به همین دلیل توانستیم با تعداد کمتری از مخلوط‌های گوسی بردارهای ویژگی را مدل‌سازی نماییم.


پارامتر دیگری که در هر دو روش پیشنهادی از آن استفاده گردید، ابعاد همسایگی‌های محلی یا همان پنجره‌ها می‌باشد. که در هر دو روش از پنجره‌ای با ابعاد $N=5 \times 5$ ، استفاده گردید. تنظیم پارامترهای بانک فیلتر گابور اعمالی در روش پیشنهادی دوم نیز بصورت ذیل می‌باشد:

- پایین‌ترین فرکانس مرکزی: $U_L = 0.1$
- بالاترین فرکانس مرکزی: $U_h = 0.4$
- سایز ماسک‌های فیلتر گابور: 11×11
- تعداد مقیاس‌های بانک فیلتر: $M=4$
- تعداد جهت‌های بانک فیلتر: $N=6$


تعیین پارامترهای فیلترهای گابور تشکیل دهنده بانک فیلتر، مربوط می‌شود به انتخاب فرکانس‌ها و جهات هر کدام از این فیلترها بطوریکه حوزه فرکانس تا حد امکان بوسیله بانک فیلتر مذکور پوشش داده شده و اطلاعات بافت را بخوبی استخراج نماید. فرکانس‌های مرکزی فیلترهای طراحی شده باید تا حد امکان به ویژگی فرکانسی بافت‌ها نزدیک باشند، در غیراینصورت پاسخ بافت به فیلتر بشدت آفت پیدا می‌کند. هر اندازه که ویژگی فرکانسی یک بافت به ویژگی فرکانسی فیلتری نزدیک‌تر باشد، پاسخ بافت مذکور به آن فیلتر بیشتر خواهد بود. لذا در این تحقیق، با توجه به مطالب ذکر شده و انجام آزمایشات مختلف، $U_L = 0.1$ و $U_h = 0.4$ بعنوان گزینه مناسب جهت تعیین فرکانس‌های مرکزی، در نظر گرفته شد. همچنین تعداد اعضای بانک فیلتر در این تحقیق، ۲۴ فیلتر می‌باشد که در ۴ مقیاس و ۶ جهت، طراحی شده است. لازم به ذکر است که انتخاب تعداد زیاد اعضای بانک فیلتر سبب ایجاد اطلاعات اضافی شده و باعث افزایش حجم محاسبات می‌گردد. در مقابل انتخاب تعداد کم فیلترها در بانک فیلتر، سبب از دست رفتن جزئیات بافت می‌شود. یکی دیگر از پارامترهای مهم دیگر در طراحی بانک فیلتر گابور، ابعاد ماسک مورد استفاده جهت انجام عملیات کانولوشن در حوزه مکان می‌باشد. ابعاد ماسک باید طوری انتخاب گردد که مصالحه‌ای بین دقت و سرعت انجام محاسبات برقرار شود [۴۴]. بنابراین در این تحقیق از ماسکی به ابعاد 11×11 استفاده شده است.

۴-۵ ارزیابی کیفی روش‌های پیشنهادی

در این بخش به ارزیابی کیفی روش‌های پیشنهادی و مقایسه آنها با روش TEXEM [۱۷]، می‌پردازیم. در شکل (۴-۵) مثال‌هایی از کیفیت تشخیص عیوب توسط روش‌های پیشنهادی ارائه شده در این پایان‌نامه و روش TEXEM، بر روی نمونه‌هایی از بافت‌های مختلف سطح خاکستری نمایش داده شده است. همانطور که از این شکل‌ها مشاهده می‌گردد، الگوی بافتی تصاویر بافت‌های سالم با بافت‌های معیوب متفاوت است، اما از دیدگاه ظاهری، دارای بافتی یکسان به نظر می‌رسند. این مثال‌ها، توانایی روش‌های پیشنهادی را جهت تشخیص عیوب از اندازه‌های کوچک تا اندازه‌های بزرگ نشان می‌دهد. همچنین تصویر بافت سالم هر یک از خانواده‌های مورد استفاده در آزمایشات، در شکل (۳-۵) بعنوان نمونه آورده شده است.



شکل(۳-۵): تصویر نمونه بافت سالم از خانواده‌های مختلف که در آزمایشات مورد استفاده قرار گرفته است.



شکل (۴-۵): مثال هایی از فرآیند تشخیص عیوب بر روی بافت های مختلف از چهار خانواده. تصاویر بافت های معیوب (از سمت چپ ستون اول)، نقشه عیوب حاصله از روش پیشنهادی اول (از چپ ستون دوم)، نقشه عیوب حاصله از روش پیشنهادی دوم (از سمت چپ ستون سوم)، نقشه عیوب حاصله از روش TEXEM (از چپ ستون چهارم).

۵-۵ ارزیابی کمی روش‌های پیشنهادی

اکنون به شرح روش استفاده شده جهت ارزیابی کمی^۱ روش‌های پیشنهادی می‌پردازیم. برای این منظور، ابتدا روش‌های پیشنهادی را بر روی مجموعه تصاویر ذکر شده اعمال نموده و سپس نقشه عیوب بدست آمده را با نقشه‌های صحت متناظر با تصویر هر بافت معیوب مقایسه نموده و نتایج مقایسه را توسط سه معیار زیر کمی‌سازی^۲ می‌نماییم:

- میزان حساسیت^۳

- میزان اختصاصی بودن^۴

- میزان صحت یا دقت^۵

میزان حساسیت نشان می‌دهد که تا چه اندازه پیکسل‌های معیوب به درستی تشخیص داده شده‌اند، میزان اختصاصی بودن نشان می‌دهد که تا چه اندازه پیکسل‌های سالم به درستی تشخیص داده شده‌اند و میزان صحت بیانگر میزان تشخیص صحیح کلیه پیکسل‌های موجود در تصویر می‌باشد. این سه معیار بصورت رابطه (۵-۱) تعریف می‌گردند:

$$\text{Sensitivity} = \frac{TP}{TP + FN} \times 100\%$$

$$\text{Specificity} = \frac{TN}{TN + FP} \times 100\% \quad (5-1)$$

$$\text{Accuracy} = \frac{TN + TP}{TN + FP + FN + TP} \times 100\%$$

که مطابق با آن

- TP بیانگر *True Positives* و یا تعداد پیکسل‌های معیوبی است که به درستی تشخیص

داده شده‌اند.

^۱ Quantitative Evaluation

^۲ Quantify

^۳ Sensitivity

^۴ Specificity

^۵ Accuracy

- *TN* بیانگر *True Negatives* و یا تعداد پیکسل‌های سالمی است که به درستی تشخیص داده شده‌اند.

- *FP* بیانگر *False Positives* و یا تعداد پیکسل‌های سالمی است که به غلط معیوب تشخیص داده شده‌اند.

- *FN* بیانگر *False Negatives* و یا تعداد پیکسل‌های معیوبی است که به غلط سالم تشخیص داده شده‌اند.

حال با اعمال سه معیار فوق بر روی کلیه تصاویر موجود در بانک مورد استفاده، می‌توان دقت و کیفیت روش‌های پیشنهادی را محاسبه نمود. جدول (۵-۱) کارایی روش‌های پیشنهادی و همچنین روش Gray-Level TEXEM [۱۷] را بر اساس معیارهای معرفی شده در بالا نشان می‌دهد.

جدول (۵-۱): ارزیابی کمی روش‌های پیشنهادی و مقایسه آن با روش TEXEM، از لحاظ کارایی توسط سه معیار "میزان حساسیت"، "میزان اختصاصی بودن"، "میزان صحت".

روش استفاده شده	میزان حساسیت	میزان اختصاصی بودن	میزان صحت
روش پیشنهادی اول	۸۸/۸	۸۹/۹	۸۹/۳۵
روش پیشنهادی دوم	۹۱/۴	۹۳/۵	۹۲/۴۵
Gray-Level TEXEM [۱۷]	۹۲/۸	۹۳/۲	۹۳

همانطور که از این جدول مشاهده می‌شود، بالاترین میزان صحت مربوط به روش TEXEM [۱۷]، بالاترین میزان اختصاصی بودن مربوط به روش پیشنهادی دوم و در نهایت بالاترین میزان حساسیت مجدداً مربوط به روش TEXEM [۱۷] می‌باشد. بدین ترتیب از آنجاییکه روش TEXEM حداقل در دو معیار کارایی، عملکرد بهتری نسبت به سایر روش‌ها از خود نشان داده، لذا می‌توان نتیجه گرفت

که روش TEXEM نسبت سایر روش‌ها از کارایی بهتری برخوردار است. در نهایت با مقایسه روابط فوق می‌توان کارایی این سه روش را بر اساس آزمایشات انجام گرفته بصورت زیر بیان نمود.

روش TEXEM < روش پیشنهادی دوم < روش پیشنهادی اول

البته منظور از کارایی در این بخش، میزان دقت در فرآیند تشخیص عیوب بوده است. بدیهی است که در بعضی از کاربردها، مسائلی نظیر میزان حجم محاسبات بطور قابل توجهی در مفهوم کارایی یک روش تأثیرگذار خواهد بود.

۵-۶ ارزیابی محاسباتی روش‌های پیشنهادی

از دیدگاه محاسباتی، همانطور که قبلاً اشاره گردید، واضح است که روش پیشنهادی دوم سریعتر از روش پیشنهادی اول می‌باشد، چرا که استفاده از مشاهدات خام محلی بعنوان اعضای بردارهای ویژگی در روش پیشنهادی دوم نسبت به استخراج بردارهای ویژگی توسط روابط ذکر شده در روش اول، و همچنین تعداد مخلوط‌های گوسی کمتر بکار رفته در روش پیشنهادی دوم نسبت به روش اول، می‌تواند از دلایل این امر باشد. جدول (۵-۲)، میانگین زمان پردازش روش‌های پیشنهادی و روش TEXEM را بر روی تعدادی از نمونه‌ها، هم در مرحله آموزش و هم در مرحله آزمون که بر روی یک پردازنده ۲.۶۶GHz، Pentium 5 با سیستم عامل Windows و ۴GB RAM صورت گرفته است را نشان می‌دهد. یک ویژگی مهم دیگری که روش پیشنهادی دوم نسبت به روش اول و TEXEM دارد این است که از یک تصویر بافت سالم در مرحله تشخیص تمایزها جهت تعیین مرز آستانه، استفاده می‌گردد. که این خود یک عامل مهم در کاهش زمان پردازش می‌باشد.

جدول (۵-۲): ارزیابی روش های پیشنهادی و روش TEXEM از لحاظ زمان پردازش در مراحل آموزش و آزمون.

روش استفاده شده	زمان پردازش در مرحله آموزش	زمان پردازش در مرحله آزمون
روش پیشنهادی اول	۳۴ ثانیه	۱۲ ثانیه
روش پیشنهادی دوم	۹ ثانیه	۲ ثانیه
Gray-level TEXEM	۱۳۱ ثانیه	۱۵ ثانیه

همانطور که از جدول بالا مشخص است زمان پردازش در روش پیشنهادی دوم، چه در مرحله آموزش و چه در مرحله آزمون، سریعتر از دو روش دیگر می باشد. این ویژگی در حجم محاسبات باعث می شود که روش پیشنهادی دوم جهت پیاده سازی صنعتی، مناسبتر از سایر روش های معرفی شده باشد. بطور خلاصه می توان زمان پردازش محاسبات در مرحله آزمون و آزمایش را بصورت زیر بیان نمود.

روش پیشنهادی دوم < روش پیشنهادی اول < روش TEXEM

فصل ششم

نتیجه‌گیری و ارائه پیشنهادات

۶-۱ نتیجه‌گیری

در این پایان‌نامه، روش جدیدی را برای تشخیص و موقعیت‌یابی خودکار عیوب بافت‌های تصادفی در تصاویر سطوح خاکستری به کمک مدل مخلوط گوسی ارائه نمودیم. همانطور که در فصل اول اشاره گردید، برخلاف روش TEXEM [۱۷]، که در آن مدل‌سازی بافت در حوزه مکانی صورت پذیرفت، این اولین باری است که از ویژگی‌های استخراج شده در حوزه فرکانس، جهت مدل‌سازی بافت‌های تصادفی استفاده می‌گردد. ساختار این پایان‌نامه بر اساس مدل‌سازی ویژگی‌های بدست آمده از تصاویر بافتهای تصادفی می‌باشد که طی دو روش پیشنهادی، جهت تشخیص نواحی معیوب ارائه گردید. به این نحو که در روش پیشنهادی اول از ویژگی‌های استخراج شده از تبدیل موجک، و در روش پیشنهادی دوم از ویژگی‌هایی که حاصل اعمال بانک فیلتر موجک گابور، جهت مدل‌سازی استفاده شد.

در این پایان‌نامه، روش‌های پیشنهادی را با روش اخیر ارائه شده در زمینه تشخیص عیوب بافت‌های تصادفی یعنی TEXEM [۱۷]، هم از نظر دقت و هم از نظر حجم محاسباتی مورد مقایسه قرار دادیم. این مقایسه با اعمال هر سه روش مذکور بر روی بانکی از تصاویر بافتی سطح کاشی‌های سرامیکی انجام گرفت که در این بانک، هفت خانواده مختلف بافتی با عیوب گوناگون و اندازه‌های متفاوت وجود داشتند. برای اندازه‌گیری میزان کارایی و دقت هر یک از این روش‌ها، از سه معیار کارایی به نام‌های "میزان صحت"، "میزان اختصاصی بودن" و "میزان حساسیت" استفاده گردید. همانطور که مشاهده گردید، دقت روش‌های پیشنهادی نسبت به روش TEXEM اندکی پایین‌تر می‌باشد.

از آنجاییکه در بسیاری از کاربردهای عملی نظیر بازبینی بصری و خودکار سطوح^۱، قابلیت پیاده‌سازی بلادرنگ^۲ یک روش تشخیص عیوب بافتی از اهمیت بسیار ویژه‌ای برخوردار است، لذا

^۱ Automatic Visual Surface Inspection

^۲ Real-Time Implementation

حجم و هزینه‌های محاسباتی یک روش نقش بسزایی در میزان کارایی آن خواهد داشت. بدین منظور، سه روش مذکور را نیز از دیدگاه محاسباتی با یکدیگر مقایسه نمودیم. در این مورد مشاهده گردید که سرعت زمان پردازش در روش پیشنهادی دوم، چه در مرحله آموزش و چه در مرحله آزمون از سایر روش‌ها بیشتر می‌باشد، و می‌تواند در کنار کارایی بالای آن کاندیدای مناسبی جهت پیاده‌سازی صنعتی به‌شمار آید.

همچنین لازم به ذکر است که در این پایان‌نامه، روش‌های پیشنهادی را بر روی تصاویر سطح کاشی‌های سرامیکی اعمال نموده‌ایم، اما روش‌های مذکور را می‌توان بر روی هر بافت تصادفی دلخواه دیگری نظیر سطح چوب، چرم و یا حتی پارچه و بافت‌های پزشکی نیز اعمال نمود. در این کاربردها نیز روش‌های تشخیص عیوب بافتی از اهمیت ویژه‌ای برخوردار هستند.

۶-۲ پیشنهادات و تحقیقات آینده

در این پایان‌نامه، اشاره شد که تعداد مخلوط‌های گوسی و ابعاد همسایگی‌های محلی در هر دو روش پیشنهادی را بصورت تجربی، انتخاب نموده‌ایم. بدیهی است یافتن روشی خودکار در این زمینه، کمک شایانی به افزایش کارایی و تمام خودکار نمودن روش پیشنهادی خواهد نمود.

گسترش روش‌های پیشنهادی به بافت‌های تصادفی رنگی نیز یکی دیگر از موضوعاتی است که می‌تواند مورد بررسی قرار گیرد. در همین راستا لازم به ذکر است که بطور کلی دو دسته عیوب می‌توانند وجود داشته باشند. دسته اول موسوم به عیوب بافتی^۱ هستند و دسته دیگر عیوب رنگی^۲ نامیده می‌شوند. همچنین باید توجه داشت که در بسیاری از کاربردها، یک عیب رنگی ممکن است یک عیب بافتی نباشد و لذا روش‌های تشخیص عیوب بافتی بطور مستقیم قادر به تشخیص عیوب رنگی با بافت سالم نمی‌باشند. بنابراین می‌توان اطلاعات رنگی و بافتی را مکمل یکدیگر در نظر گرفت.

^۱ Textural Defects

^۲ Chromatic Defects

در بخش پیش نیز اشاره نمودیم که روش پیشنهادی را می‌توان در کاربردهای دیگری در زمینه
تشخیص عیوب بافت، از جمله کاربردهای پزشکی مورد استفاده قرار داد که این مسئله را بعنوان
تحقیقات بعدی مورد بررسی قرار خواهیم داد.

مراجع

- [1] Bennamoun, M., and Bodnarova, A. (2003), "Digital image processing techniques for automatic textile quality control", *Systems Analysis Modelling Simulation*, pp. 1581–1614.
- [2] Boukouvalas, C., Kittler, J., Marik, R., Mirmehdi, M., and Petrou, M. (1995), "Ceramic tile inspection for colour and structural defects", *Proceedings of Advanced Materials and*, pp. 390–399.
- [3] Costa, C., and Petrou, M. (2000), "Automatic registration of ceramic tiles for the purpose of fault", *Machine Vision and Applications*, pp. 225–230.
- [4] Hocenski, Z., Keser, T., and Baumgartner, A. (2007), "A Simple and Efficient Method for Ceramic Tile Surface Defects Detection", *Machine Vision and Applications*.
- [5] Khodaparast, A., and Mostafa, A. (2003), "On line quality control of tiles using wavelet and statistical properties", *Proceedings of the 2nd Iranian Conference on Machine Vision*. iran.
- [6] Kim, C., and Koivo, A. (1994), "Hierarchical classification of surface defects on dusty wood boards", *Pattern Recognition Letters*, pp. 713–721.
- [7] Kumar, A. (2003), "Neural network based detection of local textile defects", *Pattern Recognition*, pp. 1645–1659.
- [8] Niskanen, M., Silv'én, O., and Kauppinen, H. (2001), "Color and texture based wood inspection with nonsupervised clustering", *Proceedings of the 12th Scandinavian Conference on Image Analysis*, pp. 336–342.
- [9] Pernkopf, F. (2004), "Detection of surface defects on raw steel blocks using Bayesian network classifiers", *Pattern Analysis and Applications*, pp. 333–342.
- [10] Zhou, H., Kassim, A., and Ranganath, S. (1998), "A fast algorithm for detecting and extracting defects in IC packages", *Machine Vision and Application*.
- [11] Mirmehdi, M., and Xie, X. (2008), *"Handbook of Texture Analysis"*. Imperial College press.
- [12] Xie, X., and Mirmehdi, M. (2007), "TEXEM: Texture exemplars for defect detection on random textured surfaces", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 29(8):1454–1464.
- [13] Hadizadeh, H., and Lopez, F. (2007), "Defect Detection in Random Color Textures using the Modified MIA T^2 Defect Maps", *4th Iranian Machine Vision Conf*, Mashhad, Iran.

- [14] Lopez, F., Prats, J.M., Ferrer, X., and Valiente, J.M. (2006), " Defect Detection in Random Color Textures using the MIA T^2 Defect Maps", *3rd International conference on Image Analysis and Recognition*, Povo de Varzim , Portugal. pp 752-763.
- [15] Monadjemi, A., Mirmehdi, M. and Thomas, B. (2004), "Restructured eigenfilter matching for novelty detection in random textures", In *British Machine Vision Conference*, pp. 637–646.
- [16] Monadjemi, A. (2004), PhD thesis. "Towards Efficient Texture Classification and Abnormality Detection". University of Bristol, UK.
- [17] Xie, X., and Mirmehdi, M. (2005), "Texture exemplars for defect detection on random textures". In *International Conference on Advances in Pattern Recognition*, pp. 404–413.
- [18] Boukouvalas, C., Kittler, J., Marik, R., and Petrou, M. (1999), " Color grading of randomly textured ceramic tiles using color histograms", *IEEE Transactions on Industry Electronics*, 46(1):219–226.
- [19] Ruber, Y., Tomasi, C., and Guibas, I. (2000), "The Earth Mover's distance as a Metric for Image Retrieval". *International Journal of Computer Vision*, pp. 99-121.
- [20] Levina, E., and Bickel, P. (2001), "The Earth Mover's distance is the Mallows distance some insights from ststistics", *International Journal of Computer Vision*, pp. 251-256.
- [21] Swain, M., and Ballard, D. (1990), "Indexing via color histograms", *International Journal of Computer Vision*, 7(1):11–32.
- [22] Pietikainen, M., Maenpaa, T., and Viertola, J. (2002), "Color texture classification with color histograms and local binary patterns", In *International Workshop on Texture Analysis and Synthesis*, pp. 109–112.
- [23] Broadhurst, R., Stough, J., Pizer, S., and Chaney, E. (2005), " Histogram statistics of local image regions for object segmentation". In *International Workshop on Deep Structure, Singularities, and Computer Vision*.
- [24] Tsai, I., Lin, C., and Lin, J. (1995), "Applying an artificial neural network to pattern recognition", *Textile Research Journal*, 65:123–130.
- [25] Haralick, R., Shanmugan, K., and Dinstein, I. (1973), "Textural features for image classification", *IEEE Transactions on Systems, Man, and Cybernetics*, 3(6):610–621.
- [26] Siew, L., Hodgson, R., and Wood, E. (1988), "Texture measures for carpet wear assessment", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 10:92–105.
- [27] Iivarinen, J., Rauhamaa, J., and Visa, A. (1996), "Unsupervised segmentation of surface defects", In *International Conference on Pattern Recognition*, pp. 356–360.

- [28] Tuceryan, M., and Jain, A. (1998), "Texture analysis". In *Handbook of Pattern Recognition and Computer Vision*, chapter 2, pp. 235–276.
- [29] Iivarinen, J. (2000), "Surface defect detection with histogram-based texture features". In *SPIE Intelligent Robots and Computer Vision XIX: Algorithms, Techniques, and Active Vision*, volume 4197, pp. 140–145.
- [30] Coroyer, C., Declercq, D., and Duvaut, P. (1997), "Texture classification using third order correlation tools". In *IEEE Signal Processing Workshop on High-Order Statistics*, pp. 171–175.
- [31] Huang, Y., and Chan, K. (2004), "Texture decomposition by harmonics extraction from higher order statistics". *IEEE Transactions on Image Processing*, 13(1):1–14.
- [32] Unser, M., and Ade, F. (1984), "Feature extraction and decision procedure for automated inspection of textured materials". *Pattern Recognition Letters*, 2(3):185–191.
- [33] Ojala, T., et al. (1996), "A comparative study of texture measures with classification based on feature distribution". *Pattern Recognition*, 29(1).
- [34] Maenpaa, T., Pietikainen, M., and Ojala, T. (2000), "Texture classification by multi-predicate local binary pattern operators". In *Proceedings of International Conference on Pattern Recognition*.
- [35] Ojala, T., Pietikainen, M., and Maenpaa, T. (2002), "Multiresolution gray-scale and rotation invariant texture classification with local binary patterns". *IEEE Transactions on Pattern Analysis and Machine Intelligence*.
- [36] Zucker, S. (1976), "Toward a model of texture", *Computer Graphics and Image Processing*. 5,190–202.
- [37] Julesz, B. (1981), "Textons, the element of texture perception and their interactions", *Nature*.290, 91–97.
- [38] Leung, T., and Malik, J. (2001), "Representing and recognizing the visual appearance of materials using three-dimensional textons", *International Journal of Computer Vision*. 43 (1), 29–44.
- [39] Zhu, S., Guo, C., Wang, Y., and Xu, Z. (2005). "What are textons?", *International Journal of Computer Vision*. 62(1-2), 121–143.
- [40] Schmid, C. (2001), "Constructing models for content-based image retrieval", In *IEEE Conference on Computer Vision and Pattern Recognition*, vol. 2, pp. 39–45.
- [41] Malik, J., and Perona, P. (1990), "Preattentive texture discrimination with early vision mechanisms", *Journal of the Optical Society of America, Series A*, 7:923–932.
- [42] Ade, F. (1983), "Characterization of texture by 'eigenfilter'", *Signal Processing*, 5(5):451–457.
- [43] Jolliffe, I. (1986), "Principal Component Analysis". *Springer-Verlag*.

- [44] Kumar, A., and Pang, G. (2002), "Defect detection in textured materials using Gabor filters", *IEEE Transactions on Industry Applications*, 38(2):425–440.
- [45] Neubauer, C. (1992), "Segmentation of defects in textile fabric", In *Proceedings of the 7th International Conference on Pattern Recognition*, volume 1, pp. 688–691.
- [46] Unser, M., and Ade, F. (1984), "Feature extraction and decision procedure for automated inspection of textured materials", *Pattern Recognition Letters*, 2(3):185–191.
- [47] D'Astous, F., and Jernigan, M. (1984), "Texture discrimination based on detailed measures of the power spectrum", In *International Conference on Pattern Recognition*, pp. 83–86.
- [48] Tsai, D., and Heish, C. (1999), "Automated surface inspection for directional textures", *Image and Vision Computing*, 18(1):49–62.
- [49] Tsai, D., and Huang, T. (2003), "Automated surface inspection for statistical textures", *Image and Vision Computing*, 21:307–323.
- [50] Daugman, J. (1980), "Two-dimensional spectral analysis of cortical receptive field profiles", *Vision Research*, 20:847–856.
- [51] Latif-Amet, L., Ertuzun, A., and Ercil, A. (2000), "An efficient method for texture defect detection: Subband domain co-occurrence matrices", *Image and Vision Computing*, 18(6-7):543–553.
- [52] Scharcanski, J. (2005), "Stochastic texture analysis for monitoring stochastic processes in industry". *Pattern Recognition Letters*, 26:1701–1709.
- [53] Yang, X., Pang, G., and Yung, N. (2005), "Robust fabric defect detection and classification using multiple adaptive wavelets". *IEEE Proceedings Vision, Image Processing*, 152(6):715–723.
- [54] Mandelbrot, B. (1983), *The Fractal Geometry of Nature*, W.H. Freeman.
- [55] Li, S. (2001), "Markov Random Filed Modeling in Image Analysis", *Springer*.
- [56] Jojic, N., Frey, N., and Kannan, A. (2003), "Epitomic analysis of appearance and shape"., In *IEEE International Conference on Computer Vision*, pp.34–42.
- [57] Conci, A., and Proenca, C. (1998), "A fractal image analysis system for fabric inspection based on box-counting method", *Computational Networks*, 30:1887–1895.
- [58] Conci, A., and Proenca, C. (2002), "A system for real-time fabric inspection and industrial decision", In *14th International Conference on Software Engineering and Knowledge Engineering*, pp. 707–714.
- [59] Besag, J. (1974), "Spatial interaction and the statistical analysis of lattice systems", *Journal of Royal Statistical Society*, B-36:344–348.

- [60] Chellappa, R. (1985), "Two-dimensional discrete Gaussian Markov random field models for image processing", In eds. L. Kanak and A. Rosenfeld, *Progress in Pattern Recognition 2*. Elsevier.
- [61] Zhu, S., Wu, Y., and Mumford, D. (1997), "FRAME: Filters, random field and maximum entropy-towards a unified theory for texture modeling", *International Journal of Computer Vision*. **27**(2), 1–20.
- [62] Cohen, F., Fan, Z., and Attali, S. (1991), "Automated inspection of textile fabrics using textural models", *IEEE Transactions on Pattern Analysis and Machine Intelligence*. **13**(8), 803–809.
- [63] Ozdemir, S., Baykut, A., Meylani, R., Ercil, R., and Ert`uz`un, A. (1998), "Comparative evaluation of texture analysis algorithms for defect inspection of textile products", In *International Conference on Pattern Recognition*, pp. 1738–1740.
- [64] Stauffer, C. (2004), "Learning a probabilistic similarity function for segmentation", In *IEEE Workshop on Perceptual Organization in Computer Vision*, pp. 50–58.
- [65] Gabor, D. (1964), "Theory of Communication," J. IEE 93,PP. 429-457.
- [66] Mallat, S. (1989), "A theory for multiresolution signal decomposition: The Wavelet representation", *IEEE Trans Pattern Anal Machine Intell (PAML)*, 11(7) : 674-693.
- [67] Bovik, AC., Clark, M., and Geisler, WS. (1990), "Multichannel texture analysis using localized spatial filters", *IEEE Trans Pattern Anal Machine Intell (PAML)*; 12: 55-73.
- [68] Weldon, D., Higin, E., and Dunn, D. F. (1996), "Gabor filter design for multiple texturesegmentation", *Optical Engineering*, vol. 35, no. 10, pp. 2852-2863.
- [69] Manjunathi, B.S., and Ma, W.Y. (1996), " Texture Features for Browsing and Retrieval of Image Data", *IEEE Trans. on PAMI*, Vol. 18, No. 8, pp. 837-842.
- [70] Ahmadian, A., Mostafa, A. (2003), "An Efficient Texture Classification Algorithm using Gabor Wavelet", *EMBC*.
- [71] Randen, T., and Husoy, J. (1999), "Texture segmentation using filters with optimized energyseparation". *IEEE Trans. on Image Processing*, 8(4):pp. 571-582.
- [72] Kumar, V., Sharan, B, S. (2007), " Pattern Recognition with Localized Gabor Wavelet Grids", *IEEE International Conference on Computational Intelligence and Multimedia Applications*, pp. 517-521.
- [73] Lian, Y. (2005), "Gabor Features Based Classification Using SVM for Face Recognition", *Lecture Notes in Computer Science*, vol. 3497, pp. 118-123.
- [74] Alimohamadi, H., Ahmadyfard, A., and Shojaee, E. (2009), " Defect Detection in Textiles Using Morphological Analysis of Optimal Gabor Wavelet Filter Response" *International Conference on Computer and Automation Engineering* , pp. 26-30.

- [75] Fine, S., Navratil, J., and Gopinath, R. (2001), "A Hybrid GMM/SVM Approach to Speaker Identification", *ICASSP*.
- [76] Reynolds, D.A., and Rose, R.C. (1995), "Robust text-independent speaker identification using gaussian mixture speaker models", *IEEE Transactions on speech and audio processing*, Vol.3, No.1.
- [77] Xu, L., and Jordan, M. (1995), "On convergence properties of the EM algorithm for Gaussian mixtures", *Neural Computation*.
- [78] Varma, M., and Zisserman, A. (2003), "Texture classification: Are filter banks necessary?", In *IEEE Conference on Computer Vision and Pattern Recognition*, pp. 691–698.
- [79] Drlje, R., Keller, A., and Hocenski, Z. (2005), "Neural Network Based Detection of Defects in Texture Surfaces", *Proceedings of the IEEE International Symposium on Industrial Electronics*, Vol. 3, pp. 1255 - 1260.
- [80] Japkowicz, N., Myers, C., and Gluck, M. (1995), "A novelty detection approach to classification", In *IJCAI-95*, pp. 518–523.
- [81] Chang, T., and Kuo, J. (1993), "Texture analysis & classification with tree-Structured wavelet transform", *IEEE Trans. Image Processing*, 2(4) : 429-441.
- [82] Bodnarova, A., Bennamoun, M., and Latham, S.J. (2000), "A constrained minimization approach to optimize GABOR filters for detecting flaws in woven textiles", *Acoustics, Speech and Signal Processing*. Volume 6, 5-9, pp. 3606- 3609.
- [83] Sobha, T., and Remya, S. (2009), "Texture Analysis based on Gaussian Mixture Modeling", *World Congress on Nature & Biologically Inspired Computing (NaBIC 2009)*.pp.1436-1440.
- [84] هادیزاده، هادی، (۱۳۸۷)، پایان‌نامه کارشناسی ارشد، "تشخیص عیوب بافت‌های تصادفی به کمک مدل مخفی مارکوف"، دانشکده مهندسی برق، دانشگاه علم و صنعت ایران.