

ارائه یک شکل جدید از الگوهای باینری محلی به منظور طبقه‌بندی بافت تصویر

مرضیه پاکدل و فرشاد تاجری‌پور

این معناست که با استفاده از ویژگی‌های استخراج‌شده از تصاویر بافتی آموزشی، بتوان طبقه تصویر آزمایشی را تشخیص داد. تاکنون روش‌های بسیار زیادی برای طبقه‌بندی بافت ارائه شده است و کارایی این روش‌ها تا حد بسیار زیادی به نوع ویژگی‌های استخراج‌شده بستگی دارد. توسریان و جین [۲]، روش‌های مختلف استخراج ویژگی برای آنالیز بافت تصویر را به پنج دسته اصلی تقسیم کرده‌اند که عبارتند از ویژگی‌های آماری، ویژگی‌های هندسی، ویژگی‌های بر اساس مدل، ویژگی‌های پردازش سیگنال و ویژگی‌های ساختاری.

برخی از روش‌های مهم برای استخراج ویژگی عبارتند از ماتریس وقوع هم‌رخدادی، ماتریس خودهمبستگی، عملگرهای ریخت‌شناسی، میدان تصادفی مارکوف، تبدیل فوریه، فیلترهای گابور، تبدیل موجک و الگوهای باینری محلی.

بدون شک، ویژگی‌های آماری مرتبه اول و دوم از اولین ویژگی‌هایی بودند که برای آنالیز بافت تصویر استفاده می‌شد. ماتریس وقوع هم‌رخدادی برای اولین بار توسط هارلیک [۳] معرفی شد و احتمال وقوع مشترک دو شدت روشنایی را در یک جهت و فاصله مشخص به دست می‌آورد. پس از ایجاد ماتریس وقوع هم‌رخدادی، ویژگی‌هایی مثل انرژی، واریانس، انترپی، تیاین و میانگین به عنوان ویژگی بافت استخراج می‌شود. محاسبه این ماتریس در جهات و فواصل مختلف پیچیدگی محاسباتی بالایی دارد و با احتساب تمام ویژگی‌ها، دقت طبقه‌بندی در حدود ۶۰ تا ۷۰ درصد گزارش شده است. دان و همکاران [۴] از ویژگی‌های آماری برای طبقه‌بندی و آشکارسازی عیوب بافت استفاده نموده‌اند. پس از آن میدان تصادفی مارکوف-گاوسی و میدان تصادفی گیبس به منظور استخراج ویژگی از بافت ارائه شدند [۵]، اما تمام این روش‌ها محدود به آنالیز بر هم کنش تصاویر در یک همسایگی و یک مقیاس هستند و تنها برای آنالیز میکروبافت‌ها نتیجه خوبی ارائه می‌دهند [۶]. به همین دلیل در سال‌های اخیر، روش‌های تفکیک‌پذیری چندگانه همانند فیلترهای گابور [۷] و تبدیل موجک [۶] مورد توجه بسیاری از متخصصان این زمینه قرار گرفته است. فیلتر گابور، یک روش پارامتریک بوده و برای استفاده از آن نیاز به تعیین چندین پارامتر است. پاکدل و همکاران [۸]، به منظور طبقه‌بندی بافت تصویر، با استفاده از الگوریتم ژنتیک پارامترهای بهینه این فیلترها را تخمین زده‌اند. یکی از مشکلات فیلترهای گابور عمود بر هم نبودن خروجی این فیلترها و در نتیجه وجود همبستگی بین ویژگی‌های استخراج‌شده می‌باشد. البته بسیاری از این مشکلات با استفاده از تبدیل موجک حل می‌شود. چن و همکاران [۹] از فیلتر ICA برای استخراج ویژگی استفاده نموده‌اند. ویژگی‌های پردازش سیگنال همچون فیلترهای گابور و تبدیل موجک هر چند نتایج خوبی ارائه داده‌اند، اما به دلیل استفاده از بانک فیلتر پیچیدگی محاسباتی بالایی دارند. پتیکان و همکاران از الگوهای باینری محلی [۱۰] و اوچالا و همکاران نیز از شکل بهبودیافته الگوهای باینری محلی [۱۱] برای استخراج ویژگی و طبقه‌بندی

چکیده: طبقه‌بندی بافت تصویر نقش بسیار مهمی در بینایی ماشین و پردازش تصویر دارد. اولین و مهم‌ترین مرحله در طبقه‌بندی بافت تصویر، استخراج ویژگی از تصویر می‌باشد. تاکنون روش‌های بسیار زیادی برای استخراج ویژگی از تصاویر بافتی ارائه شده‌اند اما از میان روش‌های موجود الگوهای باینری محلی، در شکل اصلی و بهبودیافته خود، به دلیل سادگی در پیاده‌سازی و استخراج ویژگی‌های مناسب با دقت طبقه‌بندی بالا، مورد توجه بسیاری از متخصصان این زمینه قرار گرفته است. شکل اصلی الگوهای باینری محلی هرچند از نظر پیاده‌سازی بسیار ساده است، اما زمانی که شعاع همسایگی افزایش یابد پیچیدگی محاسباتی بالایی دارد. شکل بهبودیافته الگوهای باینری محلی نیز به الگوهای همگن برچسب‌های متمایز و به تمام الگوهای غیر همگن یک برچسب یکسان انتساب می‌دهد و این امر، طبقه‌بندی تصاویری که دارای درصد بالایی از الگوهای غیر همگن می‌باشند را با مشکل مواجه می‌سازد.

در این مقاله، یک شکل جدید از الگوهای باینری محلی ارائه شده است که پیچیدگی محاسباتی آن نسبت به شکل اصلی الگوهای باینری محلی کمتر و دقت طبقه‌بندی آن نیز از شکل اصلی و بهبودیافته الگوهای باینری محلی بیشتر می‌باشد. روش ارائه‌شده در این مقاله نه تنها تصاویر با الگوهای همگن را به خوبی طبقه‌بندی می‌کند، بلکه در مورد تصاویری که دارای حجم بسیار بالایی از الگوهای غیر همگن می‌باشند نیز به خوبی عمل می‌کند. همچنین می‌توان با تغییر در بازه‌های شدت روشنایی، محلی یا سراسری بودن ویژگی‌ها را کنترل کرد. دقت طبقه‌بندی برای تمام تصاویر بافتی موجود در پایگاه داده Brodatz و Outex، کارایی روش ارائه‌شده را نشان می‌دهد.

کلید واژه: طبقه‌بندی بافت، استخراج ویژگی، الگوهای باینری محلی، شکل بهبودیافته الگوهای باینری محلی، ویژگی محلی و ویژگی سراسری.

۱- مقدمه

بررسی و تحلیل بافت، زمینه مطالعاتی مهم و سودمندی در روند پردازش تصویر و بینایی ماشین می‌باشد. در واقع می‌توان گفت که بافت هر شیء سبب تمایز اشیا از همدیگر می‌شود. پردازش تصاویر ماهواره‌ای و پزشکی، دریافت از راه دور، کنترل کیفیت اتوماتیک و پردازش اسناد، تنها تعدادی از کاربردهای پردازش بافت تصویر است.

سه مسأله اساسی مرتبط با بافت تصویر که الگوریتم‌های بینایی ماشین سعی بر حل آن دارند عبارتند از طبقه‌بندی بافت، بخش‌بندی بافت و آشکارسازی عیوب بافتی [۱]. در اکثر کاربردهای ذکرشده برای پردازش بافت، طبقه‌بندی بافت تصویر نقش بسیار مهمی دارد. طبقه‌بندی بافت به

این مقاله در تاریخ ۱۷ دی ماه ۱۳۹۰ دریافت و در تاریخ ۵ آذر ماه ۱۳۹۱ بازنگری شد.

مرضیه پاکدل، دانشکده مهندسی برق و کامپیوتر، دانشگاه شیراز، شیراز، (email: pakdel@cse.shirazu.ac.ir)

فرشاد تاجری‌پور، دانشکده مهندسی برق و کامپیوتر، دانشگاه شیراز، شیراز، (email: tajeri@shirazu.ac.ir)

همسایگی را R در نظر بگیریم، ۳^P الگوی باینری مختلف ایجاد خواهد شد. بدیهی است که با افزایش تعداد نقاط همسایگی، تعداد الگوهای باینری ایجاد شده نیز به صورت نمایی افزایش خواهد یافت. اوجالا و همکاران [۱۱] برای حل این مشکل از شکل بهبودیافته الگوهای باینری محلی استفاده نموده‌اند. در این روش ابتدا عملگری به نام یکنواختی (همگنی) تعریف شده و به همسایگی‌های یکنواخت برچسبی بین ۰ تا P و به همسایگی‌های غیر یکنواخت نیز برچسب $P+۱$ نسبت داده می‌شود، بنابراین تعداد الگوهای باینری ایجاد شده به $P+۲$ الگو کاهش می‌یابد.

در شکل اصلی و بهبودیافته الگوهای باینری محلی تباین تصویر در نظر گرفته نشده است. هرچند اوجالا و همکاران [۱۱] برای گنجاندن تباین تصویر از توزیع توأم الگوهای باینری محلی و وارپانس محلی استفاده کرده‌اند، اما این روش پیچیدگی محاسباتی بالایی دارد.

در این مقاله روشی بر اساس روش الگوهای باینری محلی ارائه شده است که نه تنها برای بافت‌هایی با الگوهای همگن به خوبی عمل می‌کند، بلکه می‌تواند بافت‌هایی را که دارای درصد بالایی از الگوهای غیر همگن هستند نیز به خوبی طبقه‌بندی نماید. در این روش به جای داشتن یک هیستوگرام برای هر تصویر، از سه هیستوگرام استفاده می‌شود که هر یک به ترتیب توزیع نقاط همسایگی با شدت روشنایی کوچک‌تر از مرکز همسایگی، توزیع نقاط همسایگی با شدت روشنایی برابر با مرکز همسایگی و توزیع نقاط همسایگی با شدت روشنایی بزرگ‌تر از مرکز همسایگی را نشان می‌دهد.


در روش الگوهای باینری محلی، هیستوگرام توزیع همسایگی‌ها مستقل از شدت روشنایی مرکز همسایگی ایجاد می‌شود. اما در روش ارائه شده، هیستوگرام پخشش همسایگی به صورت جداگانه برای هر مقدار از شدت روشنایی در مرکز همسایگی ایجاد می‌شود که این امر، باعث افزایش دقت طبقه‌بندی می‌گردد. البته می‌توان برای به دست آوردن تعداد هیستوگرام‌های کمتر، سطوح شدت روشنایی را به بازه‌هایی تقسیم کرد و نمودارهایی که شدت روشنایی مرکز همسایگی آنها در یک بازه قرار دارند با هم ادغام نمود. ادغام نمودارها، ویژگی‌های کلی‌تری از تصویر ارائه می‌دهد. بنابراین با تغییر در اندازه بازه‌ها و در نتیجه تعداد نمودارهای ادغام شده، می‌توان محلی یا سراسری بودن ویژگی‌ها را کنترل کرد.

در ادامه مقاله، در بخش ۲ روش الگوهای باینری محلی در شکل اصلی و بهبودیافته آن معرفی می‌شود. در بخش ۳ الگوریتم جدید بر پایه الگوهای باینری محلی ارائه و اثبات می‌شود. بخش ۴ به ارائه نتایج پیاده‌سازی روش پیشنهادی بر روی انواع مختلف بافت اختصاص یافته است و در نهایت در بخش ۵ به بحث و نتیجه‌گیری پرداخته می‌شود.

۲- تئوری

۲-۱ استفاده از الگوهای باینری محلی

یکی از روش‌هایی که برای استخراج ویژگی و طبقه‌بندی بافت تصویر مورد استفاده قرار می‌گیرد، روش الگوهای باینری محلی است. در این روش ابتدا یک همسایگی از تصویر در نظر گرفته شده و شدت روشنایی نقاط موجود در این همسایگی با شدت روشنایی نقطه موجود در مرکز همسایگی مقایسه می‌شود. به منظور حساس‌نبودن عملگر نسبت به چرخش تصویر، نقاط همسایگی را به صورت دایروی در نظر می‌گیرند و نقاطی را که مختصات آنها دقیقاً روی مرکز پیکسل قرار نمی‌گیرد، با درون‌یابی پیدا می‌کنند. در شکل ۱ می‌توان نمونه‌ای از همسایگی دایروی با شعاع‌های مختلف و تعداد همسایگی‌های مختلف را مشاهده



شکل ۱: همسایگی‌های دایروی به ازای مقادیر مختلف R و P ، (الف) $R=۱$ و $P=۴$ و (ب) $R=۱$ و $P=۸$.

بافت تصویر استفاده کرده‌اند. اخیراً از ترکیب روش‌های پردازش سیگنال، روش‌های آماری و روش‌های بر اساس مدل نیز به منظور استخراج ویژگی استفاده شده است. اریواگان و همکاران [۱۲]، از اعمال ماتریس وقوع هم‌رخدادی بر زیرباندی حاصل از تبدیل موجک به منظور استخراج ویژگی و طبقه‌بندی بافت استفاده نموده‌اند. رامانا و همکاران [۱۳]، میدان تصادفی مارکوف گاوسی را بر خروجی حاصل از تبدیل موجک اعمال نموده‌اند و از ویژگی‌های حاصل از این عملگر استفاده کرده‌اند. کومار و همکاران [۱۴]، از عملگرهای آماری و ریخت‌شناسی و اعمال آن بر روی خروجی تبدیل موجک تصویر برای بخش‌بندی بافت تصویر استفاده نموده‌اند.

کارهای بسیار زیادی در زمینه استخراج ویژگی و طبقه‌بندی بافت تصویر انجام گرفته است، اما مقالات بسیار کمی کارهای مختلف را با هم مقایسه کرده‌اند. وسکا و همکاران [۱۵] ویژگی‌های حاصل از ماتریس وقوع هم‌رخدادی، تبدیل فوریه، ویژگی‌های حاصل از آمارگان مرتبه دوم و ویژگی‌های آماری حاصل از اعمال تفاوت شدت روشنایی را با هم مقایسه کرده‌اند و بر اساس نتایج حاصل شده، ماتریس وقوع هم‌رخدادی و ویژگی‌های آماری حاصل از بردار تفاوت شدت روشنایی به عنوان ویژگی‌های برتر گزارش شده‌اند. راندن و هاسوی [۱۶] مطالعه گسترده‌ای بر روی روش‌های مختلف فیلترینگ انجام داده‌اند و فیلترهای مختلف را در زمینه بخش‌بندی بافت تصویر با هم مقایسه نموده‌اند، اما به طور واضح و دقیق هیچ فیلتری را بهتر از دیگری ندانسته‌اند. ماتئا و همکاران [۱۷]، روش الگوهای باینری محلی را با روش‌های فیلترینگ راندن و هاسوی مقایسه کرده‌اند و نتایج روش الگوهای باینری محلی از بهترین نتایج راندن و هاسوی نیز بهتر بوده است. در کار دیگری [۱۸] پنج روش استخراج ویژگی شامل فیلترهای گابور، فیلترهای Law، فیلترهای Ring and Wedge، ماتریس وقوع هم‌رخدادی و روش خودکاهنده بر روی بانک داده‌های مختلف با هم مقایسه شده‌اند و برای هر بانک داده یکی از روش‌ها بهتر از دیگری عمل کرده است. بنابراین در حالت کلی نمی‌توان نتیجه گرفت که یک الگوریتم برای تمام بانک داده‌ها بهتر از سایر روش‌ها عمل می‌کند.

از میان روش‌های موجود برای استخراج ویژگی، روش الگوهای باینری محلی به دلیل سادگی در پیاده‌سازی، پیچیدگی محاسباتی کم نسبت به روش‌های پردازش سیگنال و ارائه ویژگی با دقت بالا مورد توجه بسیاری از متخصصان این زمینه قرار گرفته است. الگوهای باینری محلی و شکل بهبودیافته آن هم در زمینه طبقه‌بندی بافت [۱۰] و [۱۱] و هم در زمینه آشکارسازی عیوب بافتی [۱۹]، نتایج بسیار خوبی ارائه داده‌اند. این روش، روشی غیر پارامتریک می‌باشد و تنها باید تعداد نقاط همسایگی و شعاع همسایگی تعیین شود و پارامتر دیگری در تعیین آن نقش ندارد. اما یکی از مشکلات روش الگوهای باینری محلی، تعداد الگوهای است که در نهایت به دست خواهد آمد. چنانچه تعداد نقاط همسایگی را P و شعاع

خاص را می‌توان به صورت نسبت تعداد نقاطی که دارای آن برجسب هستند به تعداد کل نقاط، تقریب زد. بنابراین در شکل بهبودیافته الگوهای باینری محلی $P+2$ دسته احتمال مختلف حاصل می‌شود که می‌توان از هیستوگرام نرمال شده این برجسب‌ها و با استفاده از نسبت درست‌نمایی لگاریتمی، بافت تصویر را طبقه بندی کرد [۲۱]. در این حالت یک نمونه S به طبقه‌ای انتساب داده می‌شود که احتمالات محاسبه شده برای این نمونه، مقدار زیر را کمینه کند

$$L(S, K) = \sum_{i=1}^{P+1} S_i \log \frac{S_i}{M_{i,k}} \quad (4)$$

که $M_{i,k}$ ها احتمالات مبنای مربوط به طبقه K و S_i ها نیز احتمالات محاسبه شده مربوط به بافت مورد بررسی می‌باشد.

۳- روش پیشنهادی برای استخراج ویژگی و طبقه‌بندی بافت بر پایه روش الگوهای باینری محلی

یکی از مشکلات روش الگوهای باینری محلی، پیچیدگی محاسباتی بالا و تعداد الگوهای ایجاد شده می‌باشد. بدیهی است که با افزایش تعداد نقاط همسایگی، تعداد الگوهای موجود و در نتیجه پیچیدگی محاسباتی به صورت نمایی افزایش پیدا می‌کند. مثلاً چنانچه تعداد نقاط همسایگی از ۸ نقطه به ۱۶ نقطه افزایش یابد، تعداد الگوها نیز از ۲۵۶ به ۶۵۵۳۶ الگو افزایش می‌یابد و یا اگر تعداد نقاط همسایگی از ۱۶ نقطه به ۲۴ نقطه افزایش یابد، تعداد الگوها نیز به ۱۶۷۷۲۱۶ افزایش پیدا می‌کند. برای حل این مشکل، اوجالا و همکاران [۱۱] از شکل بهبودیافته الگوهای باینری محلی استفاده نموده‌اند.

در شکل بهبودیافته الگوهای باینری محلی، الگوهای باینری موجود در تصویر به دو دسته تقسیم می‌شوند: الگوهای همگن و الگوهای غیر همگن. این روش به الگوهای همگن برجسی به تعداد ۱‌های موجود در الگو به مرکز همسایگی انتساب می‌دهد و به تمام الگوهای غیر همگن نیز برجسب یکسان $P+1$ را نسبت می‌دهد. هرچند با اعمال این عملگر تعداد الگوها کاهش چشمگیری می‌یابد، اما طبقه‌بندی بافت‌هایی را که دارای درصد بالایی از الگوهای غیر همگن هستند با مشکل مواجه می‌سازد. به عبارت دیگر، این روش از استخراج ویژگی تنها بر روی بافت‌های همگن متمرکز شده و از اطلاعات همسایگی‌های غیر همگن به خوبی استفاده نمی‌کند. البته شکل بهبودیافته الگوهای باینری محلی به تنهایی دقت طبقه‌بندی چندان خوبی ندارد و دلیل آن عدم توجه به تباین تصویر می‌باشد. البته این ویژگی مهم از طریق محاسبه واریانس شدت روشنایی نقاط موجود در همسایگی اعمال می‌شود

$$VAR_{P,R} = \frac{1}{P} \sum_{i=1}^{P-1} (g_i - \mu)^2 \quad (5)$$

$$\mu = \frac{1}{P} \sum_{i=1}^{P-1} g_i$$

از آنجایی که الگوهای باینری محلی و واریانس محلی مکمل همدیگر هستند، توزیع مشترک آنها یعنی $LBP_{P,R}/VAR_{P,R}$ ، بهتر از توزیع هر کدام از ویژگی‌ها به صورت جداگانه، بافت تصویر را توصیف خواهد کرد. $LBP_{P,R}/VAR_{P,R}$ یک ابزار بسیار قدرتمند می‌باشد، چرا که هم اطلاعات الگوهای محلی و هم اطلاعات واریانس محلی را استخراج می‌کند. اما واریانس یک مقدار عددی پیوسته دارد و برای ایجاد هیستوگرام توزیع توأم شکل بهبودیافته الگوهای باینری محلی و واریانس محلی، باید آن را گسسته کرد. برای این کار باید توزیع این ویژگی را

کرد. الگوی باینری محلی در یک همسایگی از تصویر به صورت زیر تعریف می‌شود [۱۰]

$$LBP_{P,R} = \sum_{i=1}^{P-1} s(g_i - g_c)^i \quad (1)$$

$$s(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases}$$

که در آن R شعاع همسایگی، P تعداد نقاط موجود در همسایگی، g_c شدت روشنایی مرکز همسایگی و g_i نیز شدت روشنایی نقاط موجود در همسایگی می‌باشد. با توجه به (۱) خروجی عملگر الگوهای باینری محلی برای هر همسایگی از تصویر، یک عدد باینری P بیتی است که دارای 2^P مقدار مختلف می‌باشد.

عدد باینری حاصل، به نحوه اندیس‌گذاری همسایگی‌ها بستگی دارد. لذا برای این که بتوان برای هر همسایگی مقدار یکتایی به دست آورد، عدد باینری حاصل را چرخانده و مقدار کمینه را به عنوان الگوی محلی به مرکز همسایگی مورد نظر انتساب می‌دهند

$$LBP_{P,R}^{ri} = \min \{POR(LBP_{P,R}, i) \mid i = 0, \dots, P-1\} \quad (2)$$

که نماد ri نمایانگر این است که عملگر نسبت به چرخش حساس نمی‌باشد و POR نیز عملگر چرخش به راست برای عدد باینری حاصل است. در (۲) عمل چرخش به سمت راست بر روی عدد باینری P بیتی، P بار انجام شده و حداقل عدد به دست آمده به ازای i های بین ۰ و $P-1$ به عنوان الگوی باینری محلی انتخاب می‌شود. با اعمال این روش، به همسایگی‌های موجود در تصویر، برجسی بین ۰ تا $2^P - 1$ نسبت داده می‌شود و در نهایت از هیستوگرام نرمال شده این برجسب‌ها، به عنوان ویژگی برای طبقه‌بندی بافت تصویر استفاده می‌شود.

۲-۲ استفاده از شکل بهبودیافته الگوهای باینری محلی برای طبقه‌بندی بافت تصویر

روش الگوهای باینری محلی در شکل اصلی خود، پیچیدگی محاسباتی بالایی دارد و با افزایش تعداد نقاط موجود در همسایگی، این پیچیدگی محاسباتی نیز افزایش می‌یابد.

مشاهده شده است که این روش، قدرت جداسازی چندان زیادی ندارد. یکی از دلایل آن، تغییر بسیار زیاد فرکانس وقوع الگوهاست. برخی از الگوها که درصد بسیار زیادی از تصویر را تشکیل می‌دهند، از ویژگی‌های اصلی بافت تصویر هستند. این الگوها، الگوهای همگن یا یکنواخت نامیده می‌شوند [۲۰]. معیار یکنواختی، نشان‌دهنده تعداد جهش‌ها در شدت روشنایی نقاط موجود در همسایگی است. به عنوان مثال عدد باینری ۱۰۰۰۰۰۱۱ دارای دو جهش در شدت روشنایی است، پس میزان یکنواختی این الگو برابر ۲ می‌باشد. در این روش الگوهایی که میزان همگنی آنها حداکثر برابر U_T باشد، به عنوان الگوهای همگن تعریف می‌شوند. شکل بهبودیافته الگوهای باینری محلی به صورت زیر تعریف می‌شود

$$LBP_{P,R}^{min} = \begin{cases} \sum_{i=1}^{P-1} s(g_i - g_c) & , U \leq U_T \\ P+1 & , U > U_T \end{cases} \quad (3)$$

با توجه به (۳)، شکل بهبودیافته الگوهای باینری محلی به همسایگی‌های همگن برجسی بین ۰ تا P و به همسایگی‌های غیر همگن، برجسب $P+1$ را نسبت می‌دهد، بنابراین هر همسایگی از تصویر می‌تواند یکی از $P+2$ مقدار مختلف را داشته باشد. احتمال برخورد به یک برجسب

$$T = p(g_c, g_{c+1}, \dots, g_{P-1}) \quad (۶)$$

که g_c شدت روشنایی مرکز همسایگی و g_i به ازای $i = 0, \dots, P-1$ نیز شدت روشنایی نقاط موجود در یک همسایگی می‌باشد. اوجالا و همکاران در ادامه کار، برای استخراج عملگری مقاوم نسبت به سطوح شدت روشنایی، بدون از دست دادن اطلاعات، میزان شدت روشنایی نقطه مرکز همسایگی را از شدت روشنایی نقاط موجود در همسایگی کم نموده‌اند

$$T = p(g_c, g_c - g_c, \dots, g_{P-1} - g_c) \quad (۷)$$

در مرحله بعد، فرض می‌شود که شدت روشنایی مرکز همسایگی (g_c) مستقل از تفاضل شدت روشنایی نقاط همسایگی و مرکز همسایگی است ($g_i - g_c$)

$$T \cong p(g_c) \cdot p(g_c - g_c, \dots, g_{P-1} - g_c) \quad (۸)$$

اما در عمل، این مستقل بودن تضمین نمی‌شود و این تنها یک تخمین است. بنابراین برای افزایش دقت این احتمال را می‌توان به صورت احتمال شرطی و به شکل زیر بازنویسی کرد

$$T = p(g_c = G_i) \cdot p(g_c - g_c, \dots, g_{P-1} - g_c | g_c = G_i) \quad (۹)$$

در (۹)، G_i یکی از سطوح شدت روشنایی دلخواه موجود در مرکز همسایگی می‌باشد. $p(g_c = G_i)$ نیز شدت روشنایی کل تصویر را مشخص می‌کند و وابسته به بافت تصویر در یک همسایگی محلی نیست، بنابراین اطلاعات مفیدی برای آنالیز بافت در بر ندارد و می‌توان آن را حذف کرد. بنابراین می‌توان (۹) را به صورت زیر تقریب زد

$$T \cong p(g_c - g_c, \dots, g_{P-1} - g_c | g_c = G_i) \quad (۱۰)$$

این عملگر بسیار جداکننده است، چرا که احتمال وقوع الگوهای مختلف را در همسایگی نقطه مرکزی با هر شدت روشنایی به دست می‌آورد. در روش الگوهای باینری محلی و شکل بهبودیافته آن، تنها احتمال وقوع هر الگو در کل تصویر و مستقل از شدت روشنایی مرکز همسایگی محاسبه می‌شود.


مقدار و علامت $g_i - g_c$ با تغییر در میانگین شدت روشنایی تغییر نخواهد کرد، بنابراین حتی با در نظر گرفتن علامت این تفاضل‌ها به جای مقدار واقعی آن نیز می‌توان خاصیت غیر حساس بودن نسبت به سطوح شدت روشنایی را به دست آورد

$$T \cong p(s(g_c - G_i), \dots, s(g_{P-1} - G_i) | g_c = G_i) \quad (۱۱)$$

البته در این عملگر جدید، تعریف $s(x)$ نیز به صورت زیر تغییر می‌کند

$$s(x) = \begin{cases} 1 & , x > 0 \\ 0 & , x = 0 \\ -1 & , x < 0 \end{cases} \quad (۱۲)$$

با توجه به این تعریف جدید از $s(x)$ ، رابطه بین شدت روشنایی نقطه مرکز همسایگی و نقاط موجود در همسایگی به سه دسته تقسیم می‌شود که با برچسب‌های ۱، ۰ و -۱ مشخص می‌گردد. این روش آستانه‌گذاری جدید به نقاط همسایگی با شدت روشنایی بزرگ‌تر از شدت روشنایی نقطه مرکز همسایگی برچسب ۱، به نقاط همسایگی با شدت روشنایی برابر با نقطه مرکز همسایگی برچسب ۰ و به نقاط همسایگی با شدت روشنایی کوچک‌تر از نقطه مرکز همسایگی برچسب -۱ را انتساب می‌دهد. با اعمال این روش جدید از آستانه‌گذاری اطلاعات رابطه بین شدت روشنایی نقطه مرکز همسایگی و نقاط موجود در همسایگی با جزئیات دقیق‌تری



شکل ۲: انتخاب همسایگی به صورت مربعی و آستانه‌گذاری به روش الگوهای باینری محلی.

برای تمام تصاویر آموزشی به دست آورد تا یک توزیع کلی حاصل شود. سپس لازم است که تعدادی آستانه تعیین شود تا بتوان این توزیع کلی را به N قسمت با تعداد ورودی مساوی تقسیم کرد. اما گسسته‌کردن یک مقدار پیوسته محدودیت‌های زیادی دارد. اولاً یک مرحله آموزش برای تعیین آستانه هر قسمت لازم است و ثانیاً تعداد قسمت‌ها بسیار مهم است. اگر تعداد قسمت‌ها را کم در نظر بگیریم، اطلاعات حاصل چندان جداکننده نیست و اگر تعداد قسمت‌ها را زیاد در نظر بگیریم، هیستوگرام حاصل اسپارس شده و پیچیدگی محاسباتی بالایی دارد. ثالثاً این نحوه گسسته‌کردن بسیار وابسته به داده‌های آموزشی است.

هرچند که روش $LBP_{P,R}/VAR_{P,R}$ دقت طبقه‌بندی خوبی را ارائه می‌دهد، اما دارای پیچیدگی محاسباتی بالایی است. مثلاً اگر از همسایگی 3×3 با ۸ نقطه در همسایگی و ۱۶ قسمت برای گسسته‌کردن واریانس استفاده کنیم، ۱۶۰ ویژگی استخراج خواهد شد. بدیهی است که با افزایش تعداد نقاط همسایگی، پیچیدگی محاسباتی نیز افزایش خواهد یافت. بنابراین استفاده از واریانس محلی برای به دست آوردن اطلاعات تباین تصویر، علاوه بر مرحله آموزش پیچیده، تعداد ویژگی‌های زیادی نیز ارائه می‌دهد.

مشکل دیگری که روش الگوهای باینری محلی با آن مواجه است عدم اعمال تفاوت میان همسایگی‌هایی با شدت روشنایی برابر با شدت روشنایی نقطه مرکز همسایگی و همسایگی‌هایی با شدت روشنایی بزرگ‌تر از شدت روشنایی مرکز همسایگی است. چرا که روش الگوهای باینری محلی تابع علامت را به صورتی تعریف کرده است که به همسایگی‌هایی با شدت روشنایی برابر یا بزرگ‌تر از شدت روشنایی مرکز همسایگی مقدار ۱ و در غیر این صورت مقدار صفر را نسبت می‌دهد.

روش الگوهای باینری محلی در نهایت به همسایگی‌های همگن برچسبی به تعداد ۱۰های موجود در الگو و به تمام همسایگی‌های غیر همگن نیز برچسب ثابتی را نسبت می‌دهد. این روش در بر دارنده هیچ اطلاعاتی در مورد همسایگی‌های با شدت روشنایی برابر یا کوچک‌تر از شدت روشنایی مرکز همسایگی نیست.

از طرفی در روش الگوهای باینری محلی، شدت روشنایی نقاط همسایگی با شدت روشنایی مرکز همسایگی مقایسه می‌شود، اما در کل هیستوگرامی که از برچسب‌ها ایجاد می‌گردد مستقل از شدت روشنایی نقطه مرکزی است. روش ارائه‌شده در این مقاله این مشکلات را به خوبی پوشش داده است.

در شکل ۲ نمونه‌ای از همسایگی مربعی و نحوه اعمال عملگر الگوهای باینری را می‌توان مشاهده کرد.

۳-۱ استنتاج روش پیشنهادی

همان طور که در شکل اصلی و بهبودیافته الگوهای باینری محلی، توسط اوجالا و همکاران [۱۱] انجام گرفته است، بافت T در یک همسایگی محلی به عنوان توزیع ترکیبی شدت روشنایی P پیکسل از تصویر در نظر گرفته می‌شود

در (۱۴)، G_{Li} و G_{Ui} به ترتیب حد پایین و حد بالای شدت روشنایی بازه i می باشد. البته بازه ها باید طوری انتخاب شوند که تمام سطوح شدت روشنایی پوشش داده شود و بازه ها با هم هم پوشانی نداشته باشند.


مثلاً برای تصاویر با سطوح خاکستری ۸ بیتی، به جای محاسبه ۳ نمودار برای هر یک از ۲۵۶ شدت روشنایی در مرکز همسایگی، می توان برای هر ۳۲ شدت روشنایی در مرکز همسایگی سه نمودار ایجاد کرد که برچسب های انتساب داده شده به صورت زیر خواهند بود

$$\begin{aligned} LBP_{P,R,I,L} &= \text{number of } -1s \\ LBP_{P,R,I,E} &= \text{number of } \cdot s \\ LBP_{P,R,I,H} &= \text{number of } 1s, \quad I_i \in [-31, 0] \\ &\vdots \\ LBP_{P,R,I_v,L} &= \text{number of } -1s \\ LBP_{P,R,I_v,E} &= \text{number of } \cdot s \\ LBP_{P,R,I_v,H} &= \text{number of } 1s, \quad I_v \in [224 - 255] \end{aligned} \quad (15)$$

در نهایت می توان از هیستوگرام توزیع سه نوع برچسب $LBP_{P,R,I,L}$ ، $LBP_{P,R,I,E}$ و $LBP_{P,R,I,H}$ به عنوان توصیف گر بافت استفاده نمود. در واقع با در نظر گرفتن این بازه ها، به جای ۷۶۸ نمودار با ۹ دسته احتمال مختلف، ۲۴ نمودار با ۹ دسته احتمال مختلف ایجاد خواهد شد. البته با ادغام تعداد بیشتری از نمودارها، باز هم می توان پیچیدگی محاسباتی روش ارائه شده را کاهش داد. ادغام نمودارها و کاهش پیچیدگی محاسباتی زمانی که شعاع همسایگی و تعداد نقاط موجود در همسایگی افزایش یابد، تأثیر بسیار بیشتری خواهد داشت. مثلاً در شکل اصلی الگوهای باینری محلی با در نظر گرفتن همسایگی با شعاع ۲ و ۱۶ نقطه در مجموعه همسایگی، نموداری با ۶۵۵۳۲ دسته احتمال مختلف ایجاد خواهد شد. اما با اعمال این عملگر جدید و ادغام نمودارها با بازه هایی به طول ۳۲، ۲۴ نمودار با ۱۷ دسته احتمال مختلف ایجاد می شود که نسبت به نموداری با ۶۵۵۳۶ دسته احتمال، کاهش بسیار زیادی در محاسبات و تعداد ویژگی ها خواهد داشت. شکل ۴، روند کلی استخراج این هیستوگرام های جدید را ارائه داده است. لازم به ذکر است که در این الگوریتم منظور از B اندازه بازه های استفاده شده برای ادغام کردن هیستوگرام ها و $Intervals$ نیز تعداد بازه های حاصل است که برابر با $256/B$ می باشد.

در واقع با تغییر در اندازه بازه های شدت روشنایی مرکز همسایگی، نوع ویژگی های استخراج شده قابل کنترل است. چنانچه بازه های ادغام را بسیار کوچک در نظر بگیریم، به عبارت دیگر نمودارهای بسیار کمی را با هم ادغام کنیم، ویژگی های حاصل بسیار محلی خواهند بود اما اگر نمودارهای زیادی را ادغام کنیم، نمودارهای حاصل ویژگی های سراسری تصویر را ارائه می دهند. پس می توان با تغییر در اندازه بازه ها، سراسری یا محلی بودن ویژگی ها را کنترل کرد، این نیز یکی از مزایای روش جدید می باشد. برای طبقه بندی بافت تصویر، در نهایت هیستوگرام های حاصل نرمال شده و همانند روش الگوهای باینری محلی، از نسبت درست نمایی لگاریتمی استفاده می شود و یک نمونه S به طبقه ای انتساب داده می شود که عبارت زیر را کمینه کند

$$\begin{aligned} L(S, k) &= \sum_{j=1}^{Intervals-1} \sum_{i=1}^P S_{i,j,L} \log(S_{i,j,L} / M_{i,j,L,k}) \\ &+ \sum_{j=1}^{Intervals-1} \sum_{i=1}^P S_{i,j,E} \log(S_{i,j,E} / M_{i,j,E,k}) \\ &+ \sum_{j=1}^{Intervals-1} \sum_{i=1}^P S_{i,j,H} \log(S_{i,j,H} / M_{i,j,H,k}) \end{aligned} \quad (16)$$



شکل ۳: نحوه آستانه گذاری توسط عملگر جدید الگوهای باینری محلی.

نشان داده می شود. شکل ۳ نحوه اعمال این روش جدید آستانه گذاری را نشان می دهد.

با استفاده از روش زیر معادله بالا برای هر همسایگی از تصویر، تبدیل به سه عدد می شود که ساختار بافت تصویر را به صورت محلی نشان می دهد

$$\begin{aligned} LBP_{P,R,G_i,L} &= \text{number of } -1's \\ LBP_{P,R,G_i,E} &= \text{number of } \cdot's \\ LBP_{P,R,G_i,H} &= \text{number of } 1's \end{aligned} \quad (13)$$

که P تعداد نقاط مجموعه همسایگی، R شعاع همسایگی، G_i شدت روشنایی نقطه مرکزی، L نشان دهنده همسایگی با شدت روشنایی کوچک تر از نقطه مرکزی، E نمایانگر همسایگی با شدت روشنایی برابر با نقطه مرکزی و H نیز همسایگی با شدت روشنایی بزرگ تر از نقطه مرکز همسایگی می باشد.

این در حالیست که شکل بهبود یافته الگوهای باینری محلی به همسایگی هایی با الگوی همگن، برچسبی به تعداد نقاط موجود در همسایگی با شدت روشنایی بزرگ تر یا مساوی با شدت روشنایی مرکز همسایگی، انتساب می دهد و به تمام همسایگی ها با الگوهای غیر همگن نیز برچسب ثابت $P+1$ تخصیص می دهد. اطلاعات تعداد نقاط موجود در مجموعه همسایگی که دارای شدت روشنایی برابر یا کوچک تر از شدت روشنایی مرکز همسایگی هستند، در شکل اصلی و بهبود یافته الگوهای باینری محلی به خوبی در نظر گرفته نمی شود.

در نهایت می توان از سه هیستوگرام توزیع همسایگی (L, E, H) در اطراف نقطه مرکز همسایگی و با هر شدت روشنایی دلخواه به عنوان ویژگی بافت استفاده کرد.

چنانچه تصاویر مورد بررسی با سطوح خاکستری ۸ بیتی باشد، ۲۵۶ سطح شدت روشنایی مختلف در تصویر وجود خواهد داشت. با اعمال این روش، برای هر سطح شدت روشنایی موجود در مرکز همسایگی سه نمودار L ، E ، H ایجاد خواهد شد. مثلاً با اعمال این عملگر بر روی همسایگی مربعی شکل با ۸ نقطه در همسایگی، ۷۶۸ نمودار مختلف ایجاد می شود که هر نمودار شامل ۹ دسته احتمال مختلف می باشد. بنابراین ۶۹۱۲ ویژگی به دست خواهد آمد که بسیار زیاد است.

البته می توان این پیچیدگی محاسباتی و تعداد ویژگی های حاصل را با ادغام کردن نمودارها تا حد بسیار زیادی کاهش داد به نحوی که پیچیدگی محاسباتی آن از شکل اصلی الگوهای باینری محلی بسیار کمتر باشد. در واقع می توان سطوح شدت روشنایی را به بازه هایی با اندازه مساوی تقسیم کرد و به جای این که به ازای هر مقدار از شدت روشنایی در مرکز همسایگی سه نمودار ایجاد شود، به ازای یک بازه معین برای شدت روشنایی در مرکز همسایگی، سه نمودار ایجاد نمود. این شکل جدید از الگوهای باینری محلی و برچسب های جدید طبق (۱۴) باز نویسی می شوند

$$\begin{aligned} LBP_{P,R,G_{Li} \leq g_c \leq G_{Ui},L} &= \text{number of } -1s \\ LBP_{P,R,G_{Li} \leq g_c \leq G_{Ui},E} &= \text{number of } \cdot s \\ LBP_{P,R,G_{Li} \leq g_c \leq G_{Ui},H} &= \text{number of } 1s \end{aligned} \quad (14)$$

ورودی: یک تصویر Im ، اندازه همسایگی P ، اندازه بازه‌های ادغام B و تعداد بازه‌ها Intervals.

خروجی: تعداد $Intervals \times 3$ نمودار توزیع همسایگی‌ها.

(۱) ابتدا تمام هیستوگرام‌ها را مقداردهی اولیه می‌کنیم:

$$H_{L,i}[\dots, P] = 0, H_{E,i}[\dots, P] = 0, H_{H,i}[\dots, P] = 0, H_{L,i}(Intervals-1)[\dots, P] = 0, H_{E,i}(Intervals-1)[\dots, P] = 0, H_{H,i}(Intervals-1)[\dots, P] = 0$$

(۲) سپس برای هر پیکسل موجود در تصویر، یک همسایگی با P نقطه در نظر گرفته و برای شدت روشنایی مرکز همسایگی g_c که در بازه i قرار دارد:

(۱-۲) سه برچسب تعداد همسایگی‌های کوچک‌تر (Low)، برابر (Equal) و بزرگ‌تر (High) از مرکز همسایگی را به دست آورده و نمودارها را به روز رسانی می‌کنیم:

$$H_{L,i}(Low)++, H_{E,i}(Equal)++, H_{H,i}(High)++$$

(۳) پایان حلقه ۲.

(۴) تمام هیستوگرام‌های حاصل نرمال می‌شوند.

(۵) هیستوگرام‌های حاصل به عنوان بردار ویژگی در نظر گرفته می‌شوند.

شکل ۴: نحوه استخراج هیستوگرام‌های جدید بر اساس روش ارائه‌شده در این مقاله.

جدول ۱: مقایسه مقادیر (۱۷) به ازای k های متفاوت برای اطلاع از تباین تصویر.

$k=0$	$k=1$	$k=2$	$k=3$	$k=4$
۰.۹۱۶۱	۰.۹۹۶۳	۰.۹۹۹۸	۱	۱
۰.۶۸۲۴	۰.۹۳۰۹	۰.۹۸۷۸	۰.۹۹۷۹	۰.۹۹۹۶

تباین تصویر به خوبی در این نمودارها پیداست. جدول ۱ مقدار (۱۷) را برای مقادیر مختلف k به دست آورده است و به خوبی می‌توان با مقایسه این اعداد اطلاعاتی در مورد تباین تصویر به دست آورد. در اینجا بافت کاموا یک بافت با تباین بالاست و بافت پشم بافتی با تباین پایین است.

روش ارائه‌شده برای هر بازه‌ای از شدت روشنایی در مرکز همسایگی هیستوگرام توزیع سه نوع برچسب را ایجاد می‌کند، بنابراین اگر تغییر یکنواختی در شدت روشنایی ایجاد گردد نمودارهای حاصل نیز تغییر خواهند کرد. برای حل این مشکل و به دست آوردن عملکردی غیر حساس نسبت به شیف‌ت در سطوح شدت روشنایی، قبل از اعمال روش ارائه‌شده و ایجاد هیستوگرام‌های توزیع سه نوع برچسب در همسایگی، ابتدا تصویر مورد بررسی طبق (۱۸) نرمال می‌شود

$$Nim = \frac{Im - \min(im)}{\max(im) - \min(im)} \times 255 \quad (18)$$

که در (۱۸)، $\min(im)$ حداقل شدت روشنایی و $\max(im)$ حداکثر شدت روشنایی موجود در تصویر است. با نرمال کردن تصویر بر اساس این رابطه، هیستوگرام‌های حاصل نسبت به انتقال یکنواخت تصویر تغییر نمی‌خواهند کرد.

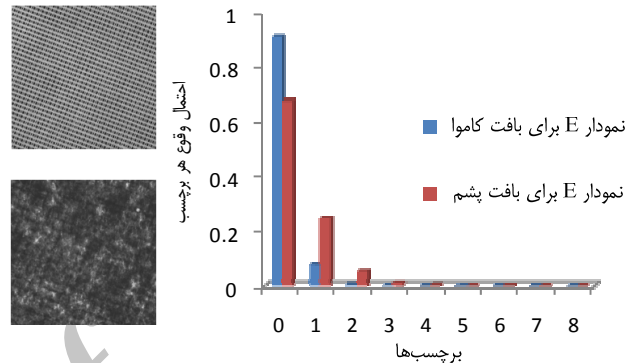
۴- نتایج پیاده‌سازی و بررسی عملکرد

در این بخش ابتدا بانک داده مورد استفاده را بررسی کرده و پس از اعمال روش ارائه‌شده در این مقاله بر روی بانک داده‌های معتبر و استاندارد، روش ارائه‌شده را با روش‌های پیشین مقایسه می‌کنیم.

۴-۱ معرفی بانک داده‌های مورد استفاده

برای بررسی عملکرد روش ارائه‌شده به منظور استخراج ویژگی و طبقه‌بندی بافت تصویر، از دو بانک داده استاندارد [۲۲] Outex و [۲۳] Brodatz استفاده شده است. بانک داده Outex شامل نمونه‌هایی از ۲۴ طبقه بافتی مختلف است. آزمایشات بر روی دو گروه تست از مجموعه داده Outex بررسی شده‌اند: TC۱۰ و TC۱۲.

این دو گروه تست شامل ۲۴ کلاس بافت مختلف هستند که تحت سه روشنایی مختلف ("horizon"، "inca"، "184") و در ۹ جهت متفاوت (۰، ۵، ۱۰، ۱۵، ۳۰، ۴۵، ۶۰، ۷۵ و ۹۰ درجه) جمع‌آوری شده‌اند.



شکل ۵: مقایسه هیستوگرام E از دو تصویر برای اطلاع از تباین تصویر.

در (۱۶)، $M_{i,j,L,k}$ احتمالات مبنای مربوط به طبقه k در نمودار L و بازه j ، $M_{i,j,E,k}$ احتمالات مبنای مربوط به طبقه k در نمودار E و بازه j ، $M_{i,j,H,k}$ احتمالات مبنای مربوط به طبقه k در نمودار H و بازه j ، $S_{i,j,L}$ احتمالات مبنای مربوط به نمونه S در نمودار L و بازه j ، $S_{i,j,E}$ احتمالات مبنای مربوط به نمونه S در نمودار E و بازه j ، $S_{i,j,H}$ نیز احتمالات مبنای مربوط به نمونه S در نمودار H و بازه j می‌باشد.

نکته مهمی که در نمودار توزیع همسایگی‌های با شدت روشنایی برابر با مرکز همسایگی گنجانده شده است، تباین تصویر می‌باشد. اگر تعداد زیادی از همسایگی‌ها دارای شدت روشنایی برابر با شدت روشنایی مرکز همسایگی باشند، در نتیجه تصویر دارای تباین پایین است و در غیر این صورت تصویری با تباین بالا را در اختیار داریم. به عبارت دیگر اگر تباین تصویر را به این صورت تعریف کنیم

$$C(k) = \sum_{i=0}^k Prob(E=i|P,R), \quad k < P \quad (19)$$

در $Prob(E=i|P,R)$ در واقع احتمال وقوع i همسایگی برابر با شدت روشنایی مرکز همسایگی است. برای تصاویری با تباین بالا و تصاویری با تباین کم، به ازای k های برابر این مقدار قابل مقایسه است. در تصاویر با تباین بالا که احتمال داشتن تعداد همسایگی‌های برابر با مرکز همسایگی به ازای مقادیر کم بیشتر است مقدار این پارامتر بیشتر خواهد داشت و در تصاویر با تباین پایین که احتمال وجود تعداد همسایگی‌های برابر با مرکز همسایگی به ازای مقادیر بالاتر بیشتر می‌باشد، این مقدار به ازای k های برابر، کمتر خواهد بود. این پارامتر در نهایت با $k = P$ دارای مقدار ۱ خواهد بود، چرا که جمع کل احتمالات می‌باشد. شکل ۵ یک تصویر با تباین بالا (بافت کاموا) و یک تصویر با تباین پایین (بافت پشم) به همراه هیستوگرام E مربوط به آنها را نشان می‌دهد. حقایق گفته‌شده در مورد

۴-۲ نتایج حاصل از آزمایشات بر روی بانک

داده Brodatz

با اعمال روش ارائه‌شده در این مقاله، برای هر تصویر تعدادی نمودار ایجاد خواهد شد که در نهایت برای به دست آوردن یک مدل نهایی از هر طبقه، نمودارهای متناظر نمونه‌های یک طبقه با هم جمع شده و میانگین هر نمودار به عنوان مدل نهایی آن طبقه در نظر گرفته می‌شود.

همان‌طور که در بخش ۳-۱ نیز بیان شد، در این پژوهش به منظور کاهش پیچیدگی محاسباتی و به دست آوردن تعداد نمودارهای کمتر، از ایده ادغام کردن نمودارها استفاده می‌شود. در این تحقیق، نمودارها با بازه‌هایی به طول ۳۲، ۶۴ و ۱۲۸ با هم ادغام شده‌اند.

روش ارائه‌شده همانند روش الگوهای باینری محلی و شکل بهبودیافته آن می‌تواند به عنوان یک روش با تفکیک‌پذیری چندگانه نیز در نظر گرفته شود و نتایج مربوط به انتخاب همسایگی با ابعاد مختلف را طبق فرمول زیر به سادگی در هم ادغام کرد و برای طبقه‌بندی بافت تصویر استفاده نمود


$$L_K^N = \sum_{n=1}^N L_K(S_K^n, M^n) \quad (20)$$

که N نشان‌دهنده تعداد عملگرهای مختلف، n اندیس عملگر مورد بررسی و K نیز نشان‌دهنده طبقه مورد بررسی می‌باشد.

در این تحقیق از همسایگی‌های مربعی‌شکل با ابعاد 3×3 و 8 نقطه در همسایگی، ابعاد 5×5 و 16 نقطه در همسایگی و ابعاد 7×7 و 24 نقطه در همسایگی استفاده شده است. همچنین در این تحقیق برای مرحله آموزش از 40 درصد از تصاویر هر طبقه که به صورت تصادفی انتخاب شده‌اند، استفاده شده است. آزمایش روش پیشنهادی نیز بر روی تمام تصاویر موجود در هر طبقه انجام گرفته است. با تقسیم‌بندی تصاویر، 861 تصویر از طبقه‌های مختلف به دست آمده است که 341 تصویر برای مرحله آموزش انتخاب می‌شود.

جدول ۲ نتایج حاصل از اعمال روش جدید با انتخاب بازه‌های مختلف $(LBP_{P,R}^B)$ (Proposed) که B اندازه بازه‌های ادغام را نشان می‌دهد، به همراه شکل بهبودیافته الگوهای باینری محلی $(LBP_{P,R}^{riu^Y})$ (Modified) را نشان می‌دهد. دقت‌های به دست آمده در جدول ۲، میانگین 10 بار اجرای روش با 10 مجموعه آموزشی و آزمایشی مختلف می‌باشد که به همراه انحراف معیار استاندارد نوشته شده است. در جدول ۱ منظور از تعداد ویژگی‌ها، تعداد کل دسته احتمالاتی است که باید مقایسه و بررسی شوند. بر اساس این جدول نتایج زیر قابل مشاهده است:

اولاً چنانچه بازه‌های ادغام را 32 در نظر بگیریم، یعنی از 8 بازه به طول 32 برای ادغام نمودارها استفاده کنیم، با داشتن 3 نمودار H ، E ، L برای هر بازه، 24 نمودار با 9 دسته احتمال مختلف ایجاد خواهد شد، بنابراین 216 ویژگی مختلف استخراج می‌شود. با انتخاب این بازه برای ادغام نمودارها، هم دقت طبقه‌بندی نسبت به شکل اصلی و بهبودیافته الگوهای باینری محلی افزایش می‌یابد و هم تعداد ویژگی‌ها نسبت به شکل اصلی الگوهای باینری محلی کاهش پیدا می‌کند. دلیل این امر، گنجانده شدن ویژگی‌های سراسری تصویر در کنار ویژگی‌های محلی می‌باشد. دقت طبقه‌بندی روش ارائه‌شده با همسایگی 3×3 و 8 نقطه در همسایگی، در حدود 10 درصد نسبت به شکل بهبودیافته الگوهای باینری محلی افزایش یافته است.



شکل ۶: سه تصویر مختلف از بانک داده Brodatz.

برای هر بافت، 20 نمونه در هر جهت وجود دارد. اندازه هر تصویر در این مجموعه داده 128×128 می‌باشد. چون تصاویر این بانک داده در جهات مختلف هستند، برای حساس‌نودن روش نسبت به چرخش تصویر، همسایگی را به صورت دایروی در نظر می‌گیریم. داده‌های آموزشی و آزمایشی در هر گروه تست به شرح زیر است:

۱) در بانک داده $TC10$ ، بافت هر طبقه با استفاده از روشن‌سازی "inca" و در جهت 0 درجه آموزش داده می‌شود و با نمونه‌هایی با همان روشنایی و در 8 جهت دیگر آزمایش می‌گردد. در این گروه تست، 480 نمونه آموزشی و 3840 نمونه آزمایشی موجود است.

۲) در بانک داده $TC12$ ، بافت هر طبقه با همان داده‌های $TC10$ آموزش داده می‌شود و با تمام نمونه‌ها با روشن‌سازی "horizon" و "t184" آزمایش می‌شود. در این گروه 480 نمونه آموزشی و 4320 نمونه آزمایشی موجود است.

بانک داده Brodatz نیز شامل 112 طبقه بافتی مختلف می‌باشد. در این بانک داده، هم تصاویر با بافت تکرارشونده و هم تصاویر با بافت غیر تکرارشونده وجود دارد. تعدادی از طبقات موجود در این آرشیو دارای درصد بالایی از همسایگی‌های همگن هستند و تعداد بسیار زیادی نیز دارای درصد بسیار بالایی از الگوهای غیر همگن می‌باشند. شکل ۶ تعدادی از این تصاویر را نشان می‌دهد. اندازه هر تصویر از این آرشیو 640×640 می‌باشد.

هر طبقه از تصاویر بانک داده Brodatz، تنها شامل یک نمونه است. به منظور آزمایش روش ارائه‌شده لازم است که تصاویر به تعدادی تصویر کوچک‌تر تقسیم شوند. تقسیم‌بندی برای تصاویری که دارای بافت‌های تکراری هستند، باید به گونه‌ای باشد که در هر قسمت بافت تکرارشونده تصویر وجود داشته باشد. برای محاسبه اندازه بافت تکرارشونده یک تصویر با بافت تکراری، می‌توان از تابع خودهمبستگی استفاده کرد [۱]. این تابع در جهت افقی و عمودی به صورت زیر تعریف می‌شود

$$C_x = \frac{1}{M \cdot (N-x)} \frac{\sum_{i=1}^{N-x} \sum_{j=1}^M I_{i,j} \cdot I_{i+x,j}}{\frac{1}{M \cdot N} \sum_{i=1}^N \sum_{j=1}^M I_{i,j}^2} \quad (19)$$

$$C_y = \frac{1}{N \cdot (M-x)} \frac{\sum_{i=1}^N \sum_{j=1}^{M-x} I_{i,j} \cdot I_{i,j+y}}{\frac{1}{M \cdot N} \sum_{i=1}^N \sum_{j=1}^M I_{i,j}^2}$$

که $M \times N$ اندازه تصویر، $I_{i,j}$ شدت روشنایی پیکسل‌ها در تصویر مرجع، C_x تابع خودهمبستگی افقی و C_y نیز تابع خودهمبستگی عمودی می‌باشد. تصاویری که بافت تکرارشونده آنها به خوبی قابل تشخیص نمی‌باشد نیز باید به گونه‌ای تقسیم شوند که بافت دیده‌شده در هر تصویر پس از تقسیم‌بندی یکسان باشد.

چون تصاویر این بانک داده تنها در یک جهت می‌باشد، نیازی به در نظر گرفتن همسایگی به صورت دایروی نیست و می‌توان برای سادگی کار، همسایگی را به شکل مربعی در نظر گرفت.

جدول ۲: مقایسه دقت طبقه‌بندی و تعداد ویژگی‌های استخراج‌شده برای تمام تصاویر بافت‌های موجود در آلبوم BRODATZ.

w, P	Modified $LBP_{P,R}^{riu\gamma}$	Proposed $LBP_{P,R}^{\gamma\tau}$	Proposed $LBP_{P,R}^{\delta\tau}$	Proposed $LBP_{P,R}^{\gamma\lambda}$
۸،۳	۸۵،۲۱۴۹ ± ۰،۸۴۸۳	۹۵،۲۷۲۹ ± ۰،۵۲۸۱	۹۴،۷۰۳۸ ± ۰،۶۹۰۸	۹۱،۲۸۹۲ ± ۰،۸۲۴۹
تعداد ویژگی‌ها	۹	۲۱۶	۱۰۸	۵۴
۱۶،۵	۸۸،۵۹۴۷ ± ۰،۳۸۶۴	۹۴،۰۸۸۳ ± ۰،۸۹۷۱	۹۲،۳۵۷۷ ± ۰،۴۴۷۵	۸۷،۹۰۹۴ ± ۱،۴۶۱۴
تعداد ویژگی‌ها	۱۷	۴۰۸	۲۰۴	۱۰۲
۲۴،۷	۸۳،۰۰۸۱ ± ۳،۸۵۳۶	۹۰،۹۱۷۵ ± ۱،۳۹۰۳	۸۷،۷۳۵۲ ± ۵،۳۶۵۹	۸۷،۵۲۷۷ ± ۱،۹۱۲۴
تعداد ویژگی‌ها	۲۵	۶۰۰	۳۰۰	۱۵۰
۸،۳+۱۶،۵	۸۹،۶۷۴۸ ± ۰،۷۱۲۷	۹۵،۴۷۰۴ ± ۰،۳۰۴۸	۹۴،۱۸۱۲ ± ۰،۵۷۲۸	۹۱،۶۴۹۲ ± ۰،۹۵۸۵
تعداد ویژگی‌ها	۲۶	۶۲۴	۳۱۲	۱۵۶
۳،۸+۲۴،۷	۹۰،۷۵۴۹ ± ۰،۴۴۵۵	۹۵،۰۵۲۳ ± ۰،۲۵۲۱	۹۳،۱۷۰۷ ± ۰،۷۲۱۸	۹۱،۰۳۳۷ ± ۰،۶۰۹۲
تعداد ویژگی‌ها	۳۴	۸۱۶	۴۰۸	۲۰۴
۵،۱۶+۷،۲۴	۸۹،۸۴۹۰ ± ۰،۷۰۱۶	۹۳،۹۲۵۷ ± ۰،۶۷۵۱	۹۲،۰۹۰۶ ± ۰،۷۱۴۸	۸۹،۳۳۶۴ ± ۰،۶۶۲۶
تعداد ویژگی‌ها	۴۲	۱۰۰۸	۵۰۴	۲۵۲
۳،۸+۵،۱۶+۷،۲۴	۹۰،۷۰۸۵ ± ۰،۴۷۴۲	۹۵،۰۹۸۷ ± ۰،۳۷۴۶	۹۳،۲۷۵۳ ± ۰،۳۶۹۱	۹۱،۰۵۶۹ ± ۰،۷۹۵۳
تعداد ویژگی‌ها	۵۱	۱۲۴۴	۶۲۲	۳۱۱

جدول ۳: مقایسه دقت طبقه‌بندی شکل بهبودیافته الگوهای باینری محلی و روش ارائه‌شده بر روی چند تصویر همگن و غیر همگن از آلبوم BRODATZ.

روش استخراج ویژگی	Class ID										میانگین دقت هر روش
	D۲	D۷	D۲۹	D۴۴	D۵۵	D۵۷	D۸۲	D۸۷	D۱۰۰	D۱۰۷	
Proposed $LBP_{P,R}^{\gamma\tau}$	۸۷،۵	۹۲	۱۰۰	۹۱،۲	۱۰۰	۶۸،۷۵	۱۰۰	۹۹،۲	۱۰۰	۱۰۰	۹۳،۸۶۵
Modified $LBP_{P,R}^{riu\gamma}$	۵۷،۵	۲۹	۷۲،۵	۴۴،۸	۱۰۰	۳۱،۲۵	۱۰۰	۶۶،۸	۱۰۰	۷۲،۵	۶۷،۴۳۵
%uniform	۷۵،۴۶	۷۴،۹۱	۷۶،۲۰	۷۲،۴۷	۸۳،۳۴	۷۶،۴۳	۸۳،۰۵	۷۶،۶۹	۸۲،۸۰	۷۵،۰۵	

یکنواختی هر تصویر در شکل بهبودیافته الگوهای باینری محلی به صورت زیر تعریف می‌شود

$$U(LBP_{P,R}) = |s(g_p - g_c) - s(g_i - g_c)| + \sum_{i=1}^{P-1} |s(g_i - g_c) - s(g_{i-1} - g_c)| \quad (21)$$

با توجه به میزان یکنواختی هر تصویر و دقت‌های به دست آمده، به روشنی قابل استنباط است که روش ارائه‌شده در این مقاله تصاویر با درصد بالایی از الگوهای غیر همگن را نیز به خوبی طبقه‌بندی می‌کند که شکل بهبودیافته الگوهای باینری محلی قادر به انجام آن نمی‌باشد. تصاویر D۲، D۷، D۲۹، D۴۴، D۵۵، D۸۷، D۱۰۷، که ستون مربوط به آنها خاکستری‌رنگ می‌باشد، تصاویری هستند که میزان یکنواختی آنها کم است و شکل بهبودیافته الگوهای باینری محلی دقت خوبی برای طبقه‌بندی آنها ارائه نمی‌دهد. اما روش ارائه‌شده در این مقاله تصاویری با درصد بالایی از الگوهای همگن و غیر همگن را به خوبی طبقه‌بندی می‌کند.

در حالت کلی، نتایج حاصل از اعمال روش جدید در تمام حالات، بهتر از شکل بهبودیافته الگوهای باینری محلی می‌باشد.

۴-۳ نتایج حاصل از آزمایشات بر روی بانک داده Outex

این بخش نتایج آزمایشات را بر روی دو گروه تست از مجموعه داده Outex بررسی می‌کند: TC۱۰ و TC۱۲. به دلیل این که تصاویر این بانک داده در جهات مختلف هستند، به منظور غیر حساس بودن روش نسبت به چرخش تصویر، همسایگی به صورت دایروی در نظر گرفته شده است. در ادامه این روش با شکل بهبودیافته الگوهای باینری محلی (Modified $LBP_{P,R}^{riu\gamma}$) و توزیع واریانس محلی ($VAR_{P,R}$) مقایسه

ثانیاً اگر بازه ادغام نمودارها را بزرگ‌تر در نظر بگیریم، یعنی ۴ بازه به طول ۶۴ داشته باشیم، مجدداً نسبت به روش الگوهای باینری محلی افزایش دقت و کاهش محاسبات را خواهیم داشت، اما نسبت به همین روش با بازه‌هایی به طول ۳۲، کاهش دقت را داریم. علت این کاهش را می‌توان سراسری بودن ویژگی‌های استخراج‌شده دانست، چرا که با افزایش اندازه بازه‌ها، ویژگی‌ها دیگر محلی نیستند و ویژگی‌های کلی تصویر می‌باشند و این امر باعث افت دقت طبقه‌بندی می‌شود. اگر باز هم بازه ادغام نمودارها را افزایش دهیم و برای شدت روشنایی نقاط مرکز همسایگی بین ۰ تا ۱۲۷ سه نمودار H ، E ، L و برای شدت روشنایی نقاط مرکزی بین ۱۲۸ تا ۲۵۵ نیز سه نمودار دیگر ایجاد کنیم، باز هم نسبت به روش الگوهای باینری محلی افزایش دقت و کاهش بسیار زیاد محاسبات را خواهیم داشت. هرچند با بزرگ‌تر شدن بازه‌ها (بزرگ‌تر از ۳۲) دقت طبقه‌بندی روش ارائه‌شده کاهش می‌یابد، اما این دقت هیچ‌گاه کمتر از دقت شکل بهبودیافته الگوهای باینری محلی نمی‌شود. به طور کلی بهترین بازه برای ادغام نمودارها، بازه‌هایی به طول ۳۲ می‌باشد.

ثانیاً به روشنی قابل مشاهده است که انتخاب همسایگی‌های کوچک‌تر، باعث افزایش دقت طبقه‌بندی می‌شود و در هر روش، بدترین نتایج مربوط به همسایگی‌های مربعی شکل 7×7 می‌باشد. البته بهترین دقت در هر روش نیز مربوط به زمانبست که از ادغام همسایگی‌ها استفاده نموده‌ایم.

جدول ۳ چند تصویر از بانک داده بروdatz را به همراه دقت طبقه‌بندی آنها توسط شکل بهبودیافته الگوهای باینری محلی و روش جدید نشان می‌دهد. در کنار هر تصویر میزان یکنواخت بودن آن نیز قرار دارد. میزان

جدول ۴: مقایسه دقت طبقه‌بندی روش ارائه‌شده با شکل بهبودیافته الگوهای باینری محلی و واریانس محلی بر روی مجموعه داده OUTEX.

P, R	$\lambda, 1$			$16, 2$			میانگین دقت هر روش
	TC10	TC12"t184"	TC12"horizon"	TC10	TC12"t184"	TC12"horizon"	
روش استخراج ویژگی							
$VAR_{P,R}$ [۲۴]	۹۰,۰۰	۶۲,۹۳	۶۴,۳۵	۸۶,۷۱	۶۳,۴۷	۶۷,۲۶	۷۲,۴۵
Modified $LBP_{P,R}^{riu\gamma}$ [۲۴]	۸۴,۸۹	۶۵,۳۰	۶۳,۷۵	۸۹,۲۴	۸۲,۲۹	۷۵,۱۳	۷۶,۷۶
Proposed $LBP_{P,R}^{\gamma}$	۹۲,۰۸	۸۱,۴۸	۷۴,۱۷	۹۲	۸۲,۶۲	۷۷,۴۸	۸۳,۳۶

جدول ۵: مقایسه دقت طبقه‌بندی روش ارائه‌شده با روش احتمال مشترک واریانس محلی و شکل بهبودیافته الگوهای باینری محلی برای چند تصویر همگن و غیر همگن در مجموعه داده OUTEX.

P, R	روش استخراج ویژگی	$\lambda, 1$			$16, 2$			$24, 3$		
		TC10	TC12"t184"	TC12"horizon"	TC10	TC12"t184"	TC12"horizon"	TC10	TC12"t184"	TC12"horizon"
Carpet-0.5	Proposed $LBP_{P,R}^{\gamma}$	100	100	100	100	100	99.44	100	100	99.44
	$LBP_{P,R}^{riu\gamma} / VAR_{P,R}$	100	100	100	100	100	100	100	100	100
Canvas-31	Proposed $LBP_{P,R}^{\gamma}$	100	78.33	83.89	99.38	93.89	77.78	100	96.67	88.89
	$LBP_{P,R}^{riu\gamma} / VAR_{P,R}$	98.12	57.00	13.88	99.37	47.22	35	100	66.11	43.88
Canvas-38	Proposed $LBP_{P,R}^{\gamma}$	87.5	95	80.56	83.18	79.44	53.89	83.75	42.22	87.22
	$LBP_{P,R}^{riu\gamma} / VAR_{P,R}$	100	55	20.55	100	66.66	17.22	100	56.11	17.22

یک همگن هستند و با افزایش شعاع همسایگی، میزان یکنواختی تصویر نیز کاهش می‌یابد. روش $LBP_{P,R}^{riu\gamma} / VAR_{P,R}$ به همین دلیل نمی‌تواند به خوبی آن را طبقه‌بندی کند، اما روش ارائه‌شده تقریباً در تمام حالات دقت طبقه‌بندی بهتری را ارائه داده است.

۴-۴ بررسی پیچیدگی محاسباتی روش ارائه‌شده

به منظور مقایسه کارایی روش ارائه‌شده با شکل اصلی و بهبودیافته الگوهای باینری محلی، علاوه بر مقایسه دقت طبقه‌بندی روش‌های مذکور، روش‌ها را از نظر پیچیدگی محاسباتی نیز باید بررسی کرد. در این پژوهش و به منظور بررسی این پارامتر مهم، تعداد عملگرهای اصلی و مورد نیاز برای پردازش یک نمونه آزمایشی در هر روش به دست آمده و بررسی می‌شود. چنانچه عملگرهای اصلی را مقایسه، جمع، تفریق، ضرب، تقسیم، توان و لگاریتم در نظر بگیریم، تعداد هر کدام از عملگرهای مورد نیاز برای یک تصویر با ابعاد $M \times N$ در جدول ۶ آورده شده است. تعداد عملگر مقایسه در روش شکل اصلی الگوهای باینری محلی $LBP_{P,R}$ ، شکل بهبودیافته الگوهای باینری محلی $LBP_{P,R}^{riu\gamma}$ و روش ارائه‌شده Proposed $LBP_{P,R}^{\gamma}$ برای هر همسایگی از تصویر یکسان و برابر با می‌باشد.

در روش شکل اصلی الگوهای باینری محلی عملگر توان برای هر همسایگی از تصویر P بار به کار برده شده است و پس از هر توان یک عملگر ضرب نیز اعمال شده است و پس از جمع آنها الگوی باینری محلی برای یک همسایگی از تصویر به دست می‌آید. در نهایت 2^P الگوی باینری محلی متفاوت ایجاد خواهد شد که برای به دست آوردن یک هیستوگرام نرمال از بخشش الگوها عمل نرمال‌سازی باید انجام گیرد که مستلزم 2^P عملگر تقسیم می‌باشد. در نهایت برای مقایسه یک نمونه آزمایشی با مدل‌های موجود از نسبت درست نمایی لگاریتمی استفاده می‌شود که بدین منظور 2^P بار عملگر جمع، ضرب، تقسیم و لگاریتم انجام می‌گیرد.

در روش شکل بهبودیافته الگوهای باینری محلی، پس از عمل مقایسه، میزان یکنواختی هر همسایگی از تصویر را باید به دست آورد که این

شده است. لازم به ذکر است که در روش توزیع واریانس محلی از نمودارهایی با ۱۲۸ ستون برای گسسته‌سازی استفاده شده است. جدول ۴ نتایج حاصل از اعمال روش‌های ذکر شده و روش ارائه‌شده، حاصل از ادغام نمودارها با بازه‌هایی به طول ۳۲ را بر روی TC10 و TC12 نشان می‌دهد. با توجه به جدول ۴ مشاهدات زیر قابل استنتاج است:

اولاً در تمام موارد روش ارائه‌شده که سطر مربوط به آن خاکستری رنگ می‌باشد، بهتر از شکل بهبودیافته الگوهای باینری محلی و واریانس محلی عمل می‌کند. روش ارائه‌شده، حتی در حالتی که آموزش با یک روشیابی و آزمایش بر روی تصاویر با روشیابی‌های دیگر انجام می‌شود نیز بهتر از دو روش دیگر عمل می‌کند.

دوماً با وجود این که نمودار واریانس تعداد ویژگی بیشتری استخراج می‌کند (تعداد ویژگی‌های حاصل از نمودار واریانس محلی ۱۲۸ می‌باشد) اما دقت طبقه‌بندی آن از شکل بهبودیافته الگوهای باینری محلی بیشتر نیست و اکثر حالات، دقت طبقه‌بندی آن بسیار کمتر از شکل بهبودیافته الگوهای باینری محلی و روش ارائه‌شده است.

سوماً دقت طبقه‌بندی توزیع توأم الگوهای باینری محلی و واریانس محلی $(LBP_{P,R}^{riu\gamma} / VAR_{P,R})$ برای تصاویر با درصد بالایی از الگوهای غیر همگن بسیار بد عمل می‌کند، اما روش ارائه‌شده در این مقاله، این نوع بافت‌ها را به خوبی طبقه‌بندی می‌کند. دلیل آن نیز انتساب یک برچسب یکسان به تمام الگوهای غیر همگن در شکل بهبودیافته الگوهای باینری محلی می‌باشد. جدول ۵ سه نوع بافت مختلف را نشان می‌دهد که برای هر طبقه بافتی در سطر اول دقت طبقه‌بندی روش ارائه‌شده و در سطر دوم نیز دقت طبقه‌بندی روش $LBP_{P,R}^{riu\gamma} / VAR_{P,R}$ وجود دارد. با توجه به دقت‌های به دست آمده و نیز میزان یکنواختی تصاویر، می‌توان نتیجه گرفت که روش جدید برای تصاویر با الگوهای غیر همگن نیز به خوبی جواب می‌دهد. مثلاً تصویر Carpet-0.5 در هر سه شعاع همسایگی یک دارای درصد بالایی از الگوهای همگن است و هم روش ارائه‌شده و هم روش $LBP_{P,R}^{riu\gamma} / VAR_{P,R}$ آن را به خوبی طبقه‌بندی کرده‌اند. اما تصاویر Canvas-31 و Canvas-38 تنها در همسایگی با شعاع

جدول ۶: مقایسه پیچیدگی محاسباتی روش ارائه شده، شکل اصلی الگوهای باینری محلی و الگوهای باینری محلی بهبود یافته.

عملگر	$LBP_{P,R}$	Modified $LBP_{P,R}^{m\gamma}$	Proposed $LBP_{P,R}^B$
مقایسه	$(M - 2R) \times (N - 2R) \times P$	$(M - 2R) \times (N - 2R) \times P$	$(M - 2R) \times (N - 2R) \times P$
جمع	$(M - 2R) \times (N - 2R) \times P + 2^P$	$(M - 2R) \times (N - 2R) \times P + P + 2$	$3 \times (P + 1) \times Intervals$
تفریق	.	$(M - 2R) \times (N - 2R) \times P$.
ضرب	$(M - 2R) \times (N - 2R) \times P + 2^P$	$P + 2$	$3 \times (P + 1) \times Intervals$
تقسیم	2×2^P	$2 \times (P + 2)$	$2 \times 3 \times (P + 1) \times Intervals$
توان	$(M - 2R) \times (N - 2R) \times P$.	.
لگاریتم	2^P	$P + 2$	$3 \times (P + 1) \times Intervals$

هر نقطه در مرکز همسایگی، سه برچسب انتساب می‌دهد. (۲) در شکل بهبود یافته الگوهای باینری محلی تباین تصویر اصلاً در نظر گرفته نمی‌شود، اما در این روش، تباین تصویر در نمودار E نهفته است. (۳) شکل بهبود یافته الگوهای باینری محلی، از هر تصویر یک هیستوگرام کلی تشکیل می‌دهد که توزیع تعداد همسایگی‌های بزرگ‌تر از نقطه مرکزی، برای همسایگی‌های همگن می‌باشد. اما روش ارائه شده، نه تنها توزیع همسایگی‌های بزرگ‌تر، برابر و کوچک‌تر از نقطه مرکز همسایگی را ایجاد می‌کند، بلکه هر نمودار را برای بازه‌ای از شدت روشنایی در مرکز همسایگی ایجاد می‌کند.

۶- کارهای آینده

در این مقاله، روش ارائه شده تنها به منظور طبقه‌بندی بافت تصویر استفاده شده است اما این روش از استخراج ویژگی، همانند سایر روش‌ها، می‌تواند به منظور بخش‌بندی بافت تصویر و آشکارسازی عیوب بافتی نیز مورد استفاده قرار گیرد. در ادامه این کار می‌توان از توزیع توأم همسایگی‌ها نیز به عنوان ویژگی بافت تصویر استفاده نمود.

مراجع

- [1] M. Petrou and P. G. Sevilla, *Image Processing Dealing with Texture*, Ch. 2, John Wiley and Sons Ltd, pp. 1-6, 2006.
- [2] M. Tuceryan and A. K. Jain, "Texture Analysis," *The Handbook of Pattern Recognition and Computer Vision*, Ch. 2, pp. 207-248, World Scientific Publishing Co., 1998.
- [3] R. M. Haralick, K. Shanmugam, and I. Dinstein, "Textural features for image classification," *IEEE Trans. on System, Man and Cybernetic*, vol. 3, no. 6, pp. 610-621, Nov. 1979.
- [4] D. Popescu, R. Dobrescu, and M. Nicolae, "Texture classification and defect detection by statistical features," *Int. J. of Circuit, System, and Signal Processing*, vol. 1, no. 1, pp. 79-85, 2007.
- [5] G. R. Cross and A. K. Jain, "Markov random field texture models," *IEEE Trans. on Pattern Analysis and Machine Intelligence*, vol. 5, no. 1, pp. 25-39, Jan. 1983.
- [6] M. Unser, "Texture classification and segmentation using wavelet frames," *IEEE Trans. on Image Processing*, vol. 4, no. 11, pp. 1549-1560, Nov. 1995.
- [7] F. Bianconi and A. Fernandez, "Evaluation of the effects of Gabor filter parameters on texture classification," *Pattern Recognition*, vol. 40, no. 12, pp. 3325-3335, 2007.
- [8] M. Pakdel and F. Tajeripour, "Texture classification using optimal Gabor filters," in *Proc. Int. eConf. on Computer and Knowledge Engineering*, pp. 208-213, 13-14 Oct. 2011.
- [9] X. Chen, X. Zeng, and D. van Alphen, "Multi-class feature selection for texture classification," *Pattern Recognition Letters*, vol. 27, no. 14, pp. 1685-1691, 2006.
- [10] M. Pietikainen, T. Ojala, and Z. Xu, "Rotation-invariant texture classification using feature distributions," *Pattern Recognition*, vol. 33, pp. 43-52, 2000.
- [11] T. Ojala, M. Pietikainen, and T. Maenpaa, "Multiresolution gray-scale and rotation invariant texture classification with local binary

مستلزم P بار عمل تفریق و جمع می‌باشد. پس از به دست آوردن میزان یکنواختی، برچسبی به آن همسایگی انتساب داده می‌شود و در نهایت $P + 2$ الگوی باینری مختلف به دست خواهد آمد. برای به دست آوردن هیستوگرام نرمال برچسب‌ها، $P + 2$ بار عمل تقسیم لازم است. در نهایت برای مقایسه یک نمونه آزمایشی با مدل‌های حاصل شده، از نسبت درست‌نمایی لگاریتمی استفاده می‌شود که مستلزم $P + 2$ بار عمل ضرب، تقسیم، لگاریتم و جمع است.

در روش ارائه شده پس از انجام عمل مقایسه و انتساب سه نوع برچسب متفاوت به هر همسایگی، نیاز به $3 \times (P + 1) \times Intervals$ بار عمل تقسیم در هر بازه شدت روشنایی، برای به دست آوردن هیستوگرام نرمال توزیع می‌باشد. در نهایت برای مقایسه یک نمونه آزمایشی با مدل‌های موجود از نسبت درست‌نمایی لگاریتمی استفاده می‌شود که مستلزم $3 \times (P + 1) \times Intervals$ بار عمل تقسیم، لگاریتم، ضرب و جمع است.

در این جدول منظور از $Intervals$ ، تعداد بازه‌های مورد استفاده است. با نگاهی به جدول ۶ می‌توان دریافت که تعداد عملگر جمع برای روش ارائه شده بسیار کمتر از شکل اصلی و بهبود یافته الگوهای باینری محلی است. در شکل بهبود یافته الگوهای باینری محلی تعداد زیادی عملگر تفریق مورد استفاده قرار گرفته است، اما در روش ارائه شده این عملگر مورد استفاده قرار نگرفته است. تعداد عملگرهای ضرب، تقسیم و لگاریتم در روش ارائه شده هرچند از شکل اصلی الگوهای باینری محلی بسیار کمتر است، اما این تعداد نسبت به شکل بهبود یافته الگوهای باینری محلی افزایش داشته است. بنابراین می‌توان ادعا کرد که روش ارائه شده هم از نظر تعداد ویژگی‌ها و هم از نظر پیچیدگی محاسباتی بسیار بهتر از شکل اصلی الگوهای باینری محلی است.

۵- بحث و نتیجه گیری

در این مقاله روشی بر اساس روش الگوهای باینری محلی، برای استخراج ویژگی و طبقه‌بندی بافت تصویر ارائه شد. با توجه به نتایج به دست آمده بر روی دو مجموعه داده استاندارد، دیده می‌شود که روش ارائه شده از دقت طبقه‌بندی بسیار خوبی برخوردار می‌باشد. روش ارائه شده از نظر پیچیدگی محاسباتی، خیلی بهتر از روش الگوهای باینری محلی است و از نظر دقت طبقه‌بندی نیز بهتر از شکل بهبود یافته الگوهای باینری محلی می‌باشد. دلیل این امر، سه نکته اساسی و مهم می‌باشد که در شکل بهبود یافته الگوهای باینری محلی در نظر گرفته نشده است، اما این روش هر سه نکته را در خود گنجانده است:

(۱) شکل بهبود یافته الگوهای باینری محلی، به همسایگی‌های همگن برچسبی بین ۰ تا P و به همسایگی‌های غیر همگن برچسب ثابت $P + 1$ را نسبت می‌دهد. در نتیجه طبقه‌بندی بافت‌های غیر همگن با مشکل مواجه می‌شود. اما در روش ارائه شده به انواع بافت‌ها، به

- [۲۱] ف. تاجری پور، ا.ا. کبیر و ع. شیخی، "آشکارسازی عیوب بافتی با استفاده از شکل بهبودیافته الگوی باینری محلی"، *نشریه مهندسی برق و مهندسی کامپیوتر ایران*، جلد ۵، شماره ۳، صص. ۱۲۸-۱۱۹، پاییز ۱۳۸۶.
- [22] T. Ojala, et al., "Outex-a new framework for empirical evaluation of texture analysis algorithms," in *Proc. of 16th Int. Conf. of Pattern Recognition*, 2002.
- [23] P. Brodatz, *Textures: A Photographic Album for Artist and Designer*, Dover, New York, 1966.
- [24] Z. Guo, L. Zhang, and D. Zheng, "Rotation invariant texture classification using LBP variance (LBPV) using global matching," *Pattern Recognition*, vol. 43, no. 3, pp. 706-719, Mar. 2010.

مرضیه پاکدل تحصیلات خود را در مقاطع کارشناسی و کارشناسی ارشد مهندسی کامپیوتر به ترتیب در سال‌های ۱۳۸۷ و ۱۳۹۱ در دانشگاه شیراز گذرانده است. وی هم‌اکنون در دانشگاه‌های پیام نور اهواز و دانشگاه آزاد اسلامی واحد گراش به تدریس می‌پردازد. زمینه‌های تحقیقاتی مورد علاقه ایشان متنوع بوده و شامل موضوعاتی از قبیل آنالیز و طبقه‌بندی بافت تصاویر، بینایی ماشین و پردازش تصاویر دیجیتال می‌باشد.

فرشاد تاجری پور تحصیلات خود را در مقاطع کارشناسی و کارشناسی ارشد مهندسی برق و الکترونیک به ترتیب در سال‌های ۱۳۷۳ و ۱۳۷۶ در دانشگاه شیراز و دکتری مهندسی برق و الکترونیک در سال ۱۳۸۶ در دانشگاه تربیت مدرس تهران به پایان رسانده است. وی هم‌اکنون استادیار دانشگاه شیراز است. زمینه‌های تحقیقاتی مورد علاقه ایشان عبارتند از: پردازش تصاویر دیجیتال، بینایی ماشین، پردازش تصاویر پزشکی و طراحی سیستم‌های بازرسی بصری.

- patterns," *IEEE Trans. on Pattern Analysis and Machine Intelligence*, vol. 24, no. 7, pp. 971-987, Jul. 2002.
- [12] S. Arivazhagan and L. Ganesan, "Texture classification using wavelet transform," *Pattern Recognition Letters*, vol. 24, no. 9-10, pp. 1513-1521, 1 Jun. 2003.
- [13] B. V. Ramana Reddy, M. Radhika Mani, and K. V. Subbaiah, "Texture classification method using wavelet transform based on Gaussian Markov random field," *International J. of Signal and Image Processing*, vol. 1, no. 1, pp. 35-39, 2010.
- [14] V. Vijaya Kumar, U. S. N. Raju, M. Radhika Mani, and A. L. Narasimha Rao, "Wavelet based texture segmentation methods based on combinatorial of morphological and statistical operations," *International J. of Computer Science and Network Security*, vol. 8, no. 8, pp. 176-181, Aug. 2008.
- [15] J. S. Weszka, C. R. Dyer, and A. Rosenfeld, "A comparative study of texture measures for terrain classification," *IEEE Trans. on System, Man and Cybernetic*, vol. 6, no. 4, pp. 267-285, 1976.
- [16] T. Randen and J. H. Husoy, "Filtering for texture classification: a comparative study," *IEEE Trans. on Pattern Analysis and Machine Intelligence*, vol. 21, no. 4, pp. 291-310, Apr. 1999.
- [17] T. Maenpaa, M. Pietikainen, and T. Ojala, "Texture classification by multi-predicate local binary pattern operators," in *Proc. 15th Int. Conf. on Pattern Recognition*, 3:951 - 954., vol. 3, pp. 939-942, Barcelona, Spain, 2000.
- [18] P. P. Koltsov, "Comparative study of texture detection and classification algorithms," *Computational Mathematics and Mathematical Physics*, vol. 51, no. 8, pp. 1460-1466, Aug. 2011.
- [19] F. Tajeripour, E. Kabir, and A. Sheikhi, "Fabric defect detection using Modified Local Binary Patterns," *EURASIP J. on Advances in Signal Processing*, vol. 8, pp. 1-12, 2008.
- [20] F. Bianconi and A. Fernandez, "On the occurrence probability of local binary patterns: a theoretical study," *J. of Mathematical Imaging and Vision Manuscript*, vol. 40, no. 3, pp. 259-268, 2011.

Archive of SID