

الگوی انتروپی محلی جهت استخراج ویژگی‌های تصاویر بافتی

محمدحسین شکور^۱ و فرشاد تاجری پور^۲

چکیده

روش‌های زیادی برای استخراج ویژگی از تصاویر بافتی ارائه شده‌اند، یکی از مهم‌ترین و ساده‌ترین روش‌ها، روش‌های مبتنی بر الگوی دودویی محلی است که به دلیل سادگی در پیاده‌سازی و استخراج ویژگی‌های مناسب با دقت طبقه‌بندی بالا، مورد توجه بسیاری از متخصصان قرار گرفته است. همچنین از ترکیب الگوی دودویی محلی و واریانس محلی ویژگی‌هایی با نتایج بهتر طبقه‌بندی تولید شده است. در اینجا از یک روش جدید بنام الگوی انتروپی محلی استفاده شده است. این روش از آن جهت که از رابطه‌ای مشابه انتروپی استفاده می‌کند بر این اساس نام‌گذاری شده است ولی از برخی جهات با رابطه انتروپی فرق دارد. روش پیشنهادی در مقایسه با الگوی دودویی محلی و واریانس محلی به نوبه مقاومت‌تر است. همچنین ترکیب آن با الگوی دودویی محلی نتایج بسیار بهتری نسبت به ترکیب واریانس محلی با الگوی دودویی محلی تولید می‌کند. الگوی انتروپی محلی همانند واریانس نشان‌دهنده میزان غیرهمسان بودن الگوهای محلی هر همسایگی است. این روش ضمن اینکه کلیه ویژگی‌های مثبت روش‌های موجود مانند غیرحساس بودن به چرخش و تغییرات روشنایی را دارد، نسبت به نوبه نیز بسیار مقاوم می‌باشد.

کلیدواژه‌ها

طبقه‌بندی بافت، استخراج ویژگی، الگوهای دودویی محلی، واریانس محلی، الگوی انتروپی محلی

۱) مقدمه

داده‌های اصلی بافتی شود. پردازش تصاویر ماهواره‌ای و پزشکی، دریافت از راه دور، کنترل کیفیت اتوماتیک و پردازش اسناد، تنها تعدادی از کاربردهای پردازش تصاویر بافتی می‌باشد. دو مسئله اساسی مرتبط با تصاویر بافتی عبارت‌اند از: طبقه‌بندی بافت و قطعه‌بندی بافت که هرکدام از این مسائل کاربردهای مهمی در پردازش تصاویر دارند که ازجمله مهم‌ترین آن‌ها آشکارسازی عیوب بافتی [۱] می‌باشد. مهم‌ترین قسمت پردازش بافت استخراج ویژگی از بافت است. روش‌های مختلفی برای این کار تاکنون ارائه شده است. طبق تحقیق توسریان و جین [۲]، روش‌های مختلف استخراج ویژگی از بافت به پنج دسته اصلی تقسیم شده است که عبارتند از: روش‌های آماری، روش‌های هندسی، روش‌های مبتنی بر مدل، روش‌های مبتنی بر پردازش فرکانس و بالاخره روش‌های ساختاری که البته در برخی موارد روش‌های هندسی را زیرمجموعه روش‌های ساختاری معرفی می‌کنند بیشترین کاربرد

پردازش بافت کاربردهای زیادی در زمینه‌های مختلف دارد. تصاویر بافتی برخلاف سایر تصاویر دیگر به دلیل پیچیدگی و تغییرات زیاد روشنایی اغلب نمی‌توان آن‌ها را به صورت سطوح خاکستری همانند سایر تصاویر پردازش کرد. در واقع می‌توان گفت که بافت هر شی سبب تمایز اشیا از هم می‌شود. ضمن اینکه بسیاری از روش‌های پیش‌پردازش نیز به راحتی قابل اعمال به بافت نیست شود و ممکن است منجر به از دست رفتن

این مقاله در دی‌ماه سال ۱۳۹۴ دریافت، در خردادماه سال ۹۵ بازنگری و در مهرماه همان سال پذیرفته شد.

^۱ گروه مهندسی کامپیوتر، واحد شیراز، دانشگاه آزاد اسلامی، شیراز، ایران.

رایانامه: mhshakoor@gmail.com

^۲ دانشکده مهندسی برق و کامپیوتر، دانشگاه شیراز، شیراز، ایران.

رایانامه: tajeri@shirazu.ac.ir

تبدیل فوری تصویر، برای استخراج ویژگی و قطعه‌بندی بافت تصویر استفاده نموده‌اند.

تاکنون کارهای بسیار زیادی در زمینه استخراج ویژگی و طبقه‌بندی بافت انجام شده است، اما مقالات بسیار کمی کارهای مختلف را با هم مقایسه کرده‌اند. وسکا و همکاران [۱۰]، ویژگی‌های حاصل از ماتریس وقوع هم‌رخدادی، تبدیل فوری و ویژگی‌های آماری حاصل از اعمال تفاوت شدت روشنایی را با هم مقایسه کرده‌اند و نتیجه‌های بهتری را برای ماتریس وقوع هم‌رخدادی و ویژگی‌های آماری حاصل از بردار تفاوت شدت روشنایی گزارش داده‌اند. راندن و هاسوی [۱۱]، مطالعه گسترده‌ای را بر روی روش‌های مختلف فیلترینگ انجام داده‌اند و فیلترهای مختلف را در زمینه قطعه‌بندی بافت با هم مقایسه نموده‌اند، اما به طور واضح و دقیق هیچ فیلتری را بهتر از دیگری ندانسته‌اند. هر فیلتری برای نوعی از تصویر خوب و برای نوع دیگر ممکن است عملکرد نامناسبی داشته باشد. اوجالا و همکاران [۱۲]، روش الگوهای دودویی محلی را با روش‌های فیلترینگ راندن و هاسوی مقایسه کردند و نتایج روش الگوهای دودویی محلی از اغلب روش‌های دیگر بهتر بوده است.

الگوی دودویی محلی دارای انواع نمونه‌های توسعه‌یافته دیگری نیز است که برای استخراج ویژگی تصاویر بافتی با ویژگی‌هایی با تمایز بیشتر می‌باشد. ژبو و همکاران الگوی دودویی محلی کامل [۱۳] یعنی CLBP ارائه شد که برخلاف سایر روش‌ها که فقط از علامت تفاضل الگوی دودویی استفاده می‌کنند در آن هم از علامت (CLBP_S) و هم از اندازه این تفاضل (CLBP_M) استفاده می‌شود ضمن اینکه اطلاعات نقطه مرکزی (CLBP_C) هم استفاده می‌شود. این روش با ترکیب این ۳ نوع اطلاعات به درصد بالایی از کلاس‌بندی دست یافته است. ژبو و همکارانش در ادامه روش دیگری بنام الگوی دودویی محلی واریانس (LBPV) را ارائه کردند [۱۴] که در آن واریانس هر همسایگی را به‌عنوان وزن هرکدام از ویژگی‌های استخراج‌شده لحاظ می‌کند. البته این روش مشکل حساس بودن به چرخش دارد که با ارائه یک نوع تکنیک بنام "جهت اصلی بافت" برطرف شده است. در [۱۵] ژائو و همکاران روش دودویی محلی شمارشی کامل (CLBC) را ارائه کردند که کاری به همگن و ناهمگن بودن الگوها ندارد و فقط بر اساس تعداد یک‌های استخراج‌شده از کد دودویی محلی ویژگی‌های را استخراج می‌کند.

یک مشکل اصلی در عملگرهای محلی حساسیت به نویز است و الگوی دودویی محلی نیز دارای همین مشکل می‌باشد. روش‌های الگوی دودویی محلی مختلفی برای مقاوم‌سازی به نویز ارائه شده است. لیائو و همکاران روشی بنام الگوی دودویی محلی غالب (DLBP) ارائه کردند [۱۶] که در آن بجای توجه

را در این بین روش‌های آماری به خود اختصاص داده‌اند. از جمله روش‌های مهم و قدیمی آماری برای استخراج ویژگی روش ماتریس هم‌رخدادی و الگوی دودویی محلی است. روش‌های خودهمبستگی و مبتنی بر مدل مارکوف نیز از جمله روش‌های مبتنی بر مدل است. ویژگی‌های حاصل از عملگرهای ریخت‌شناسی و تکستون از جمله موارد مبتنی بر ساختار است. تبدیل فوری، فیلترهای گابور، تبدیل موجک نیز روش‌هایی است که از پردازش فرکانسی برای استخراج ویژگی استفاده می‌کنند. برخی ویژگی‌های آماری مرتبه اول و دوم از اولین ویژگی‌هایی بودند که برای آنالیز بافت تصویر استفاده می‌شود. ماتریس وقوع هم‌رخدادی برای اولین بار توسط هارالیک [۳] معرفی شد که احتمال وقوع مشترک دو مقدار را در یک جهت و فاصله مشخص بدست می‌آورد. بنابراین ماتریس وقوع هم‌رخدادی در فواصل و جهات مختلف ایجاد شده و سپس ویژگی‌های آماری از قبیل انرژی، واریانس، آنتروپی، تباین و میانگین به‌عنوان ویژگی بافت استخراج می‌شود. محاسبه این ماتریس در جهات و فواصل مختلف و سپس استخراج ویژگی از آن، پیچیدگی محاسباتی بالایی دارد و با احتساب تمام ویژگی‌ها، دقت طبقه‌بندی در حدود ۶۰ تا ۷۰ درصد گزارش شده است. البته این روش علی‌رغم سادگی آن مشکلاتی هم مثل حساس بودن به چرخش و تغییر سطوح خاکستری دارد. ویژگی‌های استخراج‌شده توسط روش‌های آماری کاربردهای زیادی دارد. اوجالا و همکاران، از الگوی دودویی محلی [۴] برای طبقه‌بندی بافت تصویر استفاده کرده‌اند. با توجه به اینکه الگوی دودویی محلی (LBP) بر اساس الگوهای همگن کار می‌کند و بیشتر یکسان بودن بیت‌های استخراج‌شده را مدنظر دارد و کمتر به الگوهای ناهمگن توجه دارد. ترکیب آن با یک توصیفگر دیگری مثل واریانس محلی (VAR) می‌تواند ویژگی‌های بسیار بهتری را استخراج کند. زیرا واریانس برعکس الگوی دودویی محلی، تفاوت و غیرهمسان بودن نقاط یک ناحیه را استخراج می‌کند. لذا اوجالا و همکاران روش LBP/VAR [۵] را ارائه کردند که این روش ویژگی‌های بسیار بهتری را نسبت به LBP و VAR استخراج می‌کند. اخیراً برخی از روش‌های طبقه‌بندی بافت، از ترکیب روش‌های پردازش سیگنال، روش‌های آماری و روش‌های بر اساس مدل نیز استفاده نموده‌اند. مثلاً اریواژگان و همکاران [۶]، از اعمال ماتریس وقوع هم‌رخدادی بر زیر باندهای حاصل از تبدیل موجک به‌منظور استخراج ویژگی و طبقه‌بندی بافت استفاده نموده‌اند. هیرمس و همکاران [۷] نیز از اعمال ماتریس وقوع هم‌رخدادی بر تبدیل موجک درختی استفاده نموده‌اند. رامانا و همکاران [۸]، 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 [۹]، از ترکیب عملگرهای آماری و ریخت-شناسی بر روی خروجی

الگوهای دودویی محلی ارائه شده است که پیچیدگی محاسباتی آن نسبت به شکل اصلی الگوهای دودویی محلی کمتر و دقت طبقه‌بندی آن نیز از شکل اصلی و بهبود یافته الگوهای دودویی محلی بیشتر می‌باشد. البته این روش مخصوص بافت‌های بدون نویز است و کارایی آن برای بافت‌های نویز کم می‌شود.

(۲) روش‌های مرتبط

در این قسمت به بررسی الگوی دودویی محلی و واریانس محلی برای استخراج ویژگی از تصاویر بافتی می‌پردازیم.

(۱-۲) الگوی دودویی محلی

روش الگوی دودویی محلی، روشی غیر پارامتریک می‌باشد که باید در آن تعداد نقاط همسایگی P و شعاع همسایگی R تعیین شود. یکی از مشکلات روش الگوهای دودویی محلی اولیه، تعداد ویژگی‌های استخراج شده است که برابر با 2^P است.

0	2	0	1	2	4	0	1	0	0	19	3
8		16	8		16	1		1	5	5	6
0	0	0	32	64	128	0	0	0	3	2	4

کد دودویی محلی

وزن

کد دودویی

تصویر

شکل ۱: انتخاب همسایگی به صورت مربعی

روش الگوی دودویی محلی مزایای مختلفی دارد یکی از این مزیت‌ها، سادگی آن می‌باشد. ضمن اینکه قابلیت استخراج اطلاعات محلی را با دقت بالا دارد و چون از تفاضل سطوح خاکستری استفاده می‌کند، نسبت به تغییرات یکنوای سطوح خاکستری غیر حساس است. شکل ۱ یک مثال از نحوه محاسبه الگوی دودویی محلی را نشان می‌دهد. روابط ۱ و ۲ هم محاسبه الگوی دودویی محلی را نشان می‌دهد.

$$LBP_{P,R}(x,y) = \sum_{i=0}^{P-1} s(g_i - g_c) 2^i \quad (1)$$

$$s(g_i - g_c) = \begin{cases} 1 & g_i \geq g_c \\ 0 & g_i < g_c \end{cases} \quad (2)$$

که در آن R شعاع همسایگی، P تعداد نقاط موجود در همسایگی، g_c شدت روشنایی نقطه مرکزی و g_i نیز شدت روشنایی نقاط موجود در همسایگی می‌باشد. با توجه به شکل الگوهای دودویی محلی، خروجی این عملگر برای هر همسایگی از تصویر، یک عدد دودویی P بیتی است که دارای 2^P مقدار مختلف می‌باشد. شکل ۲ چند نمونه از همسایگی‌های دایره‌ای الگوی دودویی محلی را نشان می‌دهد. روش دیگر الگوی

به الگوهای همگن یا ناهمگن به فراوانی آن‌ها توجه شده است و الگوهایی که ۸۰ درصد از کل تصویر را به خود اختصاص می‌دهند و در اکثریت هستند برای طبقه‌بندی استفاده شد. هدف اصلی این روش مقاوم شدن به نویز بود چراکه وجود نویز باعث تغییر الگوهای همگن به الگوهای ناهمگن شده و درصد الگوهای همگن را کم می‌کند. همچنین روش دیگری بنام الگوی سه‌تایی محلی (LTP) ارائه شده است که بیشترین کاربرد مقاوم‌سازی نسبت به نویز را دارد. این روش به وسیله تن و همکاران [۱۷] ارائه شد و از هر الگوی محلی دو هیستوگرام استخراج می‌کند و آن‌ها را به متصل می‌کند. از دیگر روش‌های دودویی محلی مقاوم به نویز می‌توان به روش بسیار زمان‌بر فازی یا FLBP [۱۸] اشاره کرد که بر اساس تابع عضویت منطق فازی هیستوگرام الگوی دودویی محلی را می‌سازد.

روش‌های دیگری نیز مانند ILBP [۱۹] ارائه شده که بجای نقطه مرکزی از میانگین کل نقاط هر همسایگی استفاده می‌کند. روش‌های مقاوم به نویز دیگری هم ارائه شد. روش NTLBP توسط فتحی و نیلچی [۲۰] ارائه شد که در آن با توجه به اکثریت مقدار بیت‌های الگوی دودویی، بیت‌هایی از کد دودویی که احتمالاً حاوی نویز هستند تصحیح می‌شود. روش NRLBP نیز یک روش مقاوم به نویز است که توسط رن و همکارانش [۲۱] ارائه شد این روش بسیار وقت‌گیر است و صرفاً برای همسایگی‌های کوچک قابل استفاده است و بر اساس درصد الگوهای دودویی همگن الگوهای مشکوک به نویز را تصحیح و آن‌ها را از حالت ناهمگن به همگن تبدیل می‌کند. روش BRINT [۲۲] از دیگر روش‌های پیشرفته‌ای است که وقت زیادی برای پردازش لازم دارد و با ترکیب هیستوگرام‌های روش CLBP و میانگین‌گیری نقاط روی همسایگی اثر نویز را کاهش می‌دهد. روش CRLBP [۲۳] نیز که توسط ژائو و همکاران ارائه شد همان روش CLBP است که قبل از آن فیلتر 3×3 میانگین‌گیر وزن‌دار برای اعمال به بافت برای کاهش نویز استفاده شده است.

سونگ و همکاران [۲۴] روش الگوی تمایز محلی (LCP) را برای طبقه‌بندی بافت‌های نویزدار ارائه کردند. در این روش با جستجوی در یک مجموعه از الگوهای محلی و با در نظر گرفتن برخی معیارهای غیر محلی و در یک ناحیه بزرگتر از الگوی محلی ویژگی‌های بافتی استخراج می‌شود. ریو و همکاران [۲۵] روش الگوی دودویی محلی مرتب‌شده متوالی (scLBP) را ارائه کردند. در این روش الگوها بدون توجه به تغییراتشان کدگذاری می‌شوند. این روش مبتنی بر درخت kd است که در واقع این درخت، نوعی ساختار برای ذخیره‌سازی مجموعه متناهی از مقادیر برای تقسیم‌بندی مقادیر در فضای k بعدی می‌باشد. پاکدل و تاجری پور [۲۶] روشی جدید از الگوی دودویی محلی ارائه کردند. در این روش، یک شکل جدید از

مقادیر واریانس‌های محلی تصویر تولید گردد. برای تولید نتایج یک فاز آموزش طولانی‌تر لازم است [5]. از ترکیب هیستوگرام LBP با VAR ویژگی‌های LBP/VAR تولید می‌شود.

۳) معیارهای مقایسه و طبقه‌بندی

معیارهای مختلفی در مقالات مختلف [5] بعنوان معیار ارزیابی طبقه‌بندی و معیار فاصله در قطعه‌بندی بافت استفاده شده است که مشهورترین آنها ۳ معیار مقایسه هیستوگرام است که عبارتند از:

- معیار شباهت لگاریتمی
- معیار شباهت اشتراک هیستوگرام
- معیار فاصله مربع کای

۳ مورد اخیر روش‌هایی سریع و با حجم محاسبات کم برای مقایسه هیستوگرام استخراج‌شده از بافت‌ها بدون استفاده از روش‌های طبقه‌بندی کلاسیک و متداول است. اگر S_i و M_i به ترتیب مقادیر i امین مقدار هیستوگرام مدل (تصویر مرجع) و نمونه باشند برای مقایسه هیستوگرام اگر هر یک از هیستوگرام‌ها n تا مقدار داشته باشند. روابط بصورت ۵ تا ۷ است. معیار شباهت لگاریتمی از اولین روش‌هایی است که در مقالات استفاده دارد و بصورت رابطه ۵ تعریف می‌شود.

$$LL(S, M) = \sum_{i=1}^n S_i \cdot \log\left(\frac{S_i}{M_i}\right) \quad (5)$$

معیار شباهت اشتراک دو هیستوگرام هم در برخی موارد استفاده شده است که با رابطه ۶ بیان می‌شود.


$$HI(S, M) = \sum_{i=1}^n \min(S_i, M_i) \quad (6)$$

معیار فاصله مربع کای از دو مورد اخیر بیشتر کاربرد دارد.

$$\chi^2(S, M) = \sum_{i=1}^n \frac{(S_i - M_i)^2}{(S_i + M_i)} \quad (7)$$

روش مربع کای که در رابطه ۷ بیان شده، نه تنها مقدار دو ویژگی را با هم مقایسه می‌کند بلکه به نوعی وزن دهی هم انجام می‌دهد یعنی هرچه مقادیر مورد مقایسه بیشتر باشد مقدار کسر کمتر شده و اثر آن‌ها در مقایسه دو تصویر بافتی بیشتر لحاظ می‌شود. در این مقاله نیز مانند اغلب مقالات معتبر [۲۳-۲۱]، از روش مربع کای برای طبقه‌بندی بافت‌ها با روش طبقه‌بندی نزدیک‌ترین همسایه K-NN با $k=1$ استفاده می‌شود.

دودویی محلی روش $LBP_{P,R}^{u2}$ است که فقط از الگوهای همگن استفاده می‌کند. این روش هم مانند LBP عادی حساس به چرخش است ولی تعداد ویژگی‌های استخراج‌شده توسط آن کمتر است و برابر است با ترکیبات مختلف همگن یعنی $P(P-1)+3$ که برای P های بزرگ این تعداد خیلی زیاد است.



شکل ۲: همسایگی‌های دایره‌ای به ازای مقادیر مختلف R, P

روش‌های دیگری که در ادامه ارائه شد که برخلاف دو روش قبلی غیرحساس به چرخش است. این روش‌ها $LBP_{P,R}^{riu2}$ و $LBP_{P,R}^{ri}$ می‌باشد. از آنجاکه روش $LBP_{P,R}^{riu2}$ هم از لحاظ کارایی و هم از لحاظ سرعت و تعداد کم ویژگی‌های مناسب‌ترین و بهترین روش می‌باشد لذا روش نگاشت مورد استفاده در آن یعنی $riu2$ در اغلب مقالات و تحقیقات بعدی بعنوان روش نگاشت مناسب انتخاب شده و دو روش دیگر یعنی $iu2$ به دلیل حساسیت به چرخش (و حجم نسبتاً زیاد ویژگی‌ها) و ri به دلیل حجم زیاد ویژگی‌ها استخراج شده، نسبت به $riu2$ کمتر استفاده می‌شود. در این تحقیق نیز یک روش نگاشت غیرحساس به چرخش ارائه شده که با روش $LBP_{P,R}^{riu2}$ مقایسه شده است و کلیه پیاده‌سازی نمونه‌های دیگر LBP هم با $riu2$ انجام شده است.

۲-۲) واریانس محلی

اگر در هر همسایگی مقدار واریانس نقاط همسایگی محاسبه شود، یک توصیفگر جدید بنام واریانس محلی حاصل می‌شود.

$$\mu = \frac{1}{P} \sum_{i=0}^{P-1} g_i \quad (3)$$

$$VAR_{P,R}(x, y) = \frac{1}{P} \sum_{i=0}^{P-1} (g_i - \mu)^2 \quad (4)$$

روابط ۳ و ۴ محاسبه واریانس را نشان می‌دهند. در اینجا مقدار واریانس برای یک ناحیه محلی از نقاط همسایگی محاسبه شده است. در حقیقت رابطه ۴ مقدار واریانس محلی نقاط روی همسایگی ناحیه دایره‌ای را محاسبه می‌کند. با توجه به اینکه مقدار واریانس کمی پیوسته است باید ابتدا گسسته شود [5] سپس هیستوگرام مقادیر گسسته شده واریانس از روی کل

۴) روش پیشنهادی برای استخراج ویژگی

در اینجا یک رابطه جدید برای توصیف ویژگی‌های بافتی در یک همسایگی محلی ارائه می‌شود. از آنجاکه از لحاظ ظاهری رابطه پیشنهادی با رابطه انتروپی شباهت دارد لذا الگوی انتروپی محلی نام‌گذاری شده است.

الگوی دودویی محلی بر اساس الگوهای همگن و مشابه، ویژگی‌های را استخراج می‌کند. برعکس آن در واریانس عدم تشابه و در واقع میزان ناهمسانی الگوها استخراج می‌شود. ترکیب این دو، ویژگی‌هایی بسیار متمایزکننده را برای طبقه‌بندی تولید می‌کند. در اینجا روشی مشابه واریانس ارائه شده که ناهمسانی محلی الگوها را استخراج می‌دهد. رابطه ۸ یک رابطه استاندارد است که محاسبه مقدار انتروپی برای کل نقاط یک تصویر را نشان می‌دهد. در این مقاله رابطه ۹ و ۱۰ به‌عنوان یک توصیفگر جدید برای تصاویر بافتی بنام الگوی انتروپی محلی^۱ پیشنهاد شده است. این روابط برای یک ناحیه محلی و یک همسایگی از نقاط روی ناحیه دایروی مطابق شکل ۲ ارائه شده است.

$$Entropy_{x,y} = - \sum_{i=1}^M \sum_{j=1}^N P(g_i) \times \log(P(g_i)) \quad (8)$$


$$LEP1_{P,R}(x,y) = - \frac{1}{P} \sum_{i=0}^{P-1} g_i \times \log(1 + g_i) \quad (9)$$

$$LEP2_{P,R}(x,y) = - \frac{1}{P+1} (g_c \times \log(1 + g_c) + \sum_{i=0}^{P-1} g_i \times \log(1 + g_i)) \quad (10)$$

رابطه ۹ محاسبه‌ای مشابه انتروپی برای نقاط روی دایره برای هر همسایگی را نمایش می‌دهد. باید توجه داشت که در اینجا از مقدار خود نقاط و نه توزیع آن‌ها استفاده شده است و به دلیل شباهت رابطه‌های پیشنهادی با رابطه ۸ لذا روش پیشنهادی با نام انتروپی نام‌گذاری شده است. اگر بخواهیم در یک ناحیه محلی بسیار کوچک مشابه رابطه ۸ از رابطه اصلی انتروپی یعنی توزیع نقاط استفاده کنیم اغلب مقدار صفر تولید می‌شود لذا از خود نقاط و نه توزیع آن‌ها در رابطه پیشنهادی استفاده شده است. LEP2 هم مشابه LEP1 است ولی در آن نقطه وسط هم لحاظ شده است. یعنی انتروپی نقاط روی همسایگی و مرکز طبق رابطه ۱۰ محاسبه می‌شود. برای جلوگیری از محاسبه نامعین و جلوگیری از مقدار صفر در لگاریتم یک واحد به مقدار هرکدام از نقاط همسایگی اضافه شده است. نتایج LEP2 کمی بهتر از LEP1 است. مقدار حاصل با LEP1 یا LEP2 نمایش داده شده است. این مقادیر همانند VAR مقادیری پیوسته است که باید

گسسته شود. کلیه مراحل گسسته کردن و فاز آموزش انتروپی مشابه VAR است [5]. در این مقاله کل بازه مقادیر انتروپی به ۶۰ بازه (میله هیستوگرام) تقسیم شده است. دقیقاً همین کار برای VAR هم انجام شده است تا در شرایط مساوی نتایج واریانس و انتروپی با هم مقایسه شود.

شکل ۳ میزان میانگین تغییرات اندازه VAR و LEP را به ازای مقادیر مختلف نویز (SNR) برای پایگاه داده Outex نشان می‌دهد. طبق این شکل تغییرات اندازه LEP بر اثر نویز بسیار کمتر از میزان تغییرات اندازه VAR است. این به دلیل آن است که مقدار لگاریتم یک عدد بسیار کمتر از خود آن عدد است. تغییرات لگاریتم هم بسیار کمتر از تغییرات خود عدد است. یعنی ویژگی‌های استخراج‌شده توسط روابط ۹ و ۱۰ در برابر نویز تغییرات بسیار ناچیزی خواهند داشت درحالی‌که ویژگی‌های استخراج‌شده از واریانس محلی با افزایش نویز به شدت زیاد می‌شوند. به زبان دیگر روش ارائه شده نسبت به نویز مقاوم‌تر از روش واریانس محلی است.



شکل ۳: تغییرات اندازه VAR و LEP متناظر با تغییرات نویز

۵) نتایج پیاده‌سازی و بررسی عملکرد

برای بررسی عملکرد روش ارائه شده برای استخراج ویژگی به منظور طبقه‌بندی بافت تصویر، از مجموعه داده استاندارد Outex [۲۷], CURET [۲۸] و UIUC [۲۹] استفاده شده است. این ۳ پایگاه داده از معروف‌ترین تصاویر بافتی می‌باشد که در طبقه‌بندی و قطعه‌بندی بافت استفاده می‌شود.

پیش از بررسی نتایج پیاده‌سازی و مقایسه آن‌ها با روش‌های دیگر، ابتدا با یک شکل، مقاوم بودن روش پیشنهادی نشان داده می‌شود. شکل ۴ تغییرات ویژگی‌های استخراج‌شده در اثر اعمال نویز گاوسی با SNR=5 به یکی از تصاویر پایگاه داده UIUC را نشان می‌دهد. همان‌طوری که از این شکل و هیستوگرام استخراج‌شده (بردار ویژگی‌های) مشخص است وجود نویز باعث تغییرات بسیار شدیدی در ویژگی‌های

¹ Local Entropy Pattern (LEP)

جدول ۱ نتایج طبقه‌بندی با استفاده از ویژگی‌های استخراج‌شده توسط روش پیشنهادی و چندین روش مشهور دیگر برای تصاویر بافتی نویزی TC13 را نشان می‌دهد. مطابق با این جدول برای هر ۳ حالت از میزان نویز، مقدار دقت طبقه‌بندی با هرکدام از دو روش پیشنهادی LEP1 و LEP2 بسیار بهتر از LBP و VAR بوده است. همچنین روش LBP/LEP1 و LBP/LEP2 هر دو نتایج طبقه‌بندی بسیار بهتری نسبت به LBP/VAR تولید کرده‌اند. در جدول اخیر از ترکیب هیستوگرام LBP, VAR و LEP بهترین دقت ممکن برای همه مقادیر انحراف معیار تولید شده است.

جدول ۱ نشان می‌دهد که استفاده از روش الگوی آنتروپی محلی و ترکیب آن با LBP و VAR نتایجی به مراتب بهتر از بسیاری از روش‌های پیچیده و مقاوم به نویز مثل LTP, FLBP, LBP, NTLBP, DLBP, NRLBP, CRLBP و چند نمونه از روش LCP فراهم کرده است. استفاده از ویژگی‌های استخراج‌شده LEP1 و LEP2 بدون ترکیب آن‌ها با LBP و VAR هم نتایجی تولید کرده که به مراتب از بسیاری از روش‌های پیچیده و زمان‌بر می‌باشد. ضمن اینکه ترکیب روش‌های پیشنهادی با دیگر روش‌های الگوی دودویی محلی باعث افزایش دقت طبقه‌بندی تا ۱۵ درصد نیز می‌شود.

جدول ۱ نتایج را فقط برای شعاع همسایگی $R=1$ و تعداد همسایگی $P=8$ نشان می‌دهد. جدول ۲ نتایج پیاده‌سازی روی تصاویر بافتی TC13 را برای ۳ شعاع همسایگی مختلف نمایش می‌دهد. این تصاویر فاقد نویز هستند. نتایج حاصل از این جدول نشان می‌دهد که روش پیشنهادی برای تصاویر بدون نویز هم خوب عمل می‌کند. یک نکته دیگر این جدول آن است که برخلاف LBP و VAR، عملکرد روش پیشنهادی با افزایش شعاع و تعداد نقاط همسایگی تغییر چندانی نمی‌کند و کارایی آن برای شعاع ۲ و تعداد همسایگی ۱۶ کمی بهتر از ۲ حالت دیگر است.

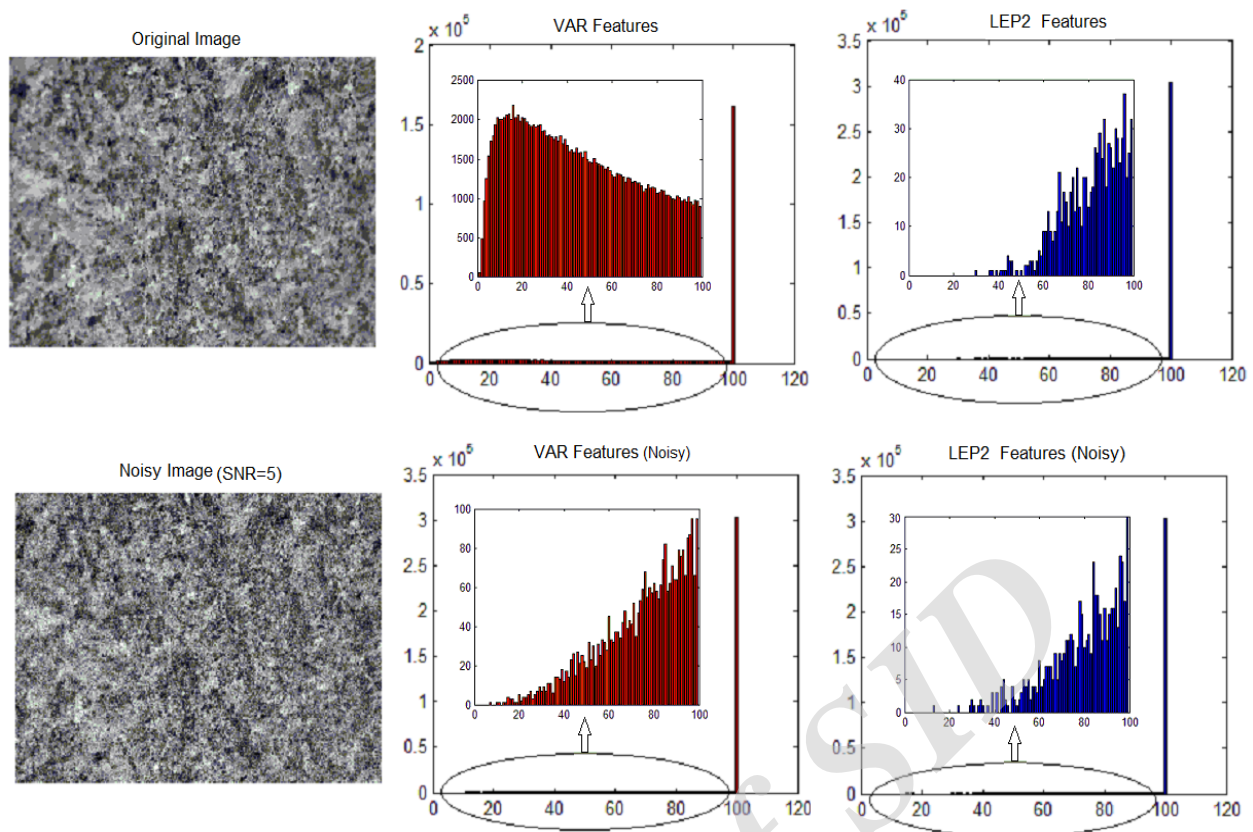
روش پیشنهادی برای پایگاه‌های داده‌ای مانند TC13 که حاوی تصاویر با لبه‌ها و جزئیات زیاد است، کارایی بسیاری بالایی دارد. در مقابل برای تصاویر مانند پایگاه داده CURET که شامل تصاویری با جزئیات و لبه‌های کم و شباهت زیاد به هم است، روش پیشنهادی دقت کمتری دارد. برای تصاویری با مشخصات مشابه با تصاویر CURET یا Outex(TC10) برخی از روش‌ها مانند LCP که از کنتراست محلی استفاده می‌کند، دقت بالاتری دارد.

استخراج‌شده توسط VAR می‌شود، درحالی‌که برای توصیفگر LEP2 این تغییرات بسیار ناچیز است. به عبارت دیگر توصیفگر پیشنهادی نسبت به نویز بسیار مقاوم می‌باشد و وجود نویز شدید گاوسی باعث نشده که ویژگی‌های استخراج‌شده تغییرات زیادی داشته باشد.

باید توجه داشت که در شکل ۴ مقدار آخرین ویژگی یعنی بازه آخر هیستوگرام مربوط به واریانس در اثر نویز تقریباً دو برابر شده ولی همین مقدار برای روش پیشنهادی، تغییر ناچیزی داشته است. همچنین سایر بازه‌های هیستوگرام‌ها، که به دلیل کوچک بودن قابل مشاهده نبود بزرگنمایی شده است. در این قسمت‌ها نیز تغییرات ویژگی‌های حاصل از توصیفگر پیشنهادی در اثر نویز، بسیار کم است.

۵-۱) نتایج پیاده‌سازی روی پایگاه Outex

مجموعه داده Outex، شامل ۲۴ کلاس بافتی است. در این پایگاه داده تعداد بسیار زیادی دسته‌بندی بافت‌ها تحت عنوان‌های مختلف وجود دارد. در این مقاله از دسته بافت‌های TC10, TC12(t), و TC13 استفاده شده است. در واقع این دسته داده تحت روشنایی خاص و در ۹ جهت چرخش متفاوت (۰، ۵، ۱۰، ۱۵، ۳۰، ۴۵، ۶۰، ۷۵ و ۹۰ درجه) جمع‌آوری شده‌اند. برای هر بافت، ۲۰ نمونه در هر جهت و با هر شدت روشنایی وجود دارد. اندازه هر تصویر در این مجموعه داده 128×128 می‌باشد. چون تصاویر این مجموعه آزمون در جهات مختلف هستند. برای TC10، بافت هر کلاس با استفاده از روشنایی "inca" و در جهت صفر درجه آموزش داده شده است و با نمونه‌هایی با همان روشنایی و در ۸ جهت دیگر آزمایش می‌گردد. در این گروه آزمون، ۴۸۰ نمونه آموزشی و ۳۸۴۰ نمونه آزمون موجود است. TC12 شامل ۹۱۲۰ تصویر بافتی است که با دو زاویه روشنایی تحت عناوین TC12(h) و TC12(t) می‌باشد که با توجه به مشابه بودن نتایج این دو دسته از بافت‌ها در اینجا فقط نتایج TC12(t) نمایش داده شده است. همچنین از دسته بافتی TC13 از همین پایگاه داده برای ارزیابی روش پیشنهادی استفاده شده است. دسته بافت‌های TC13 شامل ۶۸ کلاس بافتی است و از تنوع بسیار بالایی برخوردار است. برتری روش پیشنهادی برای این دسته از تصاویر بسیار بهتر از بسیاری از موارد دیگر است.



شکل ۴: تغییرات ویژگی‌های استخراج‌شده توسط VAR و LEP2 در اثر نویز

جدول ۱: نتایج طبقه‌بندی روی تصاویر نویزی پایگاه داده (TC13) با میزان نویز گاوسی مختلف

	TC13 (R=1,P=8)		
	$\sigma = 0.05$	$\sigma = 0.1$	$\sigma = 0.15$
LBP	18.97	13.53	11.59
VAR	15.44	8.97	9.85
LEP1	66.03	54.85	45.00
LEP2	67.35	57.50	44.85
LBP/VAR	19.85	15.74	14.12
LBP/LEP1	41.18	31.76	29.26
LBP/LEP2	39.85	31.18	29.41
LBP_VAR_LEP1	75.00	65.00	47.06
LBP_VAR_LEP2(R=1)	75.29	64.85	46.77
LBP_VAR_LEP2(R=2)	78.53	68.68	55.88
LBP_VAR_LEP2(R=3)	78.53	69.41	60.29
LTP (T=10)	25.53	16.76	14.32
LTP_LEP1	75.24	62.06	48.38
LTP_LEP2	74.85	65.29	49.26
CRLBP(a=1)	48.09	33.74	28.88
FLBP	62.50	54.10	43.61
DLBP	52.98	42.11	33.45
NRLBP	63.30	54.95	43.75
NTLBP	33.20	32.30	27.20
LCP^{re} (R=4)	55.20	44.10	40.12
LCP^{re} (R=5)	56.12	46.01	42.24
LCP^{rtu2} (R=4)	63.10	50.20	45.82
LCP^{rtu2} (R=5)	62.28	51.23	47.12
پاکدل	23.12	14.45	12.87

جدول ۲: نتایج طبقه‌بندی روی تصاویر پایگاه داده (TC13) Outex با همسایگی‌های مختلف

	(P,R)=8,1	(P,R)=16,2	(P,R)=24,3
<i>LBP^{riu 2}</i>	76.18	78.53	78.68
VAR	61.47	63.68	65.59
ENT1	87.21	88.09	86.18
ENT2	85.74	87.94	85.29
LBP/VAR	70.74	75.74	76.62
LBP/ENT1	83.24	84.56	82.50
LBP/ENT2	83.65	85.00	83.09
LBP_VAR_ENT1	92.94	92.79	92.79
LBP_VAR_ENT2	93.24	93.09	92.35
LTP (T=10)	67.65	83.97	85.74
LTP_ENT1	91.76	93.24	93.24
LTP_ENT2	91.47	92.79	93.09

جدول ۳: نتایج طبقه‌بندی روی تصاویر پایگاه داده (TC10, TC12(t), TC12(h)) Outex با همسایگی‌های مختلف

	(P,R)=8,1			(P,R)=16,2		
	TC10	TC12(t)	TC12(h)	TC10	TC12(t)	TC12(h)
<i>LBP^{riu 2}</i>	84.82	65.46	63.68	89.40	82.27	75.21
VAR	89.32	64.10	66.02	88.26	63.52	69.07
ENT1	74.69	51.90	55.00	82.86	70.25	72.78
ENT2	75.69	55.79	60.49	82.79	70.93	72.64
LBP/VAR	92.47	72.20	76.88	95.70	84.38	85.19
LBP/ENT1	95.42	80.44	80.44	94.79	86.62	87.85
LBP/ENT2	95.42	80.44	80.56	94.84	86.55	87.96
LBP_VAR_ENT1	97.64	84.70	85.79	97.60	89.07	90.02
LBP_VAR_ENT2	96.93	84.61	86.46	97.32	89.03	90.02
LTP (T=10)	90.68	81.04	81.62	97.21	92.48	89.91
LTP_ENT1	96.95	82.69	84.79	98.52	92.55	92.73
LTP_ENT2	97.16	82.80	84.44	98.46	92.38	92.80
FLBP [33]	90.63	72.31	70.63	92.99	87.13	71.67
NTLBP [40]	84.24	69.70	64.42	85.76	80.42	75.28
NRLBP [41]	89.79	73.52	69.19	89.24	78.89	73.36
پاکدل [24]	92.08	81.48	74.17	92.00	82.62	77.48



شکل برای کلیه مقادیر SNR روش LBP/LEP2 دقت طبقه‌بندی بالاتری نسبت به LBP/VAR دارد. شکل ۵-ب مقایسه دقت طبقه‌بندی برای ویژگی‌های حاصل از LBP,VAR و LEP2 را برای TC10 نمایش می‌دهد. مطابق با این نمودارها برای نویزهای شدید ($SNR < 10$) نتایج LEP2 بهتر از LBP و VAR است. بررسی نمودارهای شکل ۶ هم نتایج مشابه شکل ۴ را نشان می‌دهد. شکل ۶-الف نمودارهای مقایسه دقت LBP/VAR و LBP/LEP2 را برای داده‌های TC12 (t) نشان می‌دهد. مطابق با این شکل برای کلیه مقادیر SNR روش LBP/LEP2 دقت طبقه‌بندی بالاتری نسبت به LBP/VAR دارد. شکل ۶-ب مقایسه دقت طبقه‌بندی برای ویژگی‌های حاصل از LBP,VAR و LEP2 را برای TC12(t) نمایش می‌دهد. مطابق با این نمودارها برای نویزهای شدید ($SNR < 10$) نتایج LEP2 بهتر از LBP و VAR است.

جدول ۳ نتایج مقایسه روش پیشنهادی را برای تصاویر بدون نویز (TC10, TC12(t), TC12(h)) Outex نمایش می‌دهد. مطابق با این جدول، دقت روش‌های پیشنهادی برای تصاویر بدون نویز، ممکن است نسبت به برخی روش‌ها مثل VAR و اغلب روش‌های دیگر کمتر باشد، ولی هنگامی که روش‌های پیشنهادی با روش‌های الگوی دودویی ترکیب می‌شود، دقت روش به شدت افزایش می‌یابد. بنابراین ترکیب روش‌های پیشنهادی با سایر روش‌های الگوی دودویی باعث می‌شود که برای تصاویر بدون نویز هم نتایج دقت طبقه‌بندی بالایی حاصل شود. در ادامه مقایسه‌ای بین ۳ توصیفگر پایه یعنی LBP,VAR و LEP1 (یا LEP2) روی داده‌های مختلف با شدت نویز مختلف، انجام می‌شود. همچنین نتایج ترکیب این توصیفگرها نیز به صورت نمودار میله‌ای مقایسه می‌شود. شکل ۵-الف نمودارهای مقایسه دقت LBP/VAR و LBP/LEP2 را برای داده‌های TC10 نشان می‌دهد. مطابق با این



در ادامه توضیح داده خواهد شد که برای برخی پایگاه‌های داده مثل CURET که تصاویر آن جزئیات کمی دارند و تصاویر رده‌های مختلف خیلی به هم شبیه هستند، عملکرد LEP کاهش می‌یابد ولی با ترکیب آن با LBP می‌توان به نتایج بهتری دست پیدا کرد. همان‌طوری که در توضیحات جدول ۱ اشاره شد، برای تصاویری مانند CURET استفاده از روش‌هایی مانند الگوی کنتراست محلی یا LCP نتایج بهتری نسبت به روش پیشنهادی فراهم می‌کند. برای تصاویری با جزئیات و لبه‌های زیاد مانند تصاویر TC13 همان‌طوری که در جدول ۱ نشان داده شده است، عملکرد روش پیشنهادی بالاترین دقت را نسبت به سایر روش‌های بروز و پیشرفته دارد. برای تصاویری مانند UIUC نیز به دلیل زیاد بودن جزئیات و لبه‌ها دقت روش پیشنهادی بالا است.

باید توجه داشت که در هرکدام از شکل‌های این مقاله فقط نتایج یکی از دو روش LEP1 یا LEP2 نمایش داده شده است. زیرا نتایج این دو روش اغلب بسیار به هم نزدیک است. همچنین نتایج پیاده‌سازی روی داده‌های TC12(h) نیز نتایج مشابه شکل‌های ۵ و ۶ دارد لذا از بیان آن صرف‌نظر شده است. در همه نمودارهای رسم شده همسایگی با شعاع ۱ و تعداد نقاط ۸ استفاده شده است.

در پیاده‌سازی‌های انجام‌شده روی تصاویر پایگاه داده Outex نشان داده شد که برای برخی تصاویر مانند TC13 که از تنوع و تغییرات بسیار زیادی برخوردار است و از ۶۸ کلاس بافتی تشکیل شده است روش پیشنهادی عملکرد بسیار خوبی دارد و دقت طبقه‌بندی در آن بسیار بهتر از روش‌های الگوی دودویی محلی و واریانس محلی است. در مقابل برای تصاویر TC10 و TC12 که ۲۴ کلاس هستند عملکرد روش پیشنهادی کمی بهتر از روش‌های الگوی دودویی محلی و واریانس است.



شکل ۵: دقت طبقه‌بندی برای تصاویر نویزدار TC10 با SNR مختلف ($R=1, P=8$)، الف) LBP/VAR و LBP/LEP2 و ب) LBP و VAR، LEP2




شکل ۶: دقت طبقه‌بندی برای تصاویر نویزدار TC12(t) با SNR مختلف ($R=1, P=8$)، الف) LBP/VAR و LBP/LEP1 و ب) LBP و VAR، LEP1


۵-۲) نتایج پیاده‌سازی روی پایگاه داده CURET

بهتر از LBP/VAR است. اما شکل ۷-ب نشان می‌دهد که استفاده از LEP2 بجای VAR و LBP فقط برای نویزهای بسیار شدید $SNR < 5$ دقت بالاتری را تولید می‌کند. ضمن اینکه نمودار LEP2 در شکل ۷-ب نشان می‌دهد که برای نویزهای $SNR > 5$ تقریباً دقت روش LEP2 ثابت است و با افزایش نویز تغییری نمی‌کند. در کل، روش پیشنهادی برای تصاویر مانند CURET که بسیار مشابه به هم هستند و بافت‌های آن جزئیات کمی دارد عملکرد مناسبی ندارد و در برابر برخی روش‌ها مانند LCP [۲۴] دقت کمتری تولید می‌کند.

پایگاه داده CURET در واقع بزرگ‌ترین و یکی از جامع‌ترین پایگاه‌های داده بافتی می‌باشد که در اکثر مقالات معتبر از آن استفاده می‌شود. این داده‌ها دارای ۶۱ کلاس است که ۹۲ تصویر بافتی در هر کلاس در زوایای دید و روشنایی‌های مختلف استفاده شده است. از ۹۲ تصویر هر کلاس ابتدا هر بار ۴۶ تصویر برای آموزش و بقیه آن‌ها برای آزمون استفاده شده است و میانگین نتایج ۱۰۰ بار آزمون تصادفی در شکل ۷ نمایش داده شده است. شکل ۷ نتایج مقایسه روش پیشنهادی با VAR و LBP و ترکیبات آن‌ها را نشان می‌دهد. شکل ۷-الف نشان می‌دهد که برای همه مقادیر SNR، روش LBP/LEP2




ب

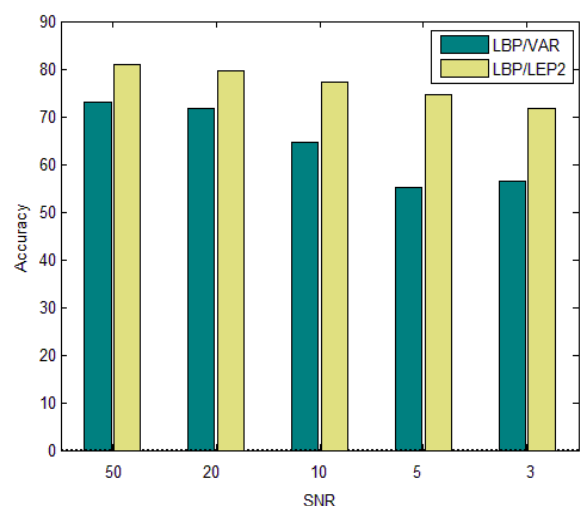


الف

شکل ۷: دقت طبقه‌بندی برای تصاویر نویزدار CURET با SNR مختلف ($R=1, P=8$) (الف) و LBP/LEP2 و BP/VAR (ب) و LBP و VAR و LEP2



ب



الف

شکل ۸: دقت طبقه‌بندی برای تصاویر نویزدار UTUC با SNR مختلف ($R=1, P=8$) (الف) و LBP/LEP2 و BP/VAR (ب) و LBP و VAR و LEP2

۳-۵) پایگاه داده UIUC

از لحاظ تعداد ویژگی‌های استخراج شده، روش LBP وقتی از نگاهت $riu2$ استفاده می‌کند $P+2$ ویژگی را برای هر تصویر استخراج می‌کند که P تعداد نقاط همسایگی است. روش VAR و LEP چون دو روشی هستند که با مقادیر پیوسته سروکار دارند لذا این مقادیر برای اینکه بتوانند به صورت مقادیر هیستوگرام درآیند باید ابتدا گسسته شود. طبق برخی تحقیقات [۵] انجام شده، تعداد میله‌های هیستوگرام نه آنقدر باید کم باشد که دقت پایین بیاید و نه آنقدر زیاد باشد که در برخی جاها در هیستوگرام گسستگی ایجاد شود طبق این تحقیقات حداقل تعداد میله‌های هیستوگرام باید ۱۰ در نظر گرفته شود. برای رسیدن به نتایج مناسب طبق [۵] باید تعداد بسیار زیادی تکرار برای فاز آموزش داشته باشیم تا بهترین محدوده برای تبدیل مقادیر پیوسته به میله‌های هیستوگرام بدست آید. در این تحقیق این تعداد تکرار را حذف کرده‌ایم تا فاز آموزش کوتاه شود در مقابل برای رسیدن به دقت بیشتر از ۶۰ تا میله هیستوگرام برای توصیف بافت استفاده می‌شود. لذا در این مقاله ۶۰ ویژگی به ازای هر بافت استخراج شده است.

طبق روش‌های نمایش داده شده در جدول‌های ۱ تا ۳ به دو روش می‌توان ویژگی‌های توصیفگرهای بافتی را با هم ترکیب کرد. یک روش ترکیب بصورت اتصال هیستوگرام‌ها است که در این روش تعداد ویژگی‌های دو روش با هم جمع می‌شود. این نوع ترکیب به صورت مثلاً LTP_LEP1 نمایش داده می‌شود. تعداد ویژگی‌های LTP_LEP1 برابر است با مجموع تعداد ویژگی‌های LTP و $LEP1$ است. نوع دیگر ترکیب دو روش به صورت ادغام است که مثلاً به صورت LBP/VAR نمایش داده می‌شود که در آن تعداد ویژگی‌های برابر با حاصل ضرب تعداد ویژگی‌های دو توصیفگر ترکیب شده است.

۶) بحث و نتیجه‌گیری

در این مقاله یک روش محلی استخراج ویژگی از بافت‌ها ارائه شده که از لحاظ عملکرد مشابه واریانس است یعنی ناهمگونی و عدم تشابه خصوصیات نقاط بافت را در یک همسایگی دایروی بیان می‌کند. ولی این روش به نوبت بسیار مقاوم‌تر است و ترکیب آن با الگوی دودویی محلی نتایج طبقه‌بندی به مراتب بهتری را تولید می‌کند. این روش مشابه واریانس نسبت به چرخش غیرحساس است همچنین تغییرات روشنایی اثری در نتایج آن ندارد و از لحاظ مقاوم بودن به نوبت بسیار بهتر از واریانس عمل می‌کند.

روش ارائه شده برای برخی تصاویر بافتی مانند UIUC و TC13 عملکرد بسیار بالایی دارد. یعنی LEP به تنهایی می‌تواند ویژگی‌هایی با تمایز بالا برای طبقه‌بندی تولید کند. این

پایگاه UIUC شامل ۲۵ کلاس است که در هر کلاس ۴۰ تصویر وجود دارد. در اینجا هر بار نیمی از تصاویر هر کلاس برای آموزش و نیم دیگر برای آزمون استفاده شده است. و میانگین ۱۰۰ بار آزمون در شکل‌های ۸ نمایش داده شده است. نتایج پیاده‌سازی در شکل ۸-الف نتایجی مشابه پایگاه داده Outex را دارد. یعنی نه تنها دقت حاصل از طبقه‌بندی با کمک ویژگی‌های استخراج شده توسط $LBP/LEP2$ برای همه مقادیر نویز بهتر از LBP/VAR است بلکه نرخ کاهش دقت طبقه‌بندی در آن نیز با سرعت کمتری کاهش می‌یابد. طبق شکل ۸-الف روش $LBP/LEP1$ بین ۱۰ تا ۲۰ درصد بهتر از LBP/VAR است. همچنین نمودارهای ۷-ب نشان می‌دهد که تقریباً $LEP2$ برای همه مقادیر نویز دقتی بالاتر از LBP و VAR را تولید کرده است. تنها برای $SNR=35$ است که دقت $LEP2$ کمی کمتر از LBP شده است. بنابراین برای این داده‌های نیز برتری روش پیشنهادی به LBP و VAR خصوصاً به VAR به وضوح قابل مشاهده است.

۴-۵) مقایسه سرعت و تعداد ویژگی‌های

در این قسمت روش پیشنهادی از لحاظ سرعت اجرا و تعداد ویژگی‌های استخراج شده برای هر بافت با روش‌های دیگر مقایسه می‌شود. از آنجا که توصیفگر بافتی ارائه شده یک توصیفگر پایه و غیر پیچیده است لذا آن را با دو توصیفگر پایه یعنی LBP و VAR مقایسه می‌کنیم.

جدول ۴ مقایسه زمان استخراج ویژگی‌های برای روش پیشنهادی و ۲ روش پایه را نمایش می‌دهد. زمان‌های نمایش داده شده مقادیر متوسط زمان استخراج ویژگی برای یک بافت از پایگاه داده Outex است. در این جدول به ازای ۳ مقدار شعاع و نقاط همسایگی زمان‌ها نشان داده شده است. مطابق با این جدول، روش پیشنهادی برای استخراج ویژگی زمان بیشتری نسبت به دو توصیفگر دیگر نیاز دارد. البته بر طبق برخی مقالات [۳۰] این زمان بسیار کمتر از برخی روش‌های مقاوم به نویز مانند FLBP و بسیاری روش‌های دیگر است.

جدول ۴: مقایسه نتایج زمان استخراج ویژگی (میلی ثانیه) برای یک تصویر بافتی پایگاه داده Outex

	R=1,P=8	R=2,P=16	R=3,P=24
LBP	5.94	10.63	15.21
VAR	7.85	14.11	21.21
LEP	11.22	22.01	31.84

VAR که دو توصیفگر پایه هستند، LEP هم نوعی توصیفگر پایه به شمار می‌رود یعنی می‌توان با ترکیب آن با سایر توصیفگرها به عملکرد بهتری دست پیدا کرد. همچنین مشابه با LBP که با توسعه آن روش‌های پیچیده و با کارایی بالاتر تولید شده، می‌توان در تحقیقات آینده ویرایش‌های جدید و کامل‌تری از LEP معرفی کرد تا به دقت‌های بالاتری از طبقه‌بندی بتوان دست پیدا کرد.

نوع بافت‌ها شامل تصاویری متفاوت هستند که حاوی تغییرات زیاد و تمایز بالایی هستند. در مقابل برای تصاویر بافتی مشابه و تغییرات و جزئیات کم، عملکرد روش ارائه شده به اندازه تصاویر با تغییرات و تمایز بالا نیست ولی بازم بهتر از الگوی دودویی و اریانس محلی است. البته برای همین نوع تصاویر هم عملکرد LBP/LEP بهتر از LBP/VAR است.

باید توجه داشت که توصیفگر ارائه شده در این مقاله بیشتر یک توصیفگر محلی پایه به شمار می‌رود. یعنی مشابه با LBP و

مراجع:

- Transaction on System, Man and Cybernetic, vol. SMC6, no. 4, pp. 267–285, 1976.
- [11] T. Randen and J.H. Husoy, "Filtering for texture classification: a comparative study," IEEE Transaction on Pattern Analysis and Machine Intelligence, vol. 21, no. 4, pp. 291–310, 1996.
- [12] T. Mäenpää, M. Pietikäinen, and T. Ojala, "Texture classification by multi-predicate local binary pattern operators," IEEE, pp. 939–942, 2000.
- [13] Z. Guo, L. Zhang and D. Zhang, "A Completed Modeling of Local Binary Pattern Pperator for Texture Classification", IEEE Trans. Image Process. 9 (16) (2010) 1657–1663.
- [14] Z. Guo, L. Zhang and D. Zhang, "Rotation Invariant Texture Classification Using LBP Variance (LBPV) with Global Matching", Pattern Recognition Journal, 43 (2010) 706–719
- [15] Y. Zhao, D. S. Huang, and W. Jia, "Completed Local Binary Count for Rotation Invariant Texture Classification", IEEE Transactions on Image Processing, vol. 21, no.10, 2012.
- [16] S. Liao, M. W. K. Law, and A. C. S. Chung, "Dominant local binary patterns for texture classification," IEEE Trans. on Image Processing, vol.18, no. 5, pp. 1107–1118, 2009.
- [17] X. Tan, and B. Triggs, Enhanced Local Texture Feature Sets for Face Recognition Under Difficult Lighting Conditions, in Proc. International Workshop on Analysis and Modeling of Faces and Gestures, 2007, pp.168–182.
- [18] T Ahonen, M Pietikainen, in Proceedings of the Finnish Signal Processing Symposium, FINSIG 2007, vol. 1. Soft histograms for local binary patterns (Oulu, Finland, 2007), pp. 1–4
- [19] H Jin, Q Liu, H Lu, X Tong, in Proceedings of the 3rd International Conference on Image and Graphics, ICIG 2004. Face detection using improved LBP under Bayesian framework (Hong Kong China, 2004), pp. 306–309
- [1] F Tajeripour, E Kabir, A Sheikhi, Fabric defect detection using modified local binary patterns, EURASIP Journal on Advances in Signal Processing 8, 1–12(2008).
- [2] M. Tuceryan, 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, I. Dinestein, "Texture features for image classification," IEEE Transaction on System, Man and Cybernetic, vol. SMC3, pp. 610–621, 1979.
- [4] M. Pietikäinen, T. Ojala, Z. Xu "Rotation-Invariant Texture Classification Using Feature Distributions," Pattern Recognition, vol. 33, pp. 43–52, 2000.
- [5] T. Ojala, M. Pietikäinen and T. Mäenpää, "Multiresolution gray-scale and rotation invariant texture classification with local binary patterns," IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 24, no. 7, pp. 971–987, 2002.
- [6] S. Arivazhagan, L. Ganesan, "texture classification using wavelet transform," Pattern Recognition Letters, vol. 24, pp. 1513–1521, 2003.
- [7] P.S. Hiremath, S. Shivashankar, "Texture classification using wavelet packet decomposition," GVIP journal, vol. 6, Issue. 2.
- [8] B.V. Ramana Reddy, M. Radhika Mani, K.V. Subbaivah, "Texture classification method using wavelet transform based on Gaussian Markov random field," International Journal of signal and Image processing, vol. 1, Issue. 1, pp. 35–39, 2010.
- [9] 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 Journal of computer science and network security, vol. 8, no. 8, pp. 176–181, 2008.
- [10] J.S. Weszka, C.R. Dyer, A. Rosenfeld, "A comparative study of texture measures for terrain classification," IEEE

- [۲۶] پاکدل م. و تاجری پور ف. ارائه یک شکل جدید از الگوهای باینری محلی به منظور طبقه‌بندی بافت تصویر، مهندسی برق و مهندسی کامپیوتر ایران، دوره: ۱۱، شماره: ۱، صفحه: ۲۳-۳۳، ۱۳۹۲.
- [20] A. Fathi and A.R. Naghsh-Nilchi, "Noise tolerant local binary pattern operator for efficient texture analysis", *Pattern Recognit. Letters*, vol. 33, no. 9, pp. 1093-1100, 2012.
- [27] T. Ojala, T. Mäenpää, M. Pietikäinen, J. Viertola, J. Kyllönen, and S. Huovinen, "Outex – new framework for empirical evaluation of texture analysis algorithm," in *Proc. International Conference on Pattern Recognition*, 2002, pp. 701-706.
- [21] J. Ren, X. Jiang, and J. Yuan, "Noise resistant local binary pattern with an embedded error correction mechanism," *IEEE Trans. Image Process.*, vol. 22, no. 10, pp. 4049-4060, 2013.
- [28] K.J. Dana, B. van Ginneken, S.K. Nayar, and J.J. Koenderink, "Reflectance and texture of real world surfaces," *ACM Transactions on Graphics*, vol. 18, no. 1, pp. 1-34, 1999.
- [22] Li Liu, Yunli Long, Paul Fieguth, Songyang Lao, and Guoying Zhao, BRINT: Binary Rotation Invariant and Noise Tolerant Texture Classification, *IEEE Trans. on Image Processing*, 2014.
- [29] S. Lazebnik, C. Schmid, and J. Ponce, A sparse texture representation using local affine regions, *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 27, no. 8, pp. 1265-1278, Aug. 2005.
- [23] Y. Zhao, W. Jia, R.X. Huc, H. Min, Completed robust local binary pattern for texture classification, *Neurocomputing*, vol. 106, pp. 68-76, 2013.
- [30] Kylberg and Sintorn, Evaluation of noise robustness for local binary pattern descriptors in texture classification, *EURASIP Journal on Image and Video Processing* 2013,17.
- [24] T. Song, H. Li, F. Meng, Q. Wu, B. Luo, B. Zeng, and M. Gabbouj, "Noise-robust texture description using local contrast patterns via global measures," *IEEE Signal Process. Lett.*, vol. 21, no. 1, pp. 93-96, 2014.
- [25] J. Ryu, S. Hong, H. S. Yang, Sorted Consecutive Local Binary Pattern for Texture Classification. *IEEE Trans. Image Processing* 24 (7): 2254-2265 (2015).



محمدحسین شکور در سال ۱۳۷۷ مدرک کارشناسی مهندسی کامپیوتر خود را از دانشگاه شیراز دریافت کرد. سپس در سال ۱۳۸۲ مدرک کارشناسی ارشد خود را در رشته معماری کامپیوتر اخذ نمود و بعد از آن در سال ۱۳۹۵ با درجه دکترا در هوش مصنوعی مهندسی کامپیوتر از دانشگاه شیراز فارغ‌التحصیل شد. تحقیقات ایشان بیشتر در زمینه‌ی پردازش تصویر، بینایی ماشین و شناسایی الگو است.



فرشاد تاجری پور مدارک کارشناسی و کارشناسی ارشد خود را در رشته مهندسی الکترونیک به ترتیب در سال‌های ۱۳۷۳ و ۱۳۷۷ از دانشگاه شیراز اخذ نمودند. سپس در سال ۱۳۸۸ با درجه دکترا در رشته مهندسی الکترونیک از دانشگاه تربیت مدرس فارغ‌التحصیل شدند. زمینه‌های تحقیقاتی ایشان پردازش تصویر، پردازش سیگنال و پردازش سیگنال‌های ویدئویی است. آقای دکتر تاجری پور در سال ۹۵ دار فانی را وداع گفتند. روحش شاد و یادش گرامی باد.