

روشی جدید برای ترکیب ویژگیهای بافتی و رنگی در کلاس بندی تصاویر

حسام حسن پور^{*}، کمال جمشیدی[†]، امیرحسن منجمی[‡]

چکیده

نقش رنگ در بسیاری از کارهای بازرسی غیر قابل انکار می‌باشد. با این وجود، در بعضی کارها، آنالیز بافت به دلایل وجود رنگهای غیرمفید یا سطوح غیررنگی الزامی می‌باشد. در اغلب کاربردهای بازرسی سطوح، برای بدست آوردن یک دقت خوب باید مشخصه های رنگ و بافت را با همدیگر ترکیب کرد. در همین حال پیچیدگی زمانی روشها باید تا حد ممکن پائین باشد. در این مقاله روشی جدید برای ترکیب ویژگیهای بافتی و رنگی در کاربردهای بازرسی سطوح ارائه می‌کنیم. ما یک فضای رنگی جدید معرفی خواهیم کرد، و ویژگیهای بدست آمده از آن را با ویژگیهای بافتی که با استفاده از یک الگوریتم جدید مبتنی بر LBP بدست می‌آوریم ترکیب خواهیم نمود. برای کلاس بندی تصاویر نیز از شبکه‌های عصبی مصنوعی استفاده می‌کنیم. ما همچنین از یک روش کلاس بندی اولیه/ثانویه برای ترکیب ویژگیهای بافتی و رنگی استفاده می‌کنیم. نتایج روشها با اعمال آنها برای تشخیص خرابی در سطوح فولاد توضیح داده خواهد شد.

کلمات کلیدی

کلاس بندی بافت، شبکه‌های عصبی، بازرسی سطوح فولاد، LBP، فضاهاى رنگی

A new approach for combining color and texture feature in image classification

Hesam Hasanpour, Kamal Jamshidi, Amirhasan Monadjemi

Abstract

The role of color descriptors is quite remarkable in many visual inspection tasks. Meanwhile in some other tasks, texture analysis is needed due to unevenly colored or achromatic surface of the object under test. Therefore in many surface inspection applications, color and texture must be combined to achieve a good performance. At the same time, the computational complexity of the methods must be kept as low as possible. In this paper, a methodology for combining and optimizing color and texture features in visual inspection application is proposed. We introduce a new color space, and combine its features with texture features that we obtain a changed LBP operator. We use artificial neural networks for classification of sample into normal and abnormal (defective) classes. We also use a primary/secondary multiple classification scheme for combining texture and color features. Results are demonstrated in detecting and recognizing defects on steel surfaces.

Keywords

Texture classification, neural networks, steel surface inspection, LBP, color spaces

^{*} مدرس دانشگاه آزاد واحد سبزوار، hesam_78@yahoo.com

[†] عضو هیات علمی دانشگاه اصفهان، jamshidi@eng.ui.ac.ir

[‡] عضو هیات علمی دانشگاه اصفهان، amonadjemi@yahoo.co.uk

۱- مقدمه

کنترل کیفیت تولیدات-مانند هر صفت دیگری-یکی از مسائل مهم در صنعت فولاد به شمار می‌رود. انتظار مشتریان ورق‌های فولادی برای بهبود کیفیت هر روز بیشتر می‌شود. اغلب خواص فلزات هنوز در آزمایشگاه اندازه‌گیری می‌شوند. با وجود این هنوز معیارهایی وجود دارند که باید بصورت بلادرنگ بر روی خط تولید اندازه‌گیری شوند. به خصوص خرابی‌های سطوحی که به صورت تصادفی ایجاد می‌شوند باید با یک سیستم بازرسی سطوح تشخیص داده شوند.

روشهایی برای ترکیب ویژگیهای رنگی و بافت معرفی شده است [9,10]. این روشها و اغلب روشهای دیگر با بافت و رنگ به عنوان یک پدیده مشترک رفتار کرده‌اند. اما این مقاله نشان می‌دهد که بهتر است ویژگیهای بافت و رنگ را به صورت جداگانه اندازه‌گیری کنیم. مزیت دیگر این روش آن است که می‌توانیم روش‌های استخراج ویژگیهای رنگی و بافتی را به صورت جداگانه بهینه کنیم.

هدف یک سیستم بازرسی سطوح این است که خرابی‌های سطوح را که کیفیت سطوح را با توجه به استانداردها و نیازهای کاربر تحت تاثیر قرار می‌دهد، تشخیص و کلاس‌بندی کند. نیازها معمولاً با کاربردهای خاص ورق‌های فولاد تعیین می‌شوند. در بدترین حالت، خرابی ممکن است محصول را غیرقابل استفاده کند. کاربردهای زیادی از آنالیز بافت در صنعت وجود دارد [4-1]. اما تعداد محدودی از نمونه‌های موفق کاربرد بافت در بازرسی وجود دارد. این سیستم‌ها تکنیکهای مختلفی را برای تشخیص خرابی بکار می‌برند. در بهترین حالت کارایی آنها خوب بود است، اما یک نکته ضعف مشهود این است که آنها خرابی‌ها را با توجه به تعداد محدودی سطوح خاکستری کلاس‌بندی کرده‌اند [5].

تولیدکنندگان سطوح فولاد دوست دارند که تشخیص خرابی‌هایی را هر چه بهتر و سریعتر انجام شود و مطمئن باشند که کیفیت محصولات نیازهای خریداران را برآورده می‌کند. علت انواع خرابی‌ها باید پیدا شده و هرچه زودتر رفع گردد. اگر خرابی‌هایی ایجاد می‌شود باید برای گزارشهای کیفی آماری ثبت شود. بدون یک سیستم بازرسی سطوح، شناسایی خرابی سطوح و بررسی علل خرابی می‌تواند مدت زیادی طول بکشد. در طول این تاخیر، مشکل ممکن است تکرار شود و باعث کاهش کیفیت تولید شود.

بازرسی و کلاس‌بندی کیفیت سطوح فولاد یک مرحله اساسی در کارخانجات تولید فولاد می‌باشد. با توجه به هزینه سنگین بازرسی انسانی، سرعت خط تولید، و تکراری بودن کار، ایجاد یک سیستم تشخیص خرابی و بازرسی سطوح در بهبود کارایی تولید فولاد بسیار موثر می‌باشد.

خرابی‌هایی مانند لکه‌های سیاه، سطوح سوراخ دار و تورفتگی بافت سطح را تحت تاثیر قرار می‌دهند و بنابراین یک بافت ناهنجار را معرفی می‌کنند. شکل ۱ چهار نمونه از سطوح فولاد مطلوب و نامطلوب را نشان می‌دهد.


۲- فواید بازرسی اتوماتیک سطوح در مقایسه با بازرسی معمولی

به طور معمول، اغلب خطوط تولید دارای بازرسانی هستند که کار بازرسی سطوح را انجام می‌دهند. در مقایسه با این روش بازرسی اتوماتیک سطوح فواید زیادی را دارد. با یک سیستم بازرسی اتوماتیک می‌توانیم مطمئن باشیم که ۱۰٪ سطوح بازرسی شده اند. وقتی یک خرابی خاص اتفاق می‌افتد، فوراً تشخیص داده می‌شود. همچنین نتایج بازرسی مورد قبولی را بدست می‌آوریم. از آنجائی که تصاویری از همه خرابی‌ها در دسترس است گزارشات خوبی را می‌توان ذخیره کرد. بخصوص وقتی داده‌های خراب در یک بانک ذخیره شوند. برای خطوط تولید جدید و سریع، یک سیستم بازرسی اتوماتیک تنها راه چاره می‌باشد زیرا سرعت خطوط تولید برای بازرسی معمولی بسیار بالا می‌باشد. بطور خلاصه فواید اصلی که توسط یک سیستم بازرسی بدست می‌آید عبارتند از:

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

۳- پس زمینه

اولین مرحله در روال کلاس‌بندی، ثبت تصویر با استفاده از دوربین می‌باشد. عموماً در این سیستم‌ها مستقیماً از دوربینهای دیجیتال استفاده می‌شود. بعد از این مرحله، ویژگیهای مختلفی از تصویر استخراج می‌شوند. این ویژگیها می‌توانند به عنوان مثال، میانگین، واریانس و بردارهای مربوط به توزیع سطوح خاکستری باشند. اگر چه محدودیتی در تعداد ویژگیهایی که برای یک تصویر در نظر می‌گیریم، وجود ندارد اما اضافه کردن تعداد ویژگیها، بعد از حد مشخصی تاثیری در بهبود دقت کلاس‌بندی ندارد. وقتی که ویژگیها محاسبه شدند، بردار ویژگی را برای هر تصویر تشکیل می‌دهیم. (خرابی‌های با بردار ویژگی مشابه با استفاده از کلاس‌بند شبکه عصبی، در یک کلاس قرار می‌گیرند).



شکل (۱) (الف) سطح نرمال (ب) سطح دارای فرورفتگی (ج) سطح دارای لکه های سیاه (د) سطح دارای سوراخ

که $s(\cdot)$ تابع علامت می‌باشد.

$$s(x) = \begin{cases} 1, & x \leq 0 \\ 0, & x < 0 \end{cases} \quad (2)$$

g_c و g_p مقادیر سطوح خاکستری پیکسل‌های مرکز و همسایه می‌باشند و p تعداد پیکسل‌های همسایگی را مشخص می‌کند

۴-۲ الگوریتم جدید مبتنی بر LBP

تحقیق ما بر روی کلاس‌بندی سطوح، مبتنی بر ویژگی‌های رنگ و بافت متمرکز شده است. عملگر بافت معرفی شده، اجازه تشخیص الگوهای محلی باینری یکنواخت را در هر اندازه همسایگی می‌دهد. همسایگی‌های معمول مورد استفاده در تحلیل بافت به صورت دایره‌ای یا مربعی می‌باشند اما در اینجا ما یک همسایگی جدید معرفی می‌کنیم. همسایگی جدید به صورت یک پنجره 5×5 و بصورت شکل ۲ می‌باشد.

برای اینکه، الگوهای یکنواخت را بصورت ریاضی تعریف کنیم ما یک معیار یکنواختی، U ، معرفی می‌کنیم که برابر است با تعداد تغییر علامت در الگو می‌باشد. به عنوان مثال الگوهای ۰۰۰۰۰۰۰۰ و ۱۱۱۱۱۱۱۱ دارای معیار یکنواختی برابر ۰ می‌باشند.

در حالی که فرم دودویی اعداد ۲،۴،۸،۱۶ دارای معیار یکنواختی برابر ۲ می‌باشند زیرا دقیقاً دو تغییر ۱/۰ در الگو وجود دارد. ما الگوهایی را که دارای معیار U حداکثر K هستند را به عنوان یکنواخت در نظر می‌گیریم و رابطه ۳ و ۴ را برای توصیف سطوح خاکستری به جای LBP اصلی معرفی می‌کنیم و هیستوگرام خروجی عملگر بر روی تصاویر، را به عنوان ویژگی‌های نهایی در آنالیز بافت استفاده می‌کنیم.

تکنیک‌های آنالیز بافت مانند ماتریس‌های هم‌رخداد یا روش‌های حوزه فرکانس، به علت پیچیدگی زمان محاسبه، برای سیستم‌های بازرسی بلادرنگ مناسب نمی‌باشند. اما با وجود این، آنها در اغلب مطالعات به عنوان روش‌هایی با دقت بالا شناخته شده‌اند. یک نمونه از این کارها توسط کروگر^۱ برای تشخیص بیماری ریوی با استفاده از ویژگی‌های بافتی که از طریق ماتریس‌های هم‌رخداد بدست می‌آید و آنالیز حوزه فرکانس انجام شده است هر چند عملکرد وی بصورت Off line بوده است [7].

۴- روش پیشنهادی

۴-۱-LBP پایه

الگوهای باینری محلی (LBP) توسط اجالا^۲ به عنوان توصیف‌کننده بافت مستقل از دوران مبتنی بر طیف واحد بافت^۳ معرفی شد [11]. LBP پایه، یک همسایگی 3×3 را برای هر پیکسل در نظر می‌گیرد. این هشت پیکسل همسایه، با ۱ جایگزین می‌شوند اگر مقدار آنها از مقدار پیکسل مرکزی بزرگتر یا مساوی باشد در غیر اینصورت مقدار آنها ۰ خواهد بود. در پایان پیکسل مرکزی با جمع وزن دار باینری پیکسل‌های همسایه جایگزین می‌شود و پنجره 3×3 به پیکسل بعدی منتقل می‌شود. LBP پایه را می‌توان با اندازه همسایگی‌های مختلف توسعه دهیم. LBP را می‌توان به صورت ریاضی، بصورت زیر تعریف کرد:

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

$$NEWLBP = \begin{cases} \sum_{p=0}^{P-1} s(g_p - g_c) & \text{if } U(NEWLBP) \leq K \\ P+1 & \text{otherwise} \end{cases} \quad (3)$$

$$U(NEWLBP) = \sum_{g=p,q,r,s} \sum_{t=1}^6 |s(g_t - g_c) - s(g_{t-1} - g_c)| \quad (4)$$

$$H_p = \begin{cases} \frac{R}{3} & \text{if } R \text{ is Maximum} \\ \frac{G + 255}{3} & \text{if } G \text{ is Maximum} \\ \frac{B + (2 * 255)}{3} & \text{if } B \text{ is Maximum} \end{cases} \quad (5)$$

$$S_p = \text{Max}(R, G, B) - \frac{R + G + B}{3} \quad (6)$$

$$D_p = 0.299 * R + 0.587 * G + 0.114 * B \quad (7)$$

که R، G و B سه کانال تصویر RGB میباشند. ما از میانگین و انحراف معیار کانالهای فضای رنگی جدید به عنوان ویژگیهای رنگی استفاده می‌کنیم. بنابراین بردار ویژگی، برای هر تصویر دارای ۶ عضو می‌باشد.

۶- مجموعه داده و آزمایشات

ما کارائی روش پیشنهادی را با اعمال بر روی تصاویر سطوح فولاد بررسی می‌کنیم. مجموعه تصاویر شامل چهار کلاس می‌باشد که ما هر تصویر را به یک کلاس مطلوب یا سه کلاس غیرمطلوب (لکه‌های سیاه، تورفتگی، سوراخدار) کلاس‌بندی می‌کنیم. برای کلاس‌بندی تصاویر را به زیرتصویرهای تقسیم می‌کنیم که در مجموع داده های ما شامل ۴۶۰۰ زیرتصویر می‌باشد. تصاویر ورودی ما در فرمت RGB می‌باشند. برای تبدیل این تصاویر به سطوح خاکستری، از رابطه زیر استفاده می‌کنیم:

$$F_{gr} = 0.299 * F_R + 0.587 * F_G + 0.114 * F_B; \quad (8)$$

که F_{gr} تصویر سطح خاکستری و F_R ، F_G و F_B سه کانال قرمز، سبز و آبی از تصویر RGB می‌باشد.

برای کلاس‌بندی از یک شبکه عصبی سه لایه و ۳۰ نرون میانی استفاده می‌کنیم. قبل از آموزش شبکه عصبی، ویژگیها را نرمال می‌کنیم بطوریکه مقادیر بردار ویژگی در بازه [0,1] قرار گیرند.

ابتدا از ویژگیهای بافتی برای کلاس‌بندی استفاده شد که جدول ۱ نتایج اعمال دقت کلاس بندی حاصل از اعمال الگوریتم LBP اصلی را نشان می‌دهد. در این جدول، ستون

اول نشان دهنده الگوریتم اعمال شده، ستون دوم بیان کننده اندازه زیرتصویرها، ستون سوم اندازه بردار ویژگی، ستون چهارم میانگین مربعات خطا (MSE)، ستون پنجم پیچیدگی زمانی و ستون آخر دقت کلاس بندی را مشخص می‌کند. در موارد بیان شده،

R1			P1			S6
	R2		P2		S5	
		R3	P3	S4		
q1	q2	q3	center	q4	q5	q6
		S3	P4	R4		
	S2		P5		R5	
S1			P6			R6

شکل ۲: همسایگی جدید برای یک پیکسل

۵- فضای رنگی جدید

در این قسمت، ما یک فضای رنگی جدید مبتنی بر RGB معرفی می‌کنیم. اولین کانال فضای رنگی جدید، H_p ، نگاشتی از RGB به مقداری شبیه اصل رنگ^۴ می‌باشد که ماکزیمم (R,G,B) را به مقداری مناسب در بازه [0,255] نگاشت می‌کند. در حقیقت تعریف H_p از معنی اصلی ته رنگ استنتاج شده است که رنگ غالب شی را مشخص می‌کند اما این تعریف از نظر ریاضی، خیلی با تعریف استاندارد اصل رنگ در دیگر فضاهای رنگی مشابه نمی‌باشد. دومین کانال رنگی، S_p ، اختلاف بین ماکزیمم مقدار و میانگین رنگها (شدت روشنایی) را محاسبه می‌کند که خیلی شبیه به اشباع^۵ می‌باشد. این تعریف نیز، به طور کامل با تعریف اشباع در فضای رنگی HLS سازگار نیست. در حقیقت در تعریف ما از S_p ، جمله $\text{Max}((R, G, B)) + \text{Min}((R, G, B))$ جایگزین شده است. سومین کانال رنگی، D_p مقدار سطح خاکستری تصویر را محاسبه می‌کند که جمع وزن دار سه کانال رنگی می‌باشد. تعریف ریاضی این سه کانال بصورت زیر می‌باشد:

در مرحله بعد، الگوریتم پیشنهادی *NEWLBP* را برای کلاس‌بندی استفاده می‌کنیم. جدول ۲ نتایج اعمال این الگوریتم را نشان می‌دهد. در این جدول ستون دوم بیان‌کننده شعاع همسایگی و ستون سوم اندازه معیار یکنواختی را مشخص می‌کند. همانطور که در جدول مشخص است نتایج کلاس‌بندی نسبت به الگوریتم *LBP* بهتر می‌باشد.

در مرحله بعد از فضای رنگی جدید برای کلاس‌بندی استفاده می‌کنیم جدول ۳ نتایج حاصل از این کلاس‌بندی را نشان می‌دهد. سپس از ویژگیهای رنگی و بافتی به عنوان یک بردار ویژگی استفاده می‌کنیم. جدول ۴ نتایج حاصل از این روش را نشان می‌دهد.

پیچیدگی زمانی برابر زمانی است که برای پردازش یک تصویر بر روی یک کامپیوتر پنتیوم 2.8GHZ می‌باشد. میانگین مربعات خطا، به عنوان اختلاف بین G (خروجی مورد انتظار کلاس‌بند) و C (خروجی واقعی کلاس‌بند) در N کلاس استفاده می‌کنیم. دقت کلاس‌بندی، CA ، با درصد برچسب‌گذاری درست نمونه‌ها بر کل مجموعه تست تعریف می‌شود. MSE و CA را می‌توان به صورت زیر تعریف کرد.

$$MSE = \frac{\sum_{i=1}^N (G_i - C_i)^2}{N} \quad (9)$$

$$CA = \frac{\text{No. of correct class assignment}}{\text{total no. of samples}} \quad (10)$$

جدول ۱: نتایج اعمال الگوریتم *LBP*

algorithm	Window size	N. of features	MSE	Tc	CA
lbp	64*64	256	0.0110	0.1410	0.81
lbp	64*64	64	0.0121	0.1410	0.83
lbp	128*128	256	0.00064	0.156	0.80
lbp	128*128	64	0.0017	0.156	0.81

جدول ۲: نتایج حاصل از اعمال *NEWLBP*

algorithm	R	k	Window size	N. of features	MSE	Tc	CA
Newlbp	3	5	128*128	26	0.0094	0.3750	0.90
Newlbp	3	10	128*128	26	0.00048	0.3600	0.90
Newlbp	3	5	64*64	26	0.0502	0.453	0.866
Newlbp	3	10	64*64	26	0.0061	0.4380	0.95

جدول ۳: نتایج حاصل از اعمال ویژگیهای رنگی فضای رنگی جدید

algorithm	Window size	N. of features	MSE	Tc	CA
hpsdp	128*128	6	0.029	0.094	0.85
hpsdp	64*64	6	0.0482	0.101	0.88

جدول ۴: نتایج حاصل از ترکیب ویژگیهای رنگی و بافتی به عنوان یک بردار ویژگی

algorithm	R	k	Window size	N. of features	MSE	Tc	CA
Newlbp/hpsdp	3	10	128*128	32	0.03142	0.55	0.9
Newlbp/hpsdp	3	10	64*64	32	0.02803	0.62	0.916

Algorithm	%	TC
GLCM	90	1.12
hpsdpd	88	0.07
LBPU/hpsdpd	91	00.23
New LBP/hs	98	0.2

۷- نتیجه گیری

ما در این مقاله روشی جدید برای ترکیب ویژگیهای رنگی و بافتی را با هدف تشخیص عیوب سطوح فلزی معرفی کردیم. ابتدا یک الگوریتم جدید مبتنی بر LBP برای استخراج ویژگیهای بافتی تصویر معرفی کردیم. سپس برای استخراج ویژگیهای رنگی یک فضای رنگی جدید تعریف کردیم و از میانگین و انحراف معیار کانالهای فضای رنگی معرفی شده، به عنوان ویژگیهای رنگی استفاده کردیم. ما برای کلاس بندی از دو کلاس بند استفاده می کنیم یکی برای ویژگیهای رنگی و دیگری برای ویژگیهای بافتی. خروجی این دو کلاس بند را با استفاده از یک الگوریتم پیشنهادی با هم دیگر ترکیب کردیم و کلاس نهائی تصاویر ورودی را بدست آوردیم. روش پیشنهادی ضمن اینکه دارای دقت بالائی می باشد. سرعت آن نیز نسبت به الگوریتم های مشابه مناسب قلمداد می گردد.

مراجع:

1. T.S. Newman and A.K. Jain, A survey of automated visual inspection, *Comput. Vision Image Understanding* 61 (1995) 231-262.
2. M. Pietikäinen and T. Ojala, Texture analysis in industrial applications, in *Image Technology - Advances in Image Processing, Multimedia and Machine Vision*, ed. J.L.C. Sanz, (1996) 337-359.
3. K.Y. Song, M. Petrou and J. Kittler, Texture defect detection: a review, *SPIE Vol. 1708 Applications of Artificial Intelligence X: Machine Vision and Robotics*, (1992), 99-106.
4. M. Pietikäinen et al, Approaches to texture-based classification, segmentation and surface inspection, in *Handbook of Pattern Recognition and Computer Vision*, 2nd edition, eds. C.H. Chen, L.F. Pau, P.S.P. Wang, (1999) 711-736.
5. L. Mäkelin et al, From hole detection to image processing and information technology, 50th Appita Annual General Conference, Proceedings, Vol. 1, 1996, pp. 817-822.
6. T.Ojala, et al. Gray scale and rotation invariant texture classification with Local Binary Patterns. *Proc. Sixth European Conference on Computer Vision*, Dublin, Ireland, 2000; 1:404-420.
7. R. Kruger, W. Thompson, and A. Turner. Computer diagnosis of pneumoconiosis. *IEEE Transactions on Systems, Man, and Cybernetics*, 4(1):40-49, 1974.

در پایان از یک روش اولیه/ثانویه برای ترکیب ویژگیهای رنگی و بافتی استفاده می کنیم. در این روش از دو کلاس بند، یکی برای ویژگیهای رنگی و دیگری برای ویژگیهای بافتی استفاده می کنیم. ما یک پارامتر H تعریف می کنیم که در بازه $[0,1]$ می باشد و تعیین می کند چند درصد زیرتصویرهای یک تصویر به یک کلاس تعلق داشته باشند تا آن تصویر را به آن کلاس نسبت دهیم. برای یک تصویر ورودی، ابتدا تصویر را به زیرتصویرهایی تقسیم می کنیم. سپس برای هر زیرتصویر، کلاس آن را مشخص می کنیم. با فرض اینکه ما ۱۰ کلاس داشته باشیم. برای ویژگیهای بافتی $A[0..10]$ رابدهست می آوریم که $A[I]$ برابر تعداد زیرتصویرهایی است که به کلاس I تعلق دارند.

برای ویژگیهای رنگی نیز $B[0..10]$ را به روش گفته شده بدست می آوریم. سپس الگوریتم زیر را اعمال می کنیم.

اگر $N1 = \max(A[I]) > H.sum(A[I])$ سپس تصویر متعلق به کلاس $M1$ می باشد.

در غیر این صورت

اگر $N2 = \max(B[I]) > H.sum(B[I])$ سپس تصویر متعلق به کلاس $M2$ می باشد.

در غیر این صورت

$N3 = \max(A[I] + B[I])$ و تصویر متعلق به کلاس $M3$ می باشد.

که $M1$ و $M2$ و $M3$ ایندکس مقادیر $N1$ و $N2$ و $N3$ می باشند. جدول ۵ نتایج حاصل از اعمال روش پیشنهادی را نشان می دهد. همانطور که در جدول مشخص است، بهترین دقت کلاس بندی مربوط به $k=10$ می باشد که برابر ۹۸ درصد می باشد. ضمن اینکه پیچیدگی زمانی نیز مناسب می باشد. مطالب بیان شده بطور خلاصه در جدول ۶ آمده است. در این جدول سطر دوم نتایج حاصل از اعمال ماتریس های هم رخداد را نشان می دهد. در این جدول ستون سوم بیانگر پیچیدگی زمانی الگوریتم می باشد. همانطور که در جدول مشخص است زمان محاسبه الگوریتم ماتریس های هم رخداد بسیار زیاد می باشد و برای کارهای بلادرنگ مناسب نمی باشد.

جدول ۵: نتایج اعمال الگوریتم رنگی و بافتی با الگوریتم

پیشنهادی

algorithm	k	Window size	N. of features	MSE	Tc	%
Newlbp/hpsdpd	5	128	26/6	0.03	0.422	91
Newlbp/hpsdpd	10	128	26/6	0.02	0.425	95
Newlbp/hpsdpd	5	64	26/6	0.02	0.547	96
Newlbp/hpsdpd	10	64	26/6	0.01	0.54	98

جدول ۶: جمع بندی کلاس بندی ها

8. A. Monadjemi, *Towards Efficient Texture Classification and Abnormality Detection*, phd thesis ,Bristol university ,2004.

9. Jain A and Healey G. *A multiscale representation including opponent color features for texture recognition*. *IEEE Transactions on Image Processing* Jan. 1998; 7(1): 124{128.

10. Mirmehdi M and Petrou M. *Segmentation of color textures*. *IEEE Transactions on Pattern Analysis and Machine Intelligence* 2000; 22(2): 142-159.

11. T. Ojala et al. *A comparative study of texture measures with classification based on feature distribution*. *Pattern Recognition*, 29(1), 1996.

¹ Kruger

² Ojala

³ Texture Unit Spectrum(TUS)

⁴ Hue

⁵ Saturation