



طبقه بندی بافت مستقل از دوران و مقیاس با استفاده از تبدیل Curvelet

بشرا رجائی

گروه مهندسی کامپیوتر، دانشگاه فردوسی مشهد

b_rajae60@yahoo.com

حمیدرضا پوررضا

گروه مهندسی کامپیوتر، دانشگاه فردوسی مشهد

hpourreza@ferdowsi.um.ac.ir

مقالات ارائه شده است. به طور مختصر روشهای فعلی طبقه بندی بافت را می توان به چهار کلاس، روشهای آماری، هندسی، بر پایه مدل و پردازش سیگنال، دسته بندی کرد (بر پایه طرحی از Tuceryan و Jain در سال 1998 [9]). بررسیها نشان می دهد که از بین این چهار کلاس الگوریتمهای مبتنی بر ترکیب روشهای آماری و پردازش سیگنال در سالهای اخیر، قویترین ابزارها را برای طبقه بندی بافت ارائه داده اند.

روشهای آماری توزیع مکانی سطوح خاکستری موجود در بافت را با محاسبه ویژگیهای محلی در هر نقطه از تصویر و استخراج مجموعه ای از آماره ها، مبنای طبقه بندی قرار می دهند که از بین آنها می توان به روشهای بر پایه ماتریسهای Co-occurrence [4] و روشهای تفاضل سطوح خاکستری [12] اشاره کرد.

روشهای پردازش سیگنال محتوای فرکانسی بافت را مبنای کار خود قرار می دهند که از بین آنها می توان به تحلیلهای بر پایه Wavelet [5]، تبدیل Gabor [10] و تبدیل Curvelet [7] اشاره کرد.

در سال 1999، Candes و Donoho [2]، تبدیل Wavelet و تبدیلهای مشابه آنرا مورد بررسی قرار دادند و برخی محدودیتهای این روشها را در نمایش تصویر به اثبات رساندند. از جمله این موارد می توان به عدم کارایی این تبدیلهای در نمایش اشیا با گسستگیهای منحنی شکل، وجود تعداد عناصر

چکیده: در این مقاله، روش جدیدی برای استخراج ویژگیهای مستقل از دوران و مقیاس بافت، با استفاده از تبدیل Curvelet و ماتریسهای Co-occurrence ارائه شده است. در فاز طبقه بندی، طبقه بند Support Vector Machine با هسته RBF، به منظور طبقه بندی 20 کلاس بافت از بانک استاندارد Brodatz مورد استفاده قرار گرفته است. به منظور اثبات کارایی این روش، در مجموع 14480 بافت در 12 زاویه و 4 مقیاس متفاوت مورد بررسی قرار گرفته اند که از بین آنها ده درصد کل تصاویر به صورت تصادفی جهت آموزش طبقه بند SVM و مابقی به منظور تست انتخاب شده اند. نتایج تجربی نشان دهنده نرخ طبقه بندی بالا در استفاده از این روش می باشد.

واژه های کلیدی: طبقه بندی بافت، استقلال از دوران و مقیاس، تبدیل Curvelet، طبقه بند SVM

1. مقدمه

طبقه بندی بافت یکی از زمینه های حائز اهمیت در حوزه تحلیل تصویر می باشد. شناخت شیء، تصویر برداری پزشکی، بررسی سطوح، تقسیم بندی مستندات و OCR، تنها مثالهای اندکی از کاربردهایی است که طبقه بندی بافت در آنها نقش کلیدی دارد. این زمینه تقریباً از سه دهه پیش به صورت فعال پیگیری و روشهای گوناگونی برای حل مسائل مختلف در

جهتی ثابت در هر مقیاس و وجود عناصر همسانگرد اشاره کرد. Candes و Donoho سپس تبدیلهای Ridgelet و Curvelet را پیشنهاد دادند که شکل عناصر پایه آنها غیر همسانگرد و به شدت حساس به جهت و تعداد عناصر جهتی در آن نیز وابسته به مقیاس می باشد (به منظور بررسی دقیقتر این مباحث رجوع شود به [2]). در حوزه طبقه بندی بافت طی بررسی صورت گرفته، نشان داده شده است که این ویژگیهای تبدیل Curvelet نسبت به روشهای قبلی، نتایج طبقه بندی به نحو قابل توجهی بهبود می بخشد [7].

در کاربردهای واقعی بسیار دشوار و در پاره موارد غیر ممکن است که تصاویری با زاویه و مقیاس یکسان تهیه کنیم. در این گونه موارد ایجاد استقلال از دوران و مقیاس هم از حوزه عملی و هم از حوزه تئوری بسیار حائز اهمیت است. از جمله تحقیقات متنوعی که در این زمینه صورت گرفته می توان به [6] اشاره کرد.

بعد از فاز استخراج ویژگی های مستقل از دوران و مقیاس، باید با استفاده از یک طبقه بند، ویژگیهای استخراج شده را طبقه بندی کرد. طبقه بندهای زیادی وجود دارد که از بین آنها می توان به طبقه بندهای آماری پارامتریک که از تئوری تصمیم Bayesian مشتق شده اند، طبقه بند غیر پارامتریک نزدیک ترین همسایگی و شبکه های عصبی مختلف مانند پرسپترونهای چند لایه، نام برد. در سالهای اخیر، Support Vector Machine (SVM) به عنوان یک روش طبقه بندی و رگرسیون، موفقیتهای زیادی کسب نموده است [3]. این طبقه بند در کاربردهای گوناگونی مانند شناخت ارقام، طبقه بندی متن، تشخیص اشیا و غیره، نتایج بهتری نسبت به طبقه بندهای ذکر شده، ارائه داده است.

در این مقاله بر آنیم که از ترکیب تبدیل Curvelet و ماتریس Co-occurrence و استفاده از طبقه بند SVM، به منظور ایجاد استقلال از دوران و مقیاس در طبقه بندی بافت استفاده کنیم. ادامه این مقاله به این بخشها اختصاص دارد، معرفی اجمالی ماتریسهای Co-occurrence، تبدیل Curvelet و طبقه بند SVM در بخشهای 2 تا 4، الگوریتم استخراج ویژگیها در بخش

5، طبقه بندی بافت در بخش 6 و در نهایت نیز نتایج تجربی حاصل از ارزیابی کارایی الگوریتم ارائه شده، ذکر خواهد شد.

2. ماتریس Co-occurrence

یک ماتریس Co-occurrence نرخ رخداد مقادیر خاکستری دو پیکسل وابسته از تصویر را که در فاصله و جهت بخصوصی از یکدیگر قرار گرفته اند، را بیان می کند.

ماتریس Co-occurrence ماتریسی مربعی است که عناصر آن نشان دهنده فرکانس نسبی رخداد یک جفت از مقادیر خاکستری در فاصله خاص و در یک جهت تعیین شده، می باشند. عناصر یک ماتریس Co-occurrence با ابعاد $G \times G$ به ازای بردار فاصله $d = (dx, dy)$ به صورت زیر تعریف می شوند:

$$P_d(i, j) = \left| \left\{ \left((r, s), (t, v) \right) : I(r, s) = i, I(t, v) = j \right\} \right|$$

که در آن $I(\dots)$ نشان دهنده تصویری با ابعاد $N \times N$ و G سطح خاکستری، $r = (t \uparrow s) \uparrow (t \uparrow v) \uparrow (r + dx) \uparrow (s + dy)$ و $| \cdot |$ کاردینالیتهی مجموعه می باشد.

3. تبدیل Curvelet گسسته

تبدیل Curvelet (Candes و Donoho در سال 1999)، امکان تحلیل تصویر را در بلاکهای با اندازه های متفاوت در اختیار قرار می دهد. ایده اصلی این تبدیل، تجزیه تصویر به مجموعه ای از باندهای Wavelet و سپس تحلیل هر باند به وسیله تبدیل Ridgelet محلی می باشد. اندازه بلاک می تواند در هر مقیاس تغییر کند. به طور خلاصه می توان گفت که سطوح مختلف هرم Ridgelet به منظور نمایش زیر باندهای مختلف خروجی یک بانک فیلتر، مورد استفاده قرار می گیرند.

از طرف دیگر، تجزیه به زیر باندها رابطه ای بین طول و عرض عناصر قاب ایجاد می کند به گونه ای که این عناصر غیر همسانگرد می باشند و از رابطه $width = height^2$ تبعیت می کنند. تبدیل Curvelet گسسته (DCT) تابع پیوسته $f(x_1, x_2)$ از مقیاسهای دودویی و یک بانک فیلتر استفاده می کند. این

شکل شماره 1 - محاسبه تبدیل Curvelet. شکل تجزیه تصویر اصلی به زیرباند‌ها و سپس افراز هر زیرباند را نشان می‌دهد. تبدیل Ridgelet در نهایت روی هر بلاک اعمال می‌شود.

Support Vector Machine .4

SVM (Support Vector Machine) طبقه بند منتخب تعداد زیادی از محققان برای حل مسائل مختلف طبقه بندی در دنیای واقعی بوده است [8]. در این بخش معرفی کلی ای از SVM ارائه می‌شود. یک مساله طبقه بندی دودویی با ناظر معمولاً به این صورت بیان می‌شود: با استفاده از n نمونه آموزش (x_i, y_i) که در آن $\langle x_i \rangle = (x_{i1}, x_{i2}, \dots, x_{im})$ بردار ویژگی ورودی و $y_i \in \{-1, +1\}$ برچسب عنوان کلاس طبقه بندی می‌باشد، کار تابع تفکیک کننده یا طبقه بند، یادگیری الگوهای موجود در نمونه های آموزش به گونه ایست که در مراحل بعدی بتواند بطور قابل اعتمادی به یک ورودی ناشناخته x_i ، y_i مناسبی را تخصیص دهد. SVM در اصل برای این مواقع طراحی شده است یعنی طبقه بندی دودویی، لیکن قابلیت توسعه به شرایط چند کلاسه را نیز دارد. مانند بقیه طبقه بندهای خطی، SVM تلاش می‌کند که یک مرز تصمیم خطی (فرض کنید داده ها به صورت خطی قابل تفکیک باشند) یا یک hyperplane خطی بین دو کلاس ایجاد کند.

معمولاً اعتقاد بر آنست که نقاط متعلق به دو کلاس به نحوی قرار می‌گیرند که بین آنها فاصله ای وجود دارد. SVM تلاش می‌کند فاصله بین دو کلاس را با در نظر گرفتن مساله به عنوان یک مساله برنامه ریزی درجه دو، به حداکثر خود برساند [3,11].

در شرایط غیر خطی، از یک تابع نگاشت $f(x_i)$ برای نگاشت فضای ورودی به فضای ویژگی با ابعاد بالاتر به نحوی که hyperplane غیر خطی، خطی شود، استفاده می‌گردد. به منظور جلوگیری از افزایش پیچیدگی محاسباتی و مشکلات کار کردن در ابعاد بالا، یک هسته $K(x_i, x_j)$ بکار گرفته می‌شود که در اصل مقدار هسته معادل فضای ورودی را بگونه ای محاسبه می‌کند که هیچ نگاشت صریحی نیاز نباشد.

هسته ها معمول به شرح زیر می‌باشند:

$$\text{خطی: } x_i^T x_j$$

بانک دارای این ویژگی است که فیلتر میان گذر Δ_s در نزدیکی فرکانسهای $[2^{2s}, 2^{2s+2}]$ تمرکز دارد،

$$\Delta_s = \Psi_{2^s} * f, \hat{\Psi}_{2^s}(x) = \hat{\Psi}(2^{-2^s}x).$$


در تئوری Wavelet، تجزیه به زیرباند‌های دودویی $[2^s, 2^{s+1}]$ صورت می‌گیرد، لیکن زیرباند‌های مورد استفاده در تبدیل Curvelet گسسته شکل غیر استاندارد $[2^{2s}, 2^{2s+2}]$ را دارا می‌باشند.

تجزیه Curvelet زنجیره ای از گام‌های زیر است:

- تجزیه به زیرباند‌ها.
- $f \alpha (P_0f, \Delta_1f, \Delta_2f, \dots)$.
- افراز نرم. هر زیرباند به طور نرم به مربعات مقیاس مناسب (به ضلع $\sim 2^{-s}$).
- $\Delta_s f \alpha (w_Q \Delta_s f)_{Q \in Q_s}$.
- نرمالسازی. هر مربع منتج از گام قبل به مقیاس واحد، نرمال می‌شود.
- $g_Q = (T_Q)^{-1}(w_Q \Delta_s f)$, $Q \in Q_s$.
- تحلیل Ridgelet. هر مربع نرمال شده با استفاده از تبدیل Ridgelet گسسته تحلیل می‌شود.

$$a_m = \langle g_Q, r_1 \rangle, \quad m = (Q, 1).$$

در این تعریف، زیرباند‌های دودویی $[2^{2s}, 2^{2s+1}]$ و $[2^{2s+1}, 2^{2s+2}]$ قبل از اعمال تبدیل Ridgelet ادغام می‌شوند. شکل شماره 1 روند کامل محاسبه تبدیل Curvelet را نشان می‌دهد.



دیگر خواهد شد. بنابراین، برای ایجاد استقلال از مقیاس ویژگی‌هایی را نیاز داریم که از ترکیب زیرباند‌های مقیاس‌های مختلف استخراج شده باشند. به همین منظور یک سری ویژگی را نیز از ماتریس Co-occurrence ماتریس ترکیبی مقیاس‌های مختلف محاسبه خواهیم کرد.

فاز بعدی فاز انتخاب ویژگی است، باید از بین این مجموعه ویژگی‌های مناسب احتمالی با استفاده از یک معیار تفکیک کننده، بهترین ویژگی‌ها را انتخاب کنیم. معیاری که مورد استفاده قرار گرفته معیار Fisher است که در آن برای هر ویژگی مقدار آلفا به صورت زیر محاسبه می‌گردد:

$$\alpha = \frac{\text{TotalVariance}}{\text{InterClassMeanVariance}}$$

از معادله فوق واضح است که مقادیر بالای آلفا نشان دهنده تفکیک مناسب اشیا در کلاس‌های طبقه بندی متفاوت می‌باشد. در نهایت مجموعه ویژگی‌های زیر در این مطالعه با استفاده از معیار Fisher انتخاب و مورد استفاده قرار گرفتند:

1. کنتراست

$$\text{Contrast} = \sum_{g=0}^{G-1} g^2 \left(\sum_{\substack{g'=1 \\ |g'-g|=g}}^{G-1} \sum_{g''=1}^{G-1} p(g', g'') \right)$$

2. انرژی

$$\text{Energy} = \sum_{g=1}^G \sum_{g'=1}^G (p(g, g'))^2$$

3. آنترپی

$$\text{Entropy} = - \sum_{g=1}^G \sum_{g'=1}^G p(g, g') \log(p(g, g'))$$

4. مجموع مربعات (واریانس)

$$\text{Variance} = \sum_{g=1}^G \sum_{g'=1}^G (g - m)^2 p(g, g')$$

5. همبستگی

$$\text{Correlation} = \frac{1}{s_x s_y} \left(\sum_{g=1}^G \sum_{g'=1}^G (gg') p(g, g') - m_x m_y \right)$$

6. گشتاور تفاضلی معکوس.

$$\text{IDM} = \sum_{g=1}^G \sum_{g'=1}^G \frac{1}{1 + (g - g')^2} p(g, g')$$

در روابط فوق، p تصویر مورد مطالعه به ابعاد $G \times G$ می‌باشد.

تابع پایه شعاعی RBF: $e^{-g \|x_i - x_j\|^2}, g > 0$.

چند جمله‌ای از درجه d : $(gx_i^T x_j + a)^d, g > 0$.


MLP: $\tanh(gx_i^T x_j + a)$.

در تمام این روابط r ، g و d پارامترهای طبقه بندی هستند.

5. الگوریتم استخراج ویژگی

به عنوان اولین گام در طبقه بندی بافت، می‌باید در مورد ویژگی‌هایی که جهت تفکیک بافت‌های مختلف مناسب هستند، تصمیم‌گیری کنیم. Haralick و همکارانش 14 ویژگی بافت را که از ماتریس‌های Co-occurrence استخراج می‌شود و هر یک نماینده یک مشخصه تصویر مانند، درشتی، کنتراست، همگنی و پیچیدگی بود، معرفی کردند [4]. حال بر آنیم که به منظور ایجاد طبقه بندی مستقل از دوران و مقیاس از ویژگی‌های فوق و خواص تبدیل Curvelet بهره ببریم.

شکل زیر که تبدیل Curvelet یکی از بافتهای تست این مقاله است را در نظر بگیرید:



شکل شماره 2. تبدیل Curvelet یکی از بافت‌های تست مقاله

از آنجا که دوران در تصویر باعث انتقال ضرایب بین زیرباند‌های یک مقیاس می‌گردد، برای ایجاد استقلال از دوران، تمام زیرباند‌های هر مقیاس را با هم ترکیب کرده و ماتریس Co-occurrence نتیجه را محاسبه می‌کنیم. همچنین تغییر مقیاس در تصویر باعث انتقال ضرایب به مقیاس‌های

هسته RBF با مقادیر گامای 1 و C برابر با 1000 مورد استفاده قرار گرفته است.

7. نتایج تجربی

به منظور بررسی کارایی الگوریتم پیشنهادی، 20 تصویر بافت، هر یک به ابعاد 640×640 از بانک استاندارد Brodatz [1] مورد استفاده قرار گرفته است. این تصاویر در شکل شماره 3 نشان داده شده اند. سپس به منظور تست ویژگیهای استقلال از دوران و مقیاس که در این مقاله مد نظر است، طی سه مرحله پردازشهایی روی این 20 تصویر صورت گرفته که نتیجه کار مجموعه تصاویر مناسب جهت ارزیابی این الگوریتم را در اختیار قرار می دهد:

مرحله 1. هر یک از 20 تصویر اولیه به 4 مقیاس 0.8 تا 1.4 با فاصله 0.2 برده می شود. تعداد تصاویر پس از این مرحله $80 = 4 \times 20$ تصویر خواهد بود.

مرحله 2. 80 تصویر حاصل از مرحله 1 تحت 12 زاویه از صفر تا 165 درجه، با فواصل 15 درجه، دوران می یابند. خروجی این مرحله نیز $960 = 12 \times 80$ تصویر خواهد بود.

مرحله 3. از تصاویر مرحله قبل نمونه هایی با ابعاد 128×128 استخراج می شود و 14480 تصویر جهت تست الگوریتم ایجاد می شود.

چند نمونه از تصاویر مقیاسها و دورانهای مختلف در شکل شماره 4 نشان داده شده است.

به طور کلی، به ازای هر تصویر ورودی I الگوریتم طبقه بندی بافت مستقل از دوران و مقیاس شامل گامهای زیر جهت استخراج ویژگیها می باشد:

گام 1. تجزیه تصویر به زیرباندها با استفاده از تبدیل Curvelet. از آنجا که مقیاسهای بالا اطلاعات اندکی از تصویر را در بر دارند، می توان به راحتی از آنها چشم پوشی کرد. به این منظور فقط از اولین دو مقیاس هرم Curvelet در این بررسی استفاده خواهد شد.

گام 2. به ازای هر مقیاس ماتریس ترکیبی آن مقیاس را با کنار هم قرار دادن تمام زیرباندهای آن مقیاس تشکیل می دهیم. سپس ماتریس Co-occurrence آن مقیاس را با پارامترهای $d = 1$ (فاصله تفکیک پیکسل) و زوایای 0، 45، 90 و 135 درجه می سازیم. ماتریس ترکیبی مقیاس یک و دو را به ترتیب $mat1$ و $mat2$ و ماتریس Co-occurrence هر یک را $Co1$ و $Co2$ می نامیم.

گام 3. به ازای مقیاسهای تصویر ماتریس ترکیبی هر یک را کنار هم قرار داده و آن را $mat3 = [mat1 \text{ } mat2]$ (ماتریس Co-occurrence آن را $Co3$) می نامیم. سپس ماتریس ترکیبی هر یک را $Co3$ می نامیم.

گام 4. محاسبه کتراست، انرژی، آنتروپی، واریانس و گشتاور تفاضلی را به ازای سه ماتریس $Co1$ ، $Co2$ و $Co3$.


گام 5. ساخت بردار ویژگی:

$$f = [Cont_{Co1} \ Ent_{Co1} \ Var_{Co1} \ Cor_{Co1} \ IDM_{Co1} \ Cont_{Co2} \ Ent_{Co2} \ Var_{Co2} \ Cor_{Co2} \ IDM_{Co2} \ Cont_{Co3} \ Ent_{Co3} \ Var_{Co3} \ Cor_{Co3} \ IDM_{Co3}]$$


بنابراین طول بردار ویژگی برای هر بافت 18 می باشد.

6. طبقه بندی بافت

پس از این مرحله، نوبت به طبقه بندی تصاویر بافت با استفاده از طبقه بند SVM می باشد. این فاز شامل دو مرحله آموزش طبقه بند با استفاده از بردار ویژگی تعدادی تصویر شناخته شده و در نهایت تست و تعیین نرخ صحت طبقه بندی الگوریتم پیشنهادی با تصاویر شناخته نشده، می باشد. در این بررسی



شکل شماره 3. 20 کلاس بافت به ابعاد 640×640 از بانک Brodatz



شکل شماره 4. چند نمونه از تصاویر با زوایای دوران و مقیاسهای مختلف

بندی		بندی	
٪86.04	D82	٪99.45	D55
٪96.82	D80	٪89.78	D56
٪94.06	D79	٪100	D11
٪93.64	D49	٪78.72	D15
٪88.81	D26	٪100	D16
٪100	D65	٪95.58	D17
٪95.85	D51	٪91.16	D18
٪100	D52	٪99.17	D95
٪100	D53	٪88.81	D20
٪94.48	D21	٪89.78	D83
میانگین درصد صحت طبقه بندی تصاویر به ازای 14480 تصویر انتخابی: ٪94.1			

از مجموع این 14480 تصویر 10 درصد آنها یعنی 1448 تصویر به عنوان تصاویر آموزش و مابقی جهت تست به کار گرفته شده اند. لازم به ذکر است که به منظور ایجاد شرایط واقعی در تست الگوریتم، انتخاب تصاویر آموزش به صورت تصادفی صورت گرفته است.

در جدول شماره یک نتایج این طبقه بندی ارائه شده است. درصدها حاصل 10 بار طبقه بندی و محاسبه میانگین می باشد (به دلیل انتخاب تصادفی تصاویر آموزش). تصاویر با توجه به درصد صحت طبقه بندی حاصل می توان نتیجه گرفت که ویژگیهای انتخابی از تبدیل Curvelet، قادر به ایجاد استقلال از دوران و مقیاس بوده و در برای تغییرات مقیاس و زاویه بافت، مقاوم هستند.

8. نتیجه گیری

طبقه بندی تصاویر بافت بخصوص تصاویر با زوایا و مقیاسهای متفاوت، یکی از چالشهای مهم در حوزه تحلیل

جدول شماره یک - درصد صحت طبقه بندی مستقل از دوران و مقیاس بافت

نام کلاس	نرخ طبقه	نام کلاس	نرخ طبقه

- [8] Rajpoot, K.M., Rajpoot, N.M., 2004. Wavelets and Support Vector Machines for Texture Classification. Proceedings 8th IEEE International Multitopic Conference (INMIC), Lahore, Pakistan.
- [9] Tuceryan, M. and Jain, A.K., 1998. Texture analysis. In: Chen, L.F., Pau, L.F., Wang, P.S.P. (Eds.), Handbook of Pattern Recognition and Computer Vision, second ed. World Scientific, Singapore.
- [10] Turner, M.R., 1986. Texture Discrimination by Gabor Functions. Biological Cybernetics, 55, 71-82.
- [11] Vapnik, V., Statistical Learning Theory, Wiley, New York, 1998.
- [12] Weszka, J.S., Dyer, C.R., Rosenfeld, A., 1976. A comparative study of texture measures for terrain classification. IEEE Trans. System Man Cybernat. SMC-6 (4), 269-286.

و طبقه بندی تصویر می باشد. این مقاله یک روش موثر در طبقه بندی بافت مستقل از دوران و مقیاس بر اساس تبدیل Curvelet ارائه داده است. استخراج ویژگیهای مستقل از دوران و مقیاس برای یک تصویر شامل ترکیب زیرباندهای مناسب از هرم Curvelet، محاسبه ماتریس Co-occurrence آن و در نهایت انتخاب یک مجموعه از ویژگیهای Haralick می باشد که بیشترین فاصله را بین عناصر کلاسهای مختلف و کمترین فاصله را بین عناصر موجود در هر کلاس ایجاد کنند. از آنجا که تبدیل Curvelet اطلاعات یک تصویر را در زوایا و مقیاسهای مختلف در اختیار قرار می دهد، روش ارائه شده می تواند برای طبقه بندی مستقل از دوران و مقیاس بافت مناسب باشد. نرخ طبقه بندی مورد قبول برای تعداد نسبتاً زیاد داده های تست در این مقاله اثباتی بر این مدعاست.

9. مراجع و مآخذ

- [1] Brodatz, P., 1966. Textures: A photographic Album for Artists and Designers. Dover, New York.
- [2] Candès, E.J. and Donoho, D.L., 1999. Curvelets: a surprisingly effective nonadaptive representation of objects with edges. In Curve and Surface Fitting: Saint-Malo 1999 Albert Cohen, Christophe Rabut, and Larry L. Schumaker (eds.) Vanderbilt University Press, Nashville, TN.
- [3] Cristianini, N. and Shawe-Taylor, J., 2000. An Introduction to Support Vector Machines and other kernel-based learning methods. Cambridge University Press, Cambridge, UK.
- [4] Haralick, R.M., Shanmugam, K., Dinstein, I., 1973. Texture features for image classification. IEEE Trans. System Man Cybernat. 8 (6), 610-621.
- [5] Mallat, S.G., 1989. A theory for multiresolution signal decomposition: The wavelet representation. IEEE Trans. Pattern Anal. Machine Intell. 11 (7), 674-693.
- [6] Manian, V., Vasquez, R., 1998. Scaled and rotated texture classification using a class of basis functions. Pattern Recognition 31 (12), 1937-1948.
- [7] Rajaei, B., Pourreza, H., 2006. Texture classification using Curvelet Transform. Proceedings 3rd International Conference on Artificial Intelligence in Engineering and Technology (ICAJET), Sabah, Malaysia.