

TÉCNICAS DE DESCRIÇÃO REGIONAL BASEADAS EM TEXTURA

Éldman de Oliveira Nunes/UFF

Aura Conci/UFF

1. RESUMO

A textura é considerada um descritor regional importante para segmentação e classificação de imagens naturais. Entretanto, a sua caracterização não é uma tarefa fácil. Apesar de sua importância, não existe uma definição precisa para textura. Diversas técnicas de segmentação baseadas no emprego de atributos de textura têm sido propostas, mas várias dificuldades se apresentam, como a quantificação da textura para diferentes resoluções de uma imagem. Além disso, em imagens de satélite, diversas bandas espectrais precisam ser consideradas. Em consequência, algumas aproximações são essencialmente empíricas e se ajustam à necessidades diferentes.

Neste trabalho são descritas algumas técnicas para caracterização de texturas. Dentre elas, a abordagem baseada em fractais foi enfatizada, uma vez que a geometria fractal apresenta estratégias adequadas para lidar com representações em multi-resolução. O método CDC (contagem d-cubos), desenvolvido pelos autores, é utilizado para computar a dimensão fractal local (DF) de imagens N-dimensionais. Este método permite estimar a DF de mapas temáticos compostos de N-bandas espectrais. Assim, a DF pode ser utilizada para segmentar imagens multibandas. Resultados experimentais são relatados, mostrando a qualidade da segmentação de texturas obtidas com esta ferramenta.

2. PALAVRAS CHAVES

Textura, Classificação Textural, Descritores Regionais, Segmentação, Imagens de Satélite.

3. INTRODUÇÃO

A textura refere-se a um padrão visual que possui algumas propriedades de homogeneidade que não resultam simplesmente de uma cor ou intensidade. Ao contrário de outras características, como por exemplo o brilho, a textura não pode ser definida em um pixel, mas sim através de uma região ou conjunto de pixels. Na segmentação baseada em textura, regiões homogêneas da imagem são identificadas levando-se em consideração alguma medida de textura. A análise de textura é uma importante ferramenta para segmentação de imagens de satélite uma vez que a maioria das imagens naturais possuem um certo perfil textural.

Devido a sua importância, várias abordagens empregando modelos estatísticos, modelos estruturais, modelos morfológicos, frequências espaciais, modelos fractais, redes neurais, etc, foram desenvolvidas buscando utilizar a textura como base na segmentação e descrição de uma imagem. A

finalidade deste estudo consiste em descrever alguns destes métodos para segmentação de imagens digitais por meio de sua textura.

Apesar da existência de vários métodos, nenhum deles é capaz de segmentar eficientemente todos os tipos de imagens. Isto por que a caracterização de uma textura não é uma tarefa fácil, especialmente quando mais de uma banda espectral precisa ser considerada. Várias dificuldades estão presentes, como por exemplo, à irregularidade (em brilho, matizes e bordas) de texturas naturais. Talvez a característica mais importante em um método de segmentação seja a definição básica de textura, o *texton*. Especialmente quando o *texton* pode aparecer em resoluções ou escalas diferentes.

A Geometria do Fractal apresenta estratégias adequadas para lidar com representações em multiescala. Contagem D-Cubos ou CDC é uma técnica para computar a dimensão do fractal local (DF) de imagens N-dimensionais. CDC permite calcular a DF de mapas temáticos feitos a partir de imagens multibandas. Este trabalho descreve o método CDC e apresenta experimentos e resultados empregando esta nova ferramenta para segmentação de imagens de satélite a partir de sua informação textural

4. SEGMENTAÇÃO E IMAGENS DE SATÉLITE

Imagens de satélite são imagens multibandas de representação digital complexa. Tais imagens têm a característica de serem multiespectrais, no sentido de constituírem uma coleção de imagens de uma mesma cena, num mesmo instante, obtida por vários sensores com respostas espectrais diferentes, tabela1. As imagens de satélite podem ser visualizadas na forma de composições coloridas de três bandas associadas aos canais Red, Green e Blue, conforme figura 1.




Figura 1 - Bandas de uma imagem Landsat-7 TM

Tais composições são capazes de sintetizar numa única imagem uma grande quantidade de informação e facilitam a interpretação dos objetos através da representação dessa informação em diferentes cores. Por exemplo, as seguintes composições podem ser feitas: bandas 2, 3 e 4; bandas 3, 4 e 5 e bandas 3, 5 e 4 .

Banda 1 (azul) 0.45 μm - 0.52 μm	Esta banda apresenta grande penetração em corpos d'água, sendo particularmente interessante para estudos batimétricos. Permite detalhar a turbidez da água e o traçado de correntes em corpos d'água costeiras. Apresenta sensibilidade à plumas de fumaça oriundas de queimaduras ou atividade industrial.
Banda 2 (verde) 0.52 μm - 0.60 μm	Esta banda apresenta grande sensibilidade à presença de sedimentos em suspensão na água, sendo utilizada para estudos de qualidade d'água. Tem boa penetração em corpos d'água. Boa para mapeamento de vegetação e áreas onde ocorrem atividades antrópicas.
Banda 3 (vermelho) 0.63 μm - 0.69 μm	Esta banda apresenta bom contraste entre áreas cobertas com vegetação e solo exposto, bem como discrimina diversos tipos de vegetação. É a banda mais utilizada para a delimitação das "manchas" urbanas e traçado do sistema viário. É adequada também para mapeamentos de uso do solo, agricultura e estudos de qualidade d'água.
Banda 4 (infravermelho próximo) 0.76 μm - 0.90 μm	Esta banda apresenta bom contraste entre solo e corpos d'água, permitindo o mapeamento de rios de grande porte, lagos, lagoas, reservatórios e áreas úmidas. É também sensível à morfologia do terreno, sendo muito utilizada para mapeamentos de geologia e geomorfologia. Serve para mapear a vegetação que foi queimada e permite ainda a visualização de áreas ocupadas por macrófitas aquáticas (por exemplo, aguapé). Banda muito sensível à absorção da radiação eletromagnética pelos óxidos de ferro e titânio, muito comuns nos solos tropicais muito intemperizados.
Banda 5 (infravermelho médio) 1.55 μm - 1.75 μm	Esta banda permite observar o teor de umidade nas plantas e detectar possíveis estresses na vegetação causados por falta de água. Utilizada também para obter informações sobre a umidade do solo, no entanto, pode sofrer perturbações se ocorrerem chuvas um pouco antes da cena ser imageada pelo satélite.
Banda 6 (infravermelho termal) 10.4 μm - 12.5 μm	Esta banda pode ser utilizada para mapeamento de estresse térmico em plantas, estudos de propriedade termal dos solos, mapeamento da temperatura de superfície de águas oceânicas superficiais, informações importantes para pesca e clima. Pode ser utilizada para estudos de ilhas urbanas.
Banda 7 (infravermelho médio) 2.08 μm - 2.35 μm	Esta banda apresenta sensibilidade à morfologia do terreno, servindo para estudos nas áreas de geologia, solos e geomorfologia. Utilizada também para identificação de minerais e detecção de umidade no solo e na vegetação.

Tabela 1 - Principais características e aplicações das bandas TM do satélite Landsat
Fonte: Divisão de Sensoriamento Remoto - INPE

Combinando as bandas 2, 3 e 4 aos canais B (azul), G (verde), R (vermelho), os limites entre o solo e a água com a banda 4 (infravermelho próximo) ficam mais definidos do que com a combinação 1, 2, 3. Os corpos d'água com sedimentos em suspensão aparecem em tonalidade azul clara e os com pouco sedimentos em suspensão, em azul escuro. As áreas urbanas e o solo exposto aparecem em tonalidades de azul. A banda 4 (filtro vermelho) é bastante sensível à clorofila, permitindo que se observem variações da vegetação, que aparecem em tonalidades de vermelho.

Combinando as bandas 3, 4 e 5 aos canais B, G, R (duas bandas no infravermelho do espectro eletromagnético), é possível obter uma maior diferenciação entre solo e água do que com as combinações anteriores. A vegetação é mostrada em diversas tonalidades de verde e rosa, que variam em função do tipo e das condições da vegetação. As áreas urbanas e o solo exposto são apresentados em tons rosados. A água, dependendo da quantidade de sedimentos em suspensão, aparece em preto.

Combinando as bandas 3, 5 e 4 aos canais B, G, R (uma banda no visível e duas no infravermelho), permite uma diferenciação da vegetação em tons marrons, verdes e amarelos. As áreas urbanas e os solos expostos são mostrados em tonalidades de azul claro, enquanto as áreas alagadas e a água aparecem em tons azuis escuros.

Entretanto, combinar a informação da banda não resolve todos os problemas. A distinção de regiões com mesmas características de reflectância somente é possível se a informação textural for utilizada. As classificações da textura permitem identificar regiões que têm um valor similar de cinza ou de cor em objetos diferentes se seus padrões variarem. Regiões de cobertura florestais diferentes (canopi) e regiões residenciais são caracterizadas por seu alto contraste de textura. Campos, lagos e mares aproximam seu contraste no tom e na cor, mas na textura são altamente diferentes. Os tipos de campos de agricultura têm regiões de texturas diferentes que podem ser úteis se encontrados seus limites. Assim, o emprego da análise de textura associada às possibilidades das multibandas pode contribuir para melhoria do processo de análise de imagens de sensoriamento remoto.

5. TEXTURA

Um fator de grande importância na análise de imagens é o reconhecimento de texturas. Este processo, realizado sofisticadamente pela visão humana, se reveste de grande complexidade no tratamento computacional. Parker (1997) [15]. Aliado a isso, muitos problemas, envolvendo segmentação de imagens, somente encontram solução no processamento de imagens coloridas (multibandas), onde, características como cor e textura, precisam ser levadas em consideração.

O atributo textura tem sido considerado uma importante fonte de dados para o processo de análise de imagens digitais. Presente na maioria das imagens naturais, como as exemplificadas na figura 2, a textura é fundamental para visão humana e serve como excelente descritor baseado em região contribuindo, em muitos casos, na melhoria da exatidão do processo de segmentação, descrição e classificação de imagens.



Figura 2 - Exemplos de texturas naturais e artificiais

A textura é uma expressão relacionada com as propriedades que representam a superfície de um objeto. É um termo intuitivo e de largo emprego, mas apesar de sua importância, não possui uma definição precisa.

Segundo Sklansky (1978) [18], “uma região em uma imagem apresenta uma textura única se um conjunto de estatísticas ou outra propriedade local da imagem for constante, de variação suave ou aproximadamente periódica”. Para Sonka (1993) [19], textura pode ser definida como algo que consiste de elementos mutuamente relacionados (a primitiva de textura, que pode ser um pixel ou um conjunto de pixels). McGrogan (1997) [11] define textura como uma estrutura composta de um grande número de elementos similares mais ou menos ordenados. Gonzalez (2000) [8], conceitua textura como um descritor que fornece medidas de propriedades como suavidade, rugosidade e regularidade.

Textura, pode ser definida também como uma propriedade de uma região que descreve o padrão de variação de tons de cinza e cor numa determinada área. A textura se caracteriza pela repetição de um modelo sobre uma região. Este modelo pode ser repetido de forma exata ou com pequenas variações sobre um mesmo tema. Tamanho, formato, cor e orientação dos elementos do modelo (denominados de “textons”) podem variar sobre as regiões. A variação encontrada na forma como os “textons” se relacionam é suficiente para diferenciar duas texturas. Uma região precisa possuir um tamanho grande o suficiente para exibir sua textura. Assim, seu tamanho não pode ser pequeno se comparado com um “texton”.

Algumas propriedades da textura são indicadas na literatura: Haralick (1979) [10] classifica as texturas como fortes ou fracas, sendo mais fortes quanto maior a sua regularidade, ou seja, a interdependência das primitivas de textura. Sonka (1993) [19], assevera que a descrição da textura é dependente de escala. E Castleman (1996) [1] afirma que as texturas são quantificadas avaliando-se aspectos relativos à variação de tons de cinza em seções contidas na imagem.

Conclui-se que não existe uma definição precisa, nem uma aproximação matemática formal para a quantificação da textura. No entanto, todas as definições parecem estar associadas à impressão de rugosidade e contraste criada pela variação tonal ou pela repetição de padrões visuais sobre uma região.

A análise de textura geralmente é utilizada para:

- Segmentação: divisão de uma imagem em regiões com mesmo perfil textural;
- Descrição: extração de características baseada na quantificação de seu conteúdo de textura para discriminação entre classes de objetos;
- Classificação: rotulação de uma região com determinada textura com base em exemplos de texturas conhecidas;
- Forma: empregar a informação de textura para derivar a geometria de uma superfície tri-dimensional;
- Réplica: descrever uma textura visando sua reprodução.

Técnicas que façam uso do atributo textura no processo de análise de imagens vem sendo objeto de estudo de um número crescente de pesquisadores. Algumas dessas técnicas serão apresentadas neste estudo.

6. DESCRITORES REGIONAIS BASEADOS EM TEXTURA

Existem vários métodos para extração e análise de texturas. Haralick (1979) [10] propõe várias formas estatísticas para quantificar a textura de uma imagem, dentre elas: funções de autocorrelação (autocorrelation functions), bordas texturais (textural edgeness), probabilidade de co-ocorrência

espacial de nível de cinza (spacial gray tone cooccurrence probabilities), comprimento da série de um nível de cinza (gray tone run lengths).

As Funções de Autocorrelação permitem classificar as texturas como finas ou grossas a partir da medida de suas primitivas. Texturas finas possuem primitivas pequenas, enquanto texturas grossas, primitivas grandes. **Bordas Texturais** permitem classificar as texturas como finas ou grossas a partir da quantidade de bordas por unidade de área. Texturas finas possuem um grande número de bordas por unidade de área, enquanto texturas grossas possuem um pequeno número.

Probabilidade de Co-ocorrência Espacial de Nível de Cinza também conhecida por matriz de co-ocorrência dos níveis de cinza, permite classificar as texturas como finas ou grossas a partir da co-ocorrência de seus níveis de cinza. Nas Texturas finas, os tons mudam rapidamente em função da distância, enquanto nas texturas grossas os tons mudam lentamente. Esta abordagem possui a vantagem de ser invariante às transformações na imagem, entretanto não permite revelar a forma da textura.

Comprimento da Série de um Nível de Cinza permite classificar as texturas como finas ou grossas a partir da quantidade de séries de um nível de cinza. Cada série, medida em uma das direções: horizontal, vertical ou diagonal, é composta por pixels linearmente adjacentes com mesmo nível de cinza. Texturas finas são caracterizadas por um grande número de séries de comprimento curto, enquanto texturas grossas, por um grande número de séries de comprimento longo.

Parker (1997) aborda principalmente os seguintes métodos: estatísticos, margens e texturas, energia e superfície. Dois Métodos estatísticos são sugeridos: os **Momentos de Intensidade** e a **Matriz de Co-ocorrência dos Níveis de Cinza**, já citada anteriormente. Os Momentos de Intensidade (primeiro e segundo momento) podem ser utilizados para descrever as propriedades de uma textura. A partir do histograma de intensidade de uma região podem ser calculados os momentos deste histograma. O primeiro momento, **média dos níveis de cinza**, indica a média de intensidade da região; o segundo momento, **desvio padrão**, indica como estão distribuídas as intensidades iguais dentro da região.

Margens e Texturas visam isolar textons individuais e tratá-los como objetos, partindo da idéia de que uma textura é formada por um conjunto de textons. As margens poderiam ser localizadas a partir das transições dos níveis de cinza nos limites de um texton. Assim, as propriedades dos pixels marginais poderiam ser utilizadas para caracterizar a textura. A direção e densidade dos pixels marginais, por exemplo, poderiam ser utilizados para segmentar regiões. Mudanças bruscas de direção ou intensidade dos pixels marginais provavelmente indicariam o limite entre duas regiões. A utilização da informação da margem pode ser associado ao método de co-ocorrência de níveis de cinza potencializando os resultados em termos de habilidade de discriminação.

Energia e Textura, baseada na medida de energia de Laws, consiste numa coleção de máscaras de convolução especificamente para o propósito de computar a energia em uma textura. Filtros específicos são aplicados aos dados para extrair suas propriedades e de acordo com critérios pré-definidos, o significado dessas propriedades é calculado utilizando para isso, um método estatístico que computa a energia de uma região texturizada. O sucesso deste método para segmentar texturas o tornou padrão de comparação para novos algoritmos.

Superfície e textura considera a imagem em níveis de cinza como uma superfície tridimensional, onde o nível de cinza é a terceira dimensão. No método de **Dispersão de Vetor**, a imagem de textura

consiste em um conjunto de pequenos planos ou faces. A normal de cada plano da imagem é um vetor, e a variação nas direções normais para uma região de muitas faces produz uma avaliação que pode caracterizar a textura de uma região. O método de Dispersão de Vetor é na verdade uma primeira aproximação da imagem. Outro método, **Curva e Superfície**, trata a imagem como uma superfície polinomial, apresentando uma melhor aproximação às variações locais de formato.

Segundo Gonzalez (2000) [8], as principais técnicas utilizadas para descrever texturas podem ser divididas em estatísticas, estruturais e espectrais. As **abordagens estatísticas** (momentos do histograma e matriz de co-ocorrência de níveis de cinza) descrevem a textura através de grandezas que as caracterizam como suave, áspera, granular, etc. As **técnicas estruturais** (conceitos estruturais) descrevem a textura como arranjos de primitivas da imagem. O modelo estrutural lida com o conceito de primitiva da textura (texton). Esta primitiva é um elemento fixo que se repete numa área da imagem. As **técnicas espectrais** lidam com as regiões no domínio das frequências espaciais (espectro de Fourier). Através das propriedades do espectro de Fourier é possível identificar características como periodicidade global.

Métodos baseados em análises de multi resoluções estão sendo desenvolvidos sob a alegação de serem capazes de suprir as deficiências encontradas em técnicas anteriores. A principal justificativa é devido a estes métodos não possuírem recursos para caracterização eficiente da textura em diferentes escalas. Trabalhos recentes relatam o uso de transformações wavelet e fractais como solução para uma análise multi resoluções efetiva e consistente.

Wavelets modelam a textura no domínio da frequência espacial, segundo a aplicação de um banco de filtros sobre as regiões da imagem, obtendo como vetor de características as medidas de energia de cada sub-banda. Duas propriedades principais caracterizam os fractais: a auto-semelhança e a dimensão fractal. A auto-semelhança é uma característica que os objetos fractais possuem, de cada pequena porção sua, poder ser vista como uma réplica reduzida do todo. E a dimensão fractal é uma medida que quantifica a densidade dos fractais no espaço métrico em que são definidas e pode ser utilizada para determinação da rugosidade de uma textura. As próximas seções fornecerão um detalhamento maior sobre algumas destas técnicas utilizadas para descrição de texturas.

7.1 AUTOCORRELAÇÃO

A função de autocorrelação de uma imagem pode ser utilizada para detectar padrões repetitivos nos elementos de uma textura. A autocorrelação $r(dr, dc)$ de uma imagem $N+1 \times N+1$, para uma deslocação $d=(dr, dc)$, é dada por:

$$r(dr, dc) = \frac{\sum_{r=0}^N \sum_{c=0}^N I[r, c] I[r+dr, c+dc]}{\sum_{r=0}^N \sum_{c=0}^N I^2[r, c]} = \frac{I[r, c] \circ I_d[r, c]}{I[r, c] \circ I[r, c]}$$

Para texturas regulares, a função de autocorrelação caracteriza-se por ter picos e vales.

7.2 LOCAL BINARY PARTITION (LBP)

Neste método, para cada pixel p existente na imagem, cada um dos oito pixels vizinhos é examinado para verificar se a sua intensidade é superior à de p . Os resultados obtidos desta análise são usados para construir um número binário – $b_1b_2b_3b_4b_5b_6b_7b_8$ – em que $b_i=0$, se a intensidade do

i-ésimo vizinho é menor ou igual à de **p**, e **b_i**=1, se ela for superior. A textura da imagem é representada por um histograma destes números binários. Duas imagens ou regiões são comparadas por processamento das distâncias **L₁**, entre os histogramas assim definidos, sendo **L₁** dado por:

$$L_1(H_1, H_2) = \sum_{i=1}^n |H_1[i] - H_2[i]|$$

7.3 MEDIDA DE ENERGIA DE LAWS

Laws desenvolveu uma abordagem de energia-textura que mede o valor ou a quantidade de variação dentro de uma janela de tamanho fixo. Este método utiliza um conjunto de nove máscaras de convolução de 5x5 para processar a energia da textura, que é depois representada por um vetor de nove números para cada *pixel* da imagem em análise.

$$\begin{aligned} \text{L5 (Level)} &= [1 \ 4 \ 6 \ 4 \ 1] \\ \text{E5 (Edge)} &= [-1 \ -2 \ 0 \ 2 \ 1] \\ \text{S5 (Spot)} &= [-1 \ 0 \ 2 \ 0 \ -1] \\ \text{R5 (Ripple)} &= [1 \ -4 \ 6 \ -4 \ 1] \end{aligned}$$

O primeiro passo no procedimento de Laws é retirar os efeitos da iluminação, passando uma pequena janela por toda a imagem, subtraindo a média local para cada *pixel*, de forma a produzir uma imagem pré-processada em que a média da intensidade de cada vizinhança é próxima de zero. Sendo **F_k[i,j]** o resultado da filtragem com a *k*-ésima máscara, no *pixel* **[i,j]**, o mapa da energia da textura, **E_k**, para o filtro *k* é dado por:

$$E_k[r,c] = \sum_{j=c-7}^{c+7} \sum_{i=r-7}^{r+7} |F_k[i,j]|$$

Cada mapa de energia de textura é uma imagem completa, representando a aplicação da *k*-ésima máscara à imagem inicial. Tendo sido produzidos os dezesseis mapas de energia, alguns pares simétricos são combinados, resultando nos nove mapas finais:

L5E5 / E5L5	L5S5 / S5L5	L5R5 / R5L5
E5E5	E5S5 / S5E5	E5R5 / R5E5
S5R5 / R5S5	S5S5	R5R5

Deles resulta uma imagem com um vetor de nove atributos de textura em cada *pixel*.

7.4 MOMENTOS DO HISTOGRAMA

Momentos de Intensidade podem ser utilizados para descrever as propriedades de uma textura. A partir do histograma de intensidade de uma região é possível o cálculo dos momentos deste histograma. O primeiro momento, **média dos níveis de cinza**, indica a média de intensidade da região; o segundo momento, **desvio padrão**, indica como estão distribuídas as intensidades iguais dentro da região.

Basicamente, o método da média dos níveis de cinza consiste na substituição do valor do nível de cinza de cada *pixel* pela média obtida dos valores de uma janela **M x M** centrada neste *pixel*. Em

seguida, a imagem é delimitada em duas regiões usando os novos níveis médios. O primeiro momento não apresenta bons resultados quando as amostras estão normalizadas para os níveis de cinza, não sendo, portanto, recomendado para distinção entre texturas. O emprego do desvio padrão dos níveis de cinza apresenta melhor resultado.

O histograma $p_f(z)$ de uma imagem digital f fornece a frequência com que cada nível de cinza z ocorre em f . Ele fornece uma estimativa da densidade de probabilidade dos níveis de cinza no conjunto de imagens do qual f é uma amostra. Medidas estatísticas calculadas sobre o histograma nos dão informações gerais sobre esta população de níveis de cinza. Rosenfeld (1982) [16].

Algumas medidas utilizadas são os momentos do histograma. O n -ésimo momento do histograma pode ser calculado por:

$$m_n(z) = \sum_{i=1}^L (z_i - m)^n p(z_i)$$

em que $m = \sum_{i=1}^L z_i p(z_i)$ é a média do histograma, z_i é o nível de cinza i e L é a quantidade de níveis de cinza da imagem. Gonzalez (2000) [8]. Pela equação acima, $\mu_0 = 1$ e $\mu_1 = 0$. O segundo momento é a variância ($\sigma^2(z)$), grandeza que pode ser utilizada para medir a textura através do descritor de suavidade relativa R :

$$R = 1 - \frac{1}{1 + \sigma^2(z)}$$

Esta medida possui valor 0 para áreas de intensidade constante ($\sigma^2(z) = 0$ se todos os z_i 's possuírem o mesmo valor), e se aproxima de 1 para grandes valores de $\sigma^2(z)$.

7.5 MATRIZ DE CO-OCORRÊNCIA DE NÍVEIS DE CINZA

O cálculo dos momentos de intensidade possui a vantagem de ser fácil de realizar, mas não oferece nenhuma informação sobre a natureza repetitiva da textura. Um método estatístico que soluciona este problema é a **Co-ocorrência de Níveis de Cinza**, que consiste em experimentos estatísticos realizados sobre como um certo nível de cinza ocorre em relação a outros níveis de cinza.

A ocorrência de níveis de cinza pode ser descrito através de uma matriz de frequências relativas chamadas de matriz de co-ocorrência. Uma matriz de co-ocorrência contém informações sobre as posições dos pixels que tem valores similares de níveis de cinza. Para isso são empregadas múltiplas matrizes, uma para cada direção de interesse (horizontal, vertical e as duas diagonais). Essas matrizes são analisadas e são computados valores numéricos, denominados de descritores, que encapsulam a informação. Para construir esta matriz define-se um operador $P(d, \theta)$ que estabelece um deslocamento d na direção θ , conforme a figura 3.

A é uma matriz $k \times k$ onde k é o número de tons possíveis na imagem. Cada elemento $a_{i,j}$ é o número de vezes que um ponto com o tom i aparece na posição específica por $P(d, \theta)$ relativamente a um ponto com o tom j . Por exemplo, considerando a imagem 6×5 da figura 4, com dois tons (0 e 1) e o operador $P(1, 3\pi/4)$:

P (1, 3 $\Pi/4$)




Figura 3 – Operador P (d, θ)

0	0	1	1	0	0
1	0	0	1	1	0
1	1	0	0	1	1
0	1	1	0	0	1
0	0	1	1	0	0

Figura 4 – Matriz 6x5

A matriz de co-ocorrência correspondente é representada por:

$$A = \begin{bmatrix} 10 & 0 \\ 0 & 10 \end{bmatrix}$$

O elemento $a_{0,0}$ (canto superior esquerdo), por exemplo, representa o número de vezes que um elemento com o tom 0 aparece à distância 1 e à direita e abaixo de outro ponto com o tom 0. Um fato importante a destacar é que o tamanho da matriz de co-ocorrência depende do número de tons. Para manter este tamanho dentro dos limites manuseáveis é usual diminuir o número de tons possíveis em cada imagem.

A matriz de co-ocorrência A não caracteriza univocamente as texturas, mas a comparação de algumas medidas extraídas destas matrizes ajuda a averiguar a similaridade de duas texturas. Por exemplo, a presença de valores elevados na diagonal principal de A indica a presença de faixas na imagem com direção igual a θ e espessura inferior a d. A matriz de co-ocorrência normalizada C pode ser obtida dividindo cada elemento de A pelo número de pares de pontos na imagem que satisfaçam P (d, θ).

$$C(i,j) = a_{i,j}/n \quad \text{onde } n = \sum_{i,j} a_{i,j}$$

A matriz de co-ocorrência por si só não nos dá uma quantificação da textura. Para obter essa quantificação, podem ser extraídas desta matriz várias feições que irão quantificá-la, dependendo do aspecto de interesse. Em seu trabalho, Haralick (1973) [9] propõe 28 feições de textura que podem ser extraídas das matrizes de co-ocorrência. Como exemplo, os seguintes descritores podem ser utilizados:

Probabilidade máxima: $\max_{i,j}(c_{ij})$

Momento de diferença de elementos de ordem k: $\sum_i \sum_j (i-j)^k c_{ij}$

Momento inverso de diferença de elementos de ordem k: $\sum_i \sum_j c_{ij} / (i-j)^k \quad i \neq j$

Entropia: $-\sum_i \sum_j c_{ij} \log c_{ij}$

Uniformidade: $\sum_i \sum_j c_{ij}^2$

7.6 MORFOLOGIA MATEMÁTICA

Esta técnica, proposta por Matheron (1967) [13], consiste no deslocamento de um elemento estruturante, com uma forma geométrica qualquer, sobre a imagem binária gerando uma nova imagem binária. Segundo Claro (1995) [2], propriedades texturais podem ser obtidas através da parametrização do elemento estruturante e do número de elementos encontrados na nova imagem, em função desse parâmetro.

Erosão e dilatação são as operações elementares da Morfologia Matemática e formam a base para a construção das transformações mais complexas. Assim, numa cadeia morfológica de processamento de imagens, podemos encontrar um grande número de operadores utilizados, todos definidos a partir destas funções elementares.

Dilatação ($\oplus$) A dilatação pode ser considerada como sendo a união de todos os conjuntos obtidos a partir de translações dos pixels da imagem pelo elemento estruturante B, ou seja:

$$A \oplus B = \bigcup_{b \in B} (A)_b$$

A dilatação adiciona uma camada de pixels à região mais externa do objeto, tornando-o mais “gordo”. A geometria da nova camada de pixels é definida pelo elemento estruturante, figura 5.




Figura 5 – Forma binária (a); Algumas situações que ocorrem durante a dilatação por um elemento estruturante “cruz” (b); A camada de pixels adicionados, em verde claro (c); Forma dilatada (d).

Erosão ($\ominus$)

A Erosão pode ser considerada como sendo a interseção de todos os conjuntos obtidos a partir de translações dos pixels da imagem (A) pela reflexão do elemento estruturante (B), ou seja:

$$A \ominus B = \bigcap_{b \in B} (A)_{-b}$$

A erosão remove uma camada de pixels mais externos do objeto, tornando-o mais “fino”. A geometria dessa camada depende do elemento estruturante, figura 6.




Figura 6 – Forma binária (a); Algumas situações que ocorrem durante a erosão por um elemento estruturante “cruz” (b); A camada de pixels deletados, em verde claro (c); Forma erodida (d).

Compondo-se a dilatação e a erosão, novos operadores podem ser gerados. A abertura é uma erosão seguida de uma dilatação. A erosão desconecta os objetos, mas também os diminui. A dilatação recupera seus tamanhos originais. Esta operação geralmente suaviza o contorno de uma imagem, quebra istmos estreitos e elimina protusões finas. O fechamento é definido como uma dilatação seguida de uma erosão. Esta operação também tende a suavizar os contornos, mas, em oposição à abertura, geralmente funde as quebras em golfos finos, elimina pequenos buracos e preenche fendas em um contorno.

Um método potente para caracterizar texturas através da morfologia matemática consiste em realizar várias operações de erosão e dilatação de regiões e analisar seus resultados. Por exemplo, uma série de aberturas com um elemento estruturante “círculo” pode ser realizada sobre uma imagem que representa a textura. O raio do elemento estruturante inicialmente definido por **hmin** pode ser incrementando em cada abertura realizada até um certo **hmax**. Uma vez aplicada a abertura da imagem, se calcula a área da imagem resultante, em seguida divide-se esta área pela área da imagem

original. Com os valores obtidos pelo cálculo com diferentes raios do elemento estruturante é possível obter uma distribuição de probabilidade que pode ser utilizada como descritor da imagem.

7.7 ESPECTRO DE FOURIER

O espectro de Fourier pode ser utilizado para descrição de textura devido a algumas características como: picos proeminentes no espectro fornecem a direção dos padrões de textura; e posição dos picos no plano da frequência fornece o período espacial fundamental dos padrões.

Uma possível simplificação do espectro de Fourier para a análise de textura é definir a imagem através de duas funções, obtidas do seguinte modo:

- Expressar o espectro de Fourier em coordenadas polares: $S(r, \theta)$
- Dividi-la em duas funções unidimensionais: $S_\theta(r)$ e $S_r(\theta)$
- Integrar estas funções (para variáveis discretas):

$$S(r) = \sum_{q=0}^P S_q(r)$$

$$S(q) = \sum_{r=1}^R S_r(q)$$

sendo R o raio de uma circunferência centrada na origem.

Para cada par de coordenadas (r, θ) haverá um par de valores $S(r)$, $S(\theta)$. Variando-se essas coordenadas, é possível gerar funções unidimensionais $S(r)$ e $S(\theta)$, que constituem descrições de energia espectral da textura para uma determinada imagem ou região. Além disso, os descritores das próprias funções podem ser calculados para uma caracterização quantitativa. Descritores tipicamente utilizados com essa finalidade são a posição do valor mais alto, a média e a variância da amplitude e as variações axiais, e a distância entre a média e o maior valor da função.

As figuras 7, 8 e 9 ilustram o uso das equações $S(r)$ e $S(\theta)$ para a descrição global de textura. A figura 7 apresenta a imagem com uma textura periódica e seu espectro correspondente.




Figura 7 - Imagem com uma textura periódica e espectro de Fourier correspondente.

A figura 8 apresenta Gráficos de $S(r)$ e de $S(\theta)$, respectivamente. No gráfico de $S(r)$, são observados alguns picos, indicando a presença de algum tipo de textura. No de $S(\theta)$, ocorrem picos de 45° em 45° que corresponde à periodicidade no conteúdo de textura da imagem.




Figura 8 - Gráficos de $S(r)$ e de $S(\theta)$, respectivamente

Considerando a imagem da figura 9 e seu correspondente gráfico $S(\theta)$, por exemplo, é possível verificar picos de 90° em 90° , pois a textura ocorre mais fortemente na vertical e horizontal. Assim, a análise dos gráficos $S(\theta)$ de texturas distintas pode ser empregada para diferenciar padrões diferentes de textura.




Figura 9 - Imagem e gráfico de $S(\theta)$

Uma estratégia para classificação de texturas seria utilizar análise no domínio de Fourier para identificar as frequências espaciais mais representativas de cada classe (amostras de texturas). A energia mais alta e a condição de estar presente em apenas uma classe pode ser empregada para fins de discriminação entre as classes. Cabe destacar, entretanto, que cenas naturais possuem texturas muito complexas que requerem um grande número de frequências em sua caracterização. Desta forma, existe uma alta possibilidade de que várias das frequências espaciais selecionadas num experimento estejam também presentes em outras classes de texturas com um nível mais baixo de energia o que resulta numa perda da exatidão no processo de classificação.

7.8 WAVELETS

Wavelets representam uma forma alternativa de análise no espaço de escala. Wavelet é um método de transformação de sinais e por extensão um método geral de transformação de funções dependentes de tempo ou espaço. Há dois tipos principais de transformações: a **Transformada Wavelet** e a **Transformada de Wavelet Packets**, Daubechies (1988) [6], Daubechies (1988) [7].

O ponto de partida da transformada wavelet é a divisão de uma função $f \in L^2(\mathbb{R})$ em uma combinação linear de funções básicas do tipo:

$$f = \dots + c_0 \cdot \Phi_0 + c_1 \cdot \Phi_1 + c_2 \cdot \Phi_2 + \dots$$

onde os c_i são os coeficientes e as Φ_i , as funções básicas.

Existem diversas famílias de wavelets:

Haar: É a primeira e a mais simples de todas. É descontínua e equivale a Daubechies 1 (db1).

Daubechies: Compactly-supported orthonormal wavelets.

Biortogonal: Apresenta a propriedade de fase linear, que é necessária na reconstrução de sinais e imagens. Utiliza duas wavelets, uma para decomposição e outra para reconstrução, o que gera propriedades interessantes.

Coiflets: A função wavelet possui $2N$ momentos iguais a zero e a função escala tem $2N-1$ momentos iguais a zero.

Symlets: São wavelets simétricas. Foi proposta como uma modificação da família Daubechies pela própria, possuindo características similares as desta família.

Morlet: Não possui função escala e é explícita.

Mexican Hat: Também não possui função escala, mas não é explícita.

Meyer: A wavelet e a função escala estão definidas no domínio de frequência.

Em contraste com a tradicional Transformada de Fourier, onde as funções básicas são definidas somente pelo parâmetro frequência, na transformada de wavelets, as funções básicas são definidas por dois parâmetros: posição e escala. Isto permite a análise de fenômenos locais de uma função através da utilização de muito menos graus de liberdade. A transformada de wavelet packets utiliza, além de informações de posição e escala, também a frequência como um grau de liberdade adicional nas funções-base.

As maiores capacidades de análise dos wavelets em relação à transformada de Fourier são atingidas através da utilização de uma função, que pode ser quase qualquer uma, denominada wavelet que é escalonada (dilatação) e movida (translação) durante a transformação de wavelets. Isto permite que características de um sinal examinado sejam extraídas em função de determinada posição e tamanhos desejados. Como na transformada de Fourier somente a variação das frequências de funções seno e cosseno é possível, as características de posição do sinal são perdidas através da periodicidade dessas funções. Wangenheim (2003) [20].

Vários estudos têm tratado de responder a questão de qual família wavelet utilizar para análise de texturas. Não há, contudo, uma resposta única, uma vez que algumas wavelets se sairão melhores na análise de algumas texturas específicas, enquanto outros tipos de wavelets se sairão melhores em outras texturas. Contudo, estudos comparativos mostram que a mudança na escolha da função wavelet gera apenas pequenos efeitos nos resultados.

8 FRACTAIS

Dentre as diversas abordagens possíveis para análise de texturas, destaca-se a geometria fractal. Parker (1997) [15]. A sua utilização para caracterização de texturas é uma área nova e promissora, pois, permite identificar e classificar texturas com grande simplicidade e eficiência. Todavia, os métodos existentes que a utilizam, limitam-se a estimativa da dimensão fractal

de imagens binárias e em escala de cinza. Por isso, este trabalho tem por objetivo apresentar uma nova idéia: a identificação da textura em imagens multiespectrais. Assim, é proposto um método, denominado de **CDC** (*Contagem de D -Cubos*), que estende os conceitos expostos pelos outros métodos, permitindo estimar a dimensão fractal de imagens de qualquer dimensão.

8.1 METODOLOGIA UTILIZADA

Esta seção apresenta o aspecto principal da técnica proposta, suas possibilidades e limitações assim como algumas particularidades de aproximação conceitual. Os diversos métodos de análise de texturas descritos até aqui são largamente empregados no processamento digital de imagens. De maneira geral são técnicas sofisticadas e que exigem cálculos intensos e complexos. Tudo isso exige um considerável tempo de processamento nas aplicações que os utilizam. Os conceitos da geometria fractal podem contribuir na formulação de métodos de análise de texturas caracterizados pela simplicidade e grande eficiência.

Na década de 70, o surgimento de uma nova geometria viria revolucionar a tradicional geometria euclidiana. Esta, muito adequada para modelar quadrados, cubos, esferas e outros objetos artificiais, definidos em 1, 2 ou 3 dimensões por meio de pontos, retas ou planos, dificilmente poderia descrever objetos naturais tais como: nuvens, montanhas, raios, arbustos e folhagens, caracterizados por padrões irregulares e aparentemente randômicos. Matemáticos como: Von Koch, Peano, Hausdorff, Besicovitch, dentre outros, propuseram um novo tipo de dimensionamento, no qual os objetos não teriam dimensão inteira (como na geometria euclidiana), e sim, fracionária. Com esta nova geometria, denominada de Geometria Fractal (originário do latim *fractus*, que significa fragmentos) seria possível criar modelos mais próximos da realidade, uma vez que permitiria descrever bem as irregularidades e os processos turbulentos da natureza.

A teoria dos Fractais consiste da caracterização de duas propriedades principais que são associadas aos objetos: a auto-semelhança e a dimensão fractal. A auto-semelhança é uma característica que os objetos fractais possuem de cada pequena porção sua poder ser vista como uma réplica reduzida do todo. E a dimensão fractal é uma medida que quantifica a densidade das fractais no espaço métrico em que são definidas e serve para compará-las.

Estimando a Dimensão Fractal de Imagens Binárias

O teorema da contagem dos cubos (Box Counting Theorem) oferece um método simples para estimar a dimensão fractal de imagens binárias (2D). Para exemplificar a técnica será considerado o conjunto indicado por A na figura 10, onde A pode ser visto como a fractal triângulo de Sierpinsky. Um sistema de coordenadas cartesianas é montado e, é realizada uma contagem do número de “quadrados” de área $N_n(A)$ de lado $1/2^n$ o qual “cobre” A, então:

$$DF(A) = \lim_{n \rightarrow \infty} \frac{\log(N_n(A))}{\log(2^n)} \quad (1)$$

Pode-se obter valores satisfatoriamente exatos de $N_n(A)$ para $n = 1, 2, 3, 4, 5$ e 6 . Esses valores dependem da escolha do sistema de coordenadas e estão presentes na tabela 2.

n	$N_n(A)$	2^n	$\log N_n(A)$	$\log 2^n$
1	4	2	1,386	0,693
2	12	4	2,484	1,386
3	36	8	3,583	2,079
4	108	16	4,682	2,772
5	324	32	5,780	3,465
6	972	64	6,879	4,158

Tabela 2 - Cálculo experimental da DF do triângulo de Sierpinsky




Figura 10 - Divisão recursiva da imagem triângulo de Sierpinsky

Colocando os valores logaritmos da tabela 2 em um eixo cartesiano, como ilustrado na figura 11, obteremos uma seqüência de pontos próxima a uma reta. Fazendo uma regressão linear, tem-se uma reta; a inclinação desta reta é a medida da dimensão fractal DF (A) $\cong 1,585$, em uma variação nos limites dos lados entre 1 e 1/64 unidades.




Figura 11 - Gráfico de $\log(N_n(A)) \times \log(2^n)$.

Estimando a Dimensão Fractal de Imagens em Escala de Cinza

O método da contagem de cubos pode ser estendido para estimar a dimensão fractal de imagens em escala de cinza (3D). Além disso, variações do método têm utilização bastante difundida e é apropriado examinar algumas destas definições alternativas de dimensão, que podem ser usadas como uma tentativa de quantificar e classificar texturas de um conjunto de pixels.

Método Box-Counting (BC)

Uma extensão simples do teorema da contagem de cubos para estimar a dimensão fractal (DF) de imagens em escala de cinza é considerar a imagem como um objeto tridimensional (a terceira coordenada representa a intensidade do pixel) ou como uma superfície do terreno, cuja altura é proporcional ao valor da intensidade da imagem, como mostrado na figura 12.. Assim, a DF de uma imagem em escala de cinza pode assumir valores no intervalo entre 2 e 3.




Figura 12 - Imagem como objeto 3D.

Considere que a imagem de $M \times M$ pixels seja dividida em grades de pixels de $s \times s$ e escalonada para baixo a razão $r = s/M$. Se G for o número total dos níveis de cinza, então $G/s' = M/s$. Em cada grade haverá uma coluna de caixas de tamanho $s \times s \times s'$. Atribua o número 1, 2, ... n às caixas como mostrado na figura 13, a DF Box-Counting computada em cada banda é uma simples extensão, onde as caixas agora são elementos 3D e $N_n(A)$ da equação (1) denotam o número de caixas de comprimento lateral $1/2^n$ que interceptam o conjunto A , também na direção da intensidade do pixel (terceira coordenada).




Figura 13 - Contagem de “caixas”

Método Differential Box-Counting (DBC)

O método Differential-Box-Counting, Sarkar e Chaudhuri (1994) [17], é mais adequado do que a equação (1) para estimar a DF. Neste método, a medição da superfície de uma imagem em níveis de cinza é baseada numa extensão do método sugerido por Mandelbrot (1982) [12] para as medições do comprimento de curva. Quando utilizam-se superfícies e não mais curvas, todos os pontos no espaço

tridimensional, a distância $\in$ da superfície, devem ser considerados, cobrindo a superfície com um “cobertor” de espessura $2\in$. A área da superfície é igual ao volume ocupado pelo “cobertor” dividido por $2\in$. A espessura do cobertor é definida por sua superfície superior $u_{\in}$ e a superfície inferior $b_{\in}$.

Inicialmente, dado a função do nível de cinza $g(i, j)$, as superfícies superior e inferior na interação zero, que corresponde a um “cobertor” de espessura zero serão: $u_0(i, j) = b_0(i, j) = g(i, j)$. Para outros valores de espessura do “cobertor”, $\in = 1, 2, 3, \dots$, as superfícies cobertas inferiormente e superiormente são definidas por:

$$u_{\in} = \max \{ u_{\in-1}(i, j) + 1, \max_{|(m, n) - (i, j)| \leq 1} u_{\in-1}(m, n) \} \quad (2)$$

$$b_{\in} = \max \{ b_{\in-1}(i, j) + 1, \min_{|(m, n) - (i, j)| \leq 1} b_{\in-1}(m, n) \} \quad (3)$$

Onde $|(m, n) - (i, j)|$ é a distância entre os pixels (m, n) de uma imagem, seus vizinhos (i, j) que distam de (m, n) no máximo 1. Esses pixels são tomados como os quatro vizinhos mais próximos de (i, j) . Existem expressões semelhantes quando oito vizinhos são desejados. Será incluído no cobertor um ponto (x, y, f) quando $b_{\in}(x, y) < f \leq u_{\in}(x, y)$. Essa definição usa o fato de que o cobertor de uma superfície para o raio $\in$ inclui todos os pontos do cobertor para o raio $\in - 1$, junto com todos os pontos dentro do raio 1 das superfícies deste cobertor. A equação (2), por exemplo, assegura que uma nova superfície superior $u_{\in}$ é maior do que $u_{\in-1}$ em pelo menos 1, e também dista de pelo menos 1 de $u_{\in-1}$ nas direções horizontal e vertical.

O volume do cobertor é computado de $u_{\in}$ e $b_{\in}$ por:

$$v_{\in} = \sum_{i,j} (u_{\in}(i, j) - b_{\in}(i, j)) \quad (4)$$

Uma ilustração unidimensional do processo é mostrada na figura 14.




Figura 14 - Exemplo de limites superiores e inferiores do “cobertor” (diversas resoluções).

Com a área da superfície medida, com o raio ϵ toma-se o volume da camada adicionada pelo raio $\epsilon - 1$, dividido por 2 para considerar ambas camadas (a superior e a inferior):

$$A(\epsilon) = \frac{(v_{\epsilon} - v_{\epsilon-1})}{2} \quad (5)$$

A área da superfície fractal se comporta de acordo com a equação (6) :

$$A(\epsilon) = F\epsilon^{2-D} \quad (6)$$

A dimensão fractal pode ser obtida através do ajuste de mínimos quadrados linear no gráfico de $A(\epsilon)$ versus ϵ numa escala log-log plotada a partir da equação (6), obtendo-se uma linha com inclinação $2 - D$.

O método DBC introduz esse conceito na equação (1) computando adequadamente $N_n(A)$. Seja k o nível de cinza mínimo da imagem na grade (i,j) , e l o nível de cinza máximo da imagem na grade $(i, j)^n$, na n -ésima interação, então a aproximação DBC na equação (7) é a espessura geral na grade (i, j) .

$$n_n(i, j) = l - k + 1 \quad (7)$$

Fazendo a soma das contribuições de todas as grades na interação n :

$$N_n(A) = \sum n(i, j) \quad (8)$$

A DF pode ser estimada através do ajuste linear de mínimos quadrados no gráfico de $\log(N_n(A))$ x $\log(1/2^n)$ contado para diferentes dimensões das caixas.

Método Differential Box-Counting Modificado (MDBC)

Embora o método de DBC dê uma estimativa muito boa da DF, algumas simplificações computacionais e melhorias na eficiência do tempo são possíveis usando as modificações propostas no método original por Conci e Proença (1998) [5].

No MDBC, o espaço onde a imagem está modelada é subdividido em "boxes" de lados $s \times s \times s'$, onde S é um múltiplo do tamanho do pixel em (x,y) e s' é múltiplo do *nível* de cinza unitário na direção z . Uma imagem com tamanho $M \times M$ pixels é dividida no plano x,y em grids de $s \times s$ pixels, onde, $M/2 \geq s > 1$ e s é um inteiro. Em cada grid há uma coluna de "boxes" $s \times s \times s'$. A equação utilizada é :

$$DF_n = \frac{\text{Log}(N_n)}{\text{Log}(2^n)} \quad (9)$$

onde N_n é o número "boxes" (ou cubos) que interceptam a imagem representada.

O cálculo de N_n é feito com base nos tons de cinza dos pixels do grid (i,j) da seguinte forma: sejam **Cinza_Max (i,j)** e **Cinza_Min (i,j)** os valores máximo e mínimo dos tons de cinza da imagem no grid x,y.

$$N_n = \sum n_n(i,j) \quad (10)$$

onde,

$$n_n(i,j) = \frac{\text{inteiro}(\text{Cinza_Maximo}(i,j) - \text{Cinza_Minimo}(i,j))}{s} + 1 \quad (11)$$

N_n é tomado para os diferentes valores de n, isto é, para diferentes tamanhos de grids. Esta forma de contagem de N_n fornece uma melhor aproximação dos "boxes" que interceptam a superfície dos níveis de cinza da imagem.

A dimensão fractal da imagem é estimada por média entre as DF_n . As parcelas Cinza_max e Cinza_min, no algoritmo implementado, correspondem às duas matrizes que armazenam as informações de tons máximo e mínimo da imagem à medida que cada pequeno grid de 2×2 é "lido". Visando, principalmente, a eficiência computacional, uma imagem só é "lida" uma única vez e então, são armazenadas as matrizes Cinza_max e Cinza_min. Para uma imagem com tamanho $M \times M$ são armazenadas inicialmente duas matrizes $M/2 \times M/2$. As intensidades de cinza da imagem não precisam ser "lidas" novamente, armazenadas em matrizes $M \times M$ ou conservadas durante os cálculos. Esta implementação é particularmente importante em um processamento automático. O valor de M utilizado é 256, logo, as imagens processadas têm 256×256 e 256 níveis de cinza. Caso alguma imagem tenha tamanho (x,y) maior que 256, ela é subdividida em 256×256 para garantir a integridade do método. A partir da obtenção de uma imagem (seja armazenada em arquivo TIFF ou capturada pela câmera), o primeiro passo do método é gerar as duas matrizes de tamanho 128×128 que são as matrizes Cinza_max e Cinza_min. Na primeira interação, onde as matrizes têm 128×128 , é lido de cada matriz um "box" $2 \times 2 \times 2$. Com base nestes valores são calculados os $n_7(i,j)$ - equação (11), os N_7 - equação (10), o DF_7 - equação (9) e novas matrizes Cinza_max e Cinza_min são geradas tendo agora o tamanho de 64×64 . O limite para o término deste procedimento é o tamanho mínimo das matrizes definido em 8×8 . Este limite foi fixado tendo em conta testes (Conci e Campos (1996) [3]) de avaliação do método que quantificaram este valor como recomendável. Variações crescentes de n correspondem às variações dos grids de 2×2 , 4×4 , 8×8 ... $2^n \times 2^n$. No procedimento implementado, a variação de n é decrescente. Na primeira interação temos $n=7$, grid de 128×128 correspondentes às matrizes iniciais Cinza_max e Cinza_min.

Método da Contagem de D-Cubos (CDC)

As seções anteriores descreveram alguns métodos conhecidos para determinação da dimensão fractal de imagens binárias e monocromáticas, modeladas respectivamente nos espaços R^2 e R^3 . Em síntese, estes métodos dividem recursivamente o espaço R^2 em partes quadradas de tamanho r (objeto bidimensional) ou o espaço R^3 em partes cúbicas de tamanho r (objeto tridimensional). Em seguida, realizam a contagem do número de quadrados ou cubos que estiverem interceptando as imagens binárias e monocromáticas, respectivamente. Generalizando, podemos supor que a determinação experimental da dimensão fractal de imagens multidimensionais (com múltiplos canais) implicará na divisão recursiva do espaço R^d em partes d-cúbicas de tamanho r , seguido da contagem dos d-cubos que interceptarem a imagem.

O método **CDC** (*Contagem de D -Cubos*) proposto por Nunes e Conci (2001) [4] para se determinar a dimensão fractal de imagens multidimensionais é uma extensão dos conceitos expostos pelos outros métodos, com a vantagem de permitir calcular a dimensão fractal de imagens de qualquer dimensão.

Nas imagens binárias, o espaço R^2 é dividido por **2-cubos** de lados iguais $L_1 \times L_2$ de tamanho $1/2^n$, onde L_1 e L_2 correspondem aos eixos das coordenadas x, y da matriz de pixels da imagem, e o número de **R_2 -cubos** que intercepta a imagem é contado.

Nas imagens monocromáticas, o espaço R^3 é dividido por **3-cubos** de lados iguais $L_1 \times L_2 \times L_3$ de tamanho $1/2^n$, onde L_1 e L_2 correspondem aos eixos das coordenadas x, y da matriz de pixels da imagem e L_3 corresponde ao nível da intensidade de cinza da imagem e o número de **R_3 -cubos** que intercepta a imagem é contado.

Para imagens coloridas, o espaço R^5 é dividido por **5-cubos** de lados iguais $L_1 \times L_2 \times L_3 \times L_4 \times L_5$ de tamanho $1/2^n$, onde L_1 e L_2 correspondem aos eixos das coordenadas x, y da matriz de pixels da imagem e L_3, L_4 e L_5 são múltiplos do nível da cor no canal considerado (RGB) e o número de **R_5 -cubos** que intercepta a imagem é contado.

Nas imagens de satélite, conforme o número n de bandas espectrais consideradas, o espaço R^d é dividido por **d-cubos** de tamanho $1/2^n$ e o número de **R_d -cubos** que intercepta a imagem é contado.

Mas como dividir um espaço R^d por **d-cubos**, sendo $d > 3$? Como poderemos determinar o número de partes obtidas da divisão de um espaço R^d ? Ou ainda, quantos **d-cubos** existem numa determinada divisão recursiva do espaço R^d ?

Para responder estas perguntas, precisamos observar novamente como objetos de dimensões conhecidas se comportam em divisões recursivas. Tomemos novamente, como exemplo, o segmento, o quadrado e o cubo, objetos euclidianos de dimensão 1D, 2D e 3D, respectivamente. A figura 15 ilustra a divisão recursiva dos mesmos.




Figura 15 - Divisões recursivas de objetos 1D, 2D e 3D

- Observando o **1-cubo** (segmento) percebemos:

Dimensão	Divisões	$N_{n,1\text{-cubos}}$	Regra
1	1	2	2^1
	2	4	2^2
	3	8	2^3

- Observando o **2-cubo** (quadrado) percebemos:

Dimensão	Divisões	$N_{n,2\text{-cubos}}$	Regra
2	1	4	2^2
	2	16	2^4
	3	64	2^6

- Observando o **3-cubo** (cubo) percebemos:

Dimensão	Divisões	$N_{n,3\text{-cubos}}$	REGRA
3	1	8	2^3
	2	64	2^6
	3	512	2^9

Podemos verificar que o número de 1-cubos, 2-cubos ou 3-cubos em divisões recursivas depende da dimensão e do número de divisões. Assim, o número de 1-cubos pode ser determinado pela expressão:

$$N_{n,1\text{-cubos}} = 2^{1 \times n}, \text{ onde } n \text{ é o número de divisões.}$$

O número de 2-cubos pode ser determinado pela expressão:

$$N_{n,2\text{-cubos}} = 2^{2 \times n}, \text{ onde } n \text{ é o número de divisões.}$$

Da mesma forma:

$$N_{n,3\text{-cubos}} = 2^{3 \times n}, \text{ onde } n \text{ é o número de divisões.}$$

Generalizando, podemos concluir que o número de partes idênticas da divisão recursiva de um **d-cubo**, pode ser obtido pela expressão:

$$N_{n,d\text{-cubos}} = 2^{d \times n}, \text{ onde } d \text{ é a dimensão considerada e } n \text{ é o número de divisões.} \quad (12)$$

A dimensão fractal, então, pode ser obtida empregando-se a seguinte expressão:

$$DF_n = \frac{\text{Log } (N_{n,d\text{-cubo}})}{\text{Log } (2^n)} \quad (13)$$

onde $N_{n,d\text{-cubo}}$ é o número d-cubos que interceptam a imagem representada.

$$N_{n,d\text{-cubo}} = \sum n_n(i,j) \quad (14)$$

O cálculo de $N_{n,d\text{-cubo}}$ é feito com base nos tons de cinza dos pixels do grid (i,j), em cada banda, da seguinte forma: sejam **Cinza_Max (i,j)** e **Cinza_Min (i,j)** os valores máximo e mínimo dos tons de cinza da imagem no grid x,y,

$$n_n = \frac{\text{inteiro } (\text{Cinza_Maximo } (i,j) - \text{Cinza_Minimo } (i,j))}{s} + 1 \quad (15)$$

A tabela 3 descreve o cálculo da DF_n , empregando a equação (13), nas diversas divisões recursivas do espaço. Se considerarmos que todos os d-cubos interceptam a imagem, o valor da DF_n atingiria seu valor máximo uma vez que a imagem preencheria completamente seu espaço dimensional.

Imagens	Dimensão (d)	Divisões (n)	$N_n(d\text{-cubos})$	$\log (N_{n,d\text{-cubos}})$	$\log (2^n)$	DF_n
Binárias (nenhum canal)	2	1	4	$\log (4)$	$\log (2)$	2
		2	16	$\log (16)$	$\log (4)$	2
		3	64	$\log (64)$	$\log (8)$	2
Em escala de cinza (1 canal)	3	1	8	$\log (8)$	$\log (2)$	3
		2	64	$\log (64)$	$\log (4)$	3
		3	512	$\log (512)$	$\log (8)$	3
- (2 canais)	4	1	16	$\log (16)$	$\log (2)$	4
		2	256	$\log (256)$	$\log (4)$	4
		3	4096	$\log (4096)$	$\log (8)$	4
Coloridas (3 bandas)	5	1	32	$\log (32)$	$\log (2)$	5
		2	1024	$\log (1024)$	$\log (4)$	5
		3	32768	$\log (32768)$	$\log (8)$	5
Multiespectrais (acima de 3 bandas)	6	1	64	$\log (64)$	$\log (2)$	6
		2	4096	$\log (4096)$	$\log (4)$	6
		3	262144	$\log (262144)$	$\log (8)$	6
	...	...	...	...		...

Tabela 3 – Cálculo dos limites superiores da DF_n .

No método CDC, a DF pode ser estimada tanto através do ajuste de mínimos quadrados no gráfico $\log(N_{n,d-cubo}) \times \log(1/2^n)$, contado para as diferentes divisões recursivas n , quanto pela média dos diversos valores de DF_n .

8.2 RESULTADOS E CONTRIBUIÇÕES EFETUADAS

Na última seção, uma aproximação para estimar o DF de imagens multi bandas foi apresentada. Nesta seção, o método CDC é utilizado em alguns experimentos. Nós não examinaremos aqui a precisão da estimativa da DF para fractais clássicos em imagens binárias ou para texturas em imagens em tons de cinza porque já foram tratados em Conci e Nunes (2001) [4]. Os experimentos relatados aqui consideram um novo aspecto de seu uso na segmentação. Para imagens de satélites, nós desconhecemos resultados prévios considerando a DF. Para verificar os resultados, nós projetamos testes de invariância (em transformação afins e em combinação) e testes comparativos.

Invariância da DF em transformações afins

O método CDC mede a característica de superfície da imagem baseada em sua dimensão fractal. Então, o resultado deve ser invariante para rotações, translações, deslocamentos e escala (propriedade usual de todos objetos fractais). O Método do CDC estende o conceito de invariância para todas as bandas permitindo achar uma textura, depois transformações afins. A figura 16 mostra as simetrias possíveis em um modelo de teste. As simetrias são obtidas através da rotação e reflexão de cada pixel do modelo. A figura 17 mostra que o método CDC é invariante também em resolução.

Testando invariância com diferentes associações

Imagens Multi espectrais podem ser visualizadas como imagens coloridas se três bandas associadas aos canais vermelho, azul e verde. Cada associação de bandas aos canais RGB possuem características e aplicações específicas. A Combinação Adequada facilita a identificação de áreas através de representação da informação em cores diferentes. Conceitualmente, combinações diferentes de mesmas bandas não alteram a complexidade da imagem. Assim, CDC resulta DF constantes como mostrado na figura 18.

Teste de Segmentação

Uma textura sintética complexa feita com texturas da figura 19a e de outras imagens Landsat-7 TM foi utilizada para verificar as possibilidades de segmentação do método CDC. A figura 19b mostra o resultado encontrado.

Comparando os resultados da segmentação

A figura 20 mostra um mosaico de texturas naturais utilizadas para comparação com outras implementações. Três implementações para segmentação de imagens foram utilizados: SEGWIN, SPRING e CDC. SEGWIN é baseado em crescimento de região para análise da cor e textura (<http://www-iplab.ece.ucsb.edu/segmentation/JSEG/>). É possível observar na figura 21 uma boa diferenciação das texturas, mas muitas não foram identificadas apropriadamente. SPRING é baseado em crescimento de regiões e média estatística dentre as áreas (<http://www.inpe.br>). A Figura 22 apresenta o resultado da segmentação obtida com SPRING. Podemos observar que houve uma

definição excelente dos contornos e diferenciação das texturas. Entretanto, algumas texturas foram subdivididas em áreas menores perdendo suas características. A figura 23 apresenta o resultado da segmentação com CDC, onde se observa uma excelente diferenciação das texturas. A figura 24 apresenta um extrato de cena Landsat 5 TM, 30 m de resolução, bandas 5-4-3 em RGB, na região de Patrocônio MG/Brasil, imageada em 02-09-99 para uma aplicação em agricultura e reflorestamento. As figura 25 e 26 mostram os resultados da segmentação desta imagem utilizando os métodos SEGWIN e CDC, respectivamente.




Figura 16 - CDC invariância (FD 3.465) em transformações afins e reflexão de cores.




Figura 17 - CDC invariância (FD 3.465) em resolução




Figura 18 – CDC invariância (FD 3.465) em possíveis associações de bandas para os canais RGB (4-5-6, 40-6-5, 5-4-6, 5-6-4, 6-4-5, 6-5-4.)




Figura 19 – Mosaico de texturas naturais e resultado da segmentação com CDC

9 CONCLUSÕES

Não existe nenhum método único de segmentação que seja capaz de segmentar todos os tipos de imagens. As técnicas de segmentação atualmente existentes são variadas e especificamente desenvolvidas para uma determinada finalidade. Talvez a característica mais importante de um método de segmentação seja a definição do que é uma região semelhante. Esta definição irá conduzir todo o processo e produzirá diferentes resultados para diferentes propósitos. Duas informações relevantes estão presentes numa região: sua cor e textura. A segmentação apenas baseada na cor é a forma mais simples. Já a segmentação por textura é extremamente complexa.

Dentre os métodos para análise de texturas, a dimensão fractal se apresenta como uma área nova e promissora, pois, através da estimativa da dimensão fractal de regiões é possível identificar e classificar texturas com grande simplicidade e eficiência. Todavia, as técnicas de dimensão fractal existentes limitam-se a estimativa da dimensão fractal de imagens binárias e em escala de cinza. O método **CDC** estende os conceitos expostos pelos outros métodos fractais, permitindo estimar a dimensão fractal de imagens de qualquer dimensão. Experimentos demonstraram que CDC mantém a DF para diferentes combinações de bandas, transformações afins, e inversões da textura. Para testar as possibilidades do método CDC, amostras de texturas de imagens complexas foram realizadas e foram comparados seus resultados com os de outros métodos.

10 REFERÊNCIAS

- [1] Castleman, K., R., 1996 “Digital Image Processing, 1ed., Prentice Hall Inc, New Jersey.
- [2] Claro, Luis Otávio Thopson. “Textura de imagens utilizando conceitos de morfologia matemática”. Dissertação de mestrado do CPERSM.
- [3] Conci, A. and Campos, C.F.J., 1996, “An Efficient Box-Counting Fractal Dimension Approach for Experimental Image Variation Characterization”, Proc. IWISP, Manchester, 665-668.
- [4] A. Conci and E. O. Nunes “Multi-bands image analysis using local fractal dimension”, proceedings of SIBGRAPI Brazilian Symp. On Comp. Graphics, Image Proc. And Vision, 91-99, 2001.




Figura 20 – Mosaico de texturas de teste




Figura 21 - Segmentação usando SEGWIN.




Figura 22 - Resultado da segmentação com SPRING




Figura 23 – Resultado da segmentação com CDC

[5] Conci, A. and Proenca, C.B., 1998, "A fractal image analysis system for fabric inspection based on a box-counting method, Computer Networks and ISDN Systems, Elsevier Science, 30, Issue 20-21, 1887--1895. <http://www.caa.uff.br/~cproenca/pp.html> e <http://www.caa.uff.br/~aconci>

[6] Daubechies, I.: Orthonormal bases of wavelets with finite support – connection with discrete filters. Springer Verlag, Alemanha, 1988

[7] Daubechies, I.: Orthonormal bases of compactly supported supported wavelets. Communications in Pure and Applied Mathematics, Vol. 41, pp. 909-996, 1988.)

[8] Gonzalez, Rafael C.; Woods, Richard E., 2000. "Processamento de Imagens Digitais". São Paulo: Edgard Blucher.

[9] Haralick, R. M.; Shanmugam, K.; Dinstein It's Hak, 1973. "Textural Features for Imagen Classification. IEEE Trans. On Systems, Man and Cybernetics. Vol SMC-3, N°6, pag. 610-621.

[10] Haralick, R. M., 1979, "Statistical and Structural Approaches to Texture". Proceedings of the IEEE, v. 67, N° 5, pp. 786-803.

[11] McGroga, Nick. Texture segmentation and change detection for urban planning. <http://www.new.ox.ac.uk/~nmcgroga/work/ecsproj4/report.html>.

[12] Mandelbrot, B.B., 1982, "The Fractal Geometry of Nature", San Francisco

- [13] Matheron, G., 1967. "Elements pour une Theorie des Millieux Poreux", Masson.
- [14] Nunes, E.O. and Conci, A., 2001, "Determinação da Dimensão Fractal de Conjuntos de Pontos à Imagens de Satélites", Anais do Applicon, São Carlos, SP.
- [15] Parker, J. R., 1997, Algorithms for Image Processing and Computer Vision, John Wiley & Sons, Toronto.
- [16] Rosenfeld, Azriel; KAK, Avinash C.. *Digital picture processing*. San Diego: Academic Press, 1982.
- [17] Sarkar, N. and Chaudhuri, B. B., 1994, "An efficient differential box-counting approach to compute fractal Dimension of Image", IEEE Trans. on Systems. Man and Cyber., 24, No.1, 115--120.
- [18] Sklansky, J., 1978, "Image Segmentation and Feature Extraction". IEEE Transactions on Systems, Man, and Cybernetics, vol. 13, N° 5, PP. 907-916.
- [19] Sonka, Milan; Hlavac, Vaclav; Boyle, Roger. Image Processing, Analysis and Machine Vision. London: Chapman & Hall, 1993.
- [20] Wangenheim, Aldo von <http://www.inf.ufsc.br/~awangenh> acessado em 30 Maio de 2003.



Figura 24 – Imagem Landsat-7 TM .



Figura 25 - Resultado da segmentação com SEGWIN.




Figura 26 - Resultado da segmentação com CDC.