

# Segmentação por Textura e Localização do Contorno de Regiões em Imagens Multibandas

E.O.Nunes and A. Conci, UFF

**Abstract** — Many texture classification schemes require an excessively large image area for texture analysis, use a large number of features to represent each texture or are computationally very demanding. This paper presents a segmentation method considering all image bands information that can be used on natural or synthetic texture and on soft or rough motifs. It permits also distinction of different textures with few changes on the same type of patterns. The approach uses a proposed coefficient: CVE; to estimate region limits that can be used for very small to very large regions and permits correct real time texture boulder classification. The space positions among the pixels on the texel are considered. The bands or color information are combined considering they mean value and its standard deviation. This scheme can be used of all type of texture because the rules of what will be identified are completely given by the used and adapted to each situation.

**Index Terms** — Edge Detection, Image Segmentation, Multiband Images, Pattern Recognition, Texture.

## I. INTRODUÇÃO

A segmentação visa a identificação e separação de objetos em uma imagem [1]. Um cuidado considerável deve ser despendido nesta etapa, pois, uma segmentação eficiente praticamente garante o sucesso no reconhecimento [2].

Após a segmentação, os pixels normalmente são representados e descritos em um formato apropriado para o processamento subsequente. A representação de uma região pode ser feita considerando suas características externas (seu contorno) ou suas características internas (os pixels que compõe a região) [2]. Uma representação externa normalmente ocorre quando as características de forma são mais relevantes. E uma representação interna quando forem mais importantes propriedades como cor e textura [3].

A detecção do contorno permite definir propriedades como perímetro e forma do objeto em uma representação concisa, mas não é de simples determinação, devido a grande variação de condições de iluminação das imagens reais [4]. A segmentação por textura é um assunto que ainda necessita de muitas pesquisa. Diversos métodos de segmentação baseados neste conceito têm sido propostos [5], [6], [7].

Entretanto, nenhum método sozinho é capaz de segmentar

eficientemente todos os tipos de imagens [7]. Os diversos algoritmos de segmentação existentes foram desenvolvidos visando uma determinada aplicação. Um método que permita segmentar regiões baseadas em todas as bandas de informação, disponíveis na imagem, e localizar o contorno das regiões destas texturas considerando suas complexidades, de forma precisa e completa, sem considerar as feições que não são do interesse para extração é de grande interesse para diversas áreas de aplicação que usam imagens multibandas (como as de satélite, médicas ou coloridas) e vem a ser a proposta inovadora deste trabalho.

## II. SEGMENTAÇÃO

A segmentação é uma tarefa básica no processo de análise de imagens, mas não é fácil traduzir para o computador o sofisticado processo de seleção e agrupamento realizado pela visão humana na identificação de regiões semelhantes. Várias dificuldades estão presentes: a complexidade da textura, a irregularidade da iluminação e as imprecisões das regiões das bordas. O problema de segmentação torna-se particularmente difícil devido a textura da imagem. Métodos de agrupamento baseados na cor podem alcançar resultados satisfatórios quando as regiões que se deseja segmentar são homogêneas, porém cenas naturais são complexas pela riqueza de variações tonais e texturas presentes [8].

Talvez a característica mais importante de um método de segmentação seja a definição do que é uma região. Esta pode ser vista como um conjunto de pixels conectados envolvidos por uma borda de pixels criando um contorno ou, ainda, uma região pode ser definida como um conjunto de pixels conectados por meio de uma condição de uniformidade. Na primeira definição, a segmentação é realizada com base na descontinuidade, enquanto na segunda definição, com base na similaridade [2].

### A. Segmentação por Contorno

Os métodos mais usuais de segmentação por descontinuidade são baseados nos contornos. Nestes métodos, um objeto pode ser entendido como uma região dentro de um contorno. Para distinguir os objetos, detectam-se suas bordas e tenta-se construir uma região conectada interior a partir delas. O processo de detecção de bordas consiste na verificação da variação dos valores de luminosidade de uma imagem visando localizar e realçar os pixels de borda, através da ampliação do contraste entre esta e o fundo. Um procedimento básico utilizado na detecção de bordas é a diferenciação da imagem.

---

This work was supported in part by the CNPq under project: 302436/2004-9.

E. O. Nunes – Instituto de Computação - IC, Universidade Federal Fluminense – UFF, Brasil (e-mail: eldman@bol.com.br).

A. Conci – Instituto de Computação - IC, Universidade Federal Fluminense – UFF, Brasil (e-mail: aconci@ic.uff.br).

Sua utilização, entretanto, causa à detecção de bordas relevantes e também irrelevantes. A suavização da imagem antes da diferenciação é empregada para minimizar este efeito indesejável. Contudo, este procedimento pode comprometer a precisão na localização das bordas. Assim, existe uma dualidade entre a precisão na localização das bordas e a sensibilidade aos detalhes irrelevantes da imagem [9].

A formulação de um algoritmo de detecção de bordas que apresente um bom desempenho em diferentes contextos é uma tarefa difícil [10]. Diversos detetores de bordas com diferentes formulações matemáticas tem sido desenvolvidos para diferentes propósitos.

### B. Segmentação por Textura

Dentre as características visuais de uma imagem destacam-se a cor e a textura. Vários trabalhos tem sido realizados na construção de descritores eficientes para estas características [3], [11]. A textura, presente na maioria das imagens naturais, é fundamental na visão humana, pois, contribui na melhoria da exatidão do processo de reconhecimento e classificação de imagens [12]. Porém, seu reconhecimento envolve grande complexidade computacional [13].

A textura é um termo intuitivo e de largo emprego, mas apesar de sua importância, não possui uma definição precisa. Ela refere-se a um padrão visual que possui algumas propriedades de homogeneidade que não resultam simplesmente de uma cor ou intensidade [14]. É uma expressão relacionada com as propriedades que representam a superfície de um objeto. Apesar de não existir uma definição única e precisa, nem uma aproximação matemática formal para a quantificação da textura, as definições existentes associam a textura à impressão de rugosidade e contraste ou a repetição de padrões visuais sobre uma região [2].

## III. ESTRATÉGIA PROPOSTA

### A. O Coeficiente de Variação Espacial

Este trabalho apresenta uma estratégia para quantificar a textura de uma região multibandas. Esta medida é denominada Coeficiente de Variação Espacial (CVE) e está baseado nas medidas de posição e suas variações ou dispersões [14]. O CVE quantifica a característica de textura através de medidas estatísticas que descrevem as variações espaciais de intensidade ou cor. Duas medidas são empregadas: uma medida de posição (média) e uma medida de dispersão (desvio padrão) dos pixels pertencentes à região da imagem.

As medidas de posição constituem uma forma mais sintética de apresentar os resultados contidos nos dados observados, pois representam um valor central, em torno do qual os dados se concentram. Mas, a utilização de uma medida de posição para substituir um conjunto de dados é insuficiente para sintetizar a informação nele contida, portanto, para sintetizarmos eficientemente a informação de um conjunto de dados é necessário associar uma medida de posição a uma medida de dispersão, que vai informar como estes dados se comportam em torno da medida de posição empregada.

Para obter um único número que represente a dispersão dos dados pode-se usar a variância ou o desvio padrão que é uma medida quantitativa da dispersão de um conjunto de dados ao redor da sua média. Sendo a variância calculada a partir dos quadrados dos desvios, sua unidade é o quadrado da unidade da variável em análise, o que sob o ponto de vista prático é inconveniente. O desvio padrão, definido em (1), evita esse inconveniente, pois é definido como a raiz quadrada da variância.

$$dp = \sqrt{\frac{\sum_{i=1}^n x_i^2}{n} - \left(\frac{\sum_{i=1}^n x_i}{n}\right)^2} \quad (1)$$

As avaliações de textura calculadas apenas com base em seu histograma sofrem a limitação por não carregarem informação sobre a posição relativa dos pixels em relação uns aos outros [2]. Isto porque a textura além da tonalidade dos pixels se caracteriza pelos relacionamentos espaciais entre eles. Assim, o cálculo do CVE leva em consideração não apenas a distribuição de intensidades, mas também sua distribuição espacial pelas classes de distâncias.

O primeiro passo no cálculo do CVE é determinar o conjunto de dados de cada classe de distâncias considerando a métrica D4 (também conhecida como métrica Manhattan, cityblock ou quarteirão) de cada pixel ao centro. Para exemplificar o cálculo, considere a Fig. 1 que ilustra uma região de 7x7 pixels com seus níveis de intensidade.

85	70	86	92	60	102	202
91	81	98	113	86	119	189
96	86	102	107	74	107	194
101	91	113	107	83	118	198
99	68	107	107	76	108	194
107	94	93	115	83	115	198
94	98	98	107	81	115	194

Fig. 1. Região de 7x7 pixels para cálculo do CVE

A Fig. 1 representa com as mesmas cores os pixels com mesma distância D4 de cada pixel em relação ao pixel central, calculadas por meio de (2). Para este textons de 7x7, existem seis grupos de pixels, correspondendo às seis diferentes distâncias possíveis.

$$D_4(p, q) = |x - s| + |y - t| \quad (2)$$

A Fig. 2 representa as classes em função da distância máxima. A classe seguinte engloba os valores das classes anteriores (classe<sub>n</sub> = conjunto de pixels com D4 ≤ n).

85	70	86	92	60	102	202
91	81	98	113	86	119	189
96	86	102	107	74	107	194
101	91	113	107	83	118	198
99	68	107	107	76	108	194
107	94	93	115	83	115	198
94	98	98	107	81	115	194

85	70	86	92	60	102	202
91	81	98	113	86	119	189
96	86	102	107	74	107	194
101	91	113	107	83	118	198
99	68	107	107	76	108	194
107	94	93	115	83	115	198
94	98	98	107	81	115	194

85	70	86	92	60	102	202
91	81	98	113	86	119	189
96	86	102	107	74	107	194
101	91	113	107	83	118	198
99	68	107	107	76	108	194
107	94	93	115	83	115	198
94	98	98	107	81	115	194

Fig. 2. Seis grupos de pixels correspondentes às classes de distâncias.

O segundo passo consiste em obter a média e o coeficiente de variação para cada classe de distâncias. Em seguida, as medidas de posição e de dispersão são combinadas através de (3), cujo valor único (CVE, da classe) preserva a informação de ambas as medidas obtidas.

$$CVE = \text{Arco tan} \left( \frac{md}{dp+1} \right) \times \sqrt{md^2 + (dp+1)^2} \quad (3)$$

Onde  $md$  é a média das intensidades dos valores e  $dp$  seu desvio padrão como dado em (1). Finalmente, a média e o desvio padrão dos CVE de cada classe são novamente combinados por (3) resultando no CVE da região de textura. A Tabela I apresenta a média, o coeficiente de variação e o CVE para os dados da Fig. 1.

TABELA I  
DADOS PARA CÁLCULO DO CVE

Classe distancia	$md$	$dp+1$	CVE	$md$ CVE	$dp+1$ CVE	CVE Textura
1	102,500	12,522	149,651	142,754	4,791	219, 572
2	100,500	15,880	143,878			
3	101,375	25,327	138,552			
4	104,167	31,938	138,729			
5	107,273	35,226	141,532			
6	110,313	38,712	144,182			

O CVE é calculado para os canais RGB ou cada banda em análise considerando cada amostra. Em seguida é realizada a clusterização das amostras e os centróides das classes são calculados por meio do algoritmo Kmeans [15]. Finalmente, os valores dos centróides (CVE para os canais RGB) são utilizados na classificação do restante da imagem, Fig.3.

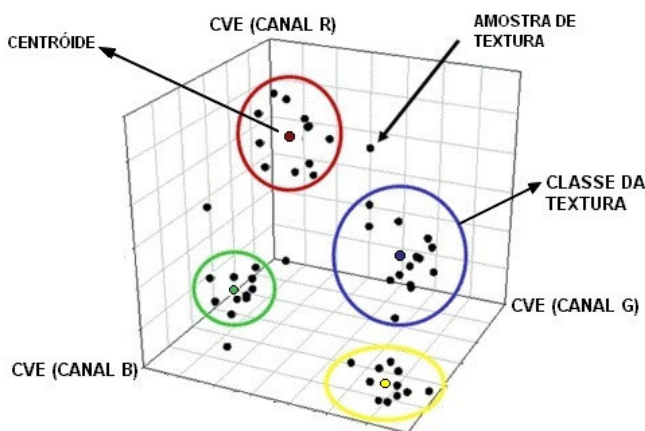


Fig. 3. Clusterização das amostras

A fim de permitir uma diferenciação do CVE de uma mesma amostra para diferentes combinações de suas bandas, o valor da intensidade do pixel em um determinado canal (R, G ou B) é substituído por um novo valor resultante da aplicação de (3) considerando os outros canais, conforme Tabela II.

TABELA II  
CÁLCULO DOS NOVOS VALORES DE INTENSIDADE

Canal	R	G	B
Intensidade	144	175	223
$a$	175	223	144
$b$	223	144	175
$x = \sqrt{a^2 + (b+1)^2}$	284,255	265,996	227,403
$y = \text{Arco tan}(a/(b+1))$	0,663	0,994	0,686
$c$	144	175	223
$d = x \times y$	188,519	264,470	155,937
$x = \sqrt{c^2 + (d+1)^2}$	238,020	317,961	272,687
$y = \text{Arco tan}(c/(d+1))$	0,650	0,583	0,958
Intensidade = $x \times y$	154,655	185,315	261,113

#### IV. TESTES EM IMAGENS SINTÉTICAS

Esta seção apresenta diversos testes realizados com a finalidade de observar o desempenho da metodologia proposta. Foram realizados testes teóricos, testes com imagens construídas sinteticamente, testes com texturas naturais, testes com imagens reais obtidas por imagens médicas e satélites. Estes testes foram projetados para examinar as características de desempenho do coeficiente de textura desenvolvido (CVE) e sua aplicabilidade em diversas situações. Pode ocorrer que devido a resolução disponível de impressão as texturas não apareçam com toda a sua riqueza de detalhes, por isto estas imagens estão disponíveis também em <http://www.ic.uff.br/~aconci/pub2006>.

##### A. Variância à Ordem de Combinação de Bandas

A Fig. 4 apresenta uma imagem sintética composta por texturas de quatro cores (marrom, rosa, azul e verde). Este padrão é usado para gerar uma imagem sintética também originada de variações do padrão, usando os bitmaps correspondentes com diversas combinações de bandas.



Fig. 4. Padrão

A ordem em que os bitmaps são usados no vídeo é atribuída sempre ao mesmo canal de cores, isto é o primeiro para o canal vermelho, o segundo para o verde e o terceiro para o azul. Deste modo, se elas não forem idênticas, resultam em sensações de cores diferentes aos olhos humanos ao serem enviadas em outra ordem. Se o modelo de identificação de cores da textura usado considerar apenas o conteúdo das bandas, as cores embora vistas diferentes por humanos são identificadas como as mesmas em um sistema de identificação automático [16].

Este teste foi projetado para mostrar como o CVE se comporta quanto à aparência das cores. Assim todas as possíveis ordens de associação são testadas gerando os padrões mostrados na Fig. 5a. O resultado do teste de

variância à combinação de bandas pode ser observado na Fig. 5b. Verifica-se que as diferentes combinações de bandas afetaram o reconhecimento da distribuição de classes de cor presentes na imagem.

Para cada uma das quatro texturas originais da Fig. 4 foram selecionadas 50 amostras que serviram de conjunto de treinamento para definição dos centróides de cada classe. Para identificação de cada classe, na Fig. 5b, a classe da textura marrom recebeu a cor laranja, a classe da textura rosa a cor vermelha, a classe da textura azul passa a ser representada pela cor azul clara (ou ciano) e a classe da textura verde pela cor amarela. Verifica-se que o CVE leva em consideração não apenas o atributo de textura da região, mas também seu atributo de cor apropriadamente, podendo ser adequado a percepção humana e não apenas considerando as bandas em separado.




Fig. 5. a) Combinação das bandas (RGB-RBG-GRB GBR - BRG - BGR); b) Imagem segmentada resultante para identificação das classes.

### B. Mosaico de Texturas Naturais

A Fig. 6. apresenta um mosaico sintético de texturas reais extraídas de imagens de satélite (Landsat -7 TM). Este mosaico foi construído com a finalidade de verificar o desempenho do método na presença de outras texturas com cores e padrões bem similares. A Fig. 6a apresenta o contorno localizado para cada classe em mosaicos de diferentes texturas extraídas: solo, vegetação, madeira e papel.

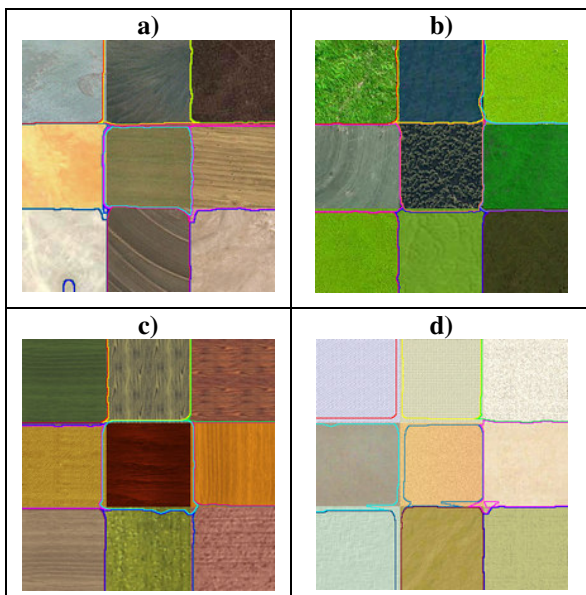


Fig. 6. Localização do contorno: a) Amostras de solo; b) Amostras de vegetação; c) Amostras de madeira; d) Amostras de papel.

A complexidade das texturas originais pode ser observada em <http://www.ic.uff.br/~aconci/pub2006> ou deduzida por uma observação cuidadosa do interior das figuras onde os contornos foram detectados. Cada textura que compõe os mosaicos possui 100x100 pixels e demonstram a complexidade de variação tonal existente. Foram selecionadas 100 amostras com janela de dimensão 11x11 pixels para cada uma das nove texturas de cada mosaico.

## V. APLICAÇÕES EM IMAGENS REAIS

Esta seção ilustra diversas aplicações possíveis com a utilização da técnica proposta neste trabalho envolvendo diferentes tipos de imagens: imagens monocromáticas, imagens coloridas, imagens médicas e imagens de satélite. Embora o conjunto de testes da seção anterior seja mais complexo estes envolvem situações reais onde a segmentação é utilizada em comparações com outros modelos.

### A. Imagens Monocromáticas

A Fig. 7a. apresenta uma imagem monocromática (480x192 pixels) com letras formadas por segmentos de linhas diagonais. Esta imagem é usada como exemplo pelo grupo JSEG (Segmentation of color-texture regions in images and vídeo) e se encontra disponível com os resultados obtidos por este sistema no site do projeto [17], [18].

A Fig. 7b. mostra o resultado obtido com a implementação do CVE. Para este teste foram selecionadas 100 amostras com janela de dimensão 7x7 pixels para classe “letras”. Um filtro de mediana com janela 3x3 foi aplicado ao resultado da segmentação. Observando o contorno localizado, repara-se que este resultado apresenta boa definição dos limites das letras. A Fig. 7c. apresenta o resultado do grupo JSEG e a figura 7d. o resultado alcançado através do programa **VISD** (Variational Image Segmentation demo) disponível em [19].




Fig. 7. a) Imagem Monocromática; b) Localização do contorno com CVE; c) Localização do contorno com JSEG; d) Localização do contorno com VISD

### B. Imagens Coloridas

A Fig. 8a. apresenta a imagem Mandril colorida com 512x512 pixels também usada em [17]. Ela apresenta diferentes texturas complexas e muitas nuances de cores. O Resultado obtido pelo coeficiente aqui proposto pode ser visto na Fig. 8b. Foram selecionadas 100 amostras com janela de dimensão 7x7 pixels para seis classes de textura: pele preta – contorno roxo; pelo e olhos amarelos – contorno amarelo; pele azul – contorno azul escuro; pele vermelha – contorno vinho;

pelo amarelo/preto – contorno verde claro; pelo branco – contorno azul claro. Um filtro de mediana com janela 3x3 foi aplicado ao resultado da segmentação resultando numa imagem com boa definição dos limites das classes. As Fig. 8c. e 8d. apresentam o resultado obtido pelo grupo JSEG [18] e VISD [19], respectivamente.




Fig. 8. a) Imagem colorida ; b) Localização do contorno com CVE; c) Localização do contorno com JSEG; d) Localização do contorno com VISD

### C. Imagens Médicas

A Fig. 9a. é uma imagem colorida de um melanoma médio (câncer de pele) com 256x256 pixels. Neste teste de segmentação foram selecionadas 100 amostras com janela de extração com dimensão de 3x3 pixels para identificar a classe de textura do melanoma. A Fig. 9b. apresenta o resultado da segmentação da Fig. 9a. onde verifica-se uma perfeita identificação do melanoma. A Fig. 9c. apresenta o contorno localizado com bordas de espessura de um pixel, resultando numa imagem com boa definição dos limites do melanoma.




Fig. 9. a) Melanoma; b) Segmentação; c) Localização do contorno

### D. Imagens de Satélites

Finalmente mais um teste foi realizado, agora empregando imagens de satélite para verificar o desempenho do método diante de imagens com texturas multiespectrais complexas e de

grande tamanho. A Fig. 10a. apresenta uma imagem de um Parque Nacional brasileiro, próximo a Brasília (512 x 512 pixels) adquirida em: 14/06/1985, pelo Landsat-5 TM Composição colorida: bandas 2/3/5. Utilizada com o propósito de verificar o desempenho do método com este tipo de imagem. Foram selecionadas três classes (água, mata e construção) com 100 amostras de cada classe, com janela de dimensão 11x11 pixels (água e mata); 3x3 pixels (construção). A Fig. 10b. mostra o resultado da segmentação da Figura 10a. e a Fig. 10c. indica a localização do contorno. É possível observar uma correta classificação dos temas e definição dos limites.

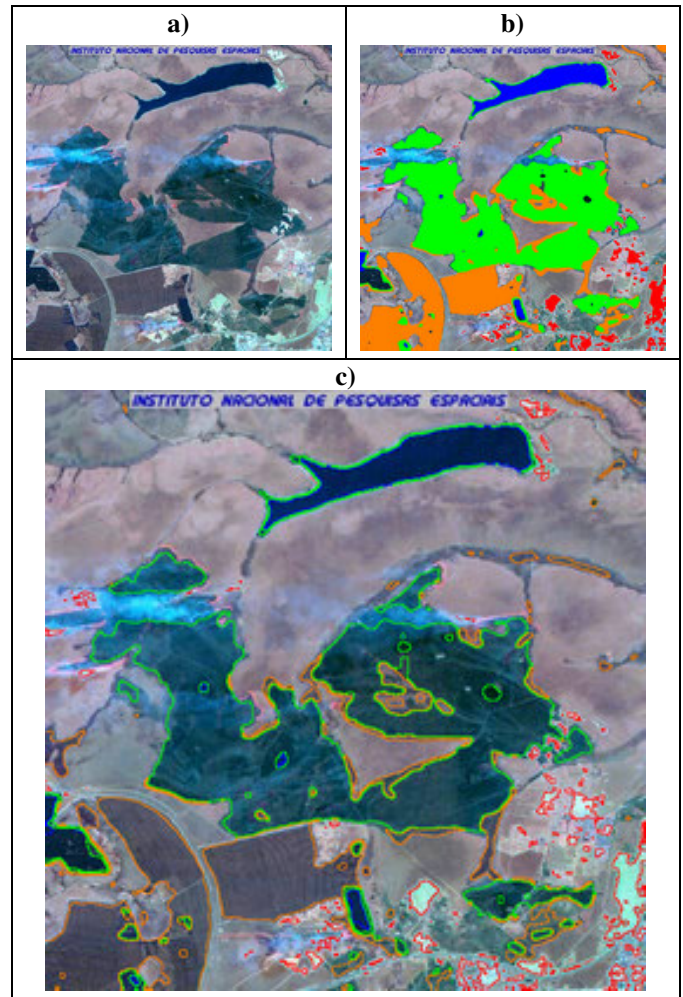


Fig. 10. a) Imagem Landsat; b) Segmentação; c) Localização do contorno.

## VI. CONCLUSÕES

Este trabalho propõe e apresenta os resultados da utilização de um novo coeficiente para caracterizar texturas complexas, representadas pelas equações (1) e (3) e descrito detalhadamente na seção III (Estratégia Proposta). O Coeficiente de Variação Espacial (CVE) proposto apresentou bons resultados na classificação de imagens coloridas permitindo distinguir diferentes classes de texturas, além de localizar o contorno de regiões de interesse, mantendo sua complexidade e localização, sem considerar as feições que não são do interesse para extração.

O CVE foi testado com diferentes tipos de imagens: monocromáticas, coloridas e multiespectrais. Na segmentação de imagens com texturas similares, na identificação de cores ligadas a forma como o ser humano percebe cores, na identificação de regiões bem pequenas e muito grandes.

Podemos afirmar, pelos testes realizados, que o CVE constitui-se numa ferramenta útil para segmentação e localização de contornos de regiões com texturas multibandas. Estas podem ser visualizadas na forma de composições coloridas de três bandas associadas aos canais Red, Green e Blue. Tais composições, capazes de sintetizar numa única imagem uma grande quantidade de informação, facilitam a interpretação dos objetos através da representação dessa informação em diferentes cores e o método proposto soube aproveitar estas características. Mas o método não se limita a apenas três bandas, podendo futuramente ampliar o número de bandas consideradas e aumentar em muito as possibilidades de análise ao ser usada toda a gama de informação das imagens capturadas multiespectralmente.

A classificação de imagens multiespectrais por regras definidas pelos centróides do Coeficiente de Variação Espacial, em cada banda espectral, pode ser aplicada nos mais diversos campos do conhecimento, onde a identificação e classificação de regiões em imagens coloridas ou multibandas se fizerem necessárias. Tal possibilidade permite vislumbrar diversas alternativas de trabalhos futuros e uma grande variedade de aplicações.

## VII. AGRADECIMENTOS

O autores agradecem as sugestões para este trabalho dos professores M. Gattass (PUC-RJ) e L. S. Ochi (UFF) na versão original deste documento como tese do primeiro autor.

## VIII. REFERÊNCIAS

- [1] K. S. Deshmukh & Shinde G. N., "An Adaptive Color Image Segmentation", *Electronic Letters on Computer Vision and Image Analysis* 5(4):12-23, 2005.
- [2] R. C. Gonzalez & R. E. Woods, *Processamento de Imagens Digitais*, São Paulo: Edgard Blucher, 2000.
- [3] B. S. Manjunath, J. R. Ohm, V. V. Vinod & A. Yamada, "Color and Texture Descriptors", *IEE Trans. Circuits and Systems for Video Technology*, Special Issue on MPEG-7, vol.11, n°6, pp.703-715, 2001.
- [4] B. Sumengen & B. S. Manjunath, "Multi-scale Edge Detection and Image Segmentation", presented at the European Signal Processing Conference (EUSIPCO), Turkey, 2005.
- [5] K. I. Chang, K. W. Bowyer & M. Sivagurunath, "Evaluation of Texture Segmentation Algorithms", *IEEE Computer Society Conference on Computer Vision and Pattern Recognition* vol. 1, pp. 1294, 1999.
- [6] T. Randen & J. H. Husoy, "Filtering for Texture Classification: A Comparative Study", *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 21(4):291-310, 1999.
- [7] E. O. Nunes & A. Conci, "Técnicas de Descrição Regional Baseadas em Textura", in: *Série Arquimedes*, vol. 2, Eds. J. M. Balthazar, G. N. da Silva, M. Tsuchida, M. Boaventura, L. S. Goes & J. D. S. Silva, 2003
- [8] Y. Deng, B. S. Manjunath & H. Shin, "Color image segmentation", *Proc. IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, Fort Collins, CO, vol.2, pp.446-51, 1999.
- [9] G. M. Do Vale & A. P. Dal Poz, "O Processo de Detecção de Bordas de Canny: Fundamentos, Algoritmos e Avaliação Experimental". In *Proc. 2002. Simpósio Brasileiro de Geomática*, pp. 292-303.

- [10] D. Ziou & S. Tabbone, *Edge Detection Techniques - An Overview*, *International Journal of Pattern Recognition and Image Analysis*, vol. 8, no.4, pp. 537-559, 1998.
- [11] E. O. Nunes & A. Conci, "Segmenting Multi Bands Images by Color and Texture Analysis", in B. Simak & P. Zahradnik, Eds. *Recent Trends in Multimedia Information Processing*, pp. 231-234, 2003.
- [12] Y. Choi, C. S. Won, Y. M. Ro, & B. S. Manjunath, "Texture Descriptors", *Introduction to MPEG-7, Multimedia Content Description Interface*, Eds. B. S. Manjunath, P. Salembier & T. Sikora. John Wiley & Sons, Ltd., 2002.
- [13] J. R. Parker, *Algorithms for Image Processing and Computer Vision*, Toronto: John Wiley & Sons, 1997.
- [14] E. O. Nunes & A. Conci, "O Coeficiente de Hurst e o Coeficiente de Variação Espacial na Segmentação de Texturas Multiespectrais", *Anais do DINCON 2005, 4º Congresso Temático de Aplicações de Dinâmica e Controle da Sociedade Brasileira de Matemática Aplicada e Computacional, Série Arquimedes*, vol. 4, Eds. J. M. Balthazar, G. N. da Silva, M. Tsuchida, M. Boaventura, L. S. Goes & J. D. S. Silva, 2005, pp. 1067-1075.
- [15] R. J. Schalkoff, *Pattern Recognition: Statistical, Structural and Neural Approaches*, New York: John Wiley & Sons, 1992.
- [16] E. O. Nunes & A. Conci, "Texture Segmentation Considering Multi Band, Multi Resolution and Affine Invariant Roughness," *XVI Brazilian Symposium on Computer Graphics and Image Processing (SIBGRAPI'03)*, pp. 254-258, 2003.
- [17] Y. Deng & B. S. Manjunath, "Unsupervised segmentation of color-texture regions in images and video", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 23, pp. 800-810, 2001.
- [18] <http://vision.ece.ucsb.edu/segmentation/jseg/jsegcolor.html>
- [19] <http://aakash.ece.ucsb.edu/imdiffuse/segment.aspx>

## IX. BIOGRAFIA

### Aura Conci

Em 1979 obteve o grau de bacharel em Engenharia Civil pela UFES. Em 1983 e 1988 obteve os graus de Mestre e Doutor respectivamente em Ciências de Engenharia pela PUC-RJ. Ela é professora titular do Departamento de Ciência da Computação da UFF desde 1994. Pesquisadora nível 1 do CNPq. Vem trabalhando em Análise de Imagens, Computação Gráfica e Computação Visual. Sua área de pesquisa concentra-se em aplicações da computação visual, biometria, imagens biomédicas e em recuperação de imagens e vídeo baseado no conteúdo (mais detalhes em <http://ic.uff.br/~aconci>).



### Éldman de Oliveira Nunes

Em 1997 obteve a graduação em Tecnologia em Processamento de Dados pela UNIDERP, Campo Grande - MS; Em 1998 obteve a Especialização em Análise de Sistemas pela Universidade Federal do Mato Grosso do Sul - UFMS, Campo Grande-MS; Em 1999 obteve a Especialização em Análise e Projeto de Sistemas pelo Centro de Estudo de Pessoal - CEP, Rio de Janeiro-RJ; Em 2001 obteve o grau de Mestre em Ciências da Computação pela Universidade Federal Fluminense - UFF, Niterói-RJ; Está concluindo em 2006 o programa de Doutorado em Ciências da Computação pela Universidade Federal Fluminense - UFF.

