

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

E. O. Nunes e A. Conci

Resumo — Muitos esquemas de classificação de textura requerem uma área de imagem excessivamente grande para análise de textura, usam um grande número de características para representar cada textura ou são computacionalmente muito exigentes. Este trabalho apresenta um método de segmentação que pode ser usado em texturas naturais ou sintéticas, suaves ou ásperas, possibilitando a distinção de diferentes texturas com pequenas variações nos mesmos tipos de padrões. A aproximação usa um coeficiente novo, desenvolvido e testado aqui pela primeira vez, denominado CVE. Este coeficiente considera a informação das bandas espectrais, levando em conta qual cor a combinação de bandas gera, bem como as posições espaciais dos pixels no texel. O CVE permite estimar os limites de regiões muito pequenas ou muito grandes, localizando corretamente as bordas da região de interesse em tempo real. Além disso, pode ser usado para todos os tipos de textura porque as regras do que será identificado são fornecidas pelo usuário e adaptadas à cada situação.

Palavras Chave — Detecção de Borda, Segmentação de Imagem, Imagens Multibandas, Reconhecimento de Padrão, Textura.

I. INTRODUÇÃO

A segmentação é uma tarefa fundamental no processamento de imagens e visa a identificação e separação de uma imagem em suas partes constituintes. Na segmentação, a imagem é dividida em regiões com propriedades comuns (intensidade, cor, textura, etc). O nível de subdivisão da imagem depende do objetivo que se pretende alcançar. A segmentação se encerra quando as partes constituintes de interesse forem isoladas, o que requer o conhecimento prévio da natureza da imagem. Assim, a segmentação é um problema orientado à aplicação, pois depende do contexto de interesse.

Traduzir para o computador o processo de seleção e agrupamento realizado pela visão humana na identificação de regiões semelhantes não é uma tarefa fácil. Várias dificuldades estão presentes: a complexidade da textura, a não-homogeneidade da iluminação (sombras próximas à borda), as irregulares e as imprecisões das regiões das bordas, etc. Não existe um modelo formal para a segmentação, o processo é essencialmente empírico e deverá se ajustar a diferentes tipos de imagens. Na análise de imagens, a eficiência obtida na identificação e separação das regiões de interesse influencia os resultados das etapas subseqüentes. Como a segmentação não é um fim em si, sua qualidade é

determinada pela adequação das regiões extraídas aos tratamentos que serão realizados nas próximas etapas.

II. SEGMENTAÇÃO

Uma vez que a segmentação visa particionar uma imagem em regiões com propriedades comuns, normalmente as técnicas de segmentação estão associadas ao conceito de região. Uma região 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 [17].

Sob a perspectiva da descontinuidade, a preocupação volta-se para obtenção de contornos conexos, a fim de que os tratamentos subseqüentes à segmentação possam extrair, a partir da imagem segmentada, propriedades como perímetro e a área das regiões. Sob a perspectiva da similaridade, a preocupação volta-se para redução do número excessivo de sub-regiões não significativas que pode causar a supersegmentação da imagem.

A. Segmentação por Contorno

Os métodos mais usuais de segmentação por descontinuidade são baseados nos contornos. Nesses 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, por meio da ampliação do contraste entre esta e o fundo. Um procedimento básico utilizado na detecção de bordas é a diferenciação da imagem. Sua utilização, entretanto, causa a detecção de bordas relevantes e irrelevantes. A suavização da imagem antes da diferenciação é empregada para minimizar esse efeito indesejável. Contudo, esse 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 [10]. A formulação de um algoritmo de detecção de bordas que apresente um bom desempenho em diferentes contextos é uma tarefa difícil [5]. Diversos detectores de bordas para variados propósitos têm sido desenvolvidos [2].

Este trabalho foi apoiado em parte pelo CNPq : 302436/2004-9.

E. O. Nunes – Instituto de Computação - IC, Universidade Federal Fluminense – UFF, Brasil (e-mail: enunes@ic.uff.br).

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

B. Segmentação por Cor e Textura

Segundo T.Mäenpää & M.Pietikäinen [20], as aproximações atuais para análise de textura colorida podem ser grosseiramente divididas em duas categorias: métodos que processam cor e textura separadamente e métodos que consideram cor e textura associadamente.

A cor é uma resposta subjetiva a um estímulo luminoso que chega na retina. Ela é uma importante característica utilizada pelos seres humanos para reconhecimento e discriminação visual. Vários trabalhos utilizam a cor na segmentação de imagens [1], [6], [14], [24].

A textura é outra importante característica utilizada pela visão humana no processo de reconhecimento e classificação de imagens [22]. Porém, de grande complexidade computacional [13]. Textura é um termo intuitivo muito empregado, mas apesar de sua importância, não possui uma definição precisa; refere-se a um padrão visual que possui algumas propriedades de homogeneidade não só relacionadas a cor ou intensidade. 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. Muitos trabalhos utilizam essa propriedade na segmentação de imagens [3], [4], [7], [15], [21].

III. ESTRATÉGIA PROPOSTA

A. O Coeficiente de Variação Espacial

Este trabalho apresenta uma medida para quantificar a textura de uma região multibandas, denominada Coeficiente de Variação Espacial (CVE) e baseada nas medidas de posição e suas variações ou dispersões [9].

O CVE quantifica a característica de textura por meio de medidas estatísticas que descrevem as variações espaciais de intensidade ou cor. Duas medidas dos pixels pertencentes à região da imagem são empregadas: uma medida de posição (média) e uma medida de dispersão (desvio padrão).

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 esses 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 de uns pixels em relação aos outros. Isso porque a textura além da tonalidade dos pixels se caracteriza pelos relacionamentos espaciais entre eles [17]. Assim, o CVE leva em consideração não apenas a distribuição de intensidades, mas também sua distribuição espacial por meio do uso das classes de distâncias.

O cálculo do CVE inicia com a definição de um conjunto de amostras de treinamento para cada região de interesse. Essas amostras são extraídas da imagem, através de janelas de tamanho $M \times M$ ($3 \times 3, 5 \times 5, \dots, 21 \times 21$), definido pelo usuário. Para cada amostra de tamanho $M \times M$, determina-se o conjunto de intensidades dos pixels por classe de distância e por canal considerado.

A métrica D_4 (também conhecida como métrica Manhattan, cityblock ou quarteirão) foi empregada para calcular a distância de cada pixel ao pixel central da amostra. Para exemplificar o cálculo, considere a Fig. 1, que ilustra uma região de 7×7 pixels com seus níveis de intensidade em cada canal RGB.

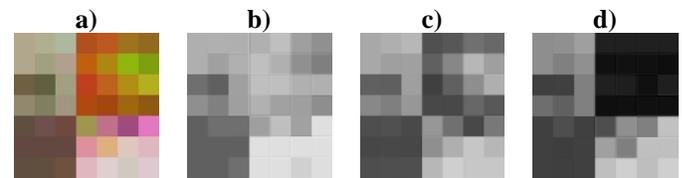


Fig. 1 – Amostra de uma região com 7×7 pixels:
a) Imagem colorida; b) Canal red; c) Canal green; d) Canal blue

Para cada amostra de tamanho $M \times M$, determina-se o conjunto de intensidades dos pixels por classe de distância e por canal considerado. A métrica D_4 (também conhecida como métrica *Manhattan*, *cityblock* ou *quarteirão*) é utilizada para calcular a distância de cada pixel ao pixel central da amostra. A Fig. 2 representa com as mesmas cores os pixels com mesma distância $D_4(p, q)$ de cada pixel $q(s, t)$ em relação ao pixel central $p(x, y)$, calculadas por meio da equação (2).

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

onde x e y são as coordenadas do pixel central e s e t , as coordenadas do pixel considerado.

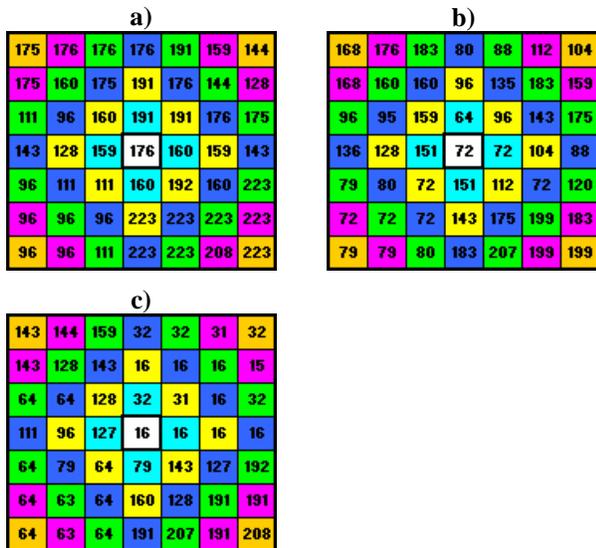


Fig. 2. Classes de distâncias para região de 7x7 pixels da figura 1: a) Canal red; b) Canal green; c) Canal blue

Para a amostra da Fig. 2, existem seis grupos de pixels, correspondentes a seis diferentes distâncias possíveis. A Fig. 3 representa as classes em função da distância máxima, considerando o canal red. A classe seguinte engloba os valores das classes anteriores ($Classe_n =$ conjunto de pixels com $D_4 \leq n$).

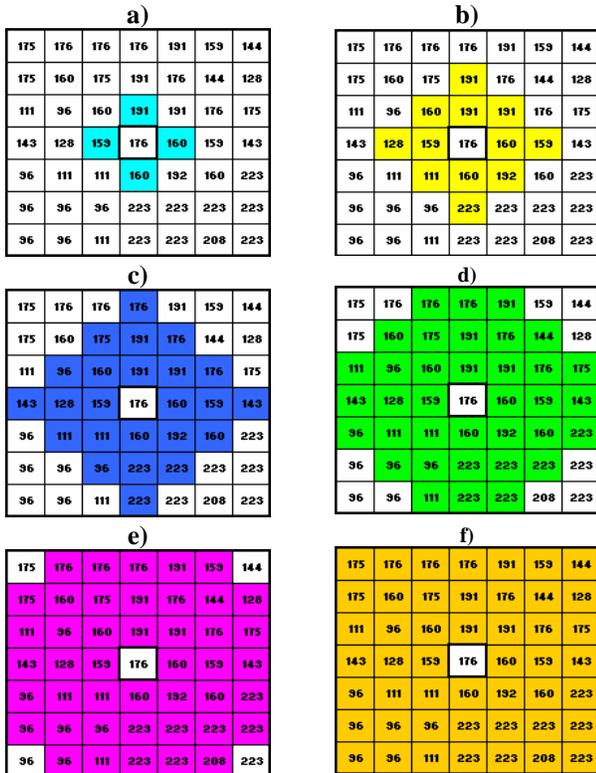


Fig. 3 – Seis grupos de pixels correspondentes às classes de distâncias: a) Distância $D_4 \leq 1$; b) Distância $D_4 \leq 2$; c) Distância $D_4 \leq 3$; d) Distância $D_4 \leq 4$; e) Distância $D_4 \leq 5$; f) Distância $D_4 \leq 6$

Para permitir uma maior caracterização das variações do coeficiente de uma 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 considerando os outros dois canais, conforme Tabela I.

Por exemplo, considerando os dados da Fig. 2, o valor da intensidade do pixel (posição - 0,0 da matriz) no canal R (Fig. 2.a) - 175 será substituído pelo resultado do cálculo considerando-se as intensidades do canal G (Fig. 2.b) - 168 e B (Fig. 2.c) - 143, ou seja, o novo valor será 192,040.

O mesmo procedimento será realizado para todos os pixels das matrizes substituindo-se o valor de suas intensidades. Esse procedimento foi adotado, visando permitir a distinção de texturas resultantes de diferentes combinações da ordem dos canais RGB.

TABELA I
CÁLCULO DOS NOVOS VALORES DE INTENSIDADE

CANAL	R	G	B
$c = Intensidade_Original$	175	168	143
a	168	143	175
b	143	175	168
$x = \sqrt{a^2 + (b+1)^2}$	221,269	226,771	243,282
$y = Arco\ tg(a/(b+1))$	0,862	0,682	0,803
$d = x \times y$	190,772	154,729	195,316
c	154,729	195,316	190,772
d	195,316	190,772	154,729
$x = \sqrt{c^2 + (d+1)^2}$	259,618	229,076	242,876
$y = Arco\ tg(c/(d+1))$	0,740	0,823	0,630
$Nova_Intensidade = x \times y$	192,040	188,594	152,902

Em seguida, a média e o desvio padrão para cada conjunto de pixels, por classe de distância, são calculados. O CVE de cada classe de distância é obtido combinando-se a média e o desvio padrão de cada conjunto por meio de (3), cujo valor único (CVE da classe) preserva a informação de ambas as medidas combinadas.

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

onde md é a média das intensidades dos valores e dp seu desvio padrão.

Então, a média ($md_{CVE} = 142,754$) e o desvio padrão ($dp+1 = 4,791$) de todos os CVE são calculados e estes valores são combinados por (3), resultando no CVE da amostra da região de interesse ($CVE_{Canal\ Red} = 219,572$), conforme Tabela II.

TABELA II
DADOS PARA CÁLCULO DO CVE (FIG. 2A)

Classe distancia	md	$dp+1$	CVE
1	102,500	12,522	149,651
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
	md_{CVE}		142,754
	$dp+1$		4,791
	$CVE_{Canal\ Red}$		219,572

O CVE de uma amostra de textura é calculado para os canais RGB ou quantos canais estiverem sendo considerados na análise. O valor do CVE em cada canal define uma coordenada do espaço euclidiano para a amostra considerada. Assim, uma amostra com os canais RGB possuirá uma coordenada ($CVE_{RED}, CVE_{GREEN}, CVE_{BLUE}$), caracterizando um ponto no espaço tridimensional, fig.3. Então, as amostras do conjunto de treinamento são agrupadas por meio do algoritmo de clusterização K-means.

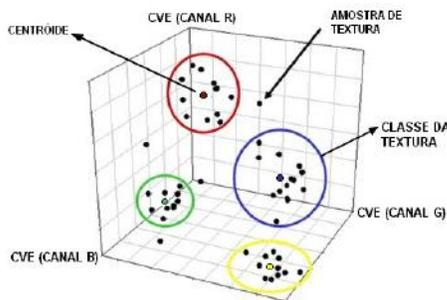


Fig. 3. Clusterização das amostras

O algoritmo *K-means* é um método de partição baseado em recolocação que necessita da definição a priori do número de agrupamentos k [18]. O critério de custo a ser minimizado é definido em função da distância das amostras em relação aos centros dos agrupamentos (centróide).

Usualmente, esse critério é a soma residual dos quadrados das distâncias. Nesse caso, a distância euclidiana é empregada. Entende-se por soma residual dos quadrados, a soma dos quadrados das distâncias dos elementos ao centróide do seu cluster. Quanto menor for esse valor, mais homogêneos serão os objetos dentro de cada grupo e melhor será a partição. O elemento representativo de um cluster é o seu centróide, que possui um valor médio para os CVE considerados em cada canal, relativo a todas as amostras do cluster. A partir de uma estimativa inicial das coordenadas dos centróides, o algoritmo calcula a distância de cada amostra do conjunto de treinamento a esses centróides.

A seguir, aloca cada amostra do conjunto de treinamento em um grupo, de acordo com a menor distância ao centróide correspondente. A nova estimativa das coordenadas dos centróides é calculada pela média aritmética das coordenadas das amostras associadas a cada grupo. Finalmente, as coordenadas dos centróides de cada cluster, que correspondem

a cada classe de interesse, são utilizadas na classificação do restante da imagem.

IV. EXPERIMENTOS

Esta seção apresenta diversos testes realizados com a finalidade de observar o desempenho da metodologia proposta. Pode ocorrer que devido à resolução disponível de impressão, as texturas não apareçam com toda a sua riqueza de detalhes, por isso estas imagens estão disponíveis também em: <http://www.ic.uff.br/~aconci/pub2006.html>

A. Variância à Ordem de Combinação de Bandas

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

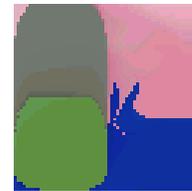


Fig. 4. Padrão

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. Desse modo, se elas não forem idênticas, resultarão 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, serão identificadas como as mesmas em um sistema de identificação automático [8].

Esse 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 à percepção humana, e não apenas considerando as bandas em separado.

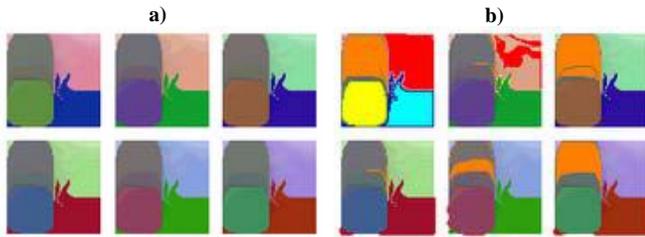


Fig. 5. a) Combinação das bandas (RGB-RBG-GRB GBR - BRG - BGR); b) Imagem segmentada resultante para identificação das classes.

B. Mosaico de Texturas Naturais

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

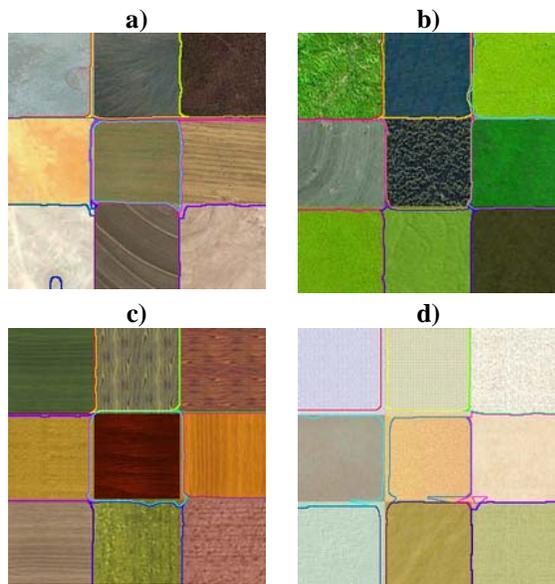


Fig. 6. Localização do contorno: a) Amostras de solo; b) Amostras de vegetação; c) Amostras de madeira; d) Amostras de papel.

Cada textura que compõe os mosaicos possui 100x100 pixels e o conjunto demonstra a complexidade de variação tonal existente. Foram selecionadas 20 amostras com janela de tamanho 11x11 pixels para cada uma das nove texturas de cada mosaico.

C. Imagens Monocromáticas

A Fig. 7a apresenta uma imagem monocromática (480x192 pixels) com letras formadas por segmentos de linhas diagonais. Essa imagem é usada como exemplo pelo grupo JSEG e se encontra disponível no site do grupo [12], [23].

A Fig. 7b mostra o resultado obtido com a implementação do CVE. Para esse teste, foram selecionadas 20 amostras com janela de tamanho 7x7 pixels para classe “letras”. Um filtro de mediana com janela 3x3 pixels foi aplicado ao resultado da segmentação. Observando o contorno localizado, repara-se que esse resultado apresenta boa definição dos limites das letras. A Fig. 7c apresenta o resultado do grupo JSEG e a

figura 7d, o resultado alcançado por intermédio do programa VISD, disponível em [11].

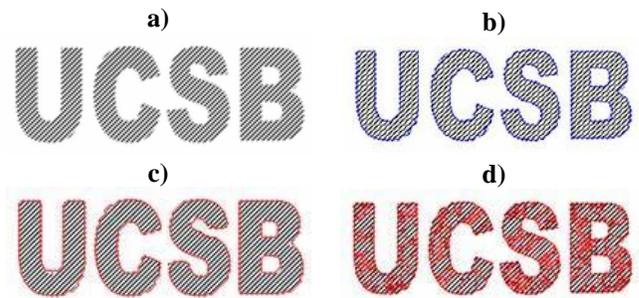


Fig. 7. a) Imagem Monocromática; b) Localização do contorno com CVE; c) Localização do contorno com JSEG; d) Localização do contorno com VISD

A Fig. 8a. apresenta uma imagem monocromática (200x157 pixels) composta pelas texturas de Brodatz D53 (padrão interno) e D49, usada por R. Jenssen e T. Eltoft [19]. Os autores utilizam o método ICA (*Independent Component Analysis*) para criar banco de filtros para segmentação de texturas. Segundo os autores, os filtros ICA são semelhantes aos filtros Gabor, mas parecem ser mais precisos porque alguns filtros têm respostas de frequência mais complexas.

A fig. 8b apresenta a segmentação da imagem da figura 8a. com 20 filtros do banco ICA [19], alcançando uma porcentagem de erro de 3,5%. A curva sólida branca marca o verdadeiro limite entre os dois padrões de textura.

A Fig. 8c mostra o resultado obtido com o método CVE. Para esse teste, foram selecionadas 30 amostras de cada classe de textura, através de uma janela de tamanho 11x11 pixels. Um filtro de mediana, com janela de tamanho de 7x7 pixels, foi aplicado ao resultado da segmentação.

A Fig. 8d apresenta a sobreposição do contorno obtido com a segmentação usando o método CVE (curva azul e vermelha – um para cada classe) com o contorno verdadeiro entre as duas classes de textura (curva sólida branca).

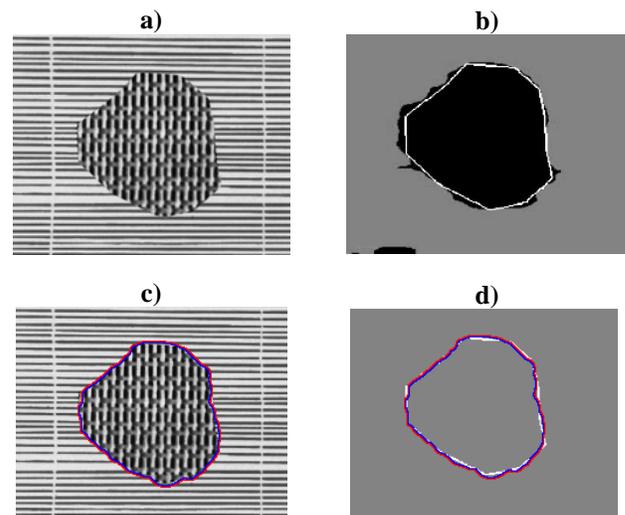


Fig. 8. a) Imagem composta por texturas de Brodatz D53 (padrão interno) e D49; b) Segmentação com ICA (cor preta) e contorno real (cor branca); c) Contorno localizado com CVE; d) Contorno com CVE (colorido) sobreposto ao contorno real (cor branca).

A Fig. 9a apresenta uma imagem monocromática (305x310 pixels) constituída por três regiões de texturas de Brodatz (D55 - Fundo, D77 - polígono e D84 - quadrado) usada por Lei Wang & Jun Liu [16]. Os autores apresentam o modelo MRMRF (*Multi Resolution Markov Random Fields*) com estimação do parâmetro MRMRF baseado em aproximação de MCMC (*Markov Chain Monte Carlo*) para segmentação de textura.

A Fig. 9b mostra o resultado obtido com o modelo MRMRF. A aproximação proposta tem a vantagem de não requerer treinamento para segmentação das texturas (método não supervisionado). Porém, a aplicação do método MCMC para estimação de parâmetro MRMRF possui elevado custo computacional.

A Fig. 9c apresenta a segmentação da imagem da Fig.9a. utilizando o método CVE. Para esse teste, foram selecionadas 30 amostras de cada classe de textura, através de uma janela de tamanho 11x11 pixels. Um filtro de mediana, com janela de tamanho de 9x9 pixels, foi aplicado ao resultado da segmentação. O contorno localizado pelo método proposto pode ser observado na Fig. 9d.

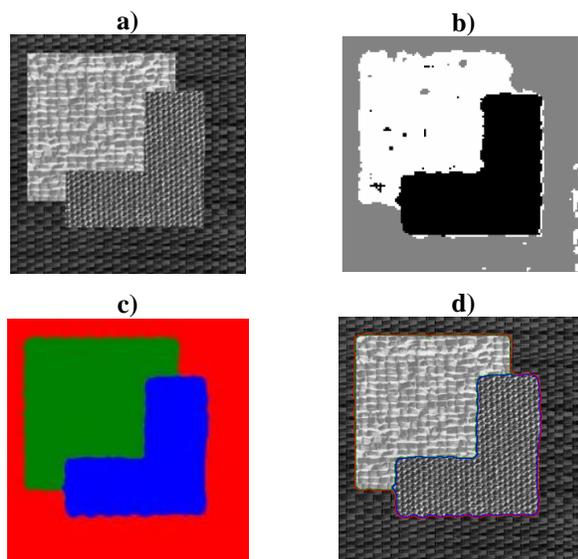


Fig. 9. Mosaico de três regiões de texturas de Brodatz (D55 - Fundo, D77 - polígono e D84 - quadrado); (b) Segmentação baseada em MRMRF; (c) Segmentação com CVE; (d) Contorno localizado com CVE (colorido).

D. Imagens Coloridas

A Fig. 10a apresenta a imagem Mandril colorida com 512x512 pixels, também usada em [23]. Ela apresenta diferentes texturas complexas e muita nuance de cores.

O resultado obtido pelo método proposto pode ser visto na Fig. 10b. Foram selecionadas 100 amostras com janela de tamanho 7x7 pixels para seis classes de textura: pele preta – contorno roxo; pêlo e olhos amarelos – contorno amarelo; pele azul – contorno azul escuro; pele vermelha – contorno vinho; pêlo amarelo/preto – contorno verde claro; pêlo branco – contorno azul claro. Um filtro de mediana com janela de 3x3 pixels foi aplicado ao resultado da segmentação resultando numa imagem com boa definição dos limites das classes. As Fig. 10c e 10d apresentam o resultado obtido pelos grupos JSEG [11] e VISD [12], respectivamente.

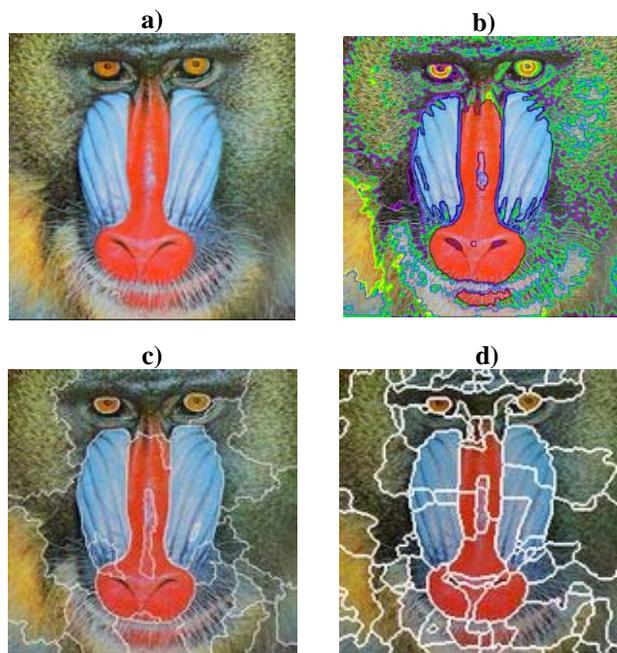


Fig. 10. a) Imagem colorida ; b) Localização do contorno com CVE; c) Localização do contorno com JSEG; d) Localização do contorno com VISD

E. Imagens Médicas

A Fig. 11a. é uma imagem colorida de um melanoma médio (câncer de pele) com 256x256 pixels. Neste teste de segmentação, foram selecionadas 30 amostras com janela de extração com dimensão de 3x3 pixels para identificar a classe de textura do melanoma. A Fig. 11b. apresenta o resultado da segmentação da Fig. 11a., na qual se verifica uma perfeita identificação do melanoma. A Fig. 11c. mostra o contorno localizado com bordas de espessura de um pixel, resultando numa imagem com boa definição dos limites do melanoma.

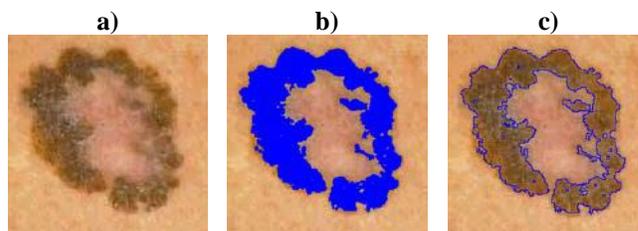


Fig. 11. a) Melanoma; b) Segmentação; c) Localização do contorno

F. Imagens de Satélites

A última série de testes emprega imagens de satélite para verificar o desempenho do método diante de imagens com texturas multiespectrais complexas e de grande tamanho.

A Fig. 12a apresenta uma imagem de um parque nacional brasileiro, próximo a Brasília (DF) (512 x 512 pixels), adquirida em 14/06/1985, pelo Landsat-5 TM, composição colorida: bandas 2/3/5. Foram selecionadas quatro classes (água, mata, terra arada e região urbana) com 100 amostras de cada classe, com janela de tamanho 3x3 pixels. A Fig. 12b mostra o resultado da segmentação da Figura 12a e a Fig. 12c indica a localização do contorno. É possível observar uma correta classificação dos temas e boa definição dos limites.

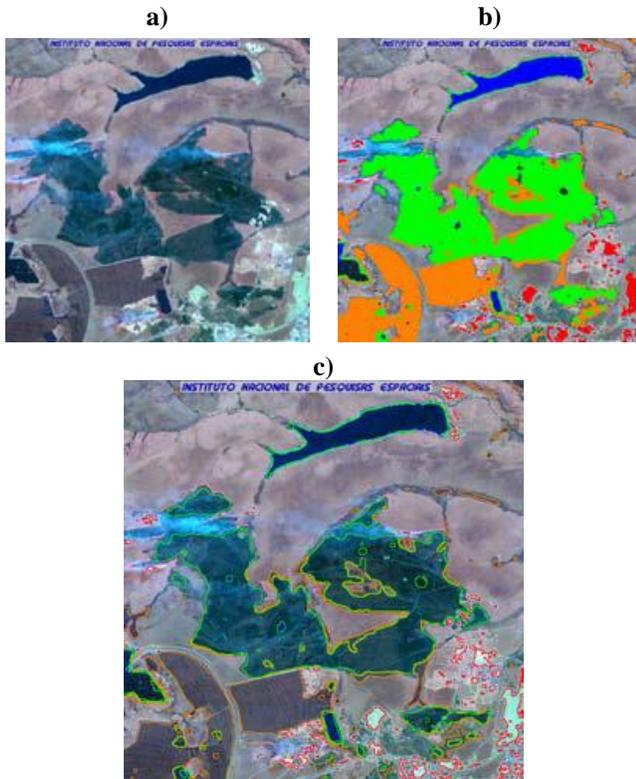


Fig. 12. a) Imagem Landsat; b) Imagem segmentada; c) Contorno.

V. CONCLUSÕES

Este trabalho propõe e apresenta os resultados da utilização de um novo coeficiente para caracterizar texturas, representado pela equação (3) e descrito detalhadamente na seção III (Estratégia Proposta). Este coeficiente, CVE, quantifica a característica de textura por intermédio de medidas estatísticas que descrevem as variações espaciais de intensidade ou cor. O coeficiente proposto é calculado com base em uma medida de posição (média) e uma medida de dispersão (desvio padrão) dos pixels pertencentes à região da imagem. As amostras do conjunto de treinamento são agrupadas utilizando-se o algoritmo de clusterização *K-Means* e as coordenadas dos centróides dos agrupamentos são utilizadas para classificação da imagem.

O CVE foi testado com diferentes tipos de imagens: monocromáticas, coloridas e multiespectrais. Os testes realizados com imagens monocromáticas permitiram verificar que o número de canais utilizados influencia no desempenho do método. Em imagens monocromáticas (que possuem apenas um canal), a equalização dos níveis de intensidade dos pixels degrada o resultado da segmentação. A ausência de outros canais de informação pode ser solucionada com a diferenciação dos níveis de luminância nas imagens consideradas. Os testes realizados com texturas coloridas complexas exigiram janelas de extração de amostras com tamanhos maiores. A extração de amostras com tamanhos menores que o padrão (*texton*) prejudicou os resultados da segmentação. Texturas com muita variedade de cores e intensidades possuem grande variância interna, o que aumentou a possibilidade de confusão entre classes diferentes de texturas.

O método proposto tem a vantagem de poder ser usado para diversos tipos de textura porque as regras relativas ao que será identificado são completamente determinadas pelo usuário e adaptadas a cada situação. Além disso, devido à sua simplicidade de implementação, o custo computacional é bastante satisfatório. O método desenvolvido 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.

Para verificar a aplicabilidade do coeficiente proposto, foram feitas diversas comparações com outros resultados disponíveis na literatura, bem como, foram elaborados testes variados visando verificar os limites de eficiência e versatilidade do método, tanto em imagens monocromáticas como multibandas. Os resultados obtidos permitiram distinguir diferentes classes de texturas, além de localizar o contorno de regiões de interesse, mantendo sua complexidade e localização. 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, em que 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.

VI. AGRADECIMENTOS

Os autores agradecem as críticas dos revisores anônimos, principalmente quanto aos experimentos e comparações relacionadas às novas indicações de referências bibliográficas, bem como as sugestões para este trabalho dos professores M. Gattass (PUC-RJ) e L. S. Ochi (UFF) na sua versão como tese do primeiro autor.

VII. REFERÊNCIAS

- [1] B.S. Manjunath, J.R.Ohm, V. V. Vinod & A. Yamada, "Color and Texture Descriptors", IEEE Trans. Circuits and Systems for Video Technology, nº especial em MPEG-7, v.11, nº6, pp. 703-715, 2001.
- [2] B. Sumengen & B.S.Manjunath, "Multi-scale Edge Detection and Image Segmentation", European Signal Processing Conference (EUSIPCO), Antalya, Turkey, 2005. Disponível em http://vision.ece.ucsb.edu/publications/view_abstract.cgi?207
- [3] C.C. Reyes-Aldasoro and A.Bhalerao. The Bhattacharyya space for feature selection and its application to texture segmentation, Pattern Recognition, v. 39, nº 5, May 2006, pp. 812-826
- [4] C. Collet and F. Murtagh. Multiband segmentation based on a hierarchical Markov model, PR(37), nº 12, pp. 2337-2347, 2004.
- [5] D. Ziou & S.Tabbone, "Edge Detection Techniques - An Overview", International Journal of Pattern Recognition and Image Analysis, v. 8, nº 4, pp. 537-559, 1998.
- [6] E.O. Nunes & A.Conci, "Segmenting Multi Bands Images by Color and Texture Analysis", in: Recent Trends in Multimedia Information Processing, Eds. B. Simak & P. Zahradnik, pp. 231-234, 2003.
- [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] 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.
- [9] 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, Eds. J.M.Balthazar, G.N. da Silva, M.Tsuchida, M.. Boaventura, L.S.Goes & J.D.S. Silva, v. 4, pp. 1067-1075, 2005.
- [10] 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, 2002.
- [11] <http://aakash.ece.ucsb.edu/imdiffuse/segment.aspx>.
- [12] <http://vision.ece.ucsb.edu/segmentation/jseg/jsegcolor.html>
- [13] J.R. Parker, Algorithms for Image Processing and Computer Vision, Toronto: John Wiley & Sons, 1997.
- [14] K.S. Deshmukh & G.N.Shinde, "An Adaptive Color Image Segmentation", Electronic Letters on Computer Vision and Image Analysis, v. 5, n° 4, pp.12-23, 2005.
- [15] Kyong I.Chang, K.W.Bowyer & M.Sivagurunath, "Evaluation of Texture Segmentation Algorithms", IEEE Computer Society Conference on Computer Vision and Pattern Recognition, v. 1, pp. 294-299, 1999.
- [16] Lei Wang & Jun Liu, "Texture Segmentation Based on MRMR Modeling", Pattern Recognition Letters, v. 21, n° 2, pp. 189-200, 2000.
- [17] R.C. Gonzalez & R. E. Woods, Processamento de Imagens Digitais, São Paulo: Edgard Blucher, 2000.
- [18] R.J. Schalkoff, Pattern Recognition: Statistical, Structural and Neural Approaches, New York: John Wiley & Sons, 1992.
- [19] R. Jenssen & T.Eltoft, "Independent Component Analysis for Texture Segmentation", Pattern Recognition, v. 36, n° 10, pp. 2301-2315, 2003.
- [20] T. Mäenpää & M.Pietikäinen, "Classification with Color and Texture: Jointly or Separately?", Pattern Recognition, v. 37, n° 8, pp. 1629-1640, 2004.
- [21] T. Randen & J.H.Husoy, "Filtering for Texture Classification: A Comparative Study", IEEE Trans. on Pattern Analysis and Machine Intelligence, v. 21, n° 4, pp. 291-310, 1999.
- [22] 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.
- [23] Yining Deng & B.S.Manjunath, "Unsupervised Segmentation of Color-texture Regions in Images and Video", IEEE Transactions on Pattern Analysis and Machine Intelligence, v. 23, n° 8, pp. 800-810, 2001.
- [24] Yining Deng, B. S. Manjunath & H. Shin, "Color image segmentation", Proc. IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'99), Fort Collins, CO, v.2, pp.446-451, 1999.

VIII. BIOGRAFIAS



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. Em agosto de 2006, concluiu o programa de Doutorado em Ciências da Computação pela Universidade Federal Fluminense – UFF.



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. Professora titular do Departamento de Ciência da Computação da UFF desde 1994 e pesquisadora 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 (mais detalhes em <http://www.ic.uff.br/~aconci>).