

Detecção de bordas em dados hiperespectrais utilizando a medida de coerência espectral

Marco Antonio Pizarro¹
David Fernandes²

¹Instituto Nacional de Pesquisas Espaciais - INPE
Caixa Postal 515 - 12227-010 - São José dos Campos - SP, Brasil
pizarro@dea.inpe.br

²Instituto Tecnológico de Aeronáutica
Caixa Postal 515 - 12227-010 - São José dos Campos - SP, Brasil
david@ita.br

Abstract. Edge operators are widely used on grey-level images but they are not completely explored on hyperspectral images, whose pixels are vectors in the spectral space. This work presents an edge detector filter based in the spatial uniformity measure of a pixel neighborhood. In the first step the similarity of the spectra in the pixel neighborhood is estimated by the normalized cross-correlation between the central pixel, take as reference, and the others pixels. If the number of the pixels that have a high cross-correlation with the central pixel is less than a given threshold the central pixel is assumed as a border pixel. The proposed border filter is compared with another method that applies locally a modified Laplacian operator in the spectral angle measurement between the central pixel and their neighborhood pixels. The same modified Laplacian operator is also applied in the Spatial Uniformity Index that take into account the number of the pixels in a neighborhood that can be considered high correlated with the central pixel. The results of the tree borders detector are tested on AVIRIS hyperspectral imagery near of Campo Grande/MS. The test area includes agricultural activities of pasture and some large fields of seasonal crops (e.g., corn and soybean). The natural vegetation cover is composed of small plots of woodland savanna.

Palavras-chave: edge detector, edge detector in hyperspectral images, detector de bordas, detector de bordas em imagens hiperespectrais.

1. Introdução e Motivação

A detecção de bordas desempenha um papel importante no processamento de imagem e na análise de sistemas imageadores. O sucesso na detecção de bordas pode ter um grande impacto sobre os resultados subsequentes de processamento de imagem, por exemplo, segmentação da região, a detecção de objetos, e pode ser usado em uma ampla gama de aplicações, de processamento de imagem e vídeo para análises de imagens multi e hiperespectral.

Detecção de bordas em imagens em escala de cinza tem sido amplamente estudada e está bem estabelecida, como exemplo cita-se o filtro de Sobel (Lyvers e Mitchell, 1988). Nas imagens hiperespectrais este tema é muito menos desenvolvido e a detecção de bordas é um grande desafio (Koschan e Abidi, 2005). Além disso, filtros para imagens de uma única banda não podem ser aplicados diretamente em imagens multibandas, na qual o valor do *pixel* é substituído por um vetor (Luo e Zhong, 2009).

Em relação às técnicas de vetores (Evans e Liu, 2006; Trahanias e Venetsanopoulos, 1993) trata cada *pixel* na imagem hiperespectral como um vetor no domínio espectral, em seguida, executa a detecção de borda neste domínio. Esta abordagem é mais eficiente por não sofrer com a variabilidade de localização do resultado da borda em função da banda individual.

As estatísticas aplicadas nas classes de alvos podem ser indevidamente influenciadas por valores extremos, que podem ser prevenidas garantindo que os *pixels* utilizados para classificação supervisionada são obtidos a partir de áreas homogêneas, ou seja, aquelas áreas que dá uma baixa resposta à borda para o operador.

Muitos operadores de borda originaram-se de medidas de homogeneidade de regiões das imagens, regiões estas utilizadas para a determinação de, por exemplo, membros de referência (*endmembers*) para modelos de mistura espectral e de processos de classificação das imagens. A detecção de bordas baseia-se na detecção de variações locais que correspondem essencialmente aos limites de objetos homogêneos na imagem. A borda também é conhecida como descontinuidade e em um sinal é geralmente definida como uma transição na intensidade ou na amplitude desse sinal, sendo considerado um bom detector de bordas aquele processo que produz linhas contínuas e finas onde as bordas existem (Evans e Liu, 2006).

A questão central da detecção de bordas em imagens multiespectrais é como integrar as informações de contraste contidas nas várias bandas para que se obtenham resultados significativos na detecção. Por sua vez os contrastes têm a sua origem nas informações espectrais e que podem ser altamente correlacionadas em algumas partes das imagens e não correlacionadas em outras partes. Assim é interessante que o detector de bordas leve em conta a redundância espectral dos espectros dos *pixels* para aumentar a robustez do processo de detecção das bordas (Drewniok, 1994).

O trabalho realizado é uma alternativa ao trabalho desenvolvido pelo Bakker e Schmidt (2002) que utiliza a informação espectral relativa dos pixels em uma vizinhança 3×3 *pixels* e o operador Laplaciano para discriminar bordas. Na alternativa apresentada propõem-se dois critérios de decisão entre borda e área homogênea um deles considerando a vizinhança 3×3 *pixels* e o operador Laplaciano e outra aplicável em uma vizinhança qualquer de $(M + 1) \times (M + 1)$ *pixels*, com M par.

2. Processo de detecção de bordas

2.1 – Uniformidade Espacial

Cada *pixel* na imagem hiperespectral pode ser representado pelo vetor espectro N -dimensional, onde cada elemento do vetor corresponde a uma banda do espectro óptico. O espectro associado ao *pixel* (i_k, j_k) , $1 \leq k \leq K$, será representada por

$$\bar{I}(i, j) = [I(i, j, 1) I(i, j, 2) I(i, j, 3) \dots I(i, j, N)]^T \quad (1)$$

O conjunto de espectros pertencentes à vizinhança $(M + 1) \times (M + 1)$, com M ímpar, centrada no *pixel* (i_k, j_k) será denotado por

$$\Omega_k = \left\{ \begin{array}{l} \bar{I}(p, q) = [I(p, q, 1), I(p, q, 2), \dots, I(p, q, N)]^T \\ | \quad i_k - M/2 \leq p \leq i_k + M/2, \quad j_k - M/2 \leq q \leq j_k + M/2 \end{array} \right\} \quad (2)$$

Para testar a homogeneidade do conjunto de espectros em Ω_k é escolhido como espectro de referência o vetor espectro do *pixel* central dado por $\bar{\bar{I}}_k = \bar{I}(i_k, j_k)$. Escolheu-se ainda a medida de coerência espectral (Pizarro e David, 2005) para se testar a uniformidade espacial entre os espectros do conjunto Ω_k e o espectro de referência. Se o número de espectros considerados bem correlacionados com o espectro de referência for maior ou igual a M_u , com $0 \leq M_u \leq M^2$, o conjunto Ω_k é então considerado como tendo uma uniformidade espacial e, portanto o *pixel* central não pertence à linha de fronteira ou borda. O fator M_u será chamado de limiar de uniformidade espacial. Qualquer espectro é considerado bem correlacionado com o espectro de referência se a coerência espectral entre esse espectro e o espectro de referência for maior que determinado limiar ψ_e , $0 \leq \psi_e \leq 1$, chamado de limiar de seleção espacial.

A coerência espectral (CE) ou coeficiente de correlação entre um espectro qualquer de Ω_k , dado por $\vec{I}(p, q)$, $i_k - M/2 \leq p \leq i_k + M/2$, $j_k - M/2 \leq q \leq j_k + M/2$, e o espectro de referência $\vec{I}_k = \vec{I}(i_k, j_k)$ é definida por

$$CE(\vec{I}_k, \vec{I}(p, q)) = \frac{\langle \vec{I}_k - \bar{\vec{I}}_k, \vec{I}(p, q) - \bar{\vec{I}}(p, q) \rangle}{\| \vec{I}_k - \bar{\vec{I}}_k \| \| \vec{I}(p, q) - \bar{\vec{I}}(p, q) \|} \quad (3)$$

onde $\langle \cdot, \cdot \rangle$ é o produto interno, $\| \cdot \| = \sqrt{\langle \cdot, \cdot \rangle}$ é a norma Euclidiana, $\bar{\vec{I}}_k$ e $\bar{\vec{I}}(p, q)$ são vetores constantes, cujas componentes são o valor médio do espectro

$$\bar{\vec{I}}_k = \frac{1}{N} \sum_{n=1}^N \vec{I}_k [1, 1, \dots, 1]^T \text{ e } \bar{\vec{I}}(p, q) = \frac{1}{N} \sum_{n=1}^N I(p, q, n) [1, 1, \dots, 1]^T \quad (4)$$

Uma nova vizinhança do *pixel* (i_k, j_k) contendo espectros com uniformidade espacial pode então ser definida pelo conjunto de vetores espectros:

$$V(i_k, j_k) = \left\{ \vec{I}(p, q), \text{ tal que } CE(\vec{I}_k, \vec{I}(p, q)) \geq \psi_e, \right. \\ \left. \text{com } i_k - M/2 \leq p \leq i_k + M/2, \quad j_k - M/2 \leq q \leq j_k + M/2 \right\} \quad (5)$$

Uma amostra espectral $k, 1 \leq k \leq K$, é considerada na linha de borda se a cardinalidade $\#V(i_k, j_k)$, do conjunto $V(i_k, j_k)$, for igual ou menor que o limiar de uniformidade espacial dado por M_u , onde $0 \leq M_u \leq M^2$. Assim os *pixels* da imagem considerados na borda podem então ser agrupados no conjunto

$$\Omega_B = \{ \vec{I}(i_{k_e}, j_{k_e}), \quad k_e = 1, 2, \dots, K_E \mid \#V(i_{k_e}, j_{k_e}) \leq M_u \} \quad (6)$$

onde K_E é o número de *pixels* na borda.

2.2 – Operador de Borda

Outro operador também baseado na medida da uniformidade espacial para a vizinhança $(M+1) \times (M+1) = 3 \times 3$ *pixels* é proposto por Bakker e Schmidt (2002). Neste método os espectros da vizinhança do *pixel* (i_k, j_k) são comparados com o espectro do *pixel* central $\vec{I}(i_k, j_k)$ utilizando-se três medidas: Ângulo Espectral (SA – *Spectral Angle*); Distância Euclidiana (DE) e Diferença de Intensidade (DI). A medida SA é definida como o arco coseno da coerência espectral da expressão (3), a DE é a norma da diferença entre dois vetores espectrais e a DI é a diferença da norma de dois vetores espectrais.

Na comparação realizada utilizou-se somente a medida SA, representada por $SA(\vec{I}_k, \vec{I}(p, q)) = \arccos[CE(\vec{I}_k, \vec{I}(p, q))]$, com os índices $1 \leq k \leq K$, $i_k - M/2 \leq p \leq i_k + M/2$ e $j_k - M/2 \leq q \leq j_k + M/2$. A medida da uniformidade espacial é feita pela média ponderada dos

valores de $SA(\vec{I}_k, \vec{I}(p, q))$ utilizando-se a seguinte matriz de ponderação $\begin{bmatrix} -1 & -2 & -1 \\ -2 & 12 & -2 \\ -1 & -2 & -1 \end{bmatrix}$, que é

uma versão modificada de um operador Laplaciano. Deste modo o operador de borda fica:

$$O(i_k, j_k) = \frac{1}{12} \left[SA(\bar{I}_k, \bar{I}(i_k - 1, j_k - 1)) + 2SA(\bar{I}_k, \bar{I}(i_k, j_k - 1)) + SA(\bar{I}_k, \bar{I}(i_k + 1, j_k - 1)) + 2SA(\bar{I}_k, \bar{I}(i_k - 1, j_k)) \right. \\ \left. + 2SA(\bar{I}_k, \bar{I}(i_k + 1, j_k)) + SA(\bar{I}_k, \bar{I}(i_k - 1, j_k + 1)) + 2SA(\bar{I}_k, \bar{I}(i_k, j_k + 1)) + SA(\bar{I}_k, \bar{I}(i_k + 1, j_k + 1)) \right] \quad (7)$$

Um *pixel* será considerado como borda se o valor do operador de borda for maior que o limiar M_b . Esse limiar é calculado a partir do histograma dos valores do operador de borda para todos os *pixels* da imagem, de modo que para um dado valor de incerteza e_b definido a priori tem-se

$$e_b = \sum_{i=M_b}^{\infty} H_O(i) \Delta_O \quad (8)$$

onde $H_O(i)$ é o i -ésimo valor do histograma do operador borda e Δ_O é o passo do histograma.

Aplicou-se também o operador Laplaciano modificado proposto por Bakker e Schmidt (2002) no índice de uniformidade espacial definido como

$$U(i_k, j_k) = \#V(i_{k_e}, j_{k_e}) / M^2 \quad (9)$$

Neste caso um *pixel* será considerado como borda se o valor do índice de uniformidade for maior que o limiar M_c . Esse limiar também é calculado a partir do histograma dos valores do índice de uniformidade para todos os *pixels* da imagem, de modo que para um dado valor de incerteza e_c definido a priori tem-se

$$e_c = \sum_{r=M_c}^{\infty} H_U(r) \Delta_U \quad (10)$$

onde $H_U(i)$ é o i -ésimo valor do histograma do índice de uniformidade espacial e Δ_U é o passo do histograma.

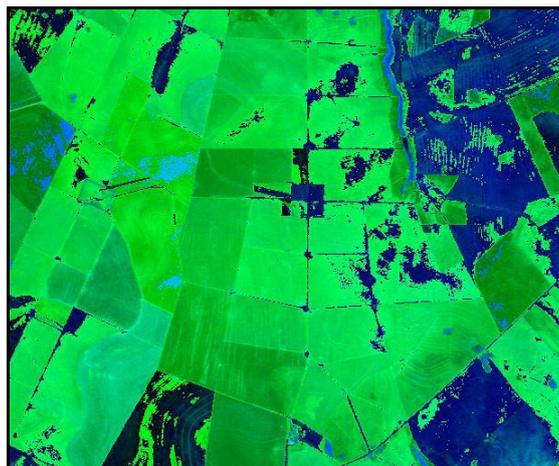
3. Resultados e Discussão

3.1 – Descrição da área teste

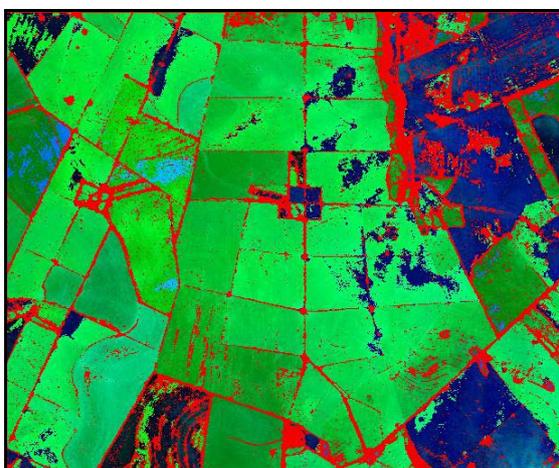
O método de detecção de bordas é aplicado no conjunto de dados hiperespectrais obtidos pelo sensor AVIRIS da área de estudo próxima à cidade de Campo Grande, MS, e nas coordenadas 19°55'S e 53°30'W. A área é dominada pela presença de Inceptisols (Areia Quartzosa) e Oxisols (Latosolo Vermelho-Escuro) que representa uma transição química de baixo para médios teores de ferro, óxidos de titânio e fração argila. Também, é caracterizada por atividades agrícolas como pasto e alguns talhões de colheitas sazonais (por exemplo, milho e soja). A cobertura de vegetação natural está composta de pequenos bosques de cerrado (Pizarro, 1999). Os detalhes sobre a correção atmosférica aplicada na subcena podem ser encontrados em Pizarro (1999), onde do total original de 224 bandas foram suprimidas as bandas iniciais de 1 a 8 e as finais de 218 a 224 totalizando 209 bandas para os processamentos.

3.2 - Detecção de bordas

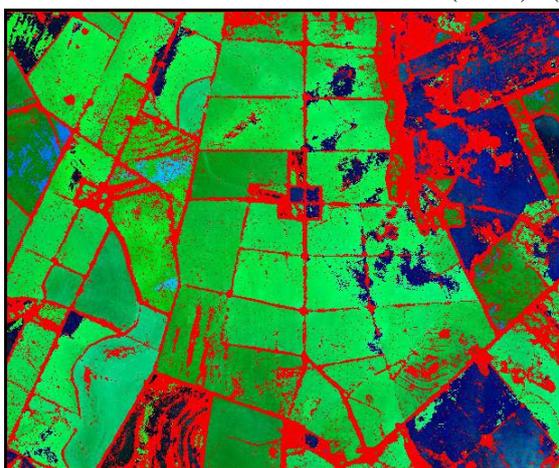
A Figura 1 mostra a cena teste em tons de verde (banda 193) e azul (banda 100) e em vermelho a detecção de bordas pelo método proposta na Seção 2.1 para dois valores diferentes do limiar de uniformidade espacial M_u .



a) Cena teste na composição banda 193 (verde) e banda 100 (azul).



b) Bordas para $(M + 1) \times (M + 1) = 5 \times 5$, $\psi_e = 0,997$ e $M_u = 13$.



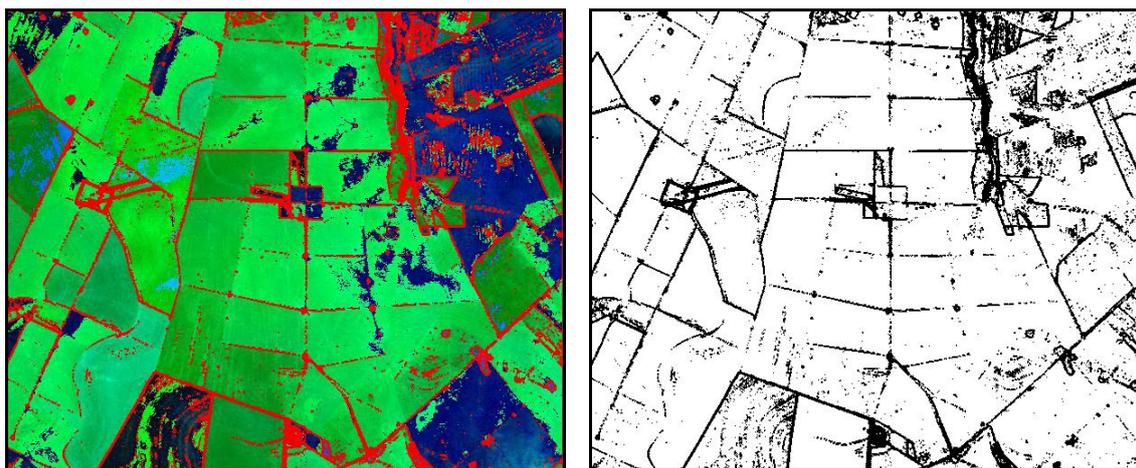
c) Bordas para $(M + 1) \times (M + 1) = 5 \times 5$, $\psi_e = 0,997$ e $M_u = 17$.

Figura 1. Imagem de referência e bordas detectadas.

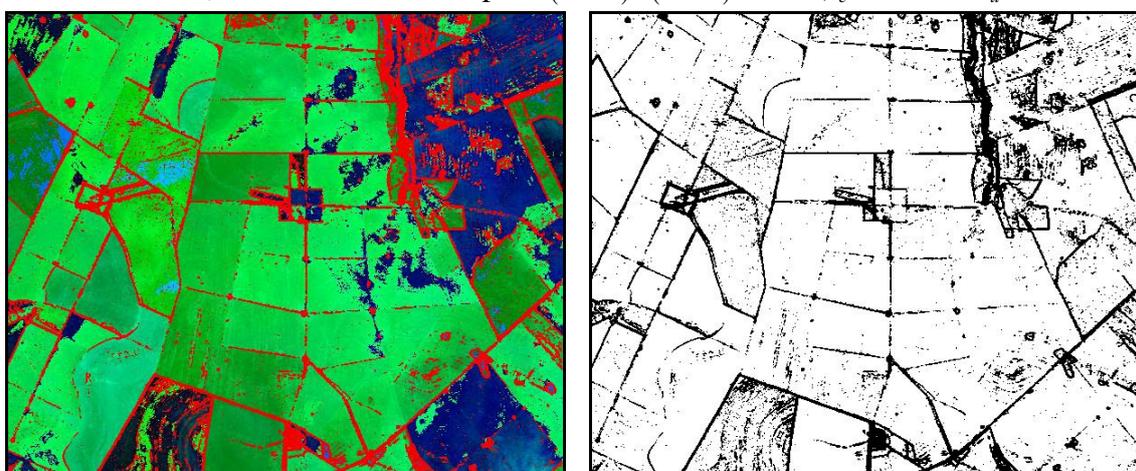
Neste resultado foi considerado uma vizinhança de 5×5 pixels, o limiar de seleção espacial $\psi_e = 0,997$ com os limiares de uniformidade espacial $M_u = 13$ e $M_u = 17$. Quanto maior os limiares ψ_e e M_u maior a restrição para que a vizinhança de $(M + 1) \times (M + 1)$ pixels seja considerada uniforme e, portanto menor a restrição para que esta mesma vizinhança seja

considerada uma borda. Este fato pode ser observado nas Figuras 1b e 1c, pois quanto maior o limiar M_u maior o número de bordas detectadas.

A Figura 2 mostra as bordas detectadas pelo método proposto considerando-se uma vizinhança de 3×3 pixels, para $\psi_e = 0,993$ e $M_u = 8$ e o método desenvolvido por Bakker e Schmidt (2002), com um valor de incerteza $e_b = 0,13$. Observa-se que com os parâmetros escolhidos ambos os métodos produzem resultados equivalentes. Chama-se a atenção para que o método de Bakker e Schmidt (2002) foi desenvolvido somente para vizinhanças 3×3 pixels.



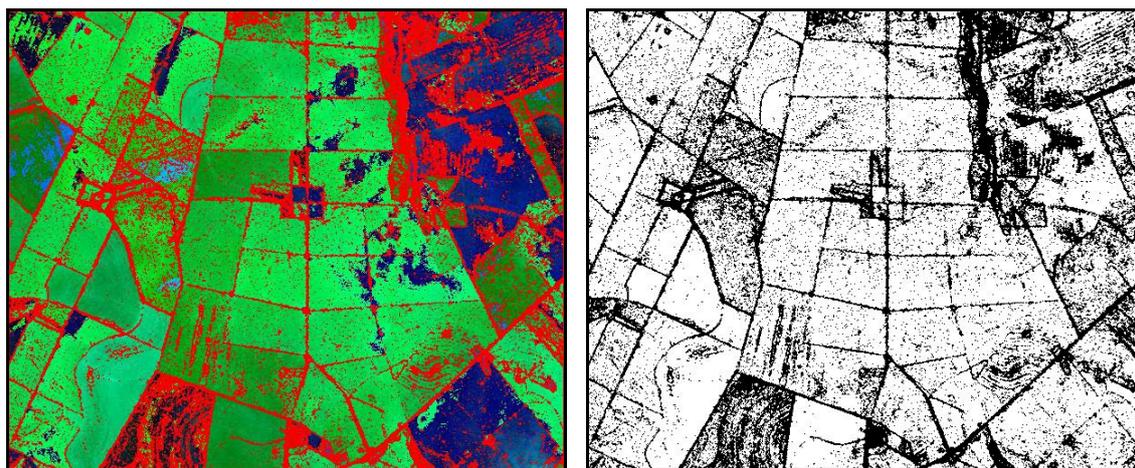
a) Bordas detectadas para $(M + 1) \times (M + 1) = 3 \times 3$, $\psi_e = 0,993$ e $M_u = 8$.



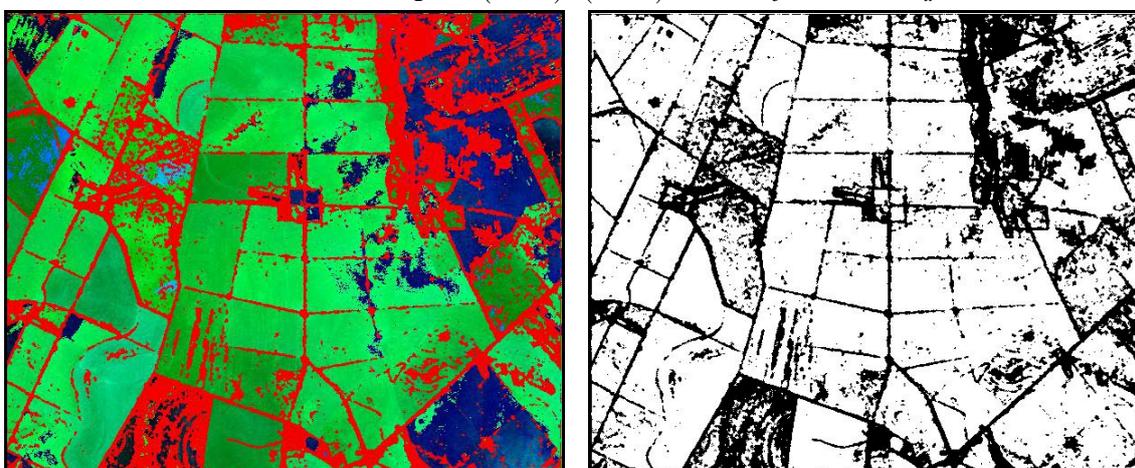
b) Bordas detectadas pelo filtro de bordas para $(M + 1) \times (M + 1) = 3 \times 3$, $e_b = 0,13$.

Figura 2. Comparação do método proposto com o filtro proposto por Bakker e Schmidt(2002).

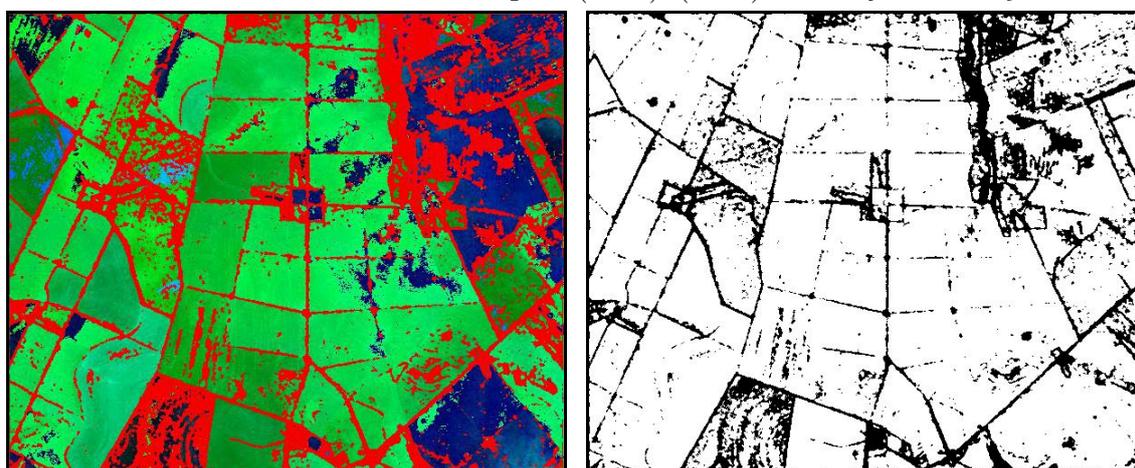
A seguir mostra-se o resultado da aplicação do filtro de bordas proposto por Bakker e Schmidt (2002) no índice de uniformidade expresso por (9). Na Figura 3a mostram-se as bordas detectadas pelo método da Seção 2.1 para $(M + 1) \times (M + 1) = 3 \times 3$, $\psi_e = 0,998$ e $M_u = 6$, nas Figuras 3b e 3c mostram-se os resultados do índice de uniformidade para $\psi_e = 0,998$, calculado por (9) ponderado pelo operador Laplaciano modificado para as incertezas $e_c = 0,25$ e $0,15$, respectivamente. Nota-se que Laplaciano modificado aplicado ao índice de uniformidade melhora a detecção de bordas eliminando o surgimento de pixels isolados no centro das regiões delimitadas por bordas.



a) Bordas para $(M + 1) \times (M + 1) = 3 \times 3$, $\psi_e = 0,998$ e $M_u = 6$.



b) Índice de uniformidade filtrado para $(M + 1) \times (M + 1) = 3 \times 3$, $\psi_e = 0,998$ e $e_c = 0,25$.



c) Índice de uniformidade filtrado para $(M + 1) \times (M + 1) = 3 \times 3$, $\psi_e = 0,998$ e $e_c = 0,15$.

Figura 3. Operador Laplaciano modificado aplicado ao índice de uniformidade.

4. Comentários Finais

Propuseram-se duas metodologias para a detecção de bordas em imagens hiperespectrais. Uma delas é baseada no conceito de uniformidade espacial descrito na Seção 2.1, o outro na aplicação do operador Laplaciano modificado no índice de uniformidade definido pela expressão (9). Compararam-se qualitativamente os métodos propostos com o operador de

borda de Bakker e Schmidt (2002), que foi o que obteve o melhor desempenho dentre aqueles analisados e implementados pelos autores.

Em relação a todos os resultados, levando-se em conta a detecção de falsas bordas ocasionadas pelos detectores de bordas, os dois melhores resultados são apresentados pelas Figuras 1b e 2b, referentes aos métodos propostos.

Bakker e Schmidt (2002) exploraram o uso de diferentes medidas da variabilidade espectral na vizinhança 3×3 considerada, o que afeta o desempenho do detector de bordas. No seu trabalho utilizaram as medidas SA, DE e DI. Neste trabalho não se explorou outras medidas de variabilidade apenas a medida SA para o filtro de bordas de Bakker e Schmidt (2002) e a CE (coerência espectral) para os filtros propostos.

4. Citações e Referências

Bakker, W.H., Schmidt, K.S., 2002. Hyperspectral edge filtering for measuring homogeneity of surface cover types. **ISPRS Journal of Photogrammetry & Remote Sensing**, v. 56, n. 4, 246-256, 2002.

Drewniok, C. Multi-spectral edge detection. Some experiments on data from Landsat-TM. **International Journal of Remote Sensing**, v.15, n.18, 3743–3765, 1994.

Evans, A.; Liu, X.U. A morphological gradient approach to color edge detection. **IEEE Transactions on Image Processing**, v. 15, n. 6, 1454-1463, June, 2006.

Koschan, A., Abidi, M.: Detection and classification of edges in color images. **IEEE Signal Processing Magazine**, Special Issue on Color Image Processing, v. 22, n. 1, 67–73, 2005

Luo, W.; Zhong, L. Spectral Similarity Measure Edge Detection Algorithm in Hyperspectral Image. 2nd **International Congress on Image and Signal Processing**, 2009. CISP '09. 17-19, Oct. 2009, p. 1-4.

Lyvers, E.P., Mitchell, O.R. Precision Edge Contrast and Orientation Estimation. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v.10, n.6, 927-937, 1988.

Pizarro, M.A.; Fernandes, D. Avaliação de métodos de estimativa de coerência espectral para seleção de membros de referência em imagens hiperespectrais. **Revista Brasileira de Cartografia**, v. 57, n. 2, p. 113-120, ago. 2005.

Pizarro, M.A. Sensoriamento remoto hiperespectral para a caracterização e identificação mineral em solos tropicais. jun. 1999. 185 p. (INPE-7249-TDI/693). **Dissertação** (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos. 1999. Disponível na biblioteca digital URLib: <<http://iris.sid.inpe.br:1912/rep-/sid.inpe.br/deise/1999/10.22.17.45>>. Acesso em: 2004, nov. 18.

Trahanias, P., Venetsanopoulos, A.: Color edge detection using vector statistics. **IEEE Transactions on Image Processing**, v.2, n.2, 259–264, 1993.