



## DETECÇÃO DE MUDANÇAS EM IMAGENS MULTITEMPORAIS DE SENSORIAMENTO REMOTO EMPREGANDO SVM COM KERNEL RBF E NOVA MÉTRICA DE PERTINÊNCIA

Neide Pizzolato Angelo<sup>1</sup>

Rute Henrique da Silva Ferreira<sup>2</sup>

### RESUMO

Este artigo investiga uma abordagem para o problema da detecção de mudanças em imagens multitemporais de sensoriamento remoto empregando *Support Vector Machines (SVM)* com o uso do kernel RBF (*Radial Base Function*) aliado a uma nova métrica de pertinência denominada Delta b. A proposta metodológica está baseada na diferença das imagens-fração produzidas para cada data. Em imagens de cenas naturais, a diferença nas frações de solo e vegetação tende a apresentar uma distribuição simétrica em torno da média de seus *pixels*. Este fato pode ser usado para modelar duas distribuições normais multivariadas: mudança e não-mudança. O algoritmo *Expectation-Maximization (EM)* é implementado para estimar os parâmetros (vetor de médias, matriz de covariância e probabilidade *a priori*) associados a estas duas distribuições. Amostras aleatórias são extraídas a partir destas duas distribuições e usadas para treinar um classificador SVM baseado no kernel RBF. A metodologia proposta é testada usando conjuntos de dados multitemporais de imagens multiespectrais Landsat-TM que cobrem a mesma cena, localizada no estado de Roraima, em duas datas diferentes. Amostras de teste são obtidas pelo uso da técnica *Change Vector Analysis (CVA)* e usadas para validar o método de estimação de pertinência. Espera-se que esta metodologia possa ser aplicada ao monitoramento agrícola e de desmatamentos florestais, entre outros estudos de caráter ambiental.

**Palavras-chave:** Detecção de Mudanças; Métodos Baseados em *Kernel*; Imagens-fração; Algoritmo EM; Análise Ambiental.

### ABSTRACT

**Change detection in multitemporal remote sensing images using SVM based on RBF Kernel and a new relevance metric.** This paper investigates an approach to the problem of change detection in multitemporal remote sensing images using Support Vector Machines (SVM) based on RBF kernel (Radial Basis Function) combined with a new relevance metric called Delta b. The

<sup>1</sup> DME/ IFM - Universidade Federal de Pelotas, Pelotas, RS, Brasil. E-mail para correspondência: [neide.angelo@gmail.com](mailto:neide.angelo@gmail.com)

<sup>2</sup> Centro Universitário La Salle – Unilasalle, Canoas, RS, Brasil.

methodology is based on the difference of the fraction images produced for each date. In images of natural scenes the difference in soil and vegetation fractions tends to have a symmetrical distribution around the mean of its *pixels*. This fact can be used to model two normal multivariate distributions: change and non-change. The Expectation-Maximization (EM) algorithm is implemented for estimating the parameters (mean vector, covariance matrix, and prior probability) associated with these two distributions. Random samples are extracted from these two distributions and used to train a SVM classifier based on RBF kernel. The proposed methodology is tested using multi-temporal data sets of multispectral images Landsat-TM covering the same scene, located in Roraima state, in two different dates. Test samples are obtained by the use of Change Vector Analysis (CVA) and used to validate the estimation method of pertinence. It is expected that this methodology can be applied to agricultural and forestry monitoring deforestation and other studies of environmental character.

**Keywords:** Change Detection; Kernel Methods; Fraction-images; EM Algorithm; Environmental Analysis.

## INTRODUÇÃO

Detectar mudanças em um conjunto imagens da mesma cena tomadas em momentos diferentes é de interesse generalizado para um grande número de aplicações em várias áreas de conhecimento, tais como: vigilância por vídeo (Xiaogang *et al.*, 2014), biologia e medicina (Bosc *et al.*, 2003). Em particular, na área de sensoriamento remoto, as técnicas de detecção de mudanças em imagens multitemporais têm sido aplicadas a monitoramento agrícola, florestal, de áreas urbanas, de geleiras e oceanos entre outros (Zanotta e Haertel, 2012).

Duas principais abordagens para o problema da detecção de mudanças têm sido propostas na literatura para uso em sensoriamento remoto: o método supervisionado e o método não supervisionado (Singh, 1989; Bruzzone *et al.*, 2004; Castellana *et al.*, 2007; Filippone e Sanguinetti, 2010).

A primeira baseia-se na análise comparativa de imagens temáticas cobrindo a mesma cena e obtidas a partir da classificação de imagens multiespectrais obtidas em datas distintas. A desvantagem deste procedimento é que ele requer informação de verdade terrestre. Já na segunda abordagem, a detecção é feita sem a interação entre o sistema e o analista, exceto durante a fase de treinamento, onde alguns parâmetros devem ser fornecidos ao sistema.

O método supervisionado oferece algumas vantagens em comparação ao método não supervisionado, como, por exemplo, a definição da natureza do tipo de mudança ocorrida, mas, por outro lado, a obtenção de amostras de treinamento é geralmente uma tarefa de difícil execução e de alto custo. Consequentemente, o uso de métodos não supervisionados para a detecção de mudanças é, a nível operacional, mais indicado e tem sido largamente explorado pelos pesquisadores no desenvolvimento de seus trabalhos (Zanotta e Haertel, 2012).

Em se tratando de detecção de mudanças, as abordagens não supervisionadas são geralmente baseadas em imagens de diferenças. Estas são produzidas pela subtração *pixel a pixel*

das imagens adquiridas em duas datas diferentes (Radke *et al.*, 2005). As diferenças podem ser calculadas, a partir dos dados originais ou a partir de dados extraídos dos originais, tais como componentes principais ou índices de vegetação. Em qualquer caso, uma imagem de diferenças é produzida e um limiar é aplicado para distinguir os *pixels* onde a mudança tenha ocorrido daqueles que permaneceram inalterados. Contudo, esse limiar não é fácil de ser obtido (Théau, 2008).

Dentre os vários métodos de detecção de mudança não supervisionada propostos na literatura, o mais amplamente utilizado é aquele conhecido como Análise do Vetor de Mudanças (CVA – *Change Vector Analysis*) (Bovolo *et al.*, 2010). A técnica de CVA é baseada em três etapas: comparação da imagem por subtração de vetores, cálculo da norma dos vetores de mudança espectral (por vezes, também a direção do vetor de mudança espectral é calculada) e limiarização.

Haertel *et al.* (2004) utilizaram o conceito de *pixel* mistura no problema da detecção de mudanças. O fenômeno de mistura em *pixels* ocorre quando um mesmo *pixel* compreende duas ou mais classes distintas, denominadas, neste contexto, de componentes (*endmembers*). Então, é possível derivar um novo conjunto de dados com as chamadas imagens-fração, as quais informam em cada *pixel* a fração ocupada por cada uma das componentes do terreno, como, por exemplo, vegetação, solo, sombra/água. Essa abordagem apresenta duas vantagens: permite uma análise em nível de *sub-pixel* e elimina a necessidade de normalização radiométrica das imagens adquiridas em datas distintas porque, no processo de fracionamento, são empregados *pixels* puros extraídos da imagem na respectiva data. Dessa forma, as imagens de diferenças são produzidas a partir da subtração de componentes geradas a partir das imagens multiespectrais.

Muitas abordagens propostas na literatura buscam modelar as distribuições para as classes mudança e não-mudança, a fim de estimar um valor adequado para o limiar que separa as duas classes (Bazi *et al.*, 2005; Bovolo *et al.*, 2010).

Por outro lado, nos últimos tempos têm surgido pesquisas com o uso de classificadores baseados em *kernels* (núcleos) em diversas áreas de aplicação como reconhecimento de faces, categorização de texto, previsão de séries temporais e reconhecimento de dígitos manuscritos.

Dentre esses classificadores, estão o *Support Vector Machines* (SVM) ou Máquinas de Vetores de Suporte, *Kernel* de Análise de Componentes Principais (KPCA), *Kernel* Discriminante de Fisher (KFD), *Kernel* k-Médias e outros (Shawe-Taylor e Cristianini, 2004).

SVM constituem um método bem interessante para tratar o problema da classificação de imagens hiperespectrais, uma vez que eles trabalham com espaços de dimensões elevadas de forma bem eficiente, assim como conseguem lidar bem com amostras ruidosas de uma forma robusta e produzem soluções esparsas, isto é, a função que define a fronteira de decisão é expressa a partir de um subconjunto de amostras de treinamento (Camps-Valls e Bruzzone, 2005).

Neste trabalho, o problema da detecção de mudanças é abordado considerando que as duas distribuições para as classes mudança e não-mudança são do tipo Normal multivariada. A partir dessa suposição, o algoritmo *Expectation-Maximization* (EM) (Duda *et al.*, 2001) é utilizado para estimar os parâmetros estatísticos destas distribuições e obter amostras de treinamento para o classificador. Após essa etapa, realiza-se uma classificação com o uso de SVM, empregando o *kernel* RBF e, a partir dos resultados dessa classificação, uma nova métrica de pertinência é obtida. Com o objetivo de testar a eficiência da métrica de pertinência, realizou-se um experimento com amostras de teste pré-selecionadas, obtidas a partir de uma adaptação do método CVA.

Zanotta e Haertel (2012) utilizaram o conceito de *pixel* mistura para estimar com mais precisão os graus de pertinência à classe mudança e uma abordagem bayesiana para estimar graus de pertinência para as classes mudança e não-mudança com base nas diferenças entre as imagens-fração estimadas para duas datas diferentes. Este trabalho, embora utilize também o conceito de *pixel* mistura, difere da pesquisa de Zanotta e Haertel (2012), pois propõe uma abordagem supervisionada para o problema com o uso do classificador *Support Vector Machines* (SVM) e uma nova métrica de pertinência obtida a partir do resultado de classificação por SVM.

## MATERIAL E MÉTODOS

O processo de detecção de mudanças investigado neste trabalho consiste nas seguintes etapas: pré-processamento (onde as imagens são registradas e as imagens-fração são produzidas), análise dos dados (produção das imagens), estimação dos parâmetros da função densidade de probabilidade das classes via algoritmo EM, produção das amostras de treinamento e classificação com SVM e determinação da pertinência dos *pixels* a partir dos resultados da classificação.

Conforme já mencionado, neste trabalho, as imagens de diferenças são produzidas a partir da subtração dos componentes vegetação e solo das imagens-fração geradas a partir das imagens multiespectrais (Haertel *et al.*, 2004). O método utilizado para estimar estas frações das componentes de mistura (*endmembers*) de cada *pixel* da imagem é o Modelo Linear de Mistura Espectral (MLME), o qual assume que a resposta espectral de cada *pixel* pode ser modelada por uma combinação linear das respostas espectrais de cada componente, ponderada pela fração da área que essa componente ocupa dentro do *pixel* (Shimabukuro e Smith, 1991).

Os valores encontrados pelo MLME devem representar da melhor forma possível os componentes (*endmembers*) para a imagem em questão. O resultado do fracionamento contará com um número de imagens igual ao número de componentes escolhidas para representar a região.

Em imagens utilizadas em sensoriamento remoto é frequente o uso dos componentes vegetação, solo e sombra/água. Contudo, este trabalho utilizou somente os componentes vegetação e solo semelhante ao proposto em Zanotta e Haertel (2012).

A figura 1 mostra o espalhamento dos dados da imagem de diferenças, considerando no eixo vertical a diferença de fração solo e no horizontal a diferença de fração vegetação.




Figura 1. Gráfico do espalhamento dos dados da imagem de diferenças.  
Fonte: Adaptado de Zanotta, 2010.

Analisando a figura 1, pode-se constatar a existência de uma correlação negativa entre a distribuição das diferenças de fração vegetação e solo. Essa correlação pode ser explicada através do consequente aumento na fração solo resultante da diminuição da fração vegetação e vice-versa.

Para essa imagem, é esperado que os *pixels* que não sofreram alteração significativa entre as duas datas (classe não-mudança) tendam a ocupar uma região próxima ao centro do diagrama de dispersão (inserida no círculo da Figura 1), enquanto *pixels* que sofreram alterações tendem a se deslocar para uma das duas extremidades do diagrama de dispersão dos dados, dependendo do tipo de mudança ocorrido nestes *pixels* (região de solo mudando para vegetação ou vice-versa).

Intuitivamente, espera-se a existência de uma sobreposição entre essas duas classes, com os perfis dos histogramas apresentando uma distribuição normal, bivariada (diferença na fração vegetação e diferença na fração solo). Além disso, o histograma da classe mudança deve apresentar uma dispersão grande, com média próxima à origem, e a classe não-mudança uma dispersão pequena quase centrada na origem. Ou seja, *pixels* sem mudança significativa devem apresentar diferenças próximas de zero, enquanto *pixels* representando mudança assumem poucos valores neste intervalo. A diferença entre as duas distribuições deve se concentrar nas variâncias das classes, com a classe mudança apresentando uma grande dispersão e a classe não-mudança, uma dispersão pequena.

Ao se analisar o histograma de dispersão da imagem em estudo em três dimensões, vê-se que existe um acúmulo de *pixels* nas proximidades da origem dos eixos diferença vegetação e solo. Porém o centro deste agrupamento de *pixels* não está centrado na origem dos eixos, mas apresenta um pequeno deslocamento no sentido positivo do eixo diferença de fração solo e está praticamente centrada na origem em relação ao eixo diferença de fração vegetação, como pode ser visto na figura 2. Embora os dados mostrem que as distribuições das classes não estejam centradas exatamente na origem dos eixos de fração vegetação e solo, as estimativas iniciais para os parâmetros das distribuições das classes mudança e não-mudança podem ser tomadas a partir dessas distribuições intuitivas. Assim, é possível supor que as distribuições de ambas as classes são do tipo normal bivariada com médias próximas à origem devido à simetria na distribuição das duas variáveis. Este fato permite a utilização do algoritmo EM com a finalidade de estimar os parâmetros das distribuições das duas classes (vetor de médias, matriz de covariâncias e probabilidade a priori) (Duda *et al.*, 2001).

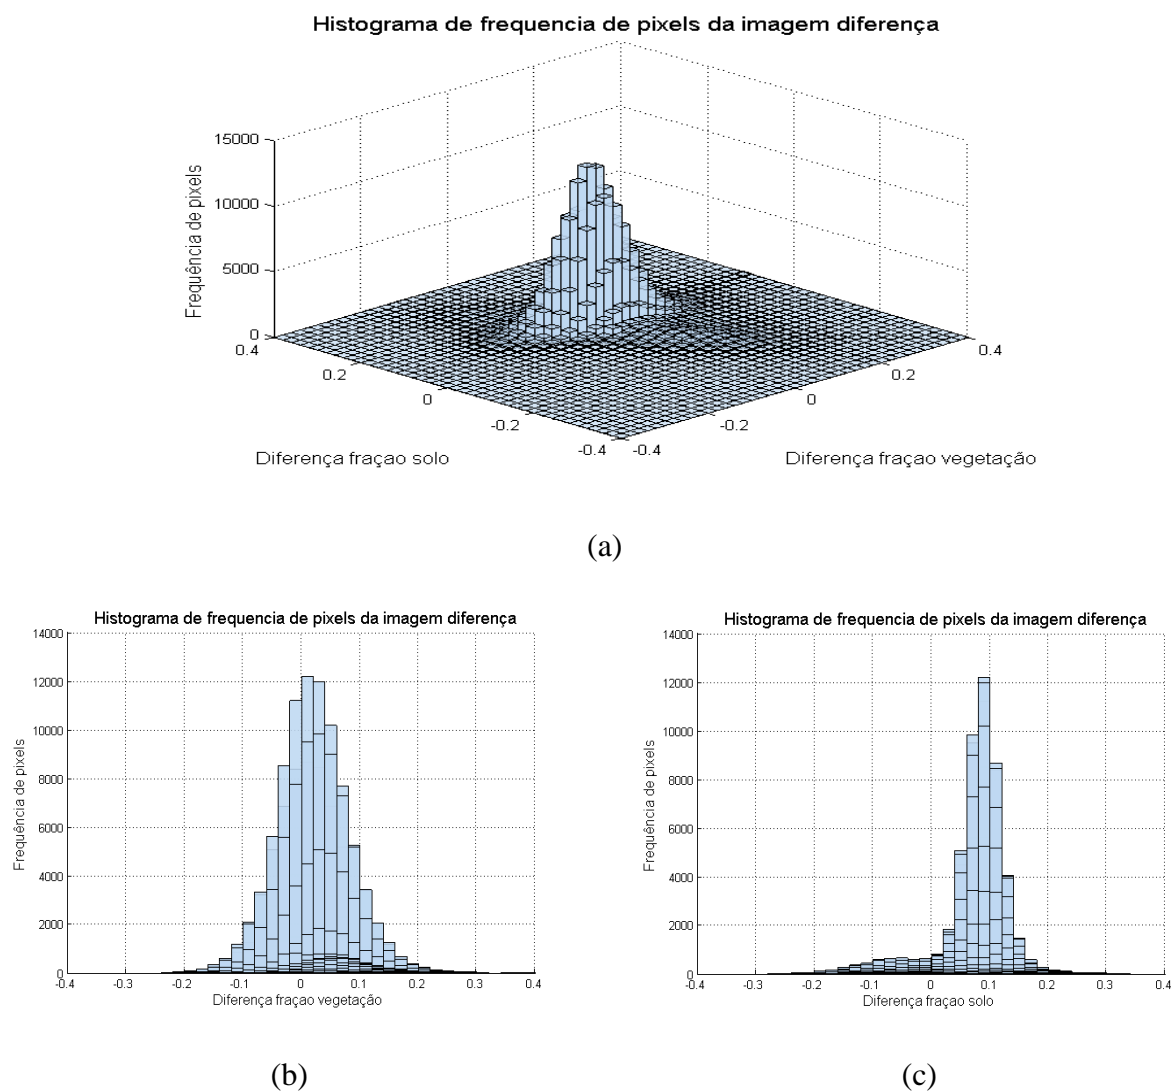


Figura 2. (a) Histograma de frequência de *pixels* da imagem diferença em estudo, (b) perfil do Histograma de frequência sobre o eixo diferença fração vegetação e (c) perfil do Histograma de frequência sobre o eixo diferença fração solo.

Consideram-se aqui as classes  $\omega_1$  e  $\omega_2$ , respectivamente, como as classes mudança e não-mudança. Assim,  $M_1$ ,  $S_1$ ,  $P(\omega_1)$ ,  $M_2$ ,  $S_2$ ,  $P(\omega_2)$  representam os vetores de médias, matrizes de covariâncias e probabilidades a priori de cada classe. Para valores iniciais dos parâmetros no algoritmo EM, algumas considerações são necessárias e podem ser ilustradas por meio da figura 1.

A classe mudança apresenta uma distribuição normal bivariada, alongada na direção de maior dispersão, que é estimada pelo primeiro autovalor ( $\lambda_1$ ). Para valor inicial no EM propõe-se utilizar a matriz de covariância para a totalidade das amostras de diferenças nas frações. Já as amostras da classe não-mudança estão concentradas em torno da origem, apresentando uma pequena dispersão, causada pelos inevitáveis ruídos nos dados e alterações não significativas presentes nesta classe. Esta dispersão será estimada pela variância na direção ortogonal à de maior variação, ou seja, na direção do segundo autovetor, e sua magnitude é estimada pelo segundo



autovalor ( $\lambda_2$ ). A distribuição desta classe tende, portanto, a estar em uma região circular em torno da origem com um raio proporcional a  $\lambda_2$  (Zanotta e Haertel, 2012).

Como geralmente o número de *pixels* apresentando pouca mudança ou mudança nula é muito maior do que o número de *pixels* apresentando sinais claros de mudança, os valores iniciais das probabilidades *a priori* das classes podem ser estimados inicialmente como 0,1 para mudança e 0,9 para não-mudança.

Assim, as estimativas iniciais para cada classe são:

$$M_1 = \begin{bmatrix} 0 \\ 0 \end{bmatrix}, S_1 = \begin{bmatrix} \text{matriz de} \\ \text{covariância} \\ \text{da amostra total} \end{bmatrix}, P(\omega_1) = 0,1, M_2 = \begin{bmatrix} 0 \\ 0 \end{bmatrix}, S_2 = \begin{bmatrix} \lambda_2 & 0 \\ 0 & \lambda_2 \end{bmatrix} \text{ e } P(\omega_2) = 0,9 \quad (1)$$

Após a convergência do algoritmo EM os parâmetros obtidos para as distribuições de classe, podem ser utilizados para obtenção de amostras de treinamento para a classificação com SVM.

A classificação com SVM utilizada neste trabalho está baseada em Abe (2005), cujo problema pode ser expresso pelas equações (2) e (3).

$$\text{Maximizar: } \sum_{i=1}^M \alpha_i - \frac{1}{2} \sum_{i,j=1}^M \alpha_i \alpha_j y_i y_j K(\mathbf{x}_i, \mathbf{x}_j) \quad (2)$$

$$\text{Sujeito a: } \sum_{i=1}^M \alpha_i y_i = 0 \quad \text{e} \quad C \geq \alpha_i \geq 0 \quad \text{para } i=1, \dots, M \quad (3)$$

Onde:  $\alpha_i$  são multiplicadores de Lagrange, M é o número de amostras consideradas,  $K(\mathbf{x}_i, \mathbf{x}_j)$  é a função de kernel e C é o parâmetro de margem ou constante de custo.

O kernel utilizado foi o RBF, descrito pela equação (4).

$$K(x, x') = e^{-\gamma \|x-x'\|^2} \quad (4)$$

Os algoritmos utilizados para a implementação do classificador SVM foram desenvolvidos no software MATLAB. Para fins de treinamento do classificador SVM, amostras randômicas foram extraídas a partir da distribuição normal multivariada, obtidas por meio da função *mvnrnd.m*, da biblioteca de funções do MATLAB, usando em cada caso os parâmetros da respectiva distribuição de classe estimados via EM. Após serem gerados por estas distribuições, os *pixels* de amostras são avaliados nas duas funções de distribuições de probabilidades. Então, aquele *pixel* amostrado que apresentar a maior probabilidade de pertencer a uma das distribuições é rotulado na classe correspondente àquela distribuição. Procedendo dessa forma, pretende-se garantir estatisticamente que as amostras geradas aleatoriamente representam, de fato, as classes. O classificador SVM é robusto e gera bons resultados mesmo com a presença de alguma amostra de treinamento incorreta,



mas, para efeito de classificação por pertinência de *pixels*, o uso de amostras de treinamento mais confiáveis deve gerar resultados mais acurados no processo de separação das classes.

Na sequência, o classificador SVM é, então, treinado a partir destas amostras de treinamento, gerando uma função de decisão que será usada para a separação das classes. Finalmente, a partir dos resultados obtidos por essa função de decisão, chega-se a métrica de estimação de pertinência que doravante será chamada de Delta b, ou seja, os *pixels* da imagem diferença são submetidos ao classificador SVM com *kernel* RBF. O uso deste *kernel* permite que a separação linear existente entre as classes em espaço de dimensão mais elevada seja feita diretamente na imagem original sem a necessidade do uso de funções de mapeamento. Este procedimento é chamado truque de *kernel*, (Abe, 2005). Uma métrica para estimar a pertinência de *pixels* às classes mudança e não-mudança poderia ser obtida através da distância de cada *pixel* mapeado neste espaço de dimensão superior ao hiperplano ótimo que separa essas classes. Dessa forma, *pixels* mais afastados ao hiperplano de separação ótimo teriam uma probabilidade maior de pertencerem à classe em que estão inseridos, e *pixels* mais próximos a este hiperplano apresentariam uma probabilidade menor de pertencer à referida classe. Contudo, cabe ressaltar que a determinação desta medida diretamente no espaço mapeado é muito complexa ou até inviável, uma vez que certos espaços mapeados apresentam um número muito elevado de dimensões (*kernel* RBF) e, também, porque a função de mapeamento equivalente ao *kernel* utilizado no classificador pode não ser conhecida (*kernel* RBF). Dessa forma, a ideia inovadora apresentada neste trabalho é estimar a distância dos *pixels* ao hiperplano de separação ótimo diretamente na imagem original, utilizando a potencialidade do truque de *kernel* de operar a separação das classes diretamente neste espaço.

A medida de estimação da distância do *pixel* mapeado ao hiperplano de separação ótimo, que também passa a ser considerada como uma estimativa de pertinência do *pixel* a uma das classes (mudança e não-mudança), é doravante denominada de Delta b ( $\Delta b$ ). Esta medida corresponde ao vetor dado pela diferença entre o valor da função de decisão gerada pelo classificador SVM em um *pixel* qualquer da imagem e o valor da função de decisão da projeção deste ponto sobre o hiperplano de separação ótimo, segundo uma direção paralela à direção determinada pelo eixo correspondente à variável dependente da função de decisão, conforme pode ser mostrado na figura 3. Embora essa medida aplicada entre o *pixel* classificado e hiperplano não seja ortogonal a ele e, portanto, não se caracterize como uma distância, ela mantém sempre a mesma angulação  $\beta$  entre o vetor normal ( $\mathbf{w}$ ) e o vetor Delta b para qualquer *pixel* da imagem, que corresponde ao mesmo ângulo entre o vetor  $\mathbf{w}$  e o eixo da variável dependente que define a função de decisão do classificador. Dessa forma, o vetor Delta b, ao ser projetado sobre o vetor normal, gerará uma medida de distância do *pixel* classificado ao hiperplano ótimo. Portanto, a magnitude do vetor Delta b é uma medida

proporcional a distância do *pixel* mapeado ao hiperplano de separação ótimo. Sendo assim, pode-se usar o resultado da classificação por SVM, que corresponde à extremidade do vetor Delta b, para estimar a pertinência de qualquer *pixel* a sua respectiva classe. Neste caso, a magnitude deste vetor determina a proximidade ou afastamento dos *pixels* ao hiperplano de separação, e o sinal do vetor Delta b representa o sinal do resultado do classificador, ou seja, a classe +1 (mudança) e a classe -1 (não-mudança).




Figura 3. Visualização da métrica de pertinência Delta b.  
Fonte: Produzido pelo autor, 2014.

Na figura 3, acima, é apresentada uma visão do plano  $x_1x_3$  pertencente ao espaço tridimensional real (espaço mapeado ou característico), onde é mostrado um *pixel*  $x_a=(x_1, x_2, x_3)$  que foi mapeado do espaço original (imagem de diferenças) para este espaço. Este ponto está inserido em um plano determinado pela função de decisão  $D(x_a) = b_a$  (plano em vermelho), onde  $b_a$  corresponde ao valor da função de decisão para o ponto  $x_a$ . Este plano é paralelo ao plano de separação ótimo entre as classes mudança e não-mudança, o qual é caracterizado pela função de decisão  $D(x) = 0$  (plano em cinza). A projeção do ponto  $a$  paralelamente ao eixo  $x_3$  sobre o plano de separação ótimo determina o ponto  $x_{a'}$ . A diferença entre os valores da função de decisão para estes pontos define o vetor  $\Delta b$ . O ângulo determinado entre este vetor e o vetor normal ao hiperplano de separação ótima (vetor  $w$ ) é  $\beta$ .

Deve-se enfatizar que essa métrica não estima um valor percentual de mudança do *pixel* ao longo do tempo, nem mesmo tem um significado estatístico específico. Essa métrica, portanto, estima o grau de confiança com que um *pixel* pode ser rotulado em uma determinada classe. Levando-se em conta que existem apenas duas classes complementares em detecção de mudanças (mudança e não-mudança), pode-se usar apenas a pertinência sobre uma delas, no caso, aquela que se refere às classes mudança, pois é possível afirmar que um *pixel*, tendo alta pertinência em uma das classes, significa que ele tem baixa pertinência na outra e vice-versa. Sendo assim, essa métrica

permitirá a estimativa da pertinência de um *pixel* classificado à classe mudança somente pelo valor de Delta b. O valor de pertinência representado por  $P_m(\mathbf{x})$  para a classe mudança será dado pela proporção entre o maior valor de Delta b e menor valor de Delta b, conforme equação (5), a seguir:

$$P_m(\mathbf{x}) = \begin{cases} \frac{\Delta b}{\max(\Delta b)}, & \text{se } \Delta b > 0 \\ 0.5, & \text{se } \Delta b = 0 \\ \left(1 - \frac{\Delta b}{\min(\Delta b)}\right), & \text{se } \Delta b < 0 \end{cases} \quad (5)$$

E a pertinência da classe não-mudança  $P_{nm}(\mathbf{x})$  é dada pela equação (6):

$$P_{nm}(\mathbf{x}) = 1 - P_m(\mathbf{x}) \quad (6)$$

A partir das equações acima, percebe-se que o menor valor de Delta b obtido após a classificação corresponderá a 0 (0% de pertinência a classe), e o maior valor de Delta b corresponderá a 1 (100% de pertinência a classe), isto é, *pixels* com valores de Delta b zero, ou próximos de zero, indicam pouca probabilidade de pertencerem à classe mudança e, portanto, possuem alta probabilidade de pertencerem à classe não-mudança, em como *pixels* com valor 1 ou próximos de 1 indicarão grande probabilidade de pertencerem à classe mudança e, dessa forma, baixa probabilidade de pertencerem à classe não-mudança.

Neste momento, é necessário afirmar que a determinação dessa métrica de pertinência é dependente da escolha do *kernel* utilizado e dos parâmetros a ele atribuídos durante o processo de classificação com SVM.

## RESULTADOS E DISCUSSÃO

Para os experimentos foram consideradas duas imagens Landsat 5-TM cobrindo a mesma área, localizada no estado de Roraima conforme ilustrado na figura 4. Esta área é caracterizada por duas planícies distintas, uma localizada a uma altitude média de 200 metros e outra localizada numa alta elevação formando um platô: o Platô do Tepequém. Uma floresta densa cobre a região de baixa elevação, enquanto a região do platô é dominada por cerrado. A imagem da primeira data foi adquirida em outubro de 1991 e a imagem da segunda data em abril de 1994. Nos experimentos, foram consideradas apenas as frações resultantes para vegetação e solo. As imagens utilizadas possuem 390625 *pixels* distribuídos em um quadrado de 625 por 625 *pixels*.




Figura 4. (a) Imagem de Data 1, composição em falsa cor 5(R), 4(G), 3(B). (b) Imagem de Data 2, composição em falsa cor 5(R), 4(G), 3(B).

Para a avaliação da acurácia dos resultados neste trabalho, foram utilizados dois procedimentos:

- a) Análise quantitativa, realizada por meio da produção de um conjunto de amostras de teste controladas usando a técnica de *Change Vector Analysis* (CVA);
- b) Análise qualitativa e quantitativa, realizada por meio da construção de um mapa de pertinência para toda a imagem.

Para a avaliação quantitativa, foi utilizado um conjunto de amostras de testes coletadas aleatoriamente da imagem de diferenças de fração com o uso do módulo do vetor de mudança preconizado na técnica CVA, porém, em vez de considerar a origem dos vetores mudança em (0,0), foi considerada a origem dos vetores translada para a média da classe não-mudança. As amostras de teste foram tomadas dessa forma em virtude de não se ter disponível dados com a verdade terrestre para a imagem em estudo. A técnica CVA gera para cada *pixel* da imagem um vetor, tendo por origem os dados do *pixel* da imagem tomado na data 1 e, como extremidade desse vetor, os dados do mesmo *pixel* tomado na data 2, ambos considerando com origem do sistema de vetores a média da classes não mudança. A utilização desta técnica permite uma estimativa confiável da mudança nos *pixels* amostrados, ou seja, *pixels* apresentando módulo CVA transladado com valores superiores a 0,3 e menores que 0,6 correspondem a *pixels* que apresentaram alguma mudança significativa ao longo do período. Os valores de módulo acima de 0,6 foram desconsiderados para que não sejam utilizadas amostras correspondentes a sombra e nuvens, que certamente correspondem à mudança, mas não representam as componentes solo e vegetação. *Pixels* com Módulo CVA transladado menores que 0,1 corresponderão a *pixels* que não apresentaram mudança significativa ao longo do período. A escolha desses intervalos visa garantir que as amostras de teste sejam representativas de suas respectivas classes.

Dessa forma, com o uso do módulo CVA transladado, considerou-se 900 *pixels* de amostra para cada classe, de forma aleatória e uniforme, ao longo da imagem de diferença, garantindo

amostras com abrangência em toda a imagem e sem qualquer tendência na sua escolha. As amostras assim coletadas foram utilizadas para comprovar, estatisticamente, a eficiência do método de determinação de pertinência.

As tabelas 1 e 2 a seguir mostram, na ordem, o melhor e pior resultado para cada conjunto de amostra de treinamento utilizada no classificador SVM com *kernel* RBF para as seguintes variáveis: o menor valor de pertinência, a média do valor de pertinência, o desvio padrão das pertinências, o maior valor de pertinência e, finalmente, o percentual de *pixels* classificados corretamente nas classes mudança e não-mudança.

Tabela 1. Avaliação da pertinência na amostra de teste gerada a partir do Módulo CVA com centro transladado e usando *kernel* RBF para classe mudança.

Número de amostras de treinamento para o classificador	Coefficiente $\gamma$	Menor valor de pertinência na classe (%)	Valor médio de pertinência na classe (%)	Desvio padrão de pertinência na classe (%)	Maior valor de pertinência na classe (%)	Percentual de <i>pixels</i> classificados com pertinência acima de 50% na classe
200	1	51,00	65,96	9,36	100,00	100,00
200	2	55,06	65,58	9,50	100,00	100,00
300	1	51,00	67,67	10,33	100,00	100,00
300	95	53,12	69,43	9,63	100,00	100,00

Tabela 2. Avaliação da pertinência na amostra de teste gerada a partir do Módulo CVA com centro transladado e usando *kernel* RBF para classe não-mudança.

Número de amostras de treinamento para o classificador	Coefficiente $\gamma$	Menor valor de pertinência na classe (%)	Valor médio de pertinência na classe (%)	Desvio padrão de pertinência na classe (%)	Maior valor de pertinência na classe (%)	Percentual de <i>pixels</i> classificados com pertinência acima de 50% na classe
200	1	51,00	87,70	9,58	100,00	100,00
200	2	46,33	74,31	15,16	100,00	87,56
300	1	51,00	90,00	9,24	100,00	100,00
300	95	48,47	84,55	11,23	100,00	99,67

A partir dos resultados apresentados nas tabelas acima para as pertinências obtidas com o *kernel* RBF, percebe-se que, com os parâmetros adequados, os *pixels* da amostra de teste foram corretamente classificados segundo a pertinência informada pela métrica Delta b, apresentando acerto mínimo acima de 87% dos *pixels* no pior caso. Assim, os resultados, em geral, mostram que a métrica proposta consegue classificar adequadamente os *pixels* da amostra de teste nas classes mudança e não-mudança, segundo as distribuições teorizadas para elas. Finalmente, baseado nos bons resultados de pertinência obtidos com a amostra de teste, pode-se afirmar que a métrica de pertinência Delta b é eficiente.



O segundo experimento aborda uma análise qualitativa e quantitativa total da imagem em estudo, através da apresentação de um mapa de pertinência de *pixels* às classes mudança e não-mudança para o melhor caso de classificação, usando 200 e 300 amostras de treinamento, conforme ilustra a Figura 5. Nesta figura verifica-se que valores de pertinência superiores a 50% correspondem a *pixel* com maior probabilidade de pertencerem à classe mudança, e que valores inferiores a 50% apresentam baixa probabilidade de pertencerem a esta classe e, portanto, devem ser considerados como pertencentes à classe não-mudança.

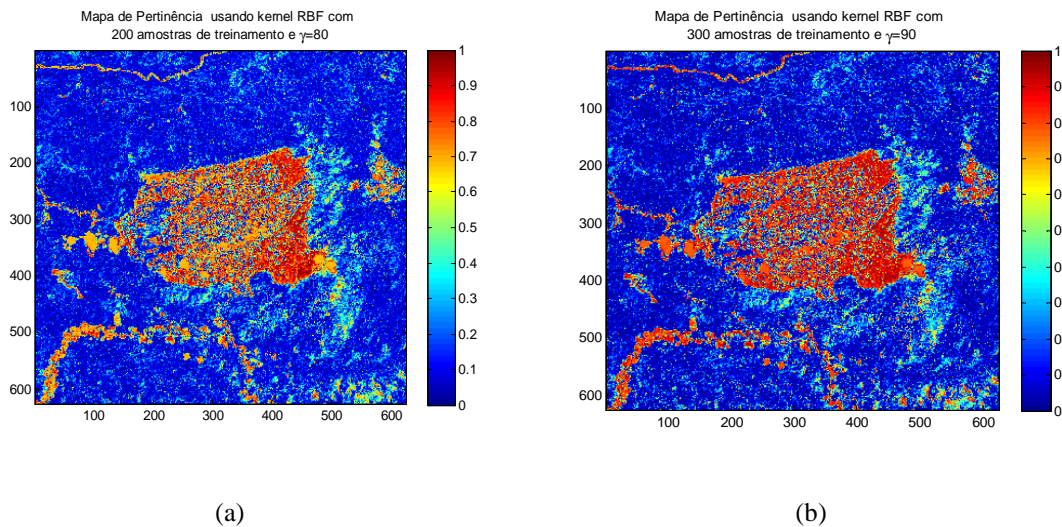


Figura 5. (a) Mapa de Pertinência usando *kernel* RBF com 200 amostras de treinamento e  $\gamma=80$ . (b) Mapa de Pertinência usando *kernel* RBF com 300 amostras de treinamento e  $\gamma=90$ .

Os experimentos desenvolvidos neste trabalho mostram a adequação da metodologia proposta, produzindo resultados bastante aceitáveis na detecção de alterações na cobertura do solo.

No experimento com todos os *pixels* da imagem real, uma inspeção visual do mapa de pertinência obtido, bem como dos valores de pertinência obtidos, parecem ser compatíveis com os resultados obtidos para essa imagem em (Zanotta e Haertel, 2012).

## CONCLUSÕES

Este trabalho investigou uma nova abordagem para o problema da detecção de mudanças em imagens multiespectrais de sensoriamento remoto empregando SVM, com o uso do *kernel* gaussiano (RBF), gerando uma nova métrica de pertinência. A proposta metodológica foi baseada na diferença das imagens-fração produzidas para cada data a partir da modelagem das distribuições normais multivariadas das classes mudança e não-mudança presentes na imagem. A seguir, o algoritmo EM foi implementado para estimar os parâmetros estatísticos associados a essas duas distribuições de classe. Posteriormente, amostras aleatórias e normalmente distribuídas foram

extraídas dessas distribuições e rotuladas segundo sua probabilidade de pertinência a cada uma das classes. Essas amostras foram, então, usadas no treinamento do classificador SVM e, do resultado dessa classificação, foi estimada uma nova métrica de pertinência de *pixels* chamada Delta b. Essa métrica foi, então, comparada à métrica apresentada no trabalho de Zanotta e Haertel (2012). A comparação apresentou boa correlação entre os resultados obtidos por ambas as métricas.

Espera-se, a partir dos bons resultados obtidos por essa nova de métrica pertinência proposta, que ela possa ser aplicada ao agronegócio, através do monitoramento agrícola de safras e, também, no controle ambiental por meio do controle de desmatamentos florestais.

Entretanto, é importante salientar que o método proposto visa à detecção de mudanças em ambientes onde prevaleçam os componentes vegetação e solo. Dessa forma, não é possível afirmar que a metodologia proposta neste trabalho, ao ser aplicada a outras imagens com diferentes componentes, possa apresentar resultados semelhantes aos obtidos neste trabalho, uma vez que outros componentes podem não apresentar as mesmas peculiaridades dos componentes vegetação e solo as quais garantiram às suposições atribuídas as distribuições normais das classes mudança e não-mudança, que por sua vez permitiram a utilização do algoritmo EM e, conseqüentemente, a geração das amostras de treinamento usada no classificador SVM.

Finalmente, baseado nos resultados promissores obtidos por esta metodologia em imagens multitemporais e multiespectrais com a utilização de poucas amostras de treinamento, sugere-se que seja realizada uma investigação sobre o uso dessa abordagem metodológica para detecção de mudança em imagens hiperespectrais. Além disso, pode ser estudada a adaptação desta métrica de pertinência a outras técnicas de detecção de mudanças como, por exemplo, o SVM *One Class* (Bovolo *et al.*, 2010).

## REFERÊNCIAS

- ABE, S. 2005. **Support Vector Machines for Pattern Classifications**. Kobe, Japão: Springer, 343p.
- BAZI, Y.; BRUZZONE, L.; MELGANI, F. 2005. An Unsupervised Approach based on the Generalized Gaussian Model to Automatic Change Detection in Multitemporal SAR Images. **IEEE Transactions on Geoscience and Remote Sensing**, **43**(4):874–886.
- BOSC, M. et al. 2002. Automatic change detection in multimodal serial MRI: Application to multiple sclerosis lesion evolution, **Neuroimage**, **20**:643–656.
- BOVOLO, F.; CAMPS-VALLS, G.; BRUZZONE, L. 2010. A Support Vector Domain Method for Change Detection in Multitemporal Images. **Pattern Recognition Letters**, **31**(10):1148–1154.



- BOVOLO, F.; MARIN, C.; BRUZZONE, L. 2012. A novel hierarchical approach to change detection with very high resolution SAR images for surveillance applications. In: GEOSCIENCE AND REMOTE SENSING SYMPOSIUM (IGARSS), 1992 – 1995, Munich, Germany. p. 1992-1995.
- BRUZZONE, L.; COSSU, R.; VERNAZZA, G. 2004. Detection of Land-cover Transitions by Combining Multidate Classifiers. **Pattern Recognition Letters**, **25**(13):1491–1500.
- CAMPS-VALLS, G.; BRUZZONE, L. 2005. Kernel-Based Methods for Hyperspectral Image Classification. **IEEE Transactions on Geoscience and Remote Sensing**, **43**(6):1351–1362.
- CASTELLANA, L.; D'ADDABBO, A.; PASQUARIELLO, G. 2007. A composed supervised/unsupervised approach to improve change detection from remote sensing. **Pattern Recognition Letters**, **28**(4):405–413.
- DUDA, R. O.; HART, P. E.; STORK, D. G. 2001. **Pattern Classification**. 2. ed. New York: John Wiley & Sons, 637p.
- FILIPPONE, M.; SANGUINETTI, G. 2010. Information Theoretic Novelty Detection. **Pattern Recognition**. **43**(3):805–814.
- HAERTEL, V.; SHIMABUKURO, Y. E.; ALMEIDA FILHO, R. 2004. Fraction Images in Multitemporal Change Detection. **International Journal of Remote Sensing**, **10**(23):5473-5489.
- RADKE, R. J. et al. 2005. Image Change Detection Algorithms: a systematic survey. **IEEE Transactions on Image Processing**, **14**(3):294–307.
- SHAWE-TAYLOR, J.; CRISTIANINI, N. 2004. **Kernel Methods for Pattern Analysis**. UK: Cambridge University Press, 462p.
- SHIMABUKURO, Y. E.; SMITH, J. A. 1991. The least-squares mixing models to generate fraction images derived from remote sensing multispectral data. **IEEE Transactions on Geoscience and Remote Sensing**, **29**(1):16–20.
- SINGH, A. 1989. Digital Change Detection Techniques using Remotely-Sensed data. **International Journal of Remote Sensing**, **43**(10):989–1003.
- THÉAU, J. 2008. **Change Detection**. Encyclopedia of Geographical Sciences. New York: Shashi Shekhar and Hui Xiong, Springer, p. 77-84.
- WANG, X.; WANG, M.; LI, W. 2014. Scene-Specific Pedestrian Detection for Static Video Surveillance. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, **36**(2):361–374.
- ZANOTTA, D. 2010. **Uma Abordagem Fuzzy na Detecção Automática de Mudanças do uso do Solo Usando Imagens de Fração e Informações de Contexto Espacial**. Dissertação (Mestrado em Sensoriamento Remoto) – Universidade Federal do Rio Grande do Sul, UFRGS, 78p.
- ZANOTTA, D.; HAERTEL, V. 2012. Gradual Land Cover Change Detection based on Multitemporal Fraction Images. **Pattern Recognition**, **45**(1):2927-2937.