

Método Multiescala de Detecção de Mudanças Aplicado a Dados de Sensoriamento Remoto

Carlos Alberto Pires de Castro Filho¹, Carlos Alberto Stelle²

¹Programa de Doutorado em Computação Aplicada – CAP
Instituto Nacional de Pesquisas Espaciais – INPE

²Programa de Mestrado em Sensoriamento Remoto – SERE
Instituto Nacional de Pesquisas Espaciais – INPE

{pires, stelle}@dpi.inpe.br

Abstract. *This work aims to apply the multiscale search method to maximize the Kullback-Liebler Distance in attributes extracted from remote sensing data in order to define the most suitable in change detection processes. Fisher's criterion was also used to measure the separability between the change and non change classes. It was concluded that there was emphasis on the Landsat TM Band 1, 2 and 3, with global accuracy above 90% on the classification.*

Resumo. *O trabalho tem por objetivo aplicar o método multiescala de busca pela máxima Distância de Kullback-Liebler em atributos originais e extraídos de dados de sensoriamento remoto visando definir qual atributo é o mais adequado no processo de detecção de mudança. O critério de Fisher também foi aplicado para mensurar a separabilidade entre as classes de mudança e não mudança. Como conclusão, observou-se destaque para as Bandas 1, 2 e 3 do sensor Landsat TM, atingindo acurácia global acima de 90%.*

Palavras-chave: *distância estatística, classificação de imagens, sensoriamento remoto, detecção de mudança.*

1. Introdução

Detecção de mudanças em dados de sensoriamento remoto é um processo que busca identificar mudanças nas feições da superfície terrestre entre diferentes datas. Análises visam detectar e monitorar não somente as feições do terreno, mas também seus processos de mudanças, modelando tendências de caráter global, regional e local.

O objetivo deste trabalho é de aplicar a Distância de Kullback-Leibler em diversas bandas oriundas ou extraídas de dados de sensoriamento remoto visando avaliar o potencial de detecção de mudanças. Além disto, será também aplicada a metodologia multiescala de detecção de mudanças onde é realizada uma busca por diversos tamanhos de amostras visando obter o tamanho que maximiza a distância entre as distribuições de probabilidades de datas distintas.

2. Metodologia

2.1 Distância de Kullback-Liebler

Visando detectar mudanças em imagens de sensoriamento remoto obtidas em diferentes datas, o modelo gaussiano e univariado da Distância de Kullback-Leibler

(r_{GKLD}) pode ser expresso pela Equação 1. Nela, μ e σ representam, respectivamente, as médias e desvios-padrões das funções distribuição de densidade de probabilidade nas imagens referentes aos tempos t e $(t+\Delta t)$.

$$r_{GKLD} = \frac{\sigma_t^4 + \sigma_{t+\Delta t}^4 + (\mu_t - \mu_{t+\Delta t})^2 (\sigma_t^2 + \sigma_{t+\Delta t}^2)}{2\sigma_t^2 \sigma_{t+\Delta t}^2} - 1 \quad (1)$$

2.2 Processamento de Imagens

A etapa de processamento das imagens visa extrair atributos dos dados de sensoriamento remoto. Foram utilizados dados gerados tanto por sensor óptico como de radar de abertura sintética (SAR), cujos atributos serão, posteriormente, avaliados no processo de detecção de mudanças.

Com relação aos dados ópticos, foram utilizadas imagens do sensor Landsat 5 *Thematic Mapper* (TM) da região da Floresta Nacional (FLONA) dos Tapajós. O único processamento realizado especificamente sobre as imagens ópticas foi o de extração do atributo de *Normalized Difference Vegetation Index* (NDVI), conforme descreve Jensen [2009].

Já, as imagens de SAR utilizadas foram do sensor ALOS/PALSAR (*Phased Array type L-band Synthetic Aperture Radar*), de frequência L nas quatro polarizações HH, HV, VH e VV. As datas das imagens foram selecionadas de tal forma que estivessem próximas às das imagens do sensor óptico Landsat TM. As bandas de entropia (H), ângulo alfa e anisotropia (A) foram extraídas das imagens de SAR conforme o processo de decomposição de alvos descrito por Cloude e Pottier [1997].

Ainda no ENVI foram realizados os processos, tanto nas imagens ópticas como nas de SAR, de reamostragem dos *pixels*, de registro entre todas as bandas em trabalho e de recorte final da área de trabalho.

2.3 Desenvolvimento do Algoritmo de Detecção de Mudanças Multiescala.

O algoritmo foi implementado utilizando a linguagem IDL (*Interactive Data Language*). A busca pelo tamanho da amostra cuja distância entre as distribuições de probabilidades de datas distintas fosse máxima utilizou o método multiescala descrito por Inglada e Mercier [2007].

O método multiescala define que durante o algoritmo é realizada uma busca *pixel* a *pixel* pela máxima Distância de Kullback-Leibler (KL) variando o tamanho da janela amostral homóloga entre as bandas de diferentes datas. Ao término do processo é gerada uma imagem de Distâncias de KL cujos *pixels* centrais da janela de busca recebem o valor desta máxima distância.

O pseudo-código do algoritmo desenvolvido é o seguinte:

1. início do algoritmo;
2. entrada das duas bandas de datas distintas t_1 e t_2 , sendo $t_2 = t_1 + \Delta t$;
3. entrada do tamanho máximo da janela multiescala: JanMax;
4. criar um arquivo TIFF referente à Distância de KL e cujos valores dos *pixels* serão calculados a seguir;
5. para cada *pixel* da banda t_1 e seu homólogo na banda t_2 , fazer;
6. determinação da dimensão máxima da janela multiescala em função da distância até a borda da imagem: DistBordaMax;
7. para cada tamanho de janela (iniciando com janela 3x3 e com acréscimos

de 4 em 4 *pixels*) menor do que JanMax ou DistBordaMax, calcular a Distância de Kullback-Leibler conforme a Equação 1;

8. armazenar somente o valor máximo obtido na etapa 7 e definir como sendo o valor do *pixel* na imagem de Distância de KL;

9. fim do algoritmo.

2.4 Metodologia de Análise dos Resultados

Inicialmente foram utilizadas as imagens ópticas de sensoriamento remoto para que fossem feitas delimitações das amostras referentes às classes de mudança e não mudança. No total foram delimitados 20 (vinte) polígonos para a classe de mudança e 20 (vinte) para a de não mudança, respectivamente, 1.800 e 2.209 *pixels*.

Paralelamente à delimitação das amostras das classes nas imagens ópticas, foi executado o algoritmo de detecção de mudanças multiescala sobre todos os atributos originais ou extraídos de datas diferentes (t_1 e t_2). Nesta etapa foi considerado que todas as bandas em trabalho possuíssem valores de nível de cinza com distribuição gaussiana.

Após a geração das imagens de mudança é iniciado o processo de coleta dos valores das amostras na imagem de Distância de KL. Observa-se que as imagens ópticas foram utilizadas somente para delimitar visualmente as classes, sendo os valores de níveis de cinza extraídos nesta etapa do processo sobre a imagem de distância.

Obtendo-se os valores das classes de mudança e não mudança, foi possível realizar uma análise, para cada atributo separadamente, buscando verificar qual foi o tamanho máximo da janela de multiescala (JanMax) que obteve a maior separabilidade entre as duas classes. Para esta análise foi utilizado o Critério de Fisher que, segundo Bishop (2006), busca analisar a separação entre duas classes através das médias e desvios padrões de suas amostras. Classes que possuem maior valor no Critério de Fisher (J), isto é, maior separação, podem possuir rotulações mais acuradas e obter melhores resultados nas classificações. O critério encontra-se na Equação 2, onde os valores de m_1 e m_2 são as médias das duas classes e os valores de s_1 e s_2 são os respectivos desvios padrões.

$$J = \frac{|m_1 - m_2|^2}{s_1^2 + s_2^2} \quad (2)$$

Após definir o tamanho JanMax para cada atributo, foi então realizado o processo de classificação sobre as respectivas imagens de Distância de KL. O método de classificação utilizado foi o de *Support Vector Machine* (SVM), método linear, com parâmetro de penalidade $C=100$. Detalhes deste método são descritos por Bishop [2006].

3. Resultado e Análise

Utilizando-se os 13 atributos em trabalho (bandas do Landsat TM B1, B2, B3, B4, B5 e B7; NDVI; ALOS/PALSAR de polarização HH, HV e VV; e bandas de decomposição de alvos de entropia, ângulo alfa e anisotropia) e aplicando o algoritmo desenvolvido com 13 diferentes tamanhos de JanMax (3, 7, 11, 15, 19, 23, 27, 31, 35, 39, 43, 47 e 51), foram geradas 169 (cento e sessenta e nove) imagens de Distância de KL. O Critério de Fisher foi então aplicado sobre todas estas imagens e os valores obtidos (J) com o respectivo tamanho de JanMax encontram-se apresentados na Tabela 1.

Após realizar a classificação SVM sobre as bandas selecionadas e utilizando os *pixels* dos 20 polígonos de cada classe como amostra de treinamento, foi realizada uma avaliação da classificação. Para a avaliação foram coletados 10 (dez) polígonos de cada classe, totalizando cerca de 1.000 *pixels* como amostras de teste para cada uma. Os resultados encontram-se na Tabela 1.

Tabela 1. Resultado da avaliação da classificação.

Atributo	Critério de Fisher (<i>J</i>)	Tamanho de JanMax	Acurácia Global	Kappa
B1	0,22	3	91,12	0,7844
B2	0,33	27	92,47	0,8221
B3	0,24	31	91,25	0,7884
B4	0,04	51	68,04	0,0240
B5	0,11	3	71,99	0,1799
B7	0,16	3	79,34	0,4484
NDVI	0,08	47	70,55	0,1097
HH/HV/VV	<0,01	3	68,14	0
H/Alfa/A	<0,01	51	68,14	0

Analisando a Tabela 1 é possível observar que os melhores resultados foram obtidos seguindo ordem semelhante à apresentada no gráfico da Figura 5 referente ao Critério de Fisher. Em ambos os casos os atributos oriundos dos dados ópticos de sensoriamento remoto obtiveram os melhores resultados, com destaque para as banda B1, B2 e B2 com acurácias globais acima de 90%. Já, os atributos originais ou extraídos de dados de SAR não conseguiram distinguir as duas classes, obtendo valores de Kappa iguais a zero.

4. Conclusões

As bandas que obtiveram os melhores resultados no processo de detecção de mudança foram as B1, B2 e B3 do sensor Landsat TM, atingindo acurácias globais acima de 90% e kappas próximos a 0,8. Segundo Jensen (2009) estas bandas (com faixas espectrais respectivamente de 0,45-0,52 μm , 0,52-0,60 μm e 0,63-0,69 μm) fornecem suporte para análise de uso da terra, solo e características da vegetação.

Referências

- Bishop, C.M. (2006), Pattern recognition and machine learning, Springer, 1st ed.
- Cloude, S. R.; Pottier, E. (1997) “An entropy based classification scheme for land application of polarimetric SAR”, IEEE Transactions on Geoscience and Remote Sensing. Vol 35. Pg 68-78.
- Inglada, J.; Mercier, G. (2007) “A new statistical similarity measure for change detection in multitemporal SAR images and its extension to multiscale change analysis”, IEEE Transactions on Geoscience and Remote Sensing. Vol 45. Pg 1432-1445.
- Jensen, J. R. (2009), Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres / Remote sensing of the environment: an earth resource perspective, PARENTESE EDITORA. 672 p. ISBN 85605070, 13: 9788560507061. (INPE--/).