

Um método de Classificação Não Supervisionada por Regiões

LEONARDO SANT'ANA BINS¹
GUARACI JOSÉ ERTHAL²
LEILA MARIA GARCIA FONSECA³

Instituto Nacional de Pesquisas Espaciais – INPE
Divisão de Processamento de Imagens – DPI

Caixa Postal 515
12201 São José dos Campos, SP, Brasil

¹leonardo@dpi.inpe.br

²gaia@dpi.inpe.br

³leila@dpi.inpe.br

Abstract. A clustering classification method is described and applied to Landsat TM images. This method differs from the conventional unsupervised classification, in the sense that the clustering algorithm is applied to a set of regions, obtained from the segmented image. The statistical parameters of these regions are used to classify each.

Key words: classification, clustering, segmentation, statistics.

1 Introdução

O problema de classificação de imagens de sensoriamento remoto tem sido um desafio na área de processamento de imagens. Vários algoritmos tem sido desenvolvidos, com o objetivo de melhorar os resultados da classificação. Quando comparados com o resultado de uma classificação manual, os resultados obtidos com estes algoritmos tem sido relativamente pior. O principal ponto a favor do fotointérprete, é que ele pode usar vários outros tipos de informações, tais como área e formato das regiões; informações contextuais, tais como as interrelações entre pixels e/ou regiões; informações topográficas e resultados de classificações anteriores, para auxiliar no processo de classificação da imagem.

Geralmente, na análise de imagens de sensoriamento remoto, o processamento é feito pixel a pixel, utilizando o atributo espectral do pixel. Um outro caminho é aquele em que a imagem é particionada em regiões, e são extraídos atributos espectrais, geométricos e contextuais, os quais são usados na classificação de cada região [Johnsson et al., 1991]. Esta abordagem é uma tentativa de incorporar outros tipos de informações além das espectrais, usualmente utilizadas, para melhorar os resultados da classificação.

Este artigo tem por objetivo apresentar resultados da classificação usando um algoritmo de “clustering” aplicado sobre um conjunto de regiões, caracterizadas pelos atributos estatísticos (média, matriz de covariância e área) —ISOSEG. Este método se

difere do método de classificação convencional não supervisionado, no sentido de que o algoritmo de “clustering” é aplicado sobre um conjunto de regiões, que é obtido à partir da imagem segmentada. Assim, a primeira etapa do método consiste em particionar a imagem em regiões e extrair os seus atributos [Bins et al, 1993; Erthal et al 1991]. A segunda etapa envolve a classificação das regiões usando o algoritmo de “clustering”, que será descrito na seção 3. O algoritmo é testado sobre uma imagem TM/Landsat, para uma região da Amazônia, e o resultado é mostrado. Uma avaliação, mais criteriosa, do desempenho da classificação digital de imagens TM/Landsat usando este algoritmo tem sido realizada [Santos et al, 1993].

2 Hipóteses

A única hipótese adotada para os dados é a de que eles obedeçam, marginalmente, uma distribuição normal k -variada, onde k é o número de bandas considerado. Isto é, a distribuição da observação em cada pixel é dada pela densidade, para todo $\mathbf{y} \in \mathbb{R}^k$:

$$\frac{1}{(2\pi|\Sigma|)^{k/2}} \exp\left(-\frac{1}{2}(\mathbf{y} - \boldsymbol{\mu})^T \Sigma^{-1}(\mathbf{y} - \boldsymbol{\mu})\right),$$

onde $|\Sigma|$ denota o determinante da matriz de covariâncias Σ , e $\boldsymbol{\mu} \in \mathbb{R}^k$ é o vetor de médias.

Assim, pode-se definir a distância de Mahalanobis entre dois pontos $\mathbf{x}, \mathbf{y} \in \mathbb{R}^k$ como:

$$(\mathbf{y} - \mathbf{x})^T \Sigma^{-1}(\mathbf{y} - \mathbf{x}). \quad (1)$$

Supondo-se também válida a independência entre diferentes observações, então o valor de (1) é a ocorrência de uma variável aleatória com distribuição χ^2 . Empregando-se a tabela da distribuição χ^2 com k graus de liberdade é possível testar a hipótese do valor \mathbf{x} ser uma ocorrência de uma certa distribuição normal multivariada. Desta forma, o valor \mathbf{x} poderá ser atribuído ou não a uma certa classe, formando assim uma regra de decisão.

Seja Z uma variável aleatória com distribuição χ^2 com k graus de liberdade. Seja $\alpha \in (0, 1)$. Seja $\mathbf{x} \in \mathbb{R}^k$, e seja

$$u = (\mathbf{x} - \boldsymbol{\mu}_j)^T \Sigma_j^{-1} (\mathbf{x} - \boldsymbol{\mu}_j)$$

a distância de Mahalanobis do ponto \mathbf{x} à classe j , caracterizada pelo vetor de médias $\boldsymbol{\mu}_j$ e pela matriz de covariâncias Σ_j . Então, se $\text{IPr}(Z \geq u) < \alpha$, com α valendo tipicamente 0.01, 0.05, etc. rejeita-se a hipótese de \mathbf{x} pertencer à classe j ao nível $1 - \alpha$.

3 Descrição do ISOSEG

Este algoritmo se baseia em técnicas de “clustering”, sendo estas técnicas já bastante conhecidas. Em [Duda, 1973], por exemplo, encontra-se uma ampla abordagem destas técnicas.

O algoritmo, descrito a seguir, utiliza a matriz de covariância e o vetor média das regiões para estimar os centros das classes. O algoritmo consiste, basicamente, de quatro etapas. A primeira delas envolve a seleção do número de classes e do limiar de aceitação. Este último define a distância entre os centros iniciais dos “clusters”, bem como o número de “clusters” que serão detectados pelo algoritmo. A lista de regiões é ordenada em ordem decrescente pela área. Espera-se que regiões com maior área sejam aquelas mais representativas da classe. O limiar de aceitação, dado em percentual, define a distância máxima de Mahalanobis a qual as regiões podem estar afastadas do centro da classe para serem consideradas como pertencentes a esta classe. De outra forma, podemos dizer que este limiar define um hiperelipsóide no espaço de atributos de tal forma que todas as regiões, cujas médias estiverem dentro do mesmo, serão consideradas como pertencentes a uma dada classe. Os valores das distâncias para cada percentual estão definidas na tabela do χ^2 .

A segunda etapa envolve a detecção das classes iniciais. O procedimento é o seguinte: toma-se os parâmetros estatísticos da primeira região na lista, como sendo os parâmetros iniciais da classe. Em um processo iterativo, remove-se da lista todas as regiões cuja distância de Mahalanobis (equação (1)) da classe seja inferior ao limiar de aceitação. Os

novos parâmetros estatísticos da classe são recalculados. Este processo é repetido até que não haja mais nenhuma remoção de regiões da lista. As próximas classes são reconhecidas da mesma forma, até que a lista de regiões fique vazia.

Na etapa anterior as regiões foram classificadas segundo uma ordem de geração dos “clusters”, podendo ocorrer que uma dada região tenha sido classificada erroneamente. Na terceira etapa as regiões são reclassificadas segundo os centros definidos na etapa anterior, para corrigir eventuais distorções. Se o número de classes detectadas for maior que o número definido na fase inicial, algumas classes devem ser eliminadas. A eliminação de classe é feita da seguinte forma: as classes são ordenadas, em ordem crescente, segundo o número de regiões classificadas como aquela classe. As classes com menor número de regiões são eliminadas, e suas regiões são reclassificadas para as classes restantes, usando o critério da mínima distância de Mahalanobis (equação (1)).

4 Resultados

Uma imagem TM/Landsat órbita 224-68-X da região da Amazônia (Serra do Roncador, estado do Mato Grosso) de tamanho 512x512 pixels foi selecionada para testar o método de classificação descrito anteriormente. As Figuras 1, 2, 3 mostram as bandas 3, 4 e 5 da imagem original, respectivamente. Primeiro, a imagem é filtrada usando o filtro da mediana [Gonzalez, 1992], com o objetivo de suavizar a textura e não perder informações de bordas, que são importantes na fase de segmentação. A imagem com as três bandas é segmentada, e a partir desta imagem segmentada, uma lista de regiões com seus atributos é gerada. A Figura 4 mostra os contornos das regiões sobrepostos à banda 5. Sobre a lista de regiões é aplicado o algoritmo ISOSEG, que gera na saída uma imagem classificada, mostrada na Figura 5. Avaliações do desempenho deste classificador estão sendo realizadas [Santos et al, 1993] sobre imagens da região amazônica, para caracterização do uso do solo.

5 Agradecimentos

Este trabalho foi desenvolvido com recursos do Projeto Temático de Equipe No. 91/3532-2 da Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP). Agradecemos a Alejandro C. Frery por sua colaboração na elaboração deste artigo.

6 Referências

Bins, L.S.; Erthal, G.J.; Fonseca, L.M.G. Três abordagens para segmentação de Imagens de

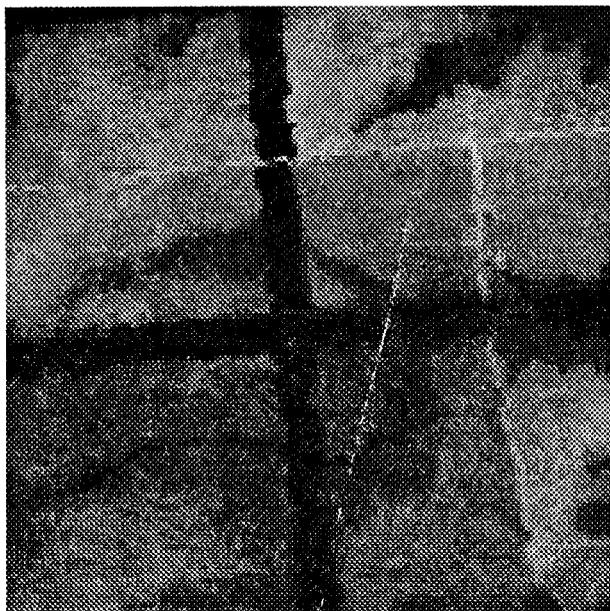


Figura 1: Banda 3.

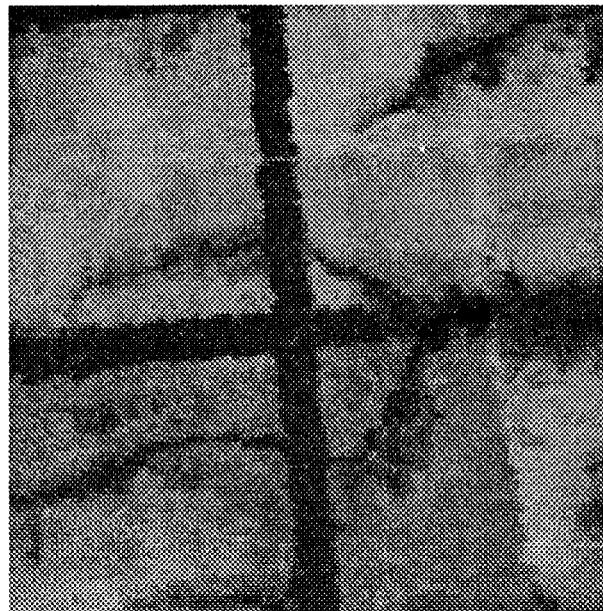


Figura 3: Banda 5.



Figura 2: Banda 4.



Figura 4: Banda 5 e contornos dos segmentos.

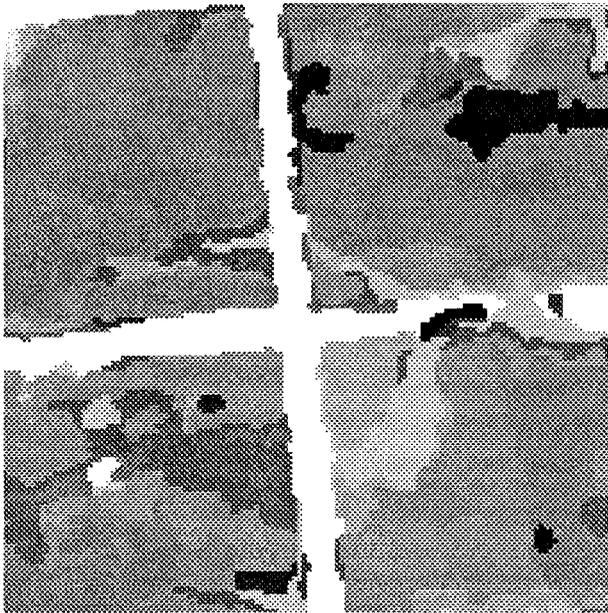


Figura 5: Imagem classificada.

Sensoriamento Remoto. Submetido ao VI Simposio Latinoamericano de Percepción Remota. Cartagena, Colombia, 3-8, outubro, 1993.

Duda, R.O.; Hart, P.E. *Pattern Classification and scene analysis*. New York, Wiley, 1973.

Erthal, G.J.; Fonseca, L.M.G.; Bins, L.S.; Velasco, F.R.D.; Monteiro, A.M.V. Um sistema de segmentação e classificação de imagens de satélite. IV SIBGRAPI'91, São Paulo, 1991, Julho, p.237-240.

Gonzalez, R.C.; Woods, R.E. *Digital Image Processing*. Reading, Addison-Wesley, 1992.

Johnsson, K.; Kanonier, J. Knowledge Based Land-use Classification. Proceedings of IGARSS'91, Espoo, Finland, 1991, vol III, p.1847-1850.

Santos, J.R.; Venturieri, A.; Bernardes, S; Krug, T.; Erthal, G.J.; Bins, L.S. Uso do SGI na avaliação do desempenho de classificação baseada em segmentos para a caracterização de uso da terra na Amazônia brasileira. Submetido ao VI Simposio Latinoamericano de Percepción Remota. Cartagena, Colombia, 3-8, outubro, 1993.