

# ESTUDO DE MÉTODOS DE PÓS-PROCESSAMENTO APLICADO A PROBLEMA DE CLASSIFICAÇÃO DE PADRÕES

Luciano Vieira Dutra  
José Carlos Moreira

Ministério da Ciência e Tecnologia - MCT  
Instituto de Pesquisas Espaciais - INPE  
Caixa Postal 515, 12201-São José dos Campos, SP, Brasil

## RESUMO

Para a separação e identificação dos diversos objetos de interesse dentro de uma imagem multiespectral, normalmente são utilizados métodos para classificação individual dos pontos das imagens (denominados *pixels*). Este tipo de método não utiliza a informação espacial existente entre os *pixels* de uma mesma classe, incorrendo em maior erro de classificação. A informação espacial pode ser adicionada à fase de classificação, normalmente com uma elevação significativa dos custos computacionais, ou pode ser aproveitada a posteriori como uma fase de pós-processamento. Apresentam-se neste trabalho, dois processos de pós-processamento. O primeiro é baseado em um levantamento de um histograma local de classe de *pixels*. O *pixel* central é reclassificado para a classe de maior frequência local, desde que seja maior que um certo limiar estabelecido. Este procedimento tem sido utilizado em diversas aplicações e, como resultado, observa-se razoável aumento nos índices de desempenho e uma melhora na qualidade visual das imagens classificadas. O segundo processo é baseado em uma generalização do conceito de erosão-dilatação aplicado às classes separadamente; não teve um resultado tão bom quanto o primeiro em termos de precisão de classificação mas permitiu a identificação de *pixels* com mais de uma classe, denominados *pixels* mistos, que ocorrem normalmente nas fronteiras entre regiões de classes diferentes facilitando a determinação mais precisa dessa fronteira.

## ABSTRACT

In order to identify the various objects within a multispectral image, per point classification methods are normally used. This kind of method does not use the spatial information among the pixels of the images, thereby producing a higher classification error. The spatial information can be added before, within and after the classification stage. This paper presents two methods of postprocessing to take account of the spatial relationship among pixels. The first one is based on a local histogram of pixel's class. The central pixel is reclassified to the most occurring class, provided the frequency is higher than a selected threshold. The results showed a fairly better classification performance and a good improvement of the visual appearance. The second method is based on a generalization of the expansion-shrinking concept of binary images applied to the individual classes each one. This method did not lead to a better performance in terms of classification precision but allowed the identification of pixels of mixed classes, which occur mainly in the border between classes, allowing a better localization of these frontiers.

## 1. INTRODUÇÃO

Os processos mais comuns de classificação de padrões normalmente operam na base de um *pixel* (elemento de imagem) por vez, onde somente a informação espectral dos diversos canais é utilizada. O mapa resultante de uma classificação desse tipo apresenta uma aparência não-uniforme (Figura 1) devido ao ruído introduzido pelo processo de quantização, pelos sensores e pelos fatores ambientais, ou seja, ao observar os resultados existirão muitos *pixels* com classificação divergente de seus vizinhos.

É razoável, entretanto, esperar que exista algum grau de correlação espacial de um *pixel* para o *pixel* vizinho e que o aproveitamento dessa correlação melhore o desempenho do classificador

Essa informação espacial pode ser incluída no processo de classificação de alguma maneira, seja numa fase de pré-processamento, quando se produzem transformações nos atributos para diminuir o ruído ou extrair atributos que carreguem a informação espacial antes do processo de classificação (Dutra e Mascarenhas, 1984); seja em tempo de classificação utilizando-se a teoria de decisão composta (Duda e Hart, 1973); ou ainda depois de efetuar a classificação, numa fase de pós-processamento (Schowengerdt, 1983), quando operações são realizadas sobre o mapa classificado de maneira a reduzir a aparência ruidosa.

Neste trabalho serão propostos alguns métodos de pós-processamento cujo resultado será analisado quanto aos aspectos qualitativo da imagem classificada e quantitativo (referente a melho

ria nas matrizes de classificação).




Fig. 1 - Imagem classificada de Guariba, Estado de São Paulo.

## 2. O MÉTODO DE CLASSIFICAÇÃO DE PADRÕES

O método de classificação que será usado neste trabalho, é a regra de decisão por máxima verossimilhança (Velasco et alii, 1978).

Decide-se que um padrão  $\vec{x}$  pertence a uma classe  $w_i$  se e somente se:

$$g_i(\vec{x}) = p(\vec{x}/w_i) P(w_i) \geq p(\vec{x}/w_j) P(w_j) = g_j(\vec{x})$$

$$i = 1, \dots, N,$$

onde

$N$  = número de classes

$g_i(\vec{x}) = (p(\vec{x}/w_i) P(w_i))$  é a função discriminante para a classe  $w_i$ .

Para densidades gaussianas pode-se derivar:

$$g_i(\vec{x}) = \ln P(w_i) - \frac{1}{2} \ln |\Sigma_i| - \frac{1}{2} (\vec{x} - \mu_i)^T \Sigma_i^{-1} (\vec{x} - \mu_i),$$

onde

$\Sigma_i$  = matriz de covariância

$\mu_i$  = vetor de média da classe  $w_i$ .

Esse esquema de categorização assinala cada um dos padrões apresentados a alguma das classes definidas anteriormente na fase de treinamento. Em problemas de sensoriamento remoto, no entanto, há sempre pontos que, de fato, não deveriam pertencer a nenhuma das classes definidas, devido à incerteza na definição da área de treinamento e na definição de um número menor de classes que as realmente existentes.

Para evitar que pontos que não pertençam a nenhuma classe sejam classificados, rejeita-se para a classe  $w_i$  o ponto cuja função discriminante for menor que um certo limiar  $T_i$  para a classe  $w_i$ . A regra passa a ser então:

$$\vec{x} \in w_i \text{ se: } g_i(\vec{x}) \geq g_j(\vec{x}) \text{ para } i \neq j$$

$$\text{e } g_i(\vec{x}) \geq T_i$$

onde  $T_i$  é limiar para a classe  $w_i$ .

## 3. MÉTODOS DE PÓS-PROCESSAMENTO

Uma técnica de suavização de classificação que usa a idéia de mínima área foi descrita por Davis e Peet (1977). Esse procedimento altera uma região conectada de uma só classe que tenha uma área menor que um certo limiar. Essa região adota a classe da região vizinha de maior fronteira. Diferentes limiares podem ser especificados para cada classe e diferentes pesos podem ser aplicados aos *pixels* de borda.

Outro exemplo de técnica de suavização é o filtro de Goldberg et alii (1975). Aqui uma janela três x três é transladada sobre a imagem e a frequência das classes dentro da janela é determinada. Se a frequência da classe do *pixel* é maior que um certo limiar  $T_1$ , nenhuma mudança é feita. Caso contrário, se a frequência da classe de maior frequência é menor que um certo limiar  $T_2$  nenhuma mudança é feita, senão calcula-se a distância euclidiana no espaço de atributos entre os centros da classe do *pixel* central e a classe mais frequente. Se essa distância é menor que um certo limiar  $T_3$ , muda-se a classe do *pixel* central para a classe do *pixel* mais frequente.

Como resultado do uso desse algoritmo, Goldberg relata melhoria na precisão de mapeamento das classes com sensível diminuição do ruído de classificação.

O primeiro algoritmo proposto neste trabalho é uma variante para o algoritmo de Goldberg, denominado UNITOT, que focaliza uma janela 3 x 3 que é transladada sobre a imagem (ver algoritmo I). Nessa região 3 x 3 conta-se o número de vezes que aparece cada classe, sendo que a classe do *pixel* central é contada  $P$  vezes, onde  $P$  é um peso fornecido pelo analista. O ponto central é reclassificado para a classe de maior frequência, desde que essa frequência seja maior que um certo limiar (LI) estabelecido pelo usuário (Figura 2). Caso contrário, o ponto central permanece não-classificado.

			Classe Contagem	
1	1	1	1	5
1	2	3	2	3
1	3	2	3	2

Fig. 2 - Contagem em uma região 3 x 3 por peso = 2.

No exemplo dado se o limiar é 4, o *pixel* central adota a classe 1. Para o limiar 5, o *pixel* central fica sem classificação.

### Algoritmo I

Dados LI = limiar de reclassificação  
P = peso para *pixel* central.

$$\text{Seja } N(k) = \sum_{i=1}^3 \sum_{j=1}^3 \delta(k - a_{ij}),$$

onde

$a_{ij}$  é a classe do *pixel* (i, j) em uma região 3 x 3

$\delta(k - a_{ij}) = 1$  se  $k = a_{ij}$  i, j  $\neq$  2

$\delta(k - a_{ij}) = P$  se  $k = a_{22}$

$\delta(k - a_{ij}) = 0$  se  $k \neq a_{ij}$

Passos:

1.  $\bar{K} = (k / N(k) \text{ é máximo});$
2. Se  $N(\bar{K}) > LI$ , então  $a_{22} \leftarrow \bar{K}$ ; senão  $a_{22} \leftarrow 0$  (ponto não-classificado).

O segundo algoritmo utilizado, denominado UNITEM (algoritmo II), processa os planos de classificação separadamente. Nesse caso poderá acontecer de um *pixel* ficar assinalado em mais de uma classe, criando-se assim automaticamente ou tras categorias de *pixels* de classificação mistos. Também nesse caso uma janela 3 x 3 é transladada sobre a imagem.

Algoritmo II

- para cada plano de classificação  $w_k$  existente, escolha dois limiares de reclassificação: LIMINF (limiar inferior) e LIMSUP (limiar superior).
- para uma janela 3 x 3 sobre um plano de classificação calcule a expressão:

$$N = \sum_{i=1}^3 \sum_{j=1}^3 b_{ij}$$

onde  $b_{ij} = 1$  (i e j  $\neq$  2) se  $a_{ij} = w_k$ ;  
 $= 0$  (i e j  $\neq$  2) se  $a_{ij} \neq w_k$ .

$a_{ij}$  é a classe do *pixel* (i, j).

Passos:

1. se  $N > LIMSUP$ , então  $b_{22} \leftarrow 1$ ;  
senão
2. se  $N < LIMINF$ , então  $b_{22} \leftarrow 0$ ;  
senão
3. o ponto permanece inalterado.

O filtro UNITEM, em casos limites, representa as operações de expansão ( $LIMINF = LIMSUP = 0$ ) e contração ( $LIMINF = LIMSUP = 8$ ) (Rosenfeld e Kak, 1982), que podem ser utilizados em vários processos de análise de geometria de imagens. Basicamente o filtro UNITEM conta o número de vizinhos de cada ponto da imagem.

Se o número de vizinhos do ponto é maior que o limiar superior (LIMSUP) o ponto central da janela é sempre assinalado para 1; se o número de vizinhos é menor que um limiar inferior, o ponto central é sempre assinalado para zero, caso contrário ele permanece sem alteração.

Uma variação do filtro UNITEM é o denominado filtro UNIPAG (algoritmo III), que também processa os planos de classificação separadamente. É um filtro que não permite que pontos que tenham poucos ou muitos vizinhos permaneçam.

Utiliza-se esse filtro em detecção de bordas de regiões conectadas. Os limiares servem para determinar a espessura de borda que está sendo detectada.

Para um processo de detecção de uma região classificada, primeiro usa-se o filtro UNITEM ou UNITOT uma ou mais vezes para eliminar pontos e buracos isolados, ou mesmo pequenos grupos de pontos ou buracos dentro do tema de interesse. Em seguida, com o uso do filtro UNIPAG, determinam-se as bordas das regiões da classe focalizada.

Algoritmo III

- Escolha dois limiares de reclassificação LIMINF (limiar inferior) e LIMSUP (limiar superior).

- Para uma janela 3 x 3 sobre o plano de interesse  $w_k$ , calcule a expressão:

$$N = \sum_{i=1}^3 \sum_{j=1}^3 b_{ij}$$

onde:  $b_{ij} = 1$  se  $a_{ij} = w_k$  (i e j  $\neq$  2)  
 $= 0$  se  $a_{ij} \neq w_k$  (i, j  $\neq$  2)

$a_{ij}$  é a classe do *pixel* (i, j) dentro da janela.

1. se  $N > LIMSUP$ , então  $b_{22} \leftarrow 0$ ;  
senão
2. se  $N < LIMINF$ , então  $b_{22} \leftarrow 0$ ;  
senão
3. o ponto permanece inalterado (1 ou 0).

Usando  $LIMINF = 1$  e  $LIMSUP = 7$ , todos os pontos que têm menos de 1 vizinho (ponto isolado) e mais de 7 vizinhos (ponto cercado) são apagados. Mascarenhas e Dutra (1980) utilizaram o algoritmo III (UNIPAG) para detectar as bordas de textura rugosa produzidas por um algoritmo de detecção bayesiana depois de sucessivos processos de propagação e contração para uniformizar o campo de bordas.

O mesmo processo se aplica a campos classificados. Estes podem ser processados por filtros do tipo UNITOT ou UNITEM para uniformização e depois pelo UNIPAG para detectar as fronteiras.

#### 4. RESULTADOS

Os experimentos foram efetuados utilizando do uma imagem LANDSAT-C, órbita 78, ponto 27, de abril de 1978, sobre a área de Ribeirão Preto. Obtiveram-se também imagens de avião sobre a mesma área, o que permitiu escolher as áreas teste e de treinamento com boa precisão para as classes cana, cananova, pasto, água, infraestrutura e mata.

Algoritmo I - Resultados

Foram efetuados testes variando o limiar e os pesos com todas as combinações possíveis para  $1 \leq LI \leq 5$ ,  $1 \leq P \leq 3$  e  $P \leq LI$ , pode-se destacar o resultado consolidado na Tabela 1 onde se observa o melhor resultado em termos de melhoria no Desempenho médio (Dm) para a combinação Limiar = 3 e Peso = 2 (para limiar 2 e peso 2 o resultado também é o mesmo) e Limiar de classificação = (L) 6.

Desempenho médio (Dm) é a média de classificação correta dos *pixels* nas áreas de treinamento e teste. Abstenção média (Am) e Confusão média (Cm) tem definição similar.

Para a combinação LI=5, P=1 ou seja, com limiar relativamente alto, existe considerável diminuição da Confusão média (Cm) com manutenção do Desempenho médio (Dm) por níveis do resulta do do sem filtro.

Ao comparar a fotografia da imagem classificada original (Figura 1) com a imagem filtrada para o caso limiar (LI) igual a 3, peso (P) igual a 2, o limiar de classificação (L) igual a 6 pode-se notar uma melhoria na qualidade visual devido à redução do ruído de classificação (Figura 3).




Fig. 3 - Imagem de Guariba com UNITOT LI = 3, P = 2 e L = 6.

No trabalho de Moreira et alii (1982), onde foi utilizado o filtro UNITOT, foi efetuado um tratamento estatístico sobre os resultados da classificação de cultura de trigo no município de Cruz Alta/RS; a conclusão foi que, também neste experimento, para o limiar LI = 2 e peso P = 2 a melhoria é significativa e oferece uma estimativa de área tão precisa quanto aquelas obtidas sem a sua utilização. Porém, pelo baixo erro de inclusão e maior classificação correta, este método aumentou a precisão de mapeamento.

TABELA 1  
DESEMPENHO PARA ÁREAS DE TREINAMENTO  
E TESTE (UNITOT)

a) ÁREAS DE TREINAMENTO L = 6

LIMIAR(LI)	PESO(P)	Dm	Am	Cm
SEM FILTRO		95,7	0,3	4,0
3	2	98,5	0	1,5
5	1	97,0	2,8	0,3

b) ÁREAS TESTE L = 6

LIMIAR(LI)	PESO(P)	Dm	Am	Cm
SEM FILTRO		80,6	0,3	19,2
3	2	85,4	0	14,6
5	1	79,8	14,1	6,8

Como conclusão pode-se estabelecer que em todo é particularmente útil para melhorar a qualidade visual da imagem com reflexos positivos sobre as matrizes de classificação, principalmente quando se usa um limiar LI alto, obtendo-se dessa forma sensível redução na confusão média. Isto sugere que em regiões de classificação duvidosa existirá na janela 3x3 pixels com as mais diversas classes, o que impede que qualquer classe em particular sobressaia. Nesses casos, onde não existe predominância em uma região 3x3 será melhor procurar o pico de frequência numa região maior, por exemplo 5x5.

Algoritmo II - Resultados

Foram realizados 3 conjuntos de testes variando os limiares superior e inferior, conforme mostra a Tabela 2, e aplicando os mesmos limiares para cada plano de classificação correspondentes às 6 classes do experimento.

Em seguida foram obtidas as matrizes de classificação; os resultados para os índices de desempenho encontram-se resumidos na mesma Tabela 2.

TABELA 2  
ÍNDICES DE DESEMPENHO PARA O ALGORITMO II

CASO	LIMINF	LIMSUP	TREINAMENTO			TESTE		
			Dm	Am	Cm	Dm	Am	Cm
1	SEM FILTRO		95,7	0,3	4,0	80,6	0,3	19,2
2	2	2	95,8	0,2	4,2	75,5	0,0	24,5
3	2	4	97,5	0,1	2,4	80,6	0,5	18,9
4	4	6	97,2	1,9	0,9	79,5	9,8	10,6

Pelo resultado da tabela acima observa-se que não houve melhoria significativa com relação aos índices de classificação correta, abstenção e ligeira melhoria nos índices de confusão média, porque a maior parte dos pixels com classes trocadas encontram-se perto das bordas, e quando se faz a filtragem por temas separados, pode acontecer que mais de uma classe fique assinalada a um pixel. Esses pixels com múltiplas classes são considerados como pixels classificados erroneamente, aumentando a contagem da Confusão média (Cm) e sugerem a existência real de mais de uma classe naquele pixel. Assim o método UNITEM pode ser utilizado como um método rápido para a investigação de pixels mistos e para o cálculo da área abrangida por cada classe. Não serão levados em consideração subáreas de pixel conforme o número de classes que ali existem.

Além disso a aplicação do algoritmo sugere sua utilização como delimitador de borda verdadeira entre duas regiões quaisquer, partindo da hipótese de que é no *pixel* misto que passa a separação entre as classes.

Os filtros com valores mais elevados de limiares conduzem a maiores diminuições na confusão média; os filtros com valores mais baixos conduzem a um maior número de *pixels* identificados como mistos. Nas Figuras 4, 5 e 6 as linhas vermelhas representam o lugar geométrico dos *pixels* mistos e são mais presentes para os casos com menores limiares.

A Tabela 3 apresenta a matriz de classificação para as áreas teste para o caso 2 onde aparecem os *pixels* que foram classificados por mais de uma classe. Os valores expressos na Tabela 3 indicam a percentagem de pontos da classe que aparece na mesma coluna acima, pontos estes que foram reclassificados para a classe que aparece à esquerda na mesma linha. Na Tabela 3, por exemplo, 12,5% dos *pixels* da classe 3 na área teste foram reclassificados para as classes 1 e 3 simultaneamente.



Fig. 5 - Filtro UNITEM caso 3.



Fig. 4 - Filtro UNITEM caso 2.



Fig. 6 - Filtro UNITEM caso 4.

TABELA 3

MATRIZ DE CLASSIFICAÇÃO DE ÁREAS TESTE PARA LIMINF = 2 E LIMSUP = 2

NOME DAS CLASSES	1	2	3	4	5	6
Não-classificadas	0,0	0,0	0,0	0,0	0,0	0,0
1 - Cana	98,1	0,0	13,9	0,0	0,0	0,0
2 - Cananova	0,0	73,1	0,0	0,0	16,7	0,0
3 - Pasto	0,0	0,0	47,2	2,8	2,8	0,0
4 - Água	0,0	0,0	0,0	80,6	5,6	0,0
5 - Infraestrutura	0,0	1,9	0,0	0,0	41,7	0,0
6 - Mata	0,0	0,0	5,6	0,0	0,0	100,0
Classes 1 e 3	1,9	0,0	12,5	2,8	0,0	0,0
Classes 2 e 5	0,0	25,0	0,0	0,0	16,7	0,0
Classes 1 e 6	0,0	0,0	19,4	0,0	0,0	0,0
Classes 3 e 4	0,0	0,0	1,4	13,9	2,8	0,0
Classes 3 e 5	0,0	0,0	0,0	0,0	5,6	0,0
Classes 2 e 3	0,0	0,0	0,0	0,0	8,3	0,0

Desempenho médio (Dm) = 75,5%

Abstenção média (Am) = 0,0%

Confusão média (Cm) = 24,5%

A matriz de classificação para as áreas teste caso 3 (limiares intermediários) apresenta menores valores percentuais de presença de pixels mistos e para o caso 4 (maiores limiares) não apresenta valores percentuais de presença de pixels mistos mas tem menor Confusão média (Cm).

A utilização do UNITOT e UNITEM pode ser iterativa, e a cada iteração podem-se variar os limiares para refinar ainda mais o processo de uniformização sem deslocar muito as fronteiras de seus locais originais.

O filtro UNIPAG (algoritmo III) aplicado ao campo classificado da classe cana, com limiares 1 e 7, depois de filtrado pelo UNITOT 3 vezes conduz ao mapa de bordas expresso na Figura 7.

Como conclusão geral pode-se estabelecer que o método UNITOT é mais eficaz com relação à melhoria do aspecto visual e dos índices de desempenho na matriz de classificação. O método UNITEM permite, no entanto, estabelecer tratamentos convenientes para classes em separado, bem como identificar *pixels* mistos, principalmente nas bordas.

O presente trabalho daqui por diante vai se desenvolver no sentido de estabelecer com exatidão a precisão do mapeamento, principalmente das bordas, com a utilização dos *pixels* mistos. Outros métodos de pós-processamento serão desenvolvidos baseados na determinação da área mínima para permanência de uma classe.




Fig. 7 - Bordas da classe 1.

## 5. REFERÊNCIAS BIBLIOGRÁFICAS

- DAVIS, W.A.; PEET, F.G. A method of smoothing digital thematic maps. *Remote Sensing of Environment*, 6(1): 45-49, 1977.
- DUDA, R.D.; HART, P.E. *Pattern classification and scene analysis*. New York, NY, John Wiley, 1973.
- DUTRA, L.V.; MASCARENHAS, N.D.A. Some experiments with spatial feature extraction methods in multispectral classification. *International Journal of Remote Sensing*, 5(2): 303-313, Mar./Apr., 1984. Publicado como relatório INPE-2443-PRE/144.
- GOLDBERG, M.; GOODENOUGH, D.; SHLIEN, S. Classification methods and error estimation for multispectral scanner data. In: CANADIAN SYMPOSIUM ON REMOTE SENSING, III, 1975.
- HARALICK, R.M.; SHANMUGAM, K; DINSTEN, I. Textural features for image classification. *IEEE Transactions on Systems, Man and Cybernetics*, 1973 SMC-3(6): 610-621.
- MASCARENHAS, N.D.A.; DUTRA, L.V. Um método para detecção de bordas de textura em imagens de recursos naturais. In: SIMPÓSIO SOBRE APLICAÇÕES GRÁFICAS POR COMPUTADOR E SISTEMAS GRÁFICOS INTERATIVOS, II, São Paulo, 1980, Anais V, 2p - 211-231.
- MOREIRA, M.A.; CHEN, S.C.; LIMA, A.M. Estudo do método uniformização de temas (UNITOT) e análise da correlação entre áreas estimadas utilizando-se dados LANDSAT e fotografias aéreas. In: SIMPÓSIO BRASILEIRO DE SENSORIA MENTO REMOTO, II, Brasília, DF, 1982, Anais Vol. 3, p. 935-942.
- ROSENFELD, A.; KAK, A.C. *Digital Picture Processing*. New York, NY, Academic, 1982.
- SCHOWENGERDT, R.A. *Techniques for image processing and classification in remote sensing*. New York, NY, ACADEMIC, 1983.
- VELASCO, F.R.D.; PRADO, L.O.C.; SOUZA, R.C.M. *Sistema Maxver: manual do usuário*. São José dos Campos, INPE, julho 1979 (INPE-1315-NTI/110).