

Conjuntos Difusos em Processamento de Imagens Digitais

Édis Mafra Lapolli^{1,2}

Ricardo Miranda Barcia³

Ana Maria Benciveni Franzoni^{1,4}

Lia Caetano Bastos¹

¹ Universidade Federal de Santa Catarina

Departamento de Engenharia Civil - CTC

C.P.476 - Campus Universitário - Trindade - Florianópolis - SC

CEP 88010-970

ecv1eml@ecv.ufsc.br

² Université de Montpellier II

Laboratoire d'informatique de robotique et de microelectronique de Montpellier - France

³ Universidade Federal de Santa Catarina

Departamento de Engenharia de Produção e Sistemas - CTC

⁴ Universidade Estadual Paulista

Instituto de Geociências e Ciências Exatas - CPGG

RESUMO

Entre as aplicações de Sensoriamento Remoto, a classificação de imagens é uma das mais importantes, sendo utilizada, principalmente, para a elaboração de mapas de uso/cobertura do solo. Esses mapas representam informações geográficas e cada região é associada a uma determinada classe de uso/cobertura do solo (solo exposto, vegetação, etc). Assim, a maioria dos classificadores tem como meta a atribuição de cada pixel a uma classe. As informações geográficas, porém, não são precisas. Muito comumente, mais de uma classe está presente numa determinada área do terreno. A associação do pixel a uma única classe faz com que parte da informação disponível não seja considerada.

Neste trabalho, é proposta uma abordagem, baseada na teoria dos conjuntos difusos, para processamento de imagens digitais.

Os métodos convencionais de classificação de imagens revelam-se muitas vezes problemáticos, no que se refere aos limites das classes e à própria resposta espectral, dentro de uma mesma classe. Esses métodos atribuem cada pixel a somente uma determinada classe, ou seja a uma classe de cobertura do solo. Portanto, para os pixels que sejam representativos de cada uma das classes, não existem problemas, enquanto para pixels que representem as classes de uso do solo, ou seja, pixels com mais de uma classe espectral, podem ocorrer distorções, tanto no cálculo dos parâmetros representativos da classe como no próprio processo de classificação.

A introdução da teoria dos conjuntos difusos permite identificar os pixels bem representativos de cada classe, bem aqueles que apresentam misturas de classes.

ABSTRACT

The utilization of the remote sensing technique for classifying images is one of the most for the building of land use / coverage maps. These maps represent geographic data and each area is related to an established land use / coverage category (uncovered soil , vegetation, etc.). Therefore, most of classifiers aim at relating a pixel to a single class. However, the data are not accurate. Commonly, more than a class are present at a given piece of land. The relation of a pixel to a single class can result in loss of part of the available data.

This paper approaches the theory of fuzzy sets as a way of processing digital images.

Traditional methods of image classification have often shown to be troublesome, especially with respect to the class limits and spectral responses inside a class. Such methods related each pixel to a single class, i.e., to a land coverage class. While there are no difficulties with pixels which represent a single class, pixels which present more than a spectral class may show distortions, either on the measurements of class characteristic parameters or on the classification process itself.

The introduction of fuzzy data allows to identify pure characteristic pixels as well as those which represent more than a single class.

1. INTRODUÇÃO

Os métodos convencionais de classificação de imagens revelam-se muitas vezes problemáticos, no que se refere aos limites das classes e a própria resposta espectral, dentro de uma mesma classe. Esses métodos atribuem cada pixel a somente uma determinada classe, ou seja a uma classe de cobertura do solo. Portanto, para os pixels que sejam bem representativos de cada uma das classes, não existem problemas, enquanto para pixels que representem mais de uma classe espectral, podem ocorrer distorções, tanto no cálculo dos parâmetros representativos da classe como no próprio processo de classificação.

Neste trabalho, é proposta uma abordagem, baseada na teoria dos conjuntos difusos, para processamento de imagens digitais.

A teoria dos conjuntos difusos fornece uma ferramenta mais adequada para modelar dados que contenham imprecisões ou que não se consiga fazer uma distinção entre eles, podendo um elemento pertencer a mais de um conjunto. Portanto, sua aplicação no processo de classificação permitirá não só identificar os elementos que pertencem a cada uma das

classes, como também aqueles que apresentam misturas de classes.

É introduzida, inicialmente, uma partição difusa do espaço espectral, dado que a abordagem desenvolvida fundamenta-se nesse conceito. A seguir, são apresentados os pontos essenciais do algoritmo. Após, o algoritmo completo é especificado.

2. PARTIÇÃO DIFUSA DO ESPAÇO ESPECTRAL

Os pixels, numa imagem digital, são definidos pelo vetor cujos componentes são os níveis de cinza em cada uma das bandas espectrais. Assim, cada pixel representa um ponto no espaço espectral por elas definido.

Dado um conjunto de pixels X , classificá-lo significa atribuir um rótulo a cada ponto de X . Esses rótulos (classes, no caso de classificação de imagens digitais) podem apresentar limites perfeitamente definidos, não acarretando incerteza quanto à atribuição realizada. Nesse caso, classificar um pixel significa particionar o espaço espectral em regiões disjuntas e atribuí-lo a uma, e somente uma, das regiões, mediante o emprego de regras de decisão definidas precisamente (Figura 1).




FIGURA 1 - Partição do Espaço Espectral

Contudo, como decorrência de imprecisões intrínsecas ao sistema real, as fronteiras entre as classes podem ser vagas ou difusas, conduzindo à impossibilidade de estabelecer critérios precisos (crisp) para as funções discriminantes. Conseqüentemente, um

determinado pixel pode pertencer, simultaneamente, a mais de uma das classes utilizadas para particionar o espaço espectral. Nesse caso, o processo de classificação consiste em realizar uma partição difusa do espaço espectral [Lapolli (1994)]. Essa partição

difusa é representada numa matriz $[f_{ki}]$, onde $k = 1, \dots, c$, sendo c o número de classes e $i = 1, \dots, n$, sendo n o total de pixels observados na imagem.

Uma representação esquemática dessa partição difusa do espaço espectral pode ser observada na Figura 2. Os círculos concêntricos representam cortes nas

funções de pertinência das classes correspondentes. Os valores de pertinência variam inversamente ao comprimento do raio. É observada, nessa figura, a sobreposição de classes em alguns pixels, o que caracteriza os casos em que existe possibilidade de um pixel conter mais de uma classe.




FIGURA 2 - Partição Difusa do Espaço Espectral

3. ALGORITMO PARA CLASSIFICAÇÃO DIFUSA

No algoritmo proposto, toda a informação disponível é utilizada para determinar as pertinências do pixel às diferentes classes.

3.1. Função de Pertinência Utilizada no Algoritmo para Classificação Difusa

O algoritmo apresentado baseia-se no método de classificação por máxima verossimilhança. O algoritmo de máxima verossimilhança parte do pressuposto de que os níveis de cinza de cada classe seguem uma distribuição multivariada (em geral a distribuição normal) e a sua regra de decisão consiste em atribuir o pixel à classe onde $p(x/c_i)p(c_i)$ seja máximo. Por trabalhar com partições do espaço espectral no contexto da teoria clássica dos conjuntos, esse algoritmo atribui pertinência 1 à classe onde $p(x/c_i)p(c_i)$ é máximo e nenhuma pertinência às demais classes. A aplicação dessa regra de decisão deixa de lado informações importantes sobre as probabilidades de o pixel pertencer a outras classes.

A existência de probabilidades não nulas em outras classes leva a supor que existem pertinências não nulas a essas classes. A abordagem proposta considera que, para realizar a classificação, deve-se criar uma partição difusa do espaço espectral. Com essa finalidade, a pertinência do pixel a uma classe é definida como:

$$f_c(x) = \frac{P_c^*(x)}{\sum_{i=1}^n P_i^*(x)} f_c(x) = \frac{P_c^*(x)}{\sum_{i=1}^n P_i^*(x)}$$

Onde: f_c = função de pertinência

P_c^* = probabilidade do pixel pertencer à classe c

n = número de classes

Se for considerado que os níveis de cinza dos pixels seguem um modelo normal multivariado para cada uma das diferentes classes, a probabilidade em cada uma das classes pode ser estimada como sendo:

$$P_c^* = \frac{1}{(2\pi)^{N/2} |\Sigma_i^*|^{1/2}} \exp\left(-\frac{1}{2} (X - \mu_i^*)^t \Sigma_i^{*-1} (X - \mu_i^*)\right)$$

Onde: μ_i^* = média difusa

Σ_i^* = matriz de covariâncias difusa

Além disso, dado que as probabilidades podem ser extremamente baixas, o que, em termos práticos, significa que a pertinência à classe é nula, é estabelecido um limiar semelhante ao utilizado no método da máxima verossimilhança. Ou seja,

$$\text{se } P_c^*(x) < \text{limiar} \Rightarrow P_c^*(x) = 0$$

No caso das probabilidades serem nulas para todas as classes, o algoritmo atribui o pixel a uma classe genérica chamada *outras*. Essa classe *outras* representa as classes que não foram consideradas no treinamento ou que o analista não considera importantes para o seu objetivo.

3.2. Cálculo dos Parâmetros da Distribuição Multivariada

Para calcular as diferentes probabilidades, é necessário estimar os parâmetros das distribuições multivariadas de cada classe, a partir de uma amostra de treinamento.

Diferentemente do método da máxima verossimilhança, no algoritmo proposto considera-se que a ocorrência de um pixel numa classe é um evento difuso. Assim, os pixels de treinamento constituem uma partição difusa e são considerados nas médias e matrizes de covariâncias de forma diferente, em função da sua pertinência à classe.

Pelo princípio da consistência possibilidade-probabilidade, os parâmetros utilizados no algoritmo proposto podem ser obtidos a partir das definições de probabilidade de um evento difuso.

Sendo A um evento difuso, uma medida de probabilidade para A pode ser definida como:

$$P(A) = \int_A f_A(x) dP$$

Onde: f_A = função de pertinência

$$dP = \begin{cases} p(x)dx & \text{se } x = \mathfrak{R} \\ p(x) & \text{se } x \text{ é discreto} \end{cases}$$

A partir da definição da medida de probabilidade para A, obtêm-se, diretamente, os valores de média e variância difusas de A [Zimmerman (1985)]. Considerando a existência de c classes em uma imagem, os conceitos de média e variância difusas podem ser generalizados, obtendo-se:

$$\mu_i^* = \frac{\sum_{i=1}^n f_c(X_i) X_i}{\sum_{i=1}^n f_c(X_i)}$$

3.3. Cálculo das Pertinências Pixels da Amostra

Para se calcular a média difusa e as covariâncias difusas, é necessário conhecer-se a pertinência de cada pixel da amostra em cada classe. Essa pertinência pode ser fornecida pelo analista, porém sua determinação não é trivial. Assim, define-se que essas pertinências são também função da probabilidade.

O algoritmo estima, a partir da amostra, as diferentes funções de probabilidade, para permitir a determinação da pertinência de cada um dos pixels da amostra a cada uma das classes.

3.4. Algoritmo de Classificação Difusa

O algoritmo desenvolvido compreende os seguintes passos:

1. INICIALIZAR - Definir as b bandas que serão usadas no processo de classificação, as k classes, associando um nome e uma cor a cada classe, bem como a composição colorida em que serão selecionadas as áreas de treinamento.
2. SELECIONAR ÁREAS DE TREINAMENTO - Delimitar, na composição colorida, áreas de treinamento para as diversas classes.
3. CALCULAR PARÂMETROS - Repetir passos 4 a 10 para cada uma das classes.
4. CALCULAR VETOR DE MÉDIAS - Calcular as médias (\bar{X}_i) , por banda, dos níveis de cinza de cada classe, utilizando todas as áreas de treinamento da classe, pela fórmula:

$$\bar{X}_i = \frac{1}{n} \sum_{L=1}^n x_{iL}$$

Onde: x_{iL} = nível de cinza do pixel L na banda i, na classe considerada

n = número total de pixels considerando todas as áreas de treinamento da classe

5. CALCULAR MATRIZ DE COVARIÂNCIAS - Calcular a matriz de covariâncias (S_c) das bandas, em cada classe, sendo cada elemento $S_c(i, j)$ dessa matriz obtido usando a seguinte fórmula:

$$S_c(i, j) = \frac{\sum_{L=1}^n (x_{iL} - \bar{x}_i)(x_{jL} - \bar{x}_j)}{n - 1}$$

Onde: x_{iL} = nível de cinza do pixel L na banda i, na classe c

\bar{x}_i = média do nível de cinza na banda i, na classe c

n = número total de pixels, considerando todas as áreas de treinamento da classe c

6. CALCULAR INVERSA - Calcular a inversa da matriz de covariâncias das bandas em cada classe (S_c^{-1}).
7. CALCULAR DETERMINANTE - Calcular o determinante da matriz de covariâncias das bandas ($|S_c|$).

8. DETERMINAR A FUNÇÃO DENSIDADE DE PROBABILIDADE MULTIVARIADA - Determinar o valor da função densidade de probabilidade $g_c(x)$ para cada pixel das amostras de treinamento da classe, pela seguinte fórmula:

$$g_c(x_i) = \frac{1}{(2\pi)^{n/2} |S_c|^{1/2}} e^{-\frac{1}{2}(x_i - \bar{x}_c)^T S_c^{-1} (x_i - \bar{x}_c)}$$

Onde: x_i = vetor dos níveis de cinza do pixel

S_c = matriz de covariâncias da classe c

\bar{x}_c = vetor de médias da classe c

n = número total de pixels, considerando todas as áreas de treinamento da classe c

9. CALCULAR VETOR DE MÉDIAS DIFUSAS -

Calcular as médias difusas (μ_i^*) por banda, dos níveis de cinza de cada classe, utilizando todas as áreas de treinamento da classe, da seguinte forma:

$$\mu_i^* = \frac{\sum_{L=1}^n g_c(x_{iL}) x_{iL}}{\sum_{L=1}^n g_c(x_{iL})}$$

Onde: g_c = função densidade de probabilidade multivariada da classe c

x_{iL} = nível de cinza do pixel L na banda i, na classe c

n = número total de pixels, considerando todas as áreas de treinamento da classe c

10. CALCULAR A MATRIZ DE COVARIÂNCIAS DIFUSA - Calcular a matriz de covariâncias difusa da classe c, (S_c^*), pela seguinte fórmula:

$$S_c^* = \frac{\sum_{i=1}^n g_c(x_i) (x_i - \mu_c^*) (x_i - \mu_c^*)^T}{\sum_{i=1}^n g_c(x_i)}$$

Onde: g_c = função densidade de probabilidade multivariada da classe c

x_i = vetor de níveis de cinza do pixel i

μ_c^* = vetor de médias difusas da classe c

n = número total de pixels, considerando todas as áreas de treinamento da classe c

11. ATRIBUIR PERTINÊNCIAS AOS PIXELS DA IMAGEM - Para cada pixel da imagem, calcular a pertinência a cada uma das classes, da seguinte forma:

$$f_c(x_i) = \frac{P_c^*(x_i)}{\sum_{L=1}^k P_L^*(x_i)}$$

Onde:

$$P_L^*(x_i) = \frac{1}{(2\pi)^{n/2} |\Sigma_L^*|^{1/2}} e^{-\frac{1}{2}(x_i - \mu_L^*)^T \Sigma_L^{*-1} (x_i - \mu_L^*)}$$

x_i = vetor de níveis de cinza do pixel i

μ_L^* = vetor de médias difusas da classe L

Σ_L^* = matriz de covariâncias difusas da classe L

n = número total de pixels, considerando todas as áreas de treinamento da classe L

4. CONCLUSÃO

O trabalho apresenta uma abordagem para classificação de imagens digitais baseada na teoria dos conjuntos difusos.

Um algoritmo para classificação é proposto e discutido. Os resultados desse algoritmo, apresentados sob a forma de partição do espaço espectral, possibilitam a obtenção de novas e relevantes informações.

Os algoritmos para classificação de imagens digitais baseados na teoria de conjuntos difusos encontrados na literatura, ao considerar apenas o conceito de partição rígida do espaço espectral, apresentam perda substancial de informação. Em termos gerais, os resultados desses algoritmos aproximam-se dos resultados dos métodos fundamentados em conceitos clássicos de estatística e probabilidade. Uma das principais vantagens do uso da lógica difusa no processamento de imagens digitais - a identificação de pixels mistura - não é viável, quando se adota uma partição rígida do espaço espectral.

A introdução do conceito de limiar para o valor de pertinências, durante o processo de classificação, reduz, consideravelmente, a perspectiva de obtenção de classificações erradas. A introdução desse limiar implica em restringir a atribuição, em alguma das classes previamente definidas, de um pixel que apresente probabilidades desprezíveis em todas as

classes. Diversas podem ser as causas que originaram essas probabilidades desprezíveis: o pixel pode estar associado a uma classe que não seja de interesse do analista; o nível de cinza pode ter sido alterado por alguma razão, quando da obtenção da imagem; as amostras definidas para estimação dos parâmetros utilizados no algoritmo ter sido mal coletadas; etc.

6. REFERÊNCIAS BIBLIOGRÁFICAS

ALVES, A. R.; LAPOLLI, E. M.; GAUTHIER, F. A.O. e BARCIA, R. M., 1991. Digital Image Processing through Fuzzy Set Theory. In Memórias del 5to Simpósio Latino-americano de Percepción Remota. Cuzco, Peru, pp. 491-495.

ALVES, A. R.; LAPOLLI, E. M., BASTOS, R. C. e BASTOS, L. C., 1993. Classificação de Imagens Digitais pelo Método da Máxima Verossimilhança: Uma Nova Abordagem, In Anais do VII Simpósio Brasileiro de Sensoriamento Remoto, Vol II, Curitiba, pp. 281-283.

DOMBI, J., 1990. Membership Fuction as an Evaluation. Fuzzy Sets and Systems. N°. 35, pp. 01-21.

JENSEN, J. R., 1986. Introductory Digital Image Processing - A Remote Sensing Perspective. Englewood Cliffs, Prentice-Hall, 379 p.

LAPOLLI, E. M.; ALVES, A. R., BASTOS, L. C. e LAPOLLI, F. R., 1991. Clasificación de Imágenes Digitales: Técnicas Usuales y Nuevas Perspectivas. In Memórias del 5to Simposio Latino-americano de Percepción Remota. Cuzco, Peru, pp. 589-595.

ZADEH, L.A. 1968. Fuzzy Algorithms. Information Control. Vol. 12, pp. 94-102.

LAPOLLI, E. M., 1994. Processamento de Imagens Digitais: Uma Abordagem Utilizando Conjuntos Difusos. Tese de Doutorado. UFSC, Florianópolis, 206p.

ZADEH, L.A. 1973. Outline of a New Approach to the Analysis of Complex Systems and Decision Processes. IEEE Transactions on Systems, Man and Cybernetics. Vol. SMC-3, N°. 1, janeiro, pp. 28-44.

ZIMMERMANN, H. J., 1985. Fuzzy Set Theory and Its Applications. Kluwer-Nighoff, Boston, Kluwer-Nighoff, 1985.

XIX Congresso Brasileiro de Cartografia XVIII Simpósio Internacional de Fotogrametria Arquitetônica e Arqueológica. 3 a 8 de Outubro de 1999 Recife - Pernambuco - Brasil

A realização do XIX Congresso Brasileiro de Cartografia reveste-se de uma grande expectativa realçada, pelo aspecto de que acontecerá juntamente com o XVIII Simpósio Internacional de Fotogrametria Arqueológica (CIPA). Este Evento ocorrerá pela primeira vez no Hemisfério Sul e representa uma oportunidade ímpar para mudarmos a mentalidade com relação à preservação e conservação do imenso acervo histórico e cultural Sul Americano. Presentes estarão cientistas, pesquisadores e professores dos mais conceituados nesta área do conhecimento e que apresentarão suas experiências, os "software" envolvidos, além de sessões "posters" de alto nível técnico e científico. Espera-se, também, o comparecimento maciço dos integrantes da (do) IPHAN, MEC, SBC, ISPRS, ICOMOS, CIPA, ONGS, Empresas da iniciativa privada do Brasil (ANEA) e da América do Sul e ainda de outras organizações que virão abrilhantar o Congresso, com seus trabalhos, experiências, troca de conhecimentos e confraternização além da possibilidade de acompanhamento dos participantes do atual estado da arte da cartografia internacional e nacional.

A escolha da cidade de Recife obteve grande repercussão no meio da comunidade científica internacional e brasileira, por Olinda ser uma cidade, considerada pelo UNESCO, Patrimônio Cultural da Humanidade, possuidora de um acervo histórico fantástico. Recife, capital do Estado de Pernambuco é o maior pólo cultural e de lazer do Nordeste Brasileiro. É uma cidade de contrastes entre monumentos históricos, construções arrojadas, o azul do mar de Porto de Galinhas e o verde arquipélago de Fernando de Noronha. Prezado colega, venha para Recife/Olinda, venha conhecer a terra mais feliz do Brasil, porque PERNAMBUCO É O LUGAR. Participe, o Congresso é de todos nós.

TEMÁRIO

O CIPA (Comitê Internacional de Fotogrametria Arquitetônica e Arqueológica) far-se-á representar por toda a sua Diretoria, além dos presidentes e adjuntos dos seus cinco grupos de trabalho, que são:

- 1 - Controle de Informação
- 2 - Processamento Digital de Imagens
- 3 - Sistemas Fotogramétricos Simples
- 4 - Registro, Documentação e Tratamento da Informação
- 5 - Arqueologia e Fotogrametria

Presentes estarão também os presidentes das oito Comissões Técnicas da SBC e seus adjuntos, a saber:

- 1 - Hidrografia
- 2 - Geodésia, Astronomia, Topografia e Agrimensura
- 3 - Cartografia
- 4 - Fotogrametria
- 5 - Sensoriamento Remoto e Interpretação de Imagens
- 6 - Cadastro Técnico Multifinalitário e Gestão Territorial
- 7 - Sistemas de Informações Geográficas
- 8 - Formação Profissional, Ensino e Pesquisa