

# EXPERIMENTO DA APLICAÇÃO DE ALGORITMOS GENÉTICOS PARA A INTEGRAÇÃO DE DADOS ESPECTRAIS E TEXTURA NA CLASSIFICAÇÃO DE IMAGENS DE ALTA RESOLUÇÃO

MAURO JOSÉ ALIXANDRINI JR.<sup>1</sup>

PROF. DR. JORGE ANTONIO SILVA CENTENO<sup>2</sup>

<sup>1</sup> Universidade Federal do Paraná - Curso de Engenharia Cartográfica

<sup>2</sup> Universidade Federal do Paraná - Departamento de Geomática  
Jardim das Américas, CP 19011, CEP 81531-990, Curitiba PR  
engenheirocartografo @ bol.com.br , centeno @ geoc.ufpr.br

---

**RESUMO** – O artigo apresenta a introdução do conceito genético em dois métodos de classificação utilizando informação espectral e textura. No primeiro caso, por fatiamento, os limites inferiores e superiores em cada banda espectral e nas bandas de textura são definidos usando algoritmos genéticos. Neste caso, a tarefa dos algoritmos genéticos consiste em encontrar o conjunto de limiares mais adequados em função das amostras disponíveis. No segundo classificador, de mínima distância, os algoritmos genéticos são utilizados para definir os “centros” das classes no espaço das variáveis. A solução pode não necessariamente coincidir com o centro de gravidade das classes. Os experimentos realizados comprovam a eficiência do uso de algoritmos genéticos, em especial o de mínima distância, por apresentar uma mais fácil convergência em relação ao processo de determinação dos limiares para o fatiamento. Esta solução pode ser utilizada para a classificação de imagens multispectrais com desempenho semelhante a outro classificador mesmo utilizando um menor número de amostras.

**ABSTRACT** - The article presents the application of the concept of evolutionary algorithms applied to the solution of the classification of spectral and texture remote sensing data. Two cases are presented. In the first one, thresholding, the upper and lower limits in each spectral band and the texture bands are defined using genetic algorithms. In this case, the task of the genetic algorithms consists of finding the set of thresholds using training pixels. In the second experimento, the minimum distance classification concept is used and the genetic algorithms are applied to define the "centers" of the classes in the feature space. The solution does not necessarily coincide with the center of gravity of the classes. The experiments carried out prove the efficiency of the genetic algorithms, in special when they are applied to the minimum distance classifier, because the process converges faster. The approach can be used for the classification of multispectral images with a performance that can be compared to the performance of other traditional classifiers, using a very small set of training pixels.

---

## 1 INTRODUÇÃO

Este artigo descreve os resultados dos experimentos realizados dentro do projeto “Análise de Imagens Multiespectrais usando Técnicas de Algoritmos Genéticos”, desenvolvido no Departamento de Geomática da UFPR. O projeto visa, em termos gerais, a classificação de imagens de satélite usando um esquema baseado nos princípios da computação evolutiva, um ramo da inteligência artificial.

A classificação multiespectral constitui uma das principais ferramentas do processamento digital de imagens de sensoriamento remoto. Sua finalidade consiste em derivar, a partir dos dados multiespectrais das imagens de satélite, informação temática a respeito da cobertura do

solo. Dito de uma maneira geral, a classificação consiste em diferenciar (classificar) os indivíduos de uma determinada população (o conjunto de pixels que compõem a imagem), enquadrando cada um deles dentro de uma das possíveis categorias (classes de uso ou cobertura do solo).

Os métodos de classificação estatística possuem certa limitação em função da necessidade de adotar algumas hipóteses como a da normalidade da distribuição dos valores do contador digital em cada banda espectral. Assim sendo, eles não podem ser usados em situações onde esta hipótese não seja satisfeita. Isto pode ocorrer quando a análise inclui informações diferentes das leituras do contador digital puro. Por exemplo, quando se deseja incluir informação a respeito da textura.

O potencial do sensoriamento remoto para o estudo da cobertura do solo foi recentemente ampliado através do incremento da resolução espacial das imagens disponíveis. O desafio consiste em desenvolver ou adaptar metodologias que facilitem a análise destas imagens, considerando as conseqüências do aumento da informação na eficiência dos algoritmos utilizados.

A uniformidade das classes de cobertura numa imagem de alta resolução é menor, em conseqüência do aumento no detalhe visível na imagem. Isto compromete as hipóteses a respeito do comportamento normal das classes. Por outro lado, novas fontes de informação, como a textura da superfície dos objetos, encontram-se disponíveis e devem ser consideradas.

O artigo abordar a questão da classificação de imagens multiespectrais de alta resolução, baseada em dados das bandas espectrais e a textura, utilizando os princípios dos algoritmos genéticos. As imagens utilizadas na pesquisa correspondem ao sistema IKONOS II, lançado no final de Setembro/99.

## 2 METODOLOGIA

### 2.1 Textura

Além da informação espectral, contida nas leituras nas diferentes bandas espectrais, uma imagem de satélite oferece outro tipo de informação, como por exemplo a de cunho espacial. Tamanho, forma e textura são elementos que contribuem com informação significativa para a análise de uma imagem. Os atributos espaciais tornam-se mais relevantes na medida em que a resolução das imagens é aumentada. A textura, em particular, pode ser estimada através da variação dos valores do contador digital em uma determinada região da imagem. Para isto, não é suficiente analisar o pixel em questão, mas esta análise deve-se estender aos pixels vizinhos, de maneira a caracterizar a textura local. Um método simples de estimar a textura é analisar os valores da variância das leituras do contador digital dos pixels numa região. Outras maneiras são a estimativa da uniformidade ou a entropia, através da análise da matriz de co-ocorrência, apresentada por HARALIK e SHAPIRO (1992).

A matriz de co-ocorrência de uma imagem é uma matriz  $k \times k$ , em que  $k$  é a quantidade de níveis de cinza da janela do filtro. A seqüência de passos para obtê-la é (JAIN et al, 1995):

- 1) Escolher o vetor que representa a posição relativa dos pixels a ser analisada ( $v$ ).
- 2) A partir da imagem, gerar a matriz de co-ocorrência  $P$ . Os elementos desta matriz ( $p_{ij}$ ) correspondem à quantidade de vezes que o nível de cinza  $j$  ocorre em na posição relativa determinada pelo vetor  $v$  em relação a pixel central com nível de cinza  $i$ .
- 3) A matriz de co-ocorrência é finalmente normalizada, dividindo-se cada elemento por  $n$ , em que  $n$  é a soma de todos os elementos da matriz.

Para caracterizar a textura de uma região utilizando dados da matriz de co-ocorrência dos níveis de cinza, podem ser utilizados os descritores:

- 1) Probabilidade máxima;
- 2) Momento de diferença de elementos de ordem  $k$ ;
- 3) Momento inverso de diferença de elementos de ordem  $k$ ;
- 4) Entropia;
- 5) Uniformidade;

A primeira propriedade fornece uma indicação da resposta mais forte a  $v$  (vetor de posição relativa). O segundo descritor possui um valor relativamente baixo quando os valores altos de  $P$  estiverem próximos da diagonal principal, devido às diferenças  $(i-j)$  serem menores lá. O terceiro descritor tem o efeito oposto. O quarto descritor é uma medida de aleatoriedade, atingindo seu valor mais alto quando todos os valores de  $P$  forem iguais. Por outro lado, o quinto descritor é menor quando os  $p_{i,j}$ 's forem iguais.

### 2.2 Classificação por fatiamento

Alternativas para a classificação de um conjunto de observações multiespectrais que não se adaptem a uma distribuição estatística podem encontradas aplicando métodos simples, como a divisão do espaço espectral fixando limites máximos e mínimos em cada banda para cada classe (*thresholding*). Neste método, a faixa de variação em cada banda é analisada para cada classe e os limites máximo e mínimo da faixa de variação são estimados. Embora o princípio seja simples, o problema torna-se complicado quando a imagem apresenta classes espectralmente próximas que podem ser confundidas ou se encontram superpostas e dificultam a separação mediante esta abordagem. A fixação dos limiares é portanto uma tarefa que demanda muito cuidado e é efetuada de maneira interativa (CHUVIECO, 1990).

### 2.3 Classificação por mínima distância

No classificador de mínima distancia somente se definem os centros das classes e o pixel é atribuído à classe cujas coordenadas no espaço espectral estiverem mais próximas do pixel (CHUVIECO, 1990). Existem varias maneiras de se calcula a distancia espacial a mais utilizada e a da distancia Euclidiana:

$$d_{x,A} = \sqrt{\sum_{k=1}^m (ND_{x,k} - ND_{A,k})^2} \quad (1)$$

onde,

$ND_{A,k}$  → é o nível de cinza central da classe  $A$  na banda  $k$ ;

$ND_{x,k}$  → é o nível de cinza do pixel  $x$  na banda  $k$ .

$dx,A$  → é a distancia Euclidiana do pixel  $x$  ao centro da classe  $A$ .

$m$  → é o número de bandas espectrais.

$k$  → é o número da banda espectral.

A questão, neste caso, é determinar os centros das classes. Este problema é resolvido adotando-se o vetor de médias da classe, estimado a partir de amostras de treinamento. No entanto, usar o centro de gravidade e o conceito de distância euclidiana pode não ser a solução mais eficiente, pois esta abordagem não leva em consideração a dispersão diferenciada dos valores nas diversas bandas.

## 2.4 Algoritmos genéticos

Os limiares do método de classificação por “fatiamento” (*thresholding*) podem ser explicitamente definidos na base da experiência do usuário e representados através de uma série de números. Já no caso dos centros das classes no processo de classificação por mínima distância, técnicas de agrupamento, ou áreas de treinamento, podem ser utilizadas para determinar a solução, que também pode ser representada como uma série de números. Em ambos os casos, uma série de números descreve uma solução particular para o problema da classificação da imagem.

Sendo uma solução composta por uma série de números, ela pode ser representada sob forma de uma cadeia binária. A cadeia resultante pode então ser tratada como uma cadeia genética, que armazena as características de uma solução particular. Como o conjunto de parâmetros ideal, a solução ótima, não é conhecido “a priori”, a proposta consiste em encontrar esta solução usando métodos de algoritmos genéticos seguindo um processo iterativo.

Os algoritmos genéticos (GOLDBERG, 1989) são uma técnica de otimização que se assemelha ao processo de seleção natural. Nele, o conjunto de parâmetros desconhecidos é submetido a um processo iterativo de seleção, descartando as soluções menos aptas e gerando novas estimativas a partir das melhores soluções.

Os algoritmos genéticos implementam um método de busca estocástico que de maneira aleatória amostra o espaço dos parâmetros e geram novas estimativas para a solução usando as melhores estimativas dos experimentos anteriores. Isto é feito de maneira similar ao processo natural de reprodução (genética). O funcionamento dos algoritmos genéticos consiste em arbitrar várias soluções para o problema e combiná-las iterativamente até atingir uma situação onde uma solução ótima é encontrada ou o conjunto de soluções converge a uma única solução (GALVÃO e VALENÇA, 1999) A cada iteração são avaliadas as novas estimativas, descartando aquelas que não satisfaçam a finalidade pretendida e preservando as melhores para gerar novas estimativas na seguinte iteração. Para combinar as soluções em cada iteração, o conjunto de parâmetros que caracteriza uma solução é codificado numa cadeia binária, similar às cadeias de cromossomos. A base para algoritmos genéticos é o aproveitamento da informação de boa qualidade de estimativas anteriores. O método converge, ou se

aproxima muito, a uma solução global na maioria dos casos.

Os algoritmos genéticos derivam de um ramo da computação evolutiva inspirada na teoria da evolução de Darwin. Os algoritmos procuram codificar a informação em forma de genes, estrutura em que as possíveis soluções são armazenadas de forma seqüencial. A um conjunto de genes dá-se o nome de população e essa população é modificada por operadores genéticos como a seleção, mutação e cruzamento. Com isso os algoritmos genéticos procuram trabalhar simultaneamente avaliando um conjunto de possíveis soluções. A seguir são apresentados os principais elementos dos algoritmos genéticos.

**Gene ou indivíduo:** Um gene é um indivíduo que tem em sua estrutura uma solução para o problema central. Neste trabalho, dois tipos de problemas são resolvidos, por isto, a codificação genética é diferente para cada caso. No primeiro caso, o “fatiamento”, o indivíduo é formado pelos limiares superior e inferior de cada classe para cada banda espectral. No segundo, a cadeia agrupa as coordenadas dos centros das classes no espaço amostral. Em ambos os casos, este indivíduo é avaliado e recebe uma certa nota (“*fitness*”) que representa sua capacidade de resolver o problema. Em outras palavras, o grau de aptidão do indivíduo é avaliado. Este indivíduo está sujeito ao cruzamento e a mutação, operadores que atuam modificando sua cadeia gene.

**População:** A população é um conjunto de indivíduos, ou soluções, que representam no momento o conjunto de melhores soluções para o problema proposto. Estes indivíduos podem ser cruzados para gerar uma nova geração. A nova população é composta pelos indivíduos gerados e uma pequena parcela dos indivíduos originais, aqueles com melhor grau de aptidão.

**Cruzamento:** O cruzamento ou “*crossover*” é o principal operador genético, ele atua cruzando as soluções fazendo com que novas gerações permaneçam com características desejáveis adquiridas de gerações anteriores.

**Mutação:** A mutação não é predominante, porém essencial para o processo de iterações genéticas, pois previne que o processo iterativo fique estagnado dentro de um mínimo local, introduzindo uma diversidade a população. Ela ocorre alterando aleatoriamente um elemento da cadeia de um indivíduo.

**Seleção:** A seleção pode ser tida como um operador que elimina os indivíduos com grau de aptidão mais baixo.

## 3 EXPERIMENTOS

A seguir são apresentados dois experimentos. O primeiro consiste no uso dos algoritmos genéticos para a determinação dos limiares do “fatiamento”, e o segundo na determinação dos centros das classes para a classificação pela distância mínima. Em ambos casos, os dados de entrada consistem em imagens multispectrais

do satélite de alta resolução Ikonos, com as bandas verde, vermelho e infra-vermelho.

Diferentes recortes de imagens Ikonos foram submetidos ao processo de classificação. Os resultados de um destes recortes serão apresentados a seguir. Os resultados obtidos foram avaliados quanto à taxa de erros, à precisão da estimativa e o tempo de processamento. A imagem utilizada como exemplo neste trabalho corresponde à região de Matinhos, no litoral paranaense. Na figura 1 é mostrado um recorte desta área que servirá para ilustrar os resultados. Este recorte mostra a presença de várias classes freqüentemente encontrados na região, como a vegetação, cobertura das edificações e o solo exposto da malha viária.



Figura 1 - Recorte da imagem Ikonos, composição falsa cor.

Para a determinação da textura no conjunto de bandas, a transformação das componentes principais foi utilizada. A primeira componente principal foi utilizada para determinar os parâmetros de textura, usando para isto a matriz de co-ocorrência. O parâmetro de textura que gerou um melhor resultado nas análises foi o da uniformidade. Utilizado em áreas 6x6 pixels, pois mantém a cobertura das casas bem definidas e a vegetação com maior separação.

Como as componentes principais apresentam como característica a capacidade de representar grande parte da informação espectral usando um número menor de bandas, a terceira componente foi descartada. Assim sendo, um novo conjunto, contendo as duas primeiras componentes e a imagem de textura foi utilizado para fins de classificação.

Com a finalidade de obter uma classificação de referência, esta imagem foi classificada segundo a abordagem estatística da máxima verossimilhança. Para isto, amostras representativas foram escolhidas na imagem. Duas séries de classificações foram efetuadas. A primeira com as bandas espectrais originais e a segunda com a imagem composta pelas duas primeiras componentes principais e a imagem de textura.

Na classificação multiespectral pelo método da máxima verossimilhança usando as bandas espectrais originais obteve-se uma acurácia global de 98%, segundo a matriz de confusão calculada a partir de 695 pixels de verificação. As classes consideradas foram: solo das vias,

cobertura das edificações, vegetação e sombra. Houve uma maior confusão em relação à identificação de telhados, pois eles foram confundidos com solo. Este erro pode ser atribuído ao processo de amostragem, pois o solo foi definido a partir de amostras colhidas nas ruas, que apresentam resposta espectral muito similar a telhados de cimento cobertos por terra. Da mesma forma, apenas a vegetação mais densa foi bem caracterizada. A vegetação rasteira ficou mal classificada, sendo confundida com construções, pois este tipo de cobertura não apresenta as características típicas da vegetação, se não é o resultado da mistura de solo e vegetação no pixel.

A mesma imagem foi classificada usando o método do “fatiamento”. Para isto, os algoritmos genéticos foram usados com o objetivo de identificar os limiares associados a cada classe em cada banda. Para esta classificação, foram colhidas 80 amostras e o processo iterativo parou após 8057 iterações, quando uma taxa de qualidade de 0.9625 foi atingida. Isto significa que 96% dos pixels das amostras de treinamento estavam classificados corretamente.

Uma comparação direta deste resultado com o da máxima verossimilhança, no entanto, não é correto, pois a abordagem do “fatiamento” é muito mais simples que a fundamentação estatística do método da máxima verossimilhança. No entanto, o resultado pode ser considerado coerente. A vegetação foi bem classificada, mas notou-se uma confusão entre solo e telhados em razão das sombras. As vias foram em sua maioria bem classificadas, com exceção de alguns casos que apresentam uma certa confusão pela presença de sombra e um outro tipo de solo. O resultado apresenta pixels mal classificados ao longo de toda a imagem.

Numa segunda fase de testes, os dados referentes à textura e às componentes principais foram classificados. Notou-se, neste experimento, perda da definição espacial da forma dos telhados, sendo estes fundidos com suas respectivas sombras. Mas por outro lado, as feições tornaram-se mais homogêneas e a classificação teve uma acurácia global de 90% na matriz de confusão para uma amostragem de 645 pixels.

Usando estes dados, os limiares do método de “fatiamento” foram procurados com os algoritmos genéticos. Para estimar os limiares foram necessárias 1667 iterações, chegando-se a um total de 97% de acertos dentre 90 amostras. O resultado possibilitou caracterizar bem os telhados, ocorrendo confusão entre vegetação e solo. Percebeu-se que o concreto e as paredes da construção foram classificados como solo devido à proximidade espectral entre estas classes. Por outro lado, as sobras e arruamento foram bem caracterizados. As sombras servem para delinear as construções.

Os mesmos dados foram utilizados para testar o desempenho dos algoritmos genéticos para determinar o melhor conjunto de centros de classes para a classificação pelo critério da distância mínima. Esta classificação resultou em uma imagem temática próxima daquela obtida com o algoritmo de hipercubos. verifica-se, no entanto, menor confusão da vegetação e um incremento

significativo na velocidade de convergência do processo iterativo. O resultado ótimo foi obtido, neste caso, após 204 iterações, obtendo-se um total de 98% dos pixels de treinamento corretamente classificados.

Na imagem temática observa-se que a confusão entre as classes “vegetação” e “solo”, é menor do que na classificação por hipercubos, que as vias podem ser mais bem separadas em relação ao resultado da máxima verossimilhança. A não separação de sombra e cobertura verificada no resultado da máxima verossimilhança, ocorre também neste método.

Uma comparação visual destes experimentos pode ser vista nas figuras 3,4, e 5. A figura 3 mostra o resultado da classificação pela máxima verossimilhança. A figura 4 mostra o resultado do fatiamento e a última figura mostra o resultado da classificação pela mínima distância.




Figura 3 – Recorte do resultado da classificação pelo método da máxima verossimilhança.




Figura 4 – Recorte do resultado do fatiamento usando algoritmos genéticos para determinar os limiares.




Figura 5 – Recorte do resultado da classificação pelo método da distância mínima usando algoritmos genéticos para determinar os centros das classes.

#### 4 CONCLUSÕES

Os resultados comprovam que é possível utilizar os algoritmos genéticos como alternativa para a solução do problema de classificação multiespectral. O potencial desta abordagem reside no fato de poder gerar soluções a partir de aproximações iterativas, convergindo para uma solução ótima que melhor satisfaça a função objetivo proposta. A função objetivo é determinada inicialmente e pode ser dada pela diferença entre a classificação gerada e a classificação esperada, através da matriz de confusão.

A textura proporcionou uma melhor separação entre classes espectralmente próximas, mas com diferenças de textura. Este foi o caso da separação entre “vegetação” e “telhados”. O parâmetro que melhor se adaptou a imagem foi o da uniformidade, visto que as coberturas apresentam textura mais lisa enquanto a vegetação, mais rugosa.

Os algoritmos genéticos comprovaram ser uma ferramenta útil para a determinação de limiares, que é uma tarefa difícil quando se lida com um número grande de variáveis e classes.

Também se observa que o uso da técnica de mínima distância reduz em muito o número de iterações com isso o tempo de classificação, porque esta técnica trabalha mudando um centro de classe esta mudança implica na modificação simultânea de todos os limites da classe. A diferença desta maneira de encontrar os centros das classes é que estes centros não necessariamente coincidem com o centro de gravidade do conjunto de amostras.

Uma vantagem na classificação utilizando algoritmos genéticos é que o número de amostras para a classificação é muito inferior àquele necessário para os métodos estatísticos. Isto ocorre porque estes métodos são baseados em probabilidade e requerem um número de amostras representativo.

## 5 REFERÊNCIAS

CHUVIECO, E.: **Fundamentos de Teledetección Espacial**. Ediciones Rialp S.A., Madrid, Espanha: 1990.

GALVÃO, C.O.; VALENÇA, M.J.S.: **Sistemas Inteligentes: Aplicações em Recursos Hídricos e Sistemas Ambientais.**, Ed. UFRGS / ABRH, Porto Alegre, 1999.

GOLDBERG, D.: **Genetic Algorithms in Search, Optimization, and Machine Learning**, Addison-Wesley, Reading, Massachusetts, 1989.

HARALICK, R.; SHAPIRO, L.: **Computer and Robot Vision**. Vol.1, Addison-Wesley Publishing Company Inc., 1992.

JAIN, R. KASTURI, R.; SCHUNCK, B. G.: **Machine Vision**, New York. McGraw-Hill Inc. 1995.

## 6 AGRADECIMENTOS

Os autores deste trabalho agradecem o apoio da UFPR que propiciou a execução desta pesquisa através de seu programa institucional de pesquisa.