

# Uma avaliação de métodos genéticos para ajuste de parâmetros de segmentação

Raul Queiroz Feitosa<sup>1</sup>  
Gilson Alexandre Ostwald Pedro da Costa<sup>1</sup>  
Cecília Maria Buarque Fredrich<sup>1</sup>  
Flávio Fortes Camargo<sup>2</sup>  
Cláudia Maria de Almeida<sup>2</sup>

<sup>1</sup>Pontifícia Universidade Católica do Rio de Janeiro – PUC-RJ  
Departamento de Engenharia Elétrica  
R. Marquês de São Vicente, 225 – 22453-900 Rio de Janeiro, RJ  
{raul, gilson, buarque}@ele.puc-rio.br

<sup>2</sup>Instituto Nacional de Pesquisas Espaciais - INPE  
Divisão de Processamento de Imagens – Divisão de Sensoriamento Remoto  
Av. dos Astronautas, 1758 – 12227-010 São José dos Campos, SP  
{almeida, fortes}@dsr.inpe.br

**Abstract.** Most segmentation algorithms have explicit parameters that must be properly set in order to produce the desired outcome, and the definition of suitable parameter values is usually a complex, time consuming task. In Costa et al. (2008), a supervised, semi-automatic parameter adaptation method based on a Genetic Algorithm (GA) was proposed. Given an initial set of reference object samples, the method searches the parameter space for (near) for values that will produce segments as similar as possible to the reference. The specific formulation of the objective function, which provides the similarity measure used in the method, privileged applications in which the objects to be segmented were homogeneous. This work addresses this issue, extending the previous work by proposing a novel objective function which considers the objects of interest to be inhomogeneous, though formed by an assembly of homogeneous parts. The software prototype that implemented the previous approach was extended with the new objective function, and an experimental evaluation of the two objective functions were performed taking into account three different segmentation algorithms and five different object classes. The analysis of the results obtained with both objective functions provides guidelines for the selection of the function to be used in different applications.

**Palavras-chave:** remote sensing, image processing, genetic algorithms, optimization methods, sensoriamento remoto, processamento de imagens, algoritmos genéticos, métodos de otimização.

## 1. Introdução

A segmentação é passo essencial no processo de análise de imagens (vide Blaschke e Strobl (2001)), pois gera os blocos básicos que serão classificados no passo subsequente do processo de interpretação. A exatidão de todo este processo, portanto, depende decisivamente da qualidade da segmentação, sendo inclusive tema de vários estudos publicados, em que se comparam diversos algoritmos de segmentação (e.g. Neubert et al. (2008)). A qualidade da segmentação depende, no entanto, não apenas do algoritmo selecionado, mas de um apropriado ajuste dos valores de seus parâmetros (vide Carleer et al. (2005)). Esse ajuste é feito, na ampla maioria dos casos práticos, através de uma longa série de tentativas e erros, não havendo garantia de que os valores ótimos serão, de fato, encontrados. Em Pignalberi et al. (2003) e Feitosa et al. (2006), propõe-se o uso de algoritmos genéticos (AG) para o ajuste automático dos parâmetros de segmentação. Trata-se de uma abordagem supervisionada (vide Zhang (1996)) em que a qualidade da segmentação é dada por uma medida de disparidade entre o resultado e um conjunto de segmentos de referência, freqüentemente chamado de “padrão ouro” e

selecionado manualmente por um analista. A idéia subjacente reside em ser o olho humano o mais confiável avaliador da qualidade da segmentação (vide Baatz et al. (2000)) e numa coleção de segmentos de referência poder representar adequadamente o que um analista percebe como “boa” segmentação. Assim, quanto menor sua disparidade em relação à referência, melhor será o resultado da segmentação.

Seguindo esta linha, algumas métricas de disparidade foram propostas (vide e.g. Feitosa et al. (2006) e Fredrich e Feitosa (2008)). Todas elas são definidas de modo que a coincidência perfeita entre segmentação e referência resulte um valor limite da disparidade, freqüentemente igual a zero. Não há, entretanto, fundamento teórico que comprove a adequação de tais métricas como medidas da qualidade para situações em que a segmentação é distinta da referência. É, por exemplo, curioso notar que todas elas podem associar um mesmo valor de disparidade a várias segmentações diferentes. Pode-se, também, questionar, se segmentações distintas com um mesmo grau de disparidade seriam percebidas por um analista humano como possuindo qualidade semelhante. De fato, pouco se tem investido em estudos que relacionem as métricas de disparidade à qualidade visual da segmentação.

O presente trabalho aborda esta questão. Especificamente, investiga-se a hipótese básica dos métodos automáticos de ajuste de parâmetros de segmentação baseados em AGs, ou seja, de que a qualidade da segmentação pode ser adequadamente expressa em termos numéricos por medidas de disparidade entre a segmentação e uma referência.

A análise experimental é realizada a partir de uma imagem QuickBird de uma área urbana. Duas funções de disparidade são consideradas na análise, uma voltada para objetos homogêneos e outra, para objetos heterogêneos.

O restante do trabalho está organizado da seguinte maneira. A próxima seção apresenta em linhas gerais a metodologia de ajuste automático dos parâmetros de segmentação baseados em AGs. A seção seguinte descreve os experimentos realizados e discute os resultados. As principais conclusões do trabalho são resumidas na última seção.

## **2. Ajuste de Parâmetros de Segmentação baseado em Algoritmos Genéticos**

A relação entre os valores dos parâmetros de segmentação, com respeito a uma dada classe de objetos, e a qualidade da segmentação resultante não pode ser formulada analiticamente. Por isso, métodos baseados em cálculo numérico não podem ser aplicados no processo de busca dos valores ótimos. Métodos estocásticos de otimização constituem, neste caso, uma alternativa viável. Sendo assim, AGs foram a técnica adotada, neste trabalho, para ajuste dos parâmetros de segmentação.

### **2.1 Algoritmos Genéticos**

Uma explicação mais detalhada sobre AGs foge ao escopo deste texto e pode ser encontrada em Michalewicz (1999) e Davis (1990).

Porém, para a compreensão das seções subseqüentes, AGs podem ser vistos como algoritmos de otimização por busca paralela, dirigida por uma função objetivo que pode ser definida livremente (vide Davis (1990)). Neste caso particular, a solução ótima são os valores dos parâmetros de segmentação, para os quais uma função de disparidade – que mede quão bem a segmentação resultante corresponde às referências fornecidas pelo usuário – atinge seu mínimo.

## 2.2 Funções de Disparidade

Foram utilizadas duas funções de disparidade, aqui apresentadas individualmente. Seus nomes originais, em inglês, serão mantidos neste texto.

Em termos matemáticos, dados um conjunto de segmentos  $S$ , uma função de disparidade  $F$  e um vetor de parâmetros  $P$ , o objetivo do AG é encontrar  $P_{\text{ótimo}}$ , definido por

$$P_{\text{ótimo}} = \arg_p (\min [F(S, P)]) \quad (1)$$

### 2.2.1 Reference Bounded Segments Booster – RBSB

Função originalmente proposta em Costa et al. (2008), a *RBSB* é formalmente definida a seguir. Sejam  $S_i$  e  $O(P)_i$  conjuntos de *pixels*; o primeiro pertencente ao  $i$ -ésimo segmento de  $S$  e o segundo, ao produto da segmentação, através de  $P$ , com maior interseção com  $S_i$ . Definem-se, ainda:

- o número de *pixels* em  $O(P)_i$  que não pertencem a  $S_i$  como  $fp_i$  (falso positivos);
- o número de *pixels* em  $O(P)_i$  que pertencem a  $S_i$  como  $vp_i$  (verdadeiro positivos);
- o número de *pixels* em  $S_i$  que não pertencem a  $O(P)_i$  como  $fn_i$  (falso negativos), e
- o número de segmentos não vazios pertencentes a  $S$  como  $n$ .

A função *RBSB* é, assim, dada por

$$F(S, P) = \frac{1}{n} \sum_{i=1}^n \frac{fp_i + fn_i}{vp_i + fn_i} \quad (2)$$

A Figura 1 mostra a representação gráfica da *RBSB*, onde  $O(P)_i$  corresponde à região de contorno sólido e  $S_i$ , à de tracejado.




Figura 1. Representação gráfica das entidades que compõem a função objetivo *RBSB*.

### 2.2.2. Larger Segments Booster - LSB

Fredrich e Feitosa (2008) propõem uma função de disparidade alternativa. Essa função, a *LSB*, favorece resultados que correspondem às referências com o mínimo de segmentos e é definida a seguir.

Sejam  $SO(P)$  o conjunto de segmentos produzidos pela segmentação que contenham *pixels* de  $S$  e  $SO(P)_i$  o subconjunto de  $SO(P)$ , cujos membros possuem pelo menos 50% de seus *pixels* em  $S_i$ . Definem-se, ainda:

- o número de *pixels* em  $SO(P)_i$  que não pertencem a  $S_i$  como  $fp_i$  (falso positivos);
- o número de *pixels* em  $SO(P)_i$  que também pertencem a  $S_i$  como  $vp_i$  (verdadeiro positivos);
- o número de *pixels* em  $S_i$  que não pertencem a  $SO(P)_i$  como  $fn_i$  (falso negativos);

- o número de *pixels* na fronteira de  $SO(P)_i$  contidos em  $(S_i)$  – ou fronteira interna das referências – como  $b_i$ , e
- o número de  $SO(P)_i$  vazios como  $NS$ .

A função *LSB* é, assim, dada por

$$F(S, P) = \frac{1}{n} \left[ NS + \sum_{SO(P)_i \neq \emptyset} \frac{fp_i + fn_i + b_i}{vp_i + fn_i} \right] \quad (3)$$

Seu comportamento é ilustrado pela Figura 2. As regiões, cujos contornos são sólidos e em preto identificam os segmentos em  $SO(P)_i$ . Já as de contorno tracejado representam em segmentos em  $S_i$ .

Os termos  $fp_i$  e  $fn_i$  favorecem soluções que sejam, estritamente, subconjuntos das referências, implicando que as segmentações de melhor avaliação sejam constituídas de inúmeros pequenos segmentos (tendendo a um único *pixel*). O termo  $b_i$  funciona justamente como um contrapeso a tal efeito, pois segmentos maiores possuem uma razão perímetro/área menor e, portanto, soluções que os contenham são favorecidas, no que diz respeito a esta entidade. Quando todos os  $SO(P)_i$  são vazios, tem-se  $NS=n$ . Nesses casos, faz-se  $F(S, P)=1$ .




Figura 2. Representação gráfica das entidades que compõem a função objetivo *LSB*.

### 3. Análise experimental

Nesta seção, apresentam-se a base de dados, o método de segmentação e seus resultados.

#### 3.1 Base de Dados

Parte de uma imagem QuickBird, de coordenadas (S 23° 13' 33"; W 45° 53' 06") e (S 23° 13' 22"; W 45° 53' 14") foi utilizada para a avaliação das funções de disparidade. As cinco bandas originais – pancromática (445 - 900 nm), azul (450 - 520 nm), verde (520 - 600), vermelha (630 - 690 nm) e infra-vermelha (760 - 900 nm) – foram fundidas em quatro, através de análise dos componentes principais. A resolução espacial resultante é igual à da banda pancromática (0.67 m). A escolha da cena deveu-se à diversidade de padrões observada.

#### 3.2 Método de Segmentação

O método de segmentação adotado baseia-se naquele proposto por Baatz e Schäpe (2000). Trata-se de um algoritmo de otimização local passo-a-passo que minimiza a heterogeneidade média dos objetos na imagem.

### 3.3 Ferramenta de Avaliação

Toda a avaliação foi realizada num protótipo em *software* que implementa o método automático de ajuste de parâmetros de segmentação, chamado *SPT (Segmentation Parameters Tuner)*, disponível através do *link* “Downloads” na página do Laboratório de Visão Computacional da PUC-Rio ([www.lvc.ele.puc-rio.br](http://www.lvc.ele.puc-rio.br)).

### 3.4. Resultados e Discussões

A análise que se segue baseia-se nos valores da função de disparidade usada como função objetivo para o AG e, também, numa análise visual dos resultados das segmentações.

As figuras (a) até (c) da Tabela 1 mostram os resultados obtidos com a função *LSB*, para objetos homogêneos, heterogêneos e mistos, respectivamente. Treinamento e validação distinguem-se pela cor; verde e amarelo.




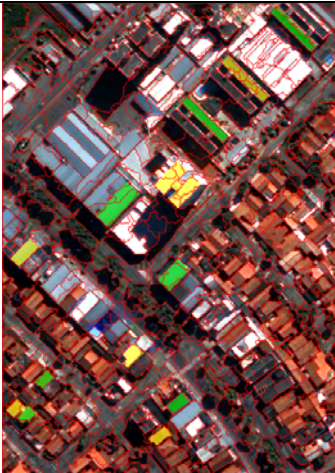
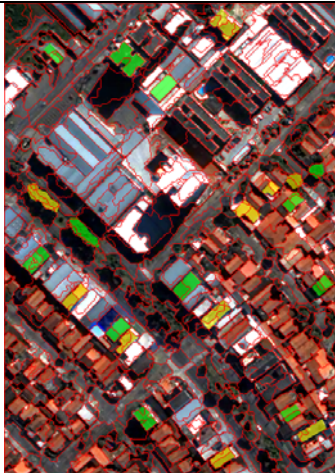
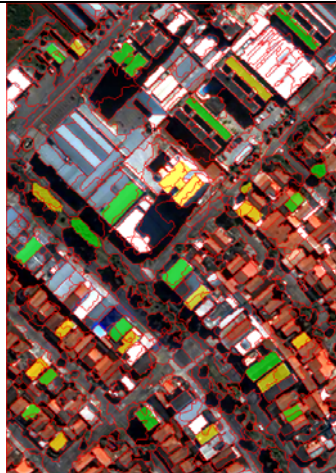
Com respeito à figura (a), nota-se que, de um modo geral, os grupos de objetos estão bem delineados. A exceção é o prédio no formato de “H” um pouco acima do centro da imagem. Este objeto, como de resto todos aqueles homogêneos muito claros, foram super segmentados. Este resultado está provavelmente associado ao fato de que nenhum objeto homogêneo muito claro fez parte do conjunto de treinamento. Um novo cálculo da disparidade foi realizado retirando-se este objeto do conjunto de validação. Verificou-se que o valor da disparidade passou de 0,38 para 0,32, ou seja, um valor ainda inferior ao alcançado na fase de treinamento. Este resultado ressalta a importância de uma escolha apropriada do conjunto de referência para o método analisado.

O experimento ilustrado pela figura (b) mostra, em relação ao experimento com objetos homogêneos, graus de disparidade superiores, quando produzidos pela função *LSB*, tanto no treinamento quanto na validação. Isto decorre de que objetos não homogêneos contêm *pixels* de fronteira entre segmentos, aumentando, assim, a disparidade medida pela Equação 3. É interessante notar a menor tendência à super-segmentação neste caso, em comparação com o que se verifica nas figuras (a) e (c) da Tabela 1. Isto é facilmente observado nos objetos ao longo da rua que cruza o quadrante inferior esquerdo da imagem. Trata-se de aglomerados de objetos basicamente de mesmo matiz (cinza), que diferem preponderantemente no brilho. A função *LSB* treinada com objetos heterogêneos é mais condescendente do que no caso anterior (treinamento com objetos homogêneos) e tende a fundir num mesmo objeto segmentos de cores parecidas. O efeito menos acentuado de super-segmentação é observado novamente no grande telhado claro que se encontra no quadrante superior direito da imagem.

Na figura (c), tem-se o resultado do experimento com objetos heterogêneos e homogêneos, presentes tanto no treinamento quanto na validação. Os valores de disparidade são próximos do que se alcançou para objetos heterogêneos (figura (b)). Visualmente, contudo, a qualidade dos resultados é distinta. Nota-se que objetos homogêneos estão mais bem delineados na figura (a), seguidos pelos na figura (c) e, por último, na figura (b). Objetos heterogêneos estão, ao contrário, mais bem delineados na figura (b), depois, na (c) e, finalmente, na (a). Neste sentido, os resultados da figura (c) representam uma espécie meio termo entre os resultados das figuras (a) e (b), o que é coerente, uma vez que o conjunto de treinamento no caso da figura (c) contém tanto objetos homogêneos, quanto heterogêneos.

De um modo geral, os mesmos comentários que comparam os resultados dos experimentos com a função *LSB* se aplicam aos resultados obtidos a partir da função *RBSB*, que são mostrados nas figuras (d) a (f) da Tabela 1.

Tabela 1. Resultados produzidos a partir das funções *LSB* e *RBSB* para referência contendo objetos homogêneos, heterogêneos e ambos.

	objetos homogêneos	objetos heterogêneos	objetos mistos
<b>LSB</b>			
	$F_{\text{treinamento}}=0,34$ $F_{\text{validação}}=0,38$ (a)	$F_{\text{treinamento}}=0,55$ $F_{\text{validação}}=0,75$ (b)	$F_{\text{treinamento}}=0,51$ $F_{\text{validação}}=0,75$ (c)
<b>RBSB</b>			
	$F_{\text{treinamento}}=0,30$ $F_{\text{validação}}=0,35$ (d)	$F_{\text{treinamento}}=0,46$ $F_{\text{validação}}=0,71$ (e)	$F_{\text{treinamento}}=0,37$ $F_{\text{validação}}=0,58$ (f)

É interessante analisar os resultados produzidos pelas duas funções de disparidade para um mesmo conjunto de treinamento e validação. Para objetos homogêneos (figuras (a) e (d)), nota-se que ambas produzem bons resultados para telhados avermelhados. Telhados azulados apresentam em alguns casos fronteiras artificiais para ambas as funções. Uma possível explicação para este comportamento pode estar no conjunto de treinamento. Este contém apenas 2 exemplos de telhados azulados. Adjacente a um deles, próximo ao centro da imagem, há outro telhado também azulado, sendo que a fronteira entre eles não se discerne com clareza do ponto de vista espectral. Esta

fronteira nebulosa pode ter trazido dificuldade para o processo de otimização. Telhados claros tenderam a ser super-segmentados para ambas as funções de disparidade, de novo possivelmente devido à ausência de telhados brancos no conjunto de treinamento.

Para objetos heterogêneos, percebe-se uma superioridade da função *LSB*. Objetos heterogêneos tendem a ser divididos em suas partes homogêneas pela função *RBSB*. Este comportamento é particularmente visível no grande telhado claro no quadrante superior direito da imagem. Em síntese, a função *LSB* tem desempenho semelhante à função *RBSB* para objetos homogêneos, e a supera quando se trata de objetos heterogêneos.

#### 4. Conclusões e Direções Futuras

Esta seção explicita as principais conclusões deste trabalho extraídas dos experimentos descritos na seção anterior.

Para objetos homogêneos o método de ajuste de parâmetro de segmentação produziu resultados bastante compatíveis com a percepção visual da qualidade da segmentação. Esta conclusão se aplica às duas funções de disparidade consideradas neste trabalho. Em ambos os casos valores de disparidade em torno de 0,35 estiveram associados a uma boa qualidade visual do resultado da segmentação.

O problema de segmentação é inerentemente mais difícil quando os objetos de interesse são heterogêneos. Isto se refletiu em valores comparativamente mais elevados dos graus de disparidade produzidos por ambas as funções consideradas. De um modo geral, muitos dos objetos heterogêneos presentes na imagem acabam sendo subdivididos em suas partes homogêneas, por melhor que seja o ajuste dos parâmetros de segmentação. Não é, portanto, possível afirmar que se alcançaram de fato os resultados ótimos em termos de qualidade visual nos experimentos realizados com objetos heterogêneos. Os resultados são, contudo, pelo menos razoáveis visualmente.

A análise evidenciou, ainda, a importância de um conjunto de referência efetivamente representativo de todos os tipos de objetos de interesse presentes na imagem. Ficou igualmente patente que os valores ótimos dos parâmetros de segmentação para um determinado tipo de objeto não serão necessariamente os valores ótimos para outro. Assim, ao se incluírem objetos de vários tipos no conjunto de referência, o método de ajuste poderá produzir resultados insatisfatórios para alguns e, no limite, para todos eles.

Estas considerações sugerem que a seleção dos objetos para a referência ocorra em mais de uma etapa, em que representantes de tipos diferentes são incluídos ou excluídos do conjunto de treinamento pelo usuário, dependendo da qualidade do resultado alcançado pelo *SPT*. Uma avaliação deste procedimento foge, contudo, do escopo do presente trabalho.

De maneira geral, os resultados experimentais confirmam que a metodologia supervisionada baseada em AGs constitui uma abordagem promissora para reduzir o tempo investido pelo operador humano no ajuste dos parâmetros de algoritmos de segmentação.

Será interessante considerar, num estudo futuro, o comportamento do método para diversos algoritmos de segmentação, utilizando todos os três disponíveis no *SPT*.

#### Referências Bibliográficas

Baatz, M.; Schäpe, A. Multiresolution Segmentation – an optimization approach for high quality multi-scale image segmentation, Heidelberg. Strobl J, Blaschke T, Griesebner G (eds) *Angewandte Geographische Informationsverarbeitung*, v. 12, p. 12-23, 2000.

- Blaschke, T.; Strobl, J. What is wrong with pixels? Some recent developments interfacing remote sensing and GIS. **GIS-Zeitschrift für Geoinformationssysteme**, n. 6, p. 12-17, 2001.
- Carleer, A. P.; Debeir, O.; Wolff, E. Assesment of very high spatial resolution satellite image segmentations. **Photogrammetric Engineering and Remote Sensing**, v. 71, n. 11, p. 1285–1294, 2005.
- Costa, G. A. O. P.; Feitosa, R. Q.; Cazes, T. B.; Feijó, B. Genetic Adaptation of Segmentation Parameters. In: Blaschke, T.; Lang, S.; Hay, G. (Eds.). **Object-Based Image Analysis: Spatial concepts for knowledge-driven remote sensing applications**. Heidelberg: Springer, 2008. p. 679-695.
- Davis, L. **Handbook of Genetic Algorithms**. New York: Van Nostrand Reinhold, 1990.
- Fredrich, C. M. B.; Feitosa, R. Q. Automatic Adaptation of Segmentation Parameters Applied to Inhomogeneous Objects Detection, Calgary. **GEOBIA - Geo-Object Based Image Analysis Conference – Proceedings**, 2008.
- Feitosa, R. Q.; Costa, G. A.; Cazes, T. B.; Feijó, B. A genetic approach for the automatic adaptation of segmentation parameters. **International Conference on Object-based Image Analysis - ISPRS Proceedings**, v. 36, n. 4/C42, 2006.
- Michalewicz, Z. **Genetic Algorithms + Data Structures = Evolution Programs**, Heidelberg: Springer, 1999.
- Neubert, M.; Herold, H.; Meinel, G. Accessing image segmentation quality – concepts, methods and application. In: Blaschke, T.; Lang, S.; Hay, G. (Eds.). **Object-Based Image Analysis: Spatial concepts for knowledge-driven remote sensing applications**. Heidelberg: Springer, 2008. cap. 8.3, p. 679-784.
- Pignalberi, G.; Cucchiara, R.; Cinque, L.; Levialdi, S. 2003. Tuning range image segmentation by genetic algorithm. **EURASIP Journal on Applied Signal Processing**, n. 8, p. 780–790, 2003.
- Zhang Y. A survey on evaluation methods for image segmentation. **Pattern Recognition**, v. 29, n. 8, p. 1335– 1346, 1996.