

Artigo recebido em: 16/05/12  
Revisado em: 25/06/12  
Aprovado em: 05/07/12

**Eduardo Freire Santana**<sup>1</sup>

**Leonardo V. Batista**<sup>1</sup>

**Richarde Marques da Silva**<sup>2</sup>

## **TÉCNICAS DE SEGMENTAÇÃO NÃO-SUPERVISIONADA: análise comparativa de mapeamentos do uso e ocupação do solo**

### **RESUMO**

Técnicas de sensoriamento remoto são fundamentais para o monitoramento das mudanças de uso da terra, principalmente em áreas extensas. O mapeamento de uso da terra, geralmente é realizado por métodos de classificação manual ou digital pixel a pixel, os quais consomem muito tempo. Este trabalho busca desenvolver um novo método para segmentação não-supervisionada de imagens de sensoriamento remoto baseado na minimização da entropia cruzada entre a distribuição de probabilidade da imagem e um modelo estatístico. Para os testes realizados, foram utilizadas quinze imagens capturadas pelo sensor TM (Thematic Mapper) do satélite Landsat 5 a partir do banco de dados do projeto de mapeamento do uso do solo da região amazônica. Os resultados indicam que a minimização da entropia cruzada está relacionada com uma segmentação coerente das imagens. A concordância média entre o classificador e o gabarito foi de 85% para as quinze imagens selecionadas e de 92% para quatro pequenas regiões que representam detalhes de uma das imagens.

**Palavras-chave:** Segmentação não-supervisionada, modelos estatísticos, sensoriamento remoto.

## **UNSUPERVISED SEGMENTATION TECHNIQUES: comparative analyze of land use and cover mapping**

### **ABSTRACT**

Remote sensing techniques are mandatory for monitoring land use changes in large areas. Land use mapping is usually performed by both manual and digital pixel based classification methods which are cost and time-consuming. In this paper, a new method for image unsupervised segmentation based on cross-entropy minimization between probability distribution of image and one statistical model. For testing 15 images captured by the sensor TM (Thematic Mapper) of the Landsat 5 satellite from the database mapping project of land use in the Amazon region were used. The results indicate that the cross-entropy minimization relates to a consistent segmentation of images. The average agreement between the classifier and the feedback was 85% for the 15 selected images and 92% for four small regions that represent details of the images.

**Keywords:** Unsupervised segmentation, statistical models, remote sensing.

<sup>1</sup> Universidade Federal da Paraíba  
Departamento de Computação  
[eduardo.freire.87@gmail.com](mailto:eduardo.freire.87@gmail.com)

<sup>2</sup> Universidade Federal da Paraíba  
[richarde@geociencias.ufpb.br](mailto:richarde@geociencias.ufpb.br)

Correspondência:

Eduardo Freire Santana  
Departamento de Informática  
Cidade Universitária  
João Pessoa-PB, Brasil  
CEP 58051-900

## INTRODUÇÃO

Processamento digital de imagens refere-se a operações realizadas sobre imagens digitais por meio de computadores. O interesse nessa disciplina deve-se principalmente a duas aplicações: melhorias para interpretação visual humana e processamento para armazenamento, transmissão e representação da informação contida em uma imagem para percepção por máquinas (GONZALEZ e WOODS, 2002). O processamento digital de imagens está correlacionado com outras áreas, como computação gráfica e visão computacional, e faz amplo uso de reconhecimento de padrões para atingir seus objetivos. Reconhecimento de padrões é a disciplina da ciência cujo objetivo é a classificação de objetos em categorias (THEODORIDIS e KOUTROUMBAS, 2009). Esses objetos podem ser, entre outros, sinais em formato de onda, textos e imagens. A classificação de imagens consiste em agrupar imagens com conteúdo semelhante de acordo com algum critério, já a segmentação de imagens tem por objetivo a criação de regiões homogêneas, de modo que a união entre regiões adjacentes não seja homogênea (PAL e PAL, 1993). O nível de segmentação de uma imagem depende do problema que está sendo resolvido e deve parar quando os objetos de interesse tiverem sido isolados.

Uma das abordagens para segmentação de imagens é a utilização de modelos estatísticos. A Teoria da Informação considera a comunicação como um problema matemático embasado na estatística, e possui grande importância para a ciência principalmente por fornecer as definições de informação e entropia e a possibilidade de quantificar estes conceitos a partir de probabilidades estimadas (SALOMON, 2007). Utilizando conceitos da Teoria da Informação, é possível medir com um valor numérico a surpresa causada pela observação de uma mensagem através da ótica de um determinado modelo estatístico. Esta medida de surpresa é a entropia cruzada entre o modelo estatístico e a distribuição de probabilidade da mensagem, e pode ser utilizada, por exemplo, como medida de dissimilaridade para dividir uma imagem em regiões.

O problema de segmentar imagens aparece com frequência em sensoriamento remoto sob a forma de detecção de mudança de paisagens e classificação do uso do solo. Sensoriamento remoto é a tecnologia para aquisição de informações sobre um objeto de estudo sem que haja contato direto com este objeto, sendo o uso mais comum desse termo o sensoriamento ótico da superfície terrestre por meio de satélites. Imagens da superfície terrestre capturadas do espaço estão disponíveis desde a década de 1960, embora possuíssem baixa resolução e fossem frequentemente registradas em ângulos oblíquos. A partir da década de 1970, com o lançamento do programa de satélites *Landsat*, e

posteriormente com o lançamento do programa SPOT, na década de 1980, foi possível a captura de imagens com ângulos quase verticais e resolução capaz de mapear recursos terrestres de forma útil (LILLESAND e KIEFER, 1999). Aplicações modernas de sensoriamento remoto envolvem a análise multiespectral de objetos localizados na superfície da Terra por meio de satélites, aeronaves e estações espaciais. A informação é obtida através de sensores que captam a energia eletromagnética emitida pela superfície terrestre em determinadas bandas de comprimento de onda. Superfícies compostas por diferentes materiais, como vegetação, água e solo, em geral, refletem diferentes proporções de energia nas faixas do espectro eletromagnético (azul, verde, vermelho, infravermelho próximo, etc.) (JENSEN, 2007).

Um dos problemas enfrentados no mapeamento de recursos e uso do solo por imagens de sensoriamento remoto é o gerenciamento de grande quantidade de dados. Para a análise quantitativa de imagens de sensoriamento remoto, a classificação supervisionada é o procedimento mais frequentemente utilizado (RICHARDS e JIA, 2006). A utilização de técnicas de segmentação presentes em sistemas de informação geográfica ajuda a reduzir o trabalho manual de interpretação das imagens, embora ainda seja tarefa do especialista a construção de um conjunto de treinamento no caso da classificação supervisionada. Segmentação de imagens não triviais é uma das tarefas mais difíceis em processamento digital de imagens, além de ser um fator crucial para o sucesso de uma análise feita por computador (GONZALEZ e WOODS, 2002). Embora haja muitos estudos sobre segmentação de imagens e segmentação de imagens de sensoriamento remoto, este problema permanece em aberto, até mesmo por sua natureza subjetiva. A investigação de um método de segmentação não-supervisionada que utiliza conceitos da Teoria da Informação pode contribuir com os avanços na área. Este trabalho tem como objetivo geral o desenvolvimento de um novo método para segmentação não-supervisionada de imagens de sensoriamento remoto por minimização da entropia cruzada entre a distribuição de probabilidade da imagem e um modelo estatístico.

## **MATERIAIS E MÉTODOS**

### **Estimação de uma Função Densidade de Probabilidade**

Classificadores baseados na Teoria Bayesiana de Decisão calculam a probabilidade de um objeto pertencer a cada uma das possíveis classes e atribui esse objeto à classe mais provável. Quando não há conhecimento *a priori* sobre a probabilidade de ocorrência de cada classe, a decisão tomada pelo classificador é definida por:

$$\text{Decida } c_i \text{ se } p(x/c_i) > p(x/c_j), \forall_j \neq i \quad (1)$$

onde  $p(x|c_i)$  é a função densidade de probabilidade da classe  $c_i$ .

Essa regra de decisão é um caso especial de uma regra geral, onde pode haver diferentes penalidades atribuídas a diferentes classificações incorretas. Nessas condições, o desempenho do classificador depende de boas estimações para as funções densidade de probabilidade, pois a tomada de decisão fica condicionada apenas à distribuição dos vetores de cada classe.

Em muitos problemas, a função densidade de probabilidade é desconhecida e precisa ser estimada a partir dos dados disponíveis. Em alguns casos, o tipo de distribuição é conhecido (distribuição normal, distribuição de Poisson, etc.), sendo necessário estimar apenas os parâmetros da função, como média ou desvio-padrão. Quando o tipo de distribuição é desconhecido, é preciso utilizar técnicas para estimação de forma não-paramétrica (THEODORIDIS e KOUTROUMBAS, 2009).

Estimações não-paramétricas são basicamente variações de aproximações feitas por histograma de uma função densidade de probabilidade desconhecida. Nenhuma suposição é feita *a priori* sobre o tipo de distribuição em questão. A função de distribuição é estimada a partir das observações realizadas, recebendo maior probabilidade as regiões onde os dados observados estão mais concentrados. A Figura 1 ilustra a estimação por um método não-paramétrico, aplicado a dois diferentes tipos de distribuições. Essa figura mostra a estimação não-paramétrica por histograma de uma distribuição normal (a) e uma distribuição bimodal (b). Nos dois casos a distribuição estimada conseguiu se aproximar da distribuição real, embora tenha sido necessário um número elevado de amostras.

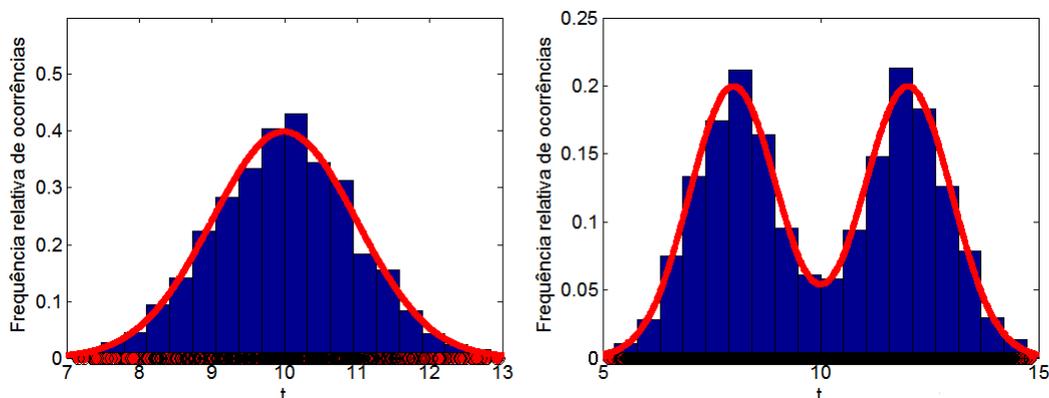


Figura 1 – Exemplos de estimação não-paramétrica  
Fonte: Yoneyama (2009).

Abordagens não-paramétricas possuem maior flexibilidade, pois se adaptam aos diferentes tipos de distribuição. Em contrapartida, precisam de um número maior de amostras para que se possa atingir uma estimativa próxima à distribuição real (YONEYAMA, 2009).

### Entropia e Modelos Estatísticos

A Teoria da Informação fornece conceitos importantes para o reconhecimento de padrões, como informação e entropia, além de possibilitar tratamento numérico para tais conceitos. Existe uma relação entre reconhecimento de padrões para compressão de dados e modelagem de uma densidade de probabilidade desconhecida. Um modelo estatístico que se aproxima da distribuição real desconhecida consegue comprimir os dados de uma mensagem reduzindo a informação média por símbolo.

A informação de uma variável aleatória  $x$  está relacionada com a surpresa causada pela observação de seu valor (BISHOP, 2006). A Equação 2 apresenta o cálculo da informação  $h(x)$  em função da probabilidade de ocorrência  $p(x)$ :

$$h(x) = -\log_2 p(x) \quad (2)$$

A função  $h(x)$  decresce monotonicamente em relação a  $p(x)$ , i. e., quanto maior for a probabilidade de ocorrência de  $x$ , menor será a informação. Caso seja utilizada a base logarítmica dois, a informação será quantificada em bits.

A entropia de uma distribuição refere-se ao grau de incerteza de uma sequência de símbolos retirados desta distribuição (DUDA *et al.*, 2001). A entropia de uma distribuição de probabilidade discreta  $p(x)$  sobre um alfabeto  $X$  é:

$$H(p) = -\sum_{x \in X} p(x) \log_2 p(x) \quad (3)$$

Em um processo de comunicação, a informação presente em uma mensagem está associada às expectativas do receptor. Entropia cruzada entre duas densidades de probabilidade é a informação média necessária para representar um símbolo, quando utilizada uma distribuição estimada por um modelo estatístico  $q(x)$  em vez da distribuição real  $p(x)$  (BISHOP, 2006).

$$H(p,q) = - \sum_{x \in X} p(x) \log_2 q(x) \quad (4)$$

Em muitas situações, a densidade real é desconhecida e a entropia cruzada não pode ser calculada diretamente pela Equação 4. Uma aproximação é feita a partir da informação observada sobre determinada mensagem retirada da densidade real. Para uma mensagem de tamanho  $N$  e um densidade estimada  $q(x)$ , a entropia cruzada é calculada pela informação média da mensagem:

$$H(p) = - \frac{1}{N} \sum_{i=1}^N \log_2 q(x_i) \quad (5)$$

A entropia cruzada pode ser utilizada para a classificação de padrões como medida de dissimilaridade entre distribuições. A Figura 2 contém a representação gráfica de duas distribuições de probabilidade, modeladas por histograma a partir de uma segmentação de área urbana e hidrografia.

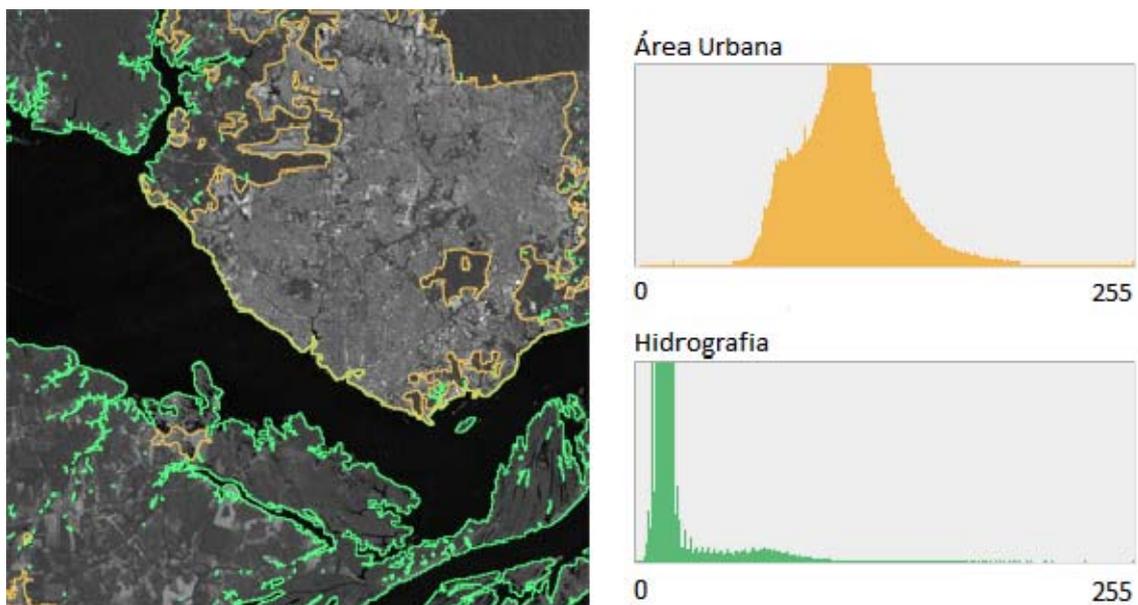


Figura 2 – Distribuições estimadas para área urbana e hidrografia.

É esperado que a distribuição de uma região possua baixa entropia cruzada com a distribuição de outra região de mesma classe, enquanto as distribuições de regiões de classes diferentes possuam alta entropia cruzada entre si.

## Inicialização de sementes através do método max-min

Um dos problemas encontrados em métodos de classificação não-supervisionada é a escolha de sementes para inicialização dos clusters. Várias abordagens para inicialização foram propostas para os algoritmos de classificação não supervisionada, muitas delas não-determinísticas (MAITRA *et al.*, 2010). O método da máxima distância mínima (max-min), por outro lado, é uma abordagem determinística que define alguma amostra observada como semente e que procura sementes distantes entre si (MIRKIN, 2005). O Algoritmo 1 descreve o processo de seleção das sementes.

### ALGORITMO 1 - MAX-MIN

Calcular todas as distâncias entre pares de vetores no conjunto de dados.  
Selecionar como sementes os dois vetores com maior distância entre si.  
Até o número desejado de sementes, repetir:  
    Selecionar como nova semente o vetor cuja distância mínima para as atuais sementes seja a maior possível.

Fonte: Maitra *et al.* (2010).

Caso o conjunto de dados seja muito grande, esse método pode tornar-se computacionalmente custoso, pois apresenta complexidade  $O(n^2)$ . Para contornar esse problema é preciso substituir a maneira como as duas primeiras sementes são escolhidas, eliminando o cálculo das distâncias entre todos os pares de vetores. No caso de imagens, pode-se escolher a primeira semente por algum critério como região mais homogênea, e as demais sementes por máxima distância mínima.

## Transformada *WATERSHED*

A Transformada *Watershed* é uma abordagem de segmentação de imagens que gera regiões com base em uma situação real de inundação (BEUCHER, 1992). A primeira etapa dessa transformada é o cálculo da imagem gradiente através de um operador de diferenciação. A imagem gradiente indica a variação dos valores da imagem em cada pixel (Figura 3).

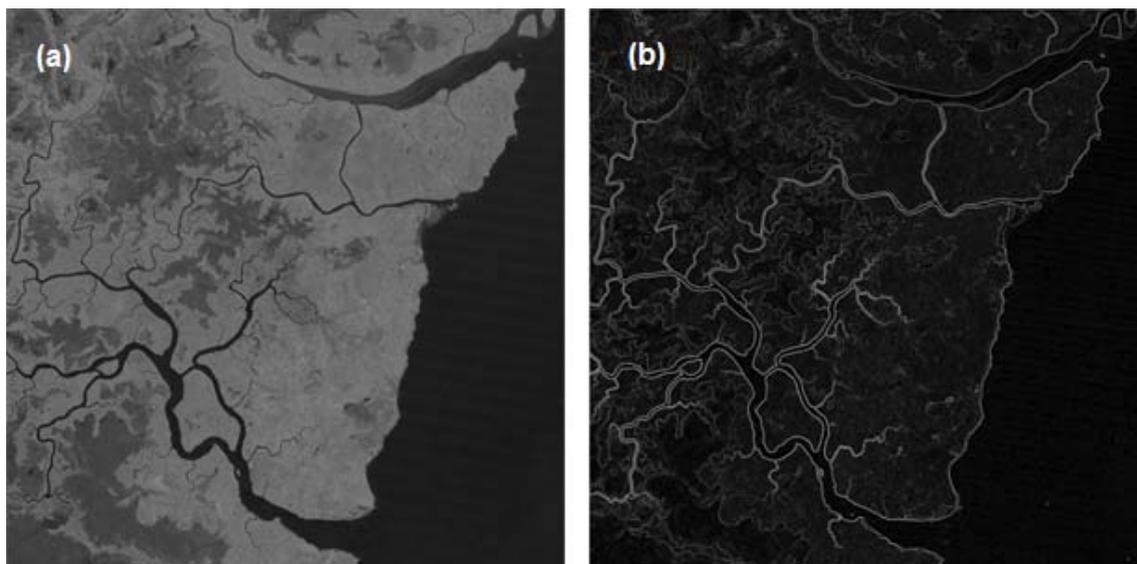


Figura 3 – Detalhe de imagem capturada pelo satélite Landsat-5, banda 4 (a); Imagem gradiente calculada pelo operador de Sobel (b).

A imagem gradiente é tratada como uma superfície topográfica, onde o valor em cada pixel significa a elevação da superfície naquele local (Figura 3).

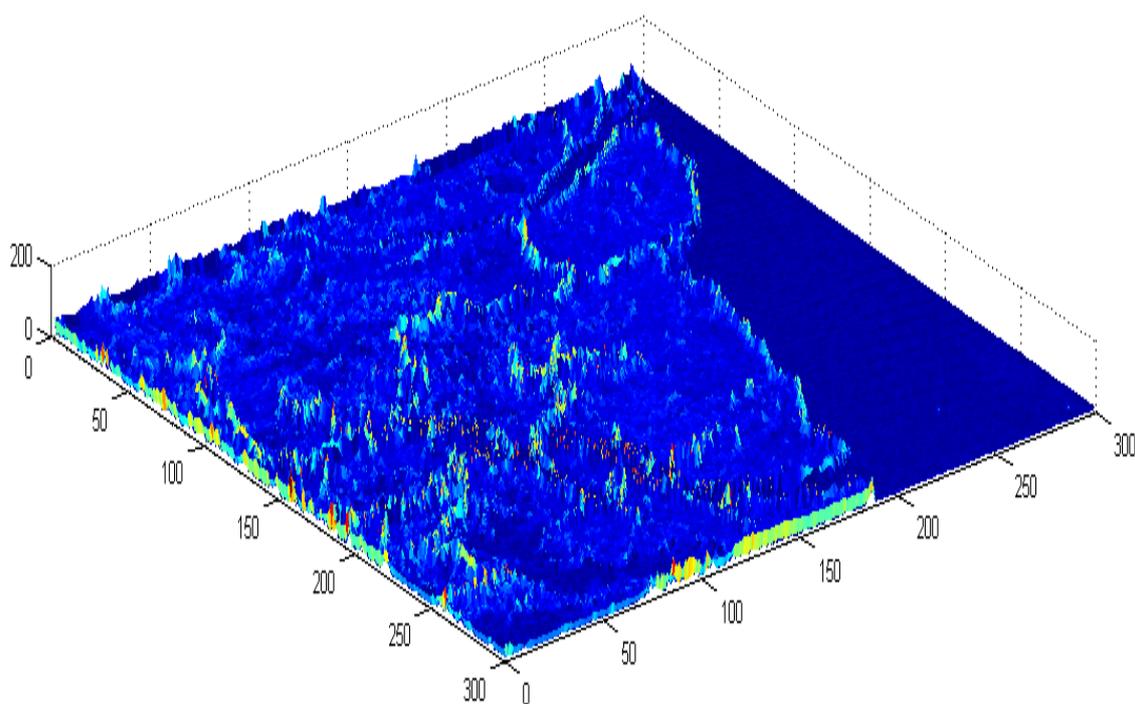


Figura 3 – Visualização topográfica da imagem gradiente da Figura 3.

O processo de inundação é então iniciado e a água começa a fluir a partir dos mínimos locais. Quando a água que parte de dois mínimos converge, é construída uma

represa delimitando as duas regiões. A Figura 4 ilustra o processo de inundação e a construção das represas.

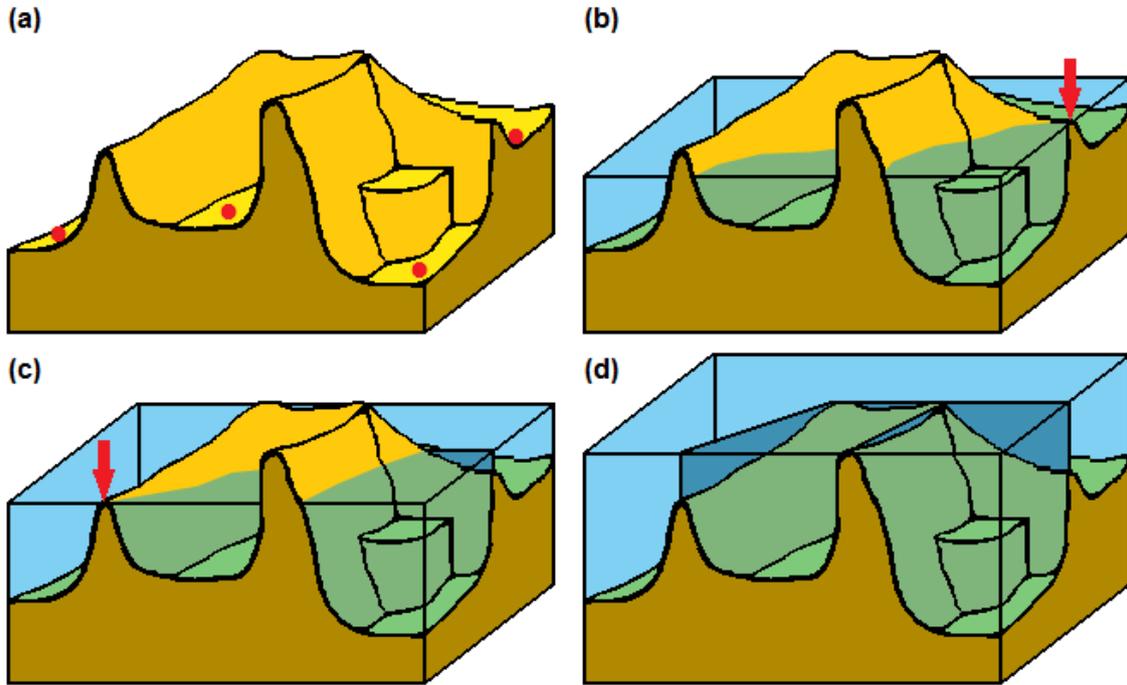


Figura 5 – Mínimos locais identificados por pontos vermelhos (a). Quando a água encontra um ponto onde pode transbordar, uma represa é construída (b). A inundação acaba ao atingir o ponto mais alto (c). As regiões delimitadas pelas represas determinam a segmentação da imagem (d). Fonte: adaptada de Beucher (1992).

O resultado do processo tende a ser uma supersegmentação da imagem, devido à presença de ruído ou padrões de texturas (BEUCHER, 1992). Os passos para a realização da Transformada *Watershed* são descritos no Algoritmo 2.

#### ALGORITMO 2 - TRANSFORMADA WATERSHED

Calcular a imagem gradiente.

Localizar os mínimos locais da imagem gradiente.

Para cada mínimo local:

    Criar uma região a partir do mínimo local.

    Repetir:

        Adicionar à região os pixels da vizinhança cujo valor na imagem gradiente é maior que o valor da região na fronteira.

    Enquanto houver pixels para serem adicionados na fronteira da região.

Fonte: Beucher (1992).

## Imagens utilizados neste estudo

Para testar o desempenho do algoritmo de segmentação proposto, foram utilizadas imagens de sensoriamento remoto da região amazônica, capturadas pelo sensor TM do satélite *Landsat-5* no ano de 2008, disponíveis no site do Instituto Nacional de Pesquisas Espaciais (INPE). A escolha por esse banco de dados se deve ao fato de se encontrar, também no site do INPE, a classificação do uso do solo para essa região, gerada pelo projeto *TerraClass*.

Em 1988, o Programa de Monitoramento do Desflorestamento na Amazônia Legal (PRODES), desenvolvido e executado pelo INPE, surgiu com o intuito de produzir a estimativa da taxa anual do desflorestamento, a partir de levantamentos sistemáticos utilizando imagens de satélite. Vinte anos após o início do PRODES, para atender as novas necessidades de qualificação das áreas desflorestadas da Amazônia, a Empresa Brasileira de Pesquisas Agropecuárias (Embrapa) e o INPE executaram um projeto em parceria, chamado *TerraClass* (EMPRESA BRASILEIRA DE PESQUISAS AGROPECUÁRIAS; INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS, 2011). A execução desse projeto resultou na elaboração de um mapa que descreve a situação do uso do solo na Amazônia durante o ano de 2008. Os dados digitais resultantes do mapeamento encontram-se disponíveis no site do INPE ([www.inpe.br](http://www.inpe.br)).

Para a avaliação do método de segmentação proposto, foram utilizadas imagens classificadas do projeto *TerraClass*. Essas imagens estão divididas por cena e encontram-se no formato vetorial *shapefile*. As classes temáticas consideradas nos testes realizados são três: hidrografia, vegetação e não floresta, derivadas das classes consideradas pelo projeto *TerraClass*. O Tabela 1 exibe descrição e legenda de cor para as classes consideradas. Os pixels marcados na imagem temática como área não observada não participam do processo de classificação.

Tabela 1 – Legenda e descrição das classes temáticas

Cor	Classe	Descrição
	Hidrografia	Rios
	Vegetação	Floresta, vegetação secundária e agricultura
	Não Floresta	Área urbana, pastos, áreas desmatadas e áreas com solo exposto
	Área não Observada	Áreas que tiveram sua interpretação impossibilitada pela presença de nuvens ou sombra de nuvens

A taxa de acertos do classificador é aferida pixel a pixel e, portanto, foi preciso converter a imagem temática disponível em formato vetorial para uma imagem em formato *raster*. Para esta tarefa, um conversor foi desenvolvido com base no documento de especificações técnicas da empresa Environmental Systems Research Institute (1998).

Para os testes realizados, foram utilizadas quinze imagens de dimensões 500x500 pixels e quatro imagens de dimensões 50x50, que representam detalhes como a transição entre rio e vegetação ou entre vegetação e solo exposto. O gabarito para os detalhes de imagem foi feito manualmente por um especialista.

### Segmentação por minimização da entropia cruzada

A entropia cruzada é calculada pela informação média de uma mensagem de acordo com um modelo estatístico. A Equação 6 apresenta o cálculo da entropia cruzada de acordo com a modelagem proposta:

$$H = -\frac{1}{|X|} \sum_{x \in X} \sum_{k=1}^N R_k(x) \left( \log_2 \frac{1}{K} + \sum_{b=1}^B \log_2 P_k(x_b) \right) \quad (6)$$

onde:

$|X|$  é o número de pixels da imagem  $X$ .

$x$  é um pixel da imagem.

$K$  é número total de clusters presentes na segmentação.

$R_k(x)$  é uma função que assume valor '1' caso o pixel  $x$  pertença ao cluster  $k$  e '0' caso contrário.

$B$  é o número de bandas que compõem a imagem.

$p_k(x_b)$  é a função densidade de probabilidade do cluster  $k$  para os valores de  $x$  na banda  $b$ .

O algoritmo desenvolvido tem por objetivo minimizar a Equação 6 através da manipulação das funções  $R_k$ . O Algoritmo 3 descreve as etapas propostas para a redução iterativa da Equação 6.

### ALGORITMO 3 - MINIMIZAÇÃO DA ENTROPIA CRUZADA

Executar a Transformada Watershed.

Selecionar sementes (regiões) pelo método max-min.

Repetir:

Estimar a densidade de probabilidade das classes de acordo com suas regiões.

Atribuir cada região à classe que obtiver menor informação.

Enquanto houver redução da entropia cruzada.

## RESULTADOS

Em cada iteração, as regiões que pertencem a um cluster têm seus pixels utilizados como amostras para a construção do modelo estatístico daquele cluster por meio de estimação não-paramétrica. O modelo estatístico de um cluster é construído de modo que haja estimativa (maior que zero) para cada um dos 256 possíveis valores que um pixel possa assumir em cada banda da imagem. Dessa forma, cada cluster  $k$  possui  $B$  funções independentes para estimação de probabilidades, uma para cada banda, construídas através de histogramas. A probabilidade estimada inicialmente para a ocorrência de qualquer valor em qualquer banda é, portanto,  $1/256$ . Ao final do treinamento, a probabilidade estimada para um determinado valor em uma banda será a frequência relativa desse valor naquela banda.

A Figura 4 ilustra a escolha das sementes e o processo de minimização da entropia cruzada. No exemplo da Figura 4, é possível perceber que já existe distinção entre as classes hidrografia, vegetação e não floresta na primeira iteração, onde as densidades de probabilidade de cada cluster são estimadas apenas com as amostras de cada semente selecionada. As iterações seguintes utilizam o modelo estatístico da iteração anterior para obter um modelo mais preciso para a redução da entropia cruzada e uma esperada melhora na segmentação da imagem.

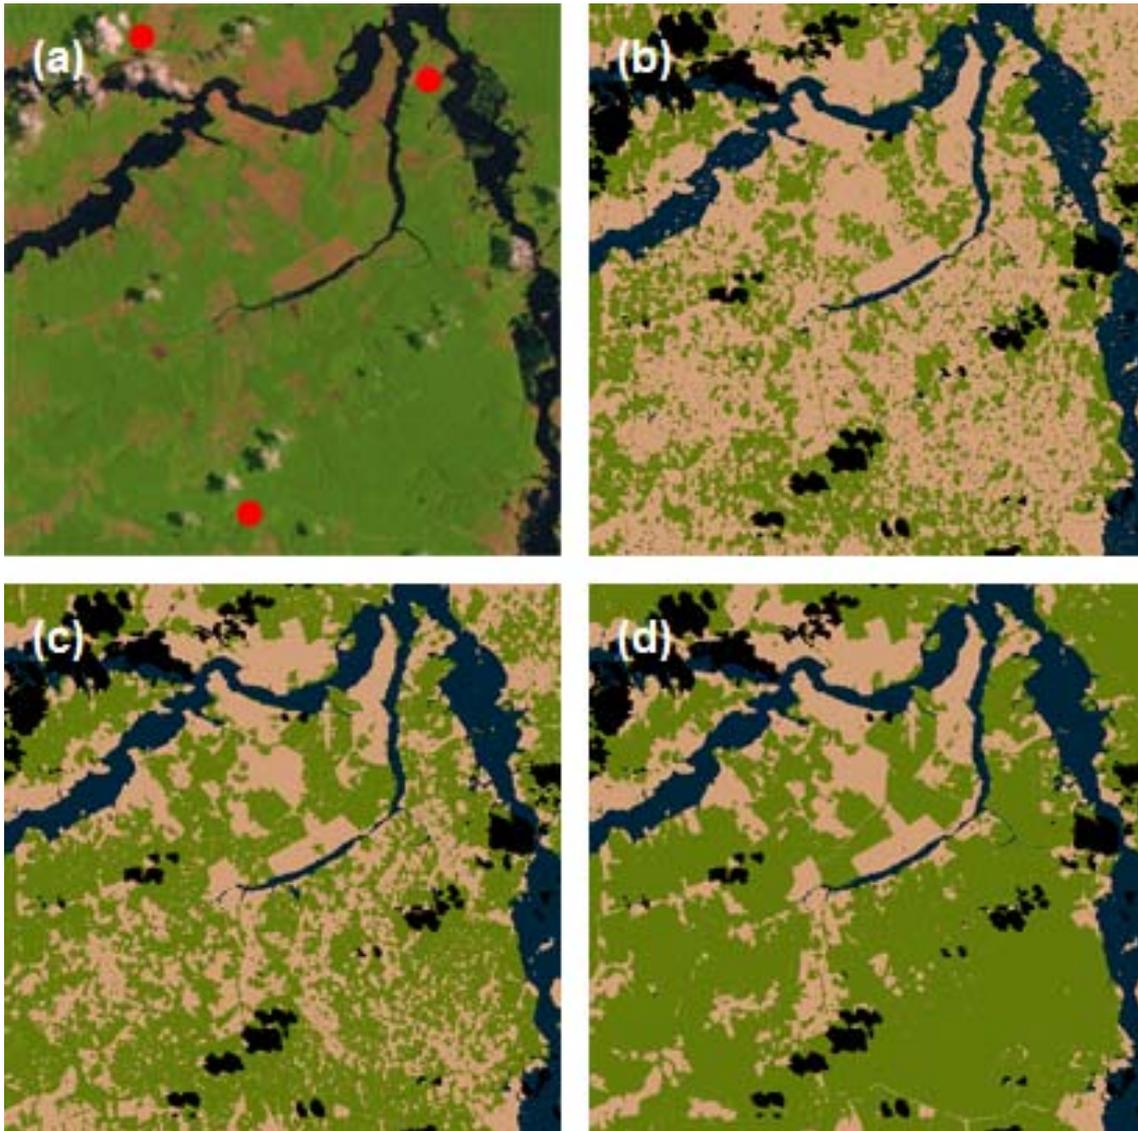


Figura 4 - Redução da entropia cruzada: seleção das sementes pelo método max-min (a). Primeira iteração: entropia=14,84 bits/símbolo; concordância observada=62,08% (b). Sexta iteração: entropia=10,58 bits/símbolo; concordância observada=76,64% (c). Fim do processo de redução da entropia (iteração 42): entropia=10,49 bits/símbolo; concordância observada=92,18% (d).

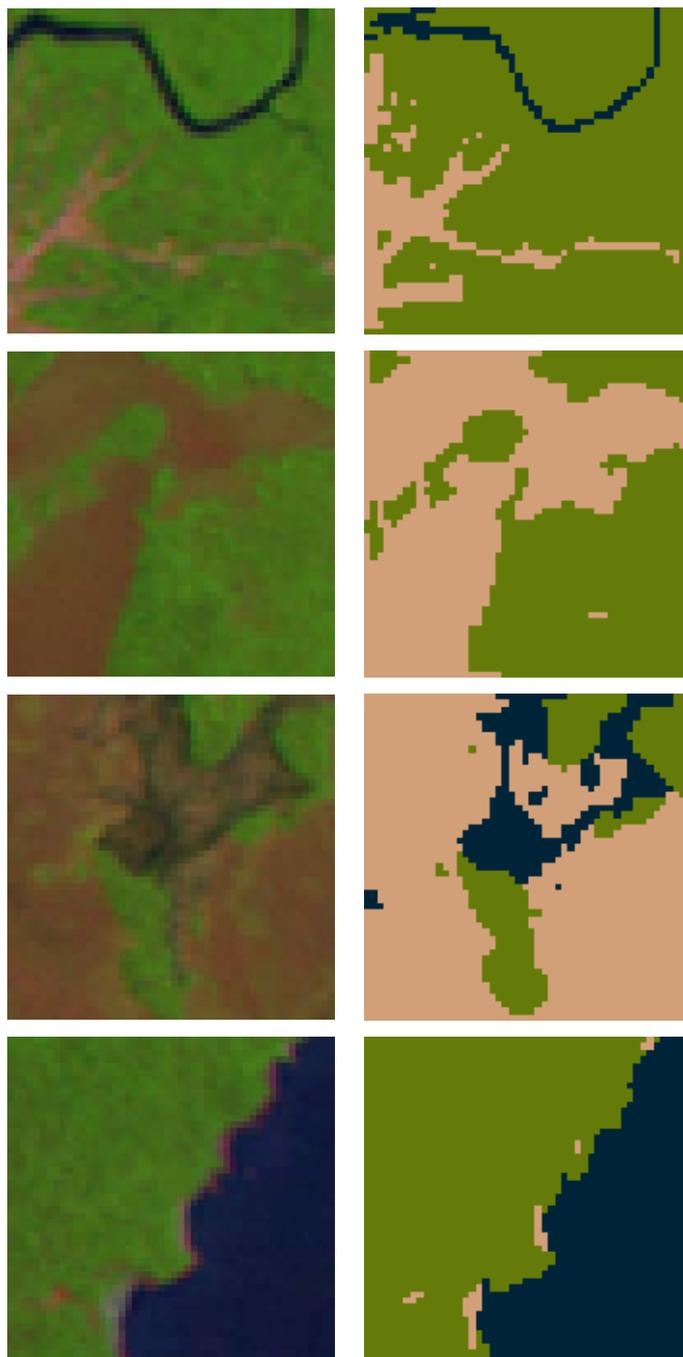


Figura 5 – Segmentação dos detalhes de imagem

## CONCLUSÕES

Os resultados obtidos indicam que o método de segmentação proposto consegue classificar as imagens de forma coerente enquanto busca a redução da entropia cruzada. A operação sobre regiões, além de acelerar o processo, adiciona contexto espacial à

segmentação, algo que não existe em métodos baseados puramente na classificação pixel a pixel.

Embora o gabarito utilizado como referência nos testes não seja totalmente preciso, a concordância média de 84,55% sobre as imagens do banco é um indicador de bom desempenho do classificador. Para os detalhes de imagem, cujos gabaritos foram segmentados manualmente, a concordância média de 91,81% também é um bom indicador. Na maioria dos casos, o índice Kappa está próximo da concordância observada, o que sugere baixa taxa de acertos por acaso.

Algo que pode ser explorado para aumentar o poder de classificação do método proposto é a utilização de um sistema hierárquico de classificação. Após a segmentação inicial das classes é possível subdividir cada classe selecionando bandas específicas que possam diferenciar, por exemplo, pastos de área urbana, ou vegetação secundária de floresta.

## REFERÊNCIAS

BEUCHER, S. The Watershed Transformation Applied to Image Segmentation. *Scanning Microscopy*, v. 6, pp. 299-314, 1992.

BISHOP, C. M. *Pattern Recognition and Machine Learning*. New York: Springer, 2006.

DUDA, R. O.; HART, P. E.; STORK, D. G. *Pattern Classification*. 2. ed. New York: Wiley Interscience, 2001.

ENVIRONMENTAL SYSTEMS RESEARCH INSTITUTE. *ESRI Shapefile Technical Description: An ESRI White Paper*. Redlands, 1998.

EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA; INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS. *Levantamento de Informações de Uso e Cobertura da Terra na Amazônia. Sumário executivo do projeto TerraClass, set. 2011.*

GONZALEZ, R. C.; WOODS, R. E. *Digital Image Processing*. 2. ed. Upper Saddle River: Prentice-Hall, 2002.

LILLESAND, T. M.; KIEFER, R. W. *Remote Sensing and Image Interpretation*. 4. ed. New York: John Wiley & Sons, 1999.

JENSEN, J. R. *Remote Sensing of the Environment: An Earth Resource Perspective*. 2. ed. Upper Saddle River: Prentice-Hall, 2007.

MAITRA, R.; PETERSON, A. D.; GHOSH, A. P. A Systematic Evaluation of Different Methods for Initializing the K-means Clustering Algorithm. *IEEE Transactions on Knowledge and Data Engineering*, 2010.

MIRKIN, B. Clustering for Data Mining: A Data Recovery Approach. London: Chapman & Hall, 2005.

PAL, N. R.; PAL, S. K. A Review on Image Segmentation Techniques. Pattern Recognition, v. 26, n. 9, pp. 1274-1294, 1993.

RICHARDS, J. A.; JIA, X. Remote Sensing Digital Image Analysis: An Introduction. 4. ed. Berlin: Springer, 2006.

SALOMON, D. Data Compression: The Complete Reference, 3. ed. New York: Springer, 2004.

THEODORIDIS, S.; KOUTROUMBAS, K. Pattern Recognition. 4. ed. London: Academic Press, 2009.

YONEYAMA, T. Estimaco No-Paramtrica. Notas de aula da disciplina Controle Tolerante a Falhas, Curso de Ps-Graduao em Engenharia Eletrnica e Computao, Instituto Tecnolgico de Aeronutica, 2009. Disponvel em: <<http://www.ele.ita.br/~takashi/didatico.htm>>. Acesso em: 17 jul. 2012.