

Revista Brasileira de Cartografia (2016), N° 68/10: 2033-2043  
Sociedade Brasileira de Cartografia, Geodésia, Fotogrametria e Sensoriamento Remoto  
ISSN: 1808-0936

# DESENVOLVIMENTO DE UM MÉTODO DE SEGMENTAÇÃO DE IMAGENS BASEADO EM AGRUPAMENTO HIERÁRQUICO DIVISIVO E FUNÇÕES KERNEL

*Developing an Image Segmentation Method Based on Hierarchical Divisive Clustering and Kernel Functions*

**Lucas Zambon Maselli & Rogério Galante Negri**

**Universidade Estadual Paulista “Júlio de Mesquita Filho” – UNESP**

**Instituto de Ciência e Tecnologia – ICT**

Departamento de Engenharia Ambiental

Rodovia Presidente Dutra, km 137,8 - Eugenio de Melo - 12247-004 - São José dos Campos, SP, Brasil

{lucas.maselli, rogerio.negri}@ict.unesp.br

*Recebido em 8 de Julho, 2016/ Aceito em 11 de Outubro, 2016*

*Received on July 5, 2016/ Accepted on October 11, 2016*

## RESUMO

A crescente disponibilidade e melhoria na qualidade de imagens da superfície terrestre via Sensoriamento Remoto tem implicado na demanda constante pelo desenvolvimento de novos métodos para o processamento e extração de informações sobre tais imagens. Dentre tais métodos, destaca-se a segmentação de imagens, a qual visa delimitar objetos distribuídos na imagem. Neste contexto, este trabalho consiste em propor um novo método de segmentação de imagens fundamentado em conceitos de Agrupamento Hierárquico Divisivo,  $K$ -Médias e Funções Kernel. Dois experimentos práticos a fim de validar o método proposto, assim como compará-lo ao método Crescimento de Regiões, foram realizados. Tais experimentos consistem na segmentação de imagens obtidas pelos satélites IKONOS-II e LANDSAT-5. A comparação entre resultados é baseada em uma medida de avaliação de segmentação proposta na literatura. Os resultados indicam que o método proposto é capaz de proporcionar resultados satisfatórios e com maior nível de detalhamento com relação às delimitações de objetos.

**Palavras chaves:** Segmentação de Imagem, Agrupamento Hierárquico Divisivo,  $K$ -Médias, Funções Kernel, Crescimento de Regiões.

## ABSTRACT

Face to the availability increasing and quality improving of images from Earth's surface via Remote Sensing, the development of new methods for processing and information extraction from such data is a permanent challenge. Image segmentation is an example of image processing method which aims to define geographic objects over the image. In this context, this work aims to propose a new image segmentation method based on Hierarchical Divisive Clustering,  $K$ -Means and Kernel Function concepts. Study cases to validate the proposed method and compare it to the Region Growing method were carried out. These experiments deal with segmentation of IKONOS-II and LANDSAT-5 images. An assessment measure presented in literature was adopted for comparison. The results indicate that the proposed method is able to provide satisfactory results with greater level of detail regarding the boundaries of objects.

**Keywords:** Image Segmentation, Hierarchical Divisive Clustering,  $K$ -Means, Kernel Functions, Region Growing.

## 1. INTRODUÇÃO

Com o avanço tecnológico em diversas áreas científicas, o Reconhecimento de Padrões e o Processamento Digital de Imagens tornam-se cada vez mais úteis em diversos setores, que vão desde a área da saúde, com imagens obtidas por raios X, até a gestão ambiental, através de imagens de satélites (GONZALEZ & WOODS, 2006). Segmentação de Imagens é uma técnica de Processamento Digital de Imagens frequentemente usada nos estudos ambientais.

A definição para a segmentação de imagens esta diretamente relacionada à área na qual será aplicada. Na área de Visão Computacional, a segmentação refere-se ao processo de decomposição de uma imagem digital em vários objetos que a formam (JAIN, 1989), já nas aplicações em Sensoriamento Remoto, a segmentação de imagens trata da delimitação de objetos geográficos ou regiões distribuídas na imagem (MOIK, 1980). Dentre diversos métodos de segmentação propostos na literatura, o Crescimento de Regiões (*Region Growing*), introduzido em ZUCKER (1976), é amplamente aceito e utilizado.

Em problemas de qualquer natureza que envolva a divisão ou junção de objetos recursivamente, o emprego de métodos de agrupamento hierárquico torna-se uma escolha conveniente. A construção hierárquica pode ocorrer de duas formas, denominadas *bottom-up* e *top-down*. Pela abordagem *bottom-up*, os agrupamentos maiores surgem da fusão de frações menores da imagem, ou seja, supersegmentos são formados pela junção de subsegmentos. Pela abordagem *top-down*, segmentos maiores são subdivididos e geram regiões menores (MUSCI *et al.*, 2013). Dentre diferentes exemplos da categoria *top-down* encontra-se o Agrupamento Hierárquico Divisivo (AHD).

Dado um conjunto de dados, o AHD consiste em particionar, de forma recursiva, tais dados em dois subconjuntos até que seja atingido algum critério de parada. Cabe observar que o AHD compreende uma etapa de particionamento dos dados, a qual exige o emprego de um segundo método para efetuar tal processo. Admitindo a aplicação do AHD em imagens, o uso do algoritmo *K-Médias* como particionador dos dados é uma opção imediata.

O algoritmo *K-Médias*, amplamente conhecido pela comunidade de Sensoriamento Remoto, quando aplicado na classificação não supervisionada de imagens, consiste determinar *k* agrupamentos sobre os vetores de atributos associados aos pixels de tal imagem. Os elementos de cada agrupamento devem apresentar características similares entre si e distintas com relação aos elementos dos outros agrupamentos. Em seguida, tais agrupamentos são representando no domínio espacial da imagem.

A determinação dos agrupamentos pelo *K-Médias* é efetuada através de comparações entre o vetor de atributo de cada pixel com relação ao representante de cada um dos *k* agrupamentos, denominado “centroide”. A habilidade de geração de agrupamentos adequados, capazes de representar adequadamente os objetos na imagem, está diretamente relacionada com a medida de similaridade empregada para comparar os vetores de atributos dos pixels aos centroides. Tais comparações são usualmente realizadas com emprego da distância euclidiana como medida de similaridade.

Com intuito de obter resultados mais adequados, outras distâncias podem ser empregadas pelo método *K-Médias*. Uma alternativa é o uso de medidas de distâncias induzidas a partir de Funções Kernel. Funções Kernel são funções estritamente positivas que correspondem ao produto interno em outro espaço, geralmente de maior dimensão, onde espera-se que a separabilidade entre os padrões seja maior. Tais funções têm revolucionado as aplicações em Reconhecimento de Padrões. Em Dhillon *et al.* (2004) o emprego de Funções Kernel para fins de cálculo de similaridade foi verificado com sucesso no método *K-Médias*, estabelecendo assim o método Kernel *K-Médias*.

Diante do contexto apresentado, este trabalho investiga o potencial do método AHD associado ao algoritmo *K-Médias*, para definição de agrupamentos, e a medidas de distâncias induzidas por Funções Kernel, para segmentação de imagens de Sensoriamento Remoto. Com finalidade de validar e avaliar o método proposto foram realizados dois estudos de caso envolvendo a segmentação de imagens obtidas pelos satélites IKONOS-II e LANDSAT-5. Comparações com o método de segmentação

por Crescimento de Regiões são incluídas neste estudo. A medida *UNWise*, propostas Reis *et al.* (2016) foi empregada a fim de obter comparações quantitativas.

## 2. CONCEITOS PRELIMINARES

A fim de fornecer uma base teórica suficiente para a formalização do segmentador proposto e para sua experimentação prática, esta seção inclui discussões sobre os conceitos de segmentação de imagens, medidas quantitativas para avaliação de resultados de segmentação, algoritmos de agrupamento de dados e medidas de distância induzidas por funções kernel.

### 2.1. Segmentação de imagens

Segmentação de imagens tem como principal atribuição identificar e isolar partes homogêneas significativas de uma imagem (SILVA, 2000). Segundo GONZALEZ & WOODS (2006), a segmentação é um processo que consiste em dividir as imagens em segmentos internamente homogêneos e externamente heterogêneos baseados em alguma característica específica. A segmentação pode ser vista como um processo onde é a região espacial ocupada pela imagem que é particionada em regiões, compostas por pixels conectados, de forma que as seguintes condições sejam respeitadas:

$$\bigcup_{i=1}^n R_i = R, \quad (1)$$

$$R_i \cap R_j = \emptyset; i, j = 1, \dots, n; i \neq j, \quad (2)$$

$$Q(R_i) = \text{Verdadeiro}; i = 1, \dots, n, \quad (3)$$

$$Q(R_i \cap R_j) = \text{Falso}; i, j = 1, \dots, n, \quad (4)$$

onde  $Q(R_i)$  é uma propriedade lógica definida sobre as características dos pixels de determinada região, sendo verdadeira se todos pixels de  $R_i$  possuírem similaridade com relação a uma dada característica, por exemplo, os valores dos níveis de cinza de seus pixels. A propriedade  $Q$  torna-se falsa na união de duas regiões distintas, uma vez que, as mesmas são dissimilares *a priori*.

Segundo Wu *et al.* (2015), o método Crescimento de Regiões é amplamente utilizado para segmentação de imagens de Sensoriamento Remoto. Tal método é baseado no conceito de agrupamento de pixels, ou sub-regiões, em

regiões maiores (GONZALEZ & WOODS, 2006). Este método é caracterizado como um segmentador de abordagem *bottom-up*.

O processo de segmentação por Crescimento de Regiões se inicia com a escolha de um conjunto de pixels “sementes”, a partir dos quais outros pixels adjacentes são conectados, caso seja detectada a existência de similaridade entre eles, a fim de determinar uma região sobre imagem. A determinação das regiões ocorre iterativamente, até que todos os pixels da imagem sejam avaliados, gerando assim regiões poligonais fechadas cujos pixels respeitam o critério de similaridade estabelecido inicialmente.

### 2.2. Avaliação de segmentação e a medida

A fim de obter resultados mais confiáveis, o desenvolvimento e/ou aprimoramento de métodos de segmentação de imagens torna-se uma prática constante. Consequentemente, a comparação entre os diferentes métodos de segmentação disponíveis na literatura, visando identificar as potencialidades de cada método, é indispensável.

Segundo Zhang (1996), os métodos de segmentação podem ser avaliados de forma analítica ou empírica, sendo o segundo considerado mais satisfatório. As avaliações empíricas podem ainda ser classificadas dentre as de “qualidade” ou “discrepância”. As avaliações empíricas de qualidade levam em conta apenas os atributos da imagem final, sem nenhum conhecimento sobre a segmentação verdadeira (LUCCA, 1998). Por outro lado, as avaliações empíricas de discrepância comparam a segmentação da imagem com uma imagem de referência que apresenta o resultado ideal da segmentação, e então as diferenças (discrepâncias) são medidas e avaliadas.

Dentre as medidas empíricas para avaliação de qualidade de segmentação de imagens, destaca-se uma recente proposta apresentada em Reis *et al.* (2016), denominada *UNWise*. Tal medida de avaliação visa a maximização da homogeneidade dentro de cada região, e a heterogeneidade entre regiões.

Considerando como o número de bandas da imagem original que sofreu um processo de segmentação, a seguinte equação calcula a homogeneidade das regiões com relação a uma

dada banda  $b$ :

$$h_b = \frac{\sum_{i=1}^n A_i \cdot V_i}{\sum_{i=1}^n A_i}; \quad b = 1, \dots, w, \quad (5)$$

onde  $V_i$  é a variância da região  $R_i$ .

A heterogeneidade entre regiões segundo o comportamento espectral da banda é dada por:

$$k_b = \frac{n \sum_{i=1}^n \sum_{j=1}^n \beta_{ij} (\bar{R}_{i_b} - \bar{I}_b)(\bar{R}_{j_b} - \bar{I}_b)}{\left(\sum_{i=1}^n (\bar{R}_{i_b} - \bar{I}_b)^2\right) \left(\sum_{i=1}^n \sum_{j=1, j \neq i}^n \beta_{ij}\right)} \quad (6)$$

onde  $\beta_{ij}$  é um indicador de proximidade, que assume 1 quando  $R_i$  e  $R_j$  são adjacente e 0 caso contrário.  $\bar{I}_b$ ,  $\bar{R}_{i_b}$  e  $\bar{R}_{j_b}$  representam os valores médios associados à  $I$  e às regiões  $R_i$  e  $R_j$ , com relação à banda  $b$ , respectivamente.

Por fim, é estabelecido o índice de avaliação *UNWise*, que relaciona a homogeneidade e heterogeneidade da segmentação por meio da expressão:

$$UNWise(I) = \min_{b=1, \dots, w} \{h_b\} + \max_{b=1, \dots, w} \{k_b\} \quad (7)$$

O cálculo do índice expresso pela equação (7), quando realizado sobre um determinado resultado de segmentação, fornece um valor real positivo. Diante diferentes resultados de segmentação para uma dada imagem, torna-se possível apontar o melhor resultado por meio da comparação entre valores revelados pela medida *UNWise*, quando calculada para cada um destes resultados. Nestas comparações, maiores valores da medida *UNWise* indicam melhores resultados de segmentação.

### 2.3. Agrupamento Hierárquico Divisivo

Análise de Agrupamentos é o nome dado ao conjunto de técnicas usadas para separar objetos em grupos de acordo com suas características (LINDEN, 2009). Dentre as técnicas de agrupamento estão os Algoritmos Hierárquicos, que são baseados em divisões sucessivas sobre o conjunto de objetos, apresentando um relacionamento de hierarquia entre os agrupamentos (EVERITT *et al.*, 2001). Existem dois tipos de agrupamentos hierárquicos: aglomerativos e divisivos.

Segundo Linden (2009), o Agrupamento

Hierárquico Divisivo (AHD) se inicia com um único agrupamento contendo todos os elementos. De modo iterativo, o conjunto corrente é separado em agrupamentos menores segundo algum critério de similaridade. O processo é repetido recursivamente até que um critério de parada previamente estabelecido seja atendido, ou seja, é um método de agrupamento de abordagem *top-down*. Dois critérios de parada convenientes são o diâmetro (i.e., a máxima distância entre dois elementos de um mesmo agrupamento) e o número mínimo de elementos em cada agrupamento. As separações dicotômicas realizadas pelo AHD podem ser representadas na forma de um dendrograma, conforme ilustrado na Figura 1. Nesta representação, os valores  $d_i$ ,  $i = 1, \dots, 8$ , representam o diâmetro dos agrupamentos.

Em cada divisão do dendrograma é aplicado um algoritmo capaz de reagrupar o conjunto de dados inicial em dois subconjuntos segundo algum critério de similaridade estabelecido *a priori*. Assim como mencionado anteriormente, o algoritmo *K-Médias* pode ser empregado neste processo.

A seção seguinte apresenta uma rápida discussão sobre o algoritmo *K-Médias* juntamente com o conceito de Funções Kernel e o uso distâncias induzidas por tais funções neste algoritmo.




Fig. 1 – Representação dos agrupamentos e relação de hierarquia entre eles.

### 2.4. K-Médias e Funções Kernel

Em Mineração de Dados, o *K-Médias* é visto não somente como popular como também um dos mais efetivos algoritmos para agrupamentos de dados (WU *et al.*, 2007).

De forma simples, este algoritmo consiste em particionar um dado conjunto de padrões em agrupamentos visando a minimização da variação intra-agrupamento e maximização da distância inter-agrupamentos (BORGES, 2010). Apesar de exigida duas condições de otimização,

basta a verificação da primeira, uma vez que a minimização da variação intra-agrupamento implicará na maximização da dissimilaridade inter-agrupamento.

Considerando que cada agrupamento possui um vetor médio  $c_i$  como representante, denomina “centroide”, com  $i = 1, \dots, k$ ; que o conjunto de dados é composto por padrões  $r_j$ , vetores estes de mesma natureza de  $c_i$ , dos quais  $q_i$  estão associados aos  $i$ -ésimo agrupamento, uma expressão para a variação intra-agrupamento é:

$$V = \sum_{i=1}^k \sum_{j=1}^{q_i} \|r_j - c_i\|^2 \quad (8)$$

onde  $\|\cdot\|$  representa a norma vetorial.

Para minimização de (8), quatro passos básicos que caracterizam o algoritmo  $K$ -Médias devem ser efetuados:

- i. Inicializar (de forma aleatória ou não) cada um dos centroides, ;
- ii. Associar cada padrão ao centroide mais similar, segundo uma medida de distância adotada;
- iii. Atualizar cada um dos centroides segundo o vetor médio dos padrões associados ao centroide em questão;
- iv. Repetir os passos (ii) e (iii) até que não haja mais alterações consideráveis entre os centroides, comparados em duas iterações sucessivas, ou que seja efetuado um número máximo de iterações definido *a priori*.

Ao alcançar uma das condições de convergência listadas na etapa (iv), a organização dos padrões em agrupamentos corresponde às associações realizadas na última execução da etapa (ii). Cabe observar que a minimização da variação intra-agrupamento é alcançada iterativamente por meio das etapas (ii) e (iii).

De acordo com a equação (8) e as etapas que caracterizam o  $K$ -Médias, uma medida de distância/similaridade é frequentemente adotada, especificamente, a distância euclidiana, dada pela norma em (8). Tal distância é responsável pela identificação e organização dos padrões em grupos semelhantes. O emprego de distâncias distintas nesta formulação implica diretamente na forma como os padrões são agrupados.

Em determinados problemas, a obtenção de

agrupamentos adequados pode ser influenciada pela heterogeneidade dos padrões. Neste contexto, funções Kernel podem ser empregadas com intuito de proporcionar melhor separação entre padrões. De modo implícito, tais funções realizam o mapeamento dos padrões para outro espaço de atributos onde a separabilidade é maior (NEGRI, 2013).

Segundo Hofmann *et al.* (2008), as Funções Kernel são representadas por:

$$K(r_i, r_j) = \langle \phi(r_i), \phi(r_j) \rangle \quad (9)$$

onde  $\langle \phi(r_i), \phi(r_j) \rangle$  representa um produto interno e  $\phi$  determina um mapeamento  $x \mapsto \phi(x) \in \mathcal{H}$ , sendo  $\mathcal{H}$  um espaço característico (de Hilbert).

Além da definição estabelecida em (9),  $K(\cdot, \cdot)$  representa uma função Kernel desde que seja simétrica e satisfaça o Teorema de Mercer. Para maiores detalhes sobre este teorema, recomenda-se a leitura de Theodoridis & Koutroumbas (2008). Uma vez satisfeita tais condições, é possível afirmar que existe um espaço vetorial onde  $K(\cdot, \cdot)$  representa um produto interno.

Uma vez que as Funções Kernel representa um produtor interno em algum espaço vetorial, as mesmas podem ser utilizadas na indução de distância. Considerando que a distância entre dois vetores  $x$  e  $y$  quaisquer pode ser representada pela norma vetorial entre tais vetores, temos a seguinte relação:

$$\begin{aligned} \|x - y\|^2 &= \langle x - y, x - y \rangle = \\ &= \langle x, x - y \rangle - \langle y, x - y \rangle = \\ &= \langle x, x \rangle - 2\langle x, y \rangle - \langle y, y \rangle \end{aligned} \quad (10)$$

e logo, diferentes distâncias são induzidas pela substituição dos produtos internos nesta relação por Funções Kernel.

As Funções Kernel Linear, Polinomial e de Base Radial são frequentemente utilizadas nas aplicações em Reconhecimento de Padrões, as quais são definidas respectivamente por:

$$K_{Linear}(x, y) = \langle x, y \rangle \quad (11)$$

$$K_{Pol}(x, y) = (1 + \langle x, y \rangle)^d; \quad d \in \mathbb{N} \quad (12)$$

$$K_{RBF}(x, y) = e^{-\frac{\|x-y\|^2}{\sigma^2}}; \quad \sigma \in \mathbb{R}_+^* \quad (13)$$

A utilização de distâncias induzidas por Funções Kernel, como as exemplificadas em (11), (12) e (13), no algoritmo *K*-Médias podem produzir resultados diferenciados em relação à formulação original (i.e., com uso da distância euclidiana, ou equivalentemente, através do Kernel Linear ou Polinomial com aplicados na relação (10)).

### 3. PROPOSTA DE SEGMENTADOR BASEADO EM AHD E FUNÇÕES KERNEL

A seção anterior abrangeu conceitos que englobam desde propriedades básicas dos métodos de segmentação de imagens, medidas para avaliação da precisão de resultados de segmentação assim como algoritmos de agrupamento que podem ser empregados para segmentação, dentre eles o AHD e *K*-Médias com uso de Funções Kernel. A presente seção emprega tais conceitos, especificamente os abordados nas seções 2.1, 2.3 e 2.4, a fim de propor um novo método de segmentação. A arquitetura do segmentador proposto é apresentada no fluxograma da Figura 2.

Em um primeiro momento, o processo de segmentação ocorre no espaço de atributos da imagem. Para isso, o AHD é empregado para agrupar os pixels da imagem no espaço de atributos. A vantagem do emprego do AHD nesta etapa é a geração de agrupamentos que dependa apenas do comportamento dos atributos (dado implicitamente pelo diâmetro dos agrupamentos) e não de uma quantidade fixa de agrupamentos.

A fim de efetuar o agrupamento dos dados, o algoritmo *K*-Médias é adotado. Distâncias induzidas por Funções Kernel, selecionadas e parametrizadas inicialmente, são empregadas com objetivo de proporcionar melhor subdivisão entre os padrões.

Depois de finalizado o agrupamento dos padrões (pixels) no espaço de atributos, tais agrupamentos são representados no domínio espacial da imagem. Neste processo de representação/reposicionamento dos agrupamentos no domínio espacial, é possível que estes agrupamentos sejam espacialmente desconexos, e por sua vez, deverão representar duas regiões distintas. Um procedimento para identificação/rotulação dos pixels que fazem parte de um mesmo agrupamento no espaço de atributos e são espacialmente conectados em uma única região é então realizado.

Uma vez que é possível a definição de regiões compostas por poucos pixels, ou mesmo por um único pixel isolado, torna-se conveniente a aglutinação destas pequenas regiões a uma região adjacente cujo comportamento espectral é semelhante. O processo de aglutinação mencionado é guiado pelo menor desvio padrão das distâncias (induzidas pela Função Kernel empregada) entre o vetor médio da região pequena aos vetores de atributos dos pixels que compõe cada uma das regiões adjacentes/vizinhas. A cada aglutinação realizada, é refeita a rotulação das componentes conectadas, até que não existam mais regiões pequenas.

De acordo com a composição de métodos e procedimentos que abrangem o segmentador proposto, cabe observar que existem dois parâmetros primários que devem ser ajustados: “diâmetro” e “número mínimo elementos”. O diâmetro é empregado na etapa de definição dos agrupamentos pelo AHD, já o número mínimo de elementos é considerado nas etapas de definição dos agrupamentos pelo AHD assim como na identificação das regiões/rotulação de componentes conectadas. Além destes parâmetros primários, devem ser selecionadas ainda a Função Kernel e respectivos parâmetros para indução de uma medida de distância, a qual é empregada pelo algoritmo *K*-Médias e pelo processo de aglutinação de regiões pequenas.

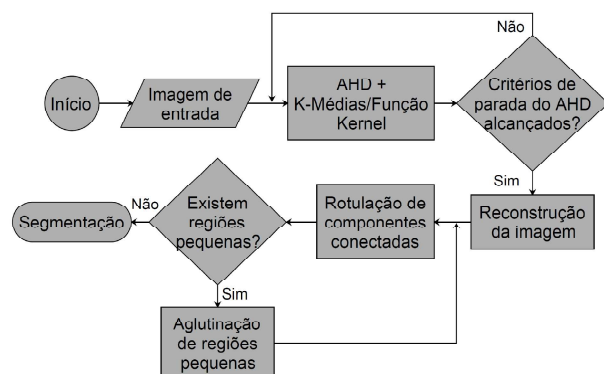


Fig. 2 – Arquitetura do segmentador proposto.

### 4. EXPERIMENTOS E RESULTADOS

Nesta seção são apresentadas duas aplicações práticas do método formalizado, as quais envolvem a segmentação de imagens adquiridas por sensores distintos. Detalhes sobre o experimento e resultados são discutidos nas Seções 4.1 e 4.2, respectivamente.

#### 4.1 Materiais e desenho do experimento

Com objetivo de verificar o desempenho do método de segmentação proposto, com o emprego de diferentes distâncias induzidas por Funções Kernel, duas aplicações práticas são apresentadas nesta seção. Comparações com o método Crescimento de Regiões são incluídas nestas aplicações. A medida *UNWise*, discutida na Seção 2.2, foi adotada para comparar tais métodos.

A primeira aplicação consistiu na utilização de uma imagem referente à região sul do município de São José dos Campos, localizado no estado de São Paulo. Esta imagem foi obtida pelo sensor MS a bordo do satélite IKONOS-II (Figura 3.a). O sensor em questão é capaz de capturar imagens com até 4 metros de resolução, nos intervalos espectrais do azul (0,45-0,52  $\mu\text{m}$ ), verde (0,52-0,60  $\mu\text{m}$ ), vermelho (0,63-0,69  $\mu\text{m}$ ) e infravermelho próximo (0,76-0,90  $\mu\text{m}$ ), sendo este último não utilizado no presente estudo. A área de estudo adotada abrange uma porção de  $600 \times 600$  pixels de dimensão, extraída da imagem. Na segunda aplicação, foi adotada uma imagem referente ao entorno da Floresta Nacional do Tapajós, no estado do Pará, obtida através do satélite LANDSAT-5 TM (Figura 3.b). A área de estudo abrange uma porção de  $400 \times 400$  pixels, com resolução espacial de 30


metros e três bandas espectrais compreendidas no intervalo entre 0,63 a 1,75  $\mu\text{m}$ .

A linguagem de programação IDL 7.1 (*Interactive Data Language*) foi empregada na implementação do método proposto, do método Crescimento de Regiões e de uma função para o cálculo da medida de avaliação *UNWise*. A escolha desta linguagem é justificada pela disponibilidade de diversas funções nativas que facilitam a programação voltada ao processamento de imagens.

Para cada um dos métodos analisados, foram empregados diferentes combinações de parâmetros. Com relação ao método proposto, foram considerados: número mínimo de elementos iguais a 50, 100 e 250 pixels, para a imagem IKONOS-II, e 50, 100, 250, 500, 750 e 1000 para a imagem LANDSAT-5; diâmetro igual a 5, 10, 25 e 50% da diagonal do espaço de atributos; grau () igual 1, 2, 3 e 5 quando empregada a Função Kernel Polinomial; regularizador () 0,5, 1,0 e 2,5 quando empregada o Kernel de Base Radial. Cabe lembrar que uma expressão equivalente à distância euclidiana é induzida pelo Kernel Polinomial quando . Já com relação ao método Crescimento de Regiões, foram considerados: predicados iguais a 15, 20, 25 e 30; e número mínimo de elementos iguais aos adotados pelo método proposto.



(a) Imagem IKONOS-II MS, em composição natural.



(b) Imagem LANDSAT-5 TM, em composição

Fig. 3 – Imagens empregadas nas aplicações práticas.

## 4.2 Resultados

Para o método de Crescimento de Regiões, os gráficos apresentados na Figura 4 auxiliaram na identificação dos parâmetros associados aos melhores resultados de segmentação, segundo a medida *UNWise*, para cada uma das imagens consideradas neste estudo. Neste método, a qualidade dos resultados está diretamente relacionada à dimensão mínima das regiões e ao predicado. É notável a tendência existente entre os melhores resultados de segmentação e os baixos valores de predicado e número mínimo de elementos por região. Os cinco melhores resultados obtidos pelo método Crescimento de Regiões, segundo a medida *UNWise*, e respectivas configurações de parâmetros, na segmentação das imagens IKONOS-II MS e LANDSAT-5 TM, são apresentados nas Tabelas 1 e 2, nesta ordem.

Tabela 1: Melhores resultados obtidos pelo método Crescimento de Regiões na segmentação da imagem IKONOS-II MS

<i>UNWise</i>	1,093	1,080	1,047	1,038	1,021
Predicado	15	20	25	20	30
# Min.El.	50	50	50	100	50

Tabela 2: Melhores resultados obtidos pelo método Crescimento de Regiões na segmentação da imagem LANDSAT-5 TM

<i>UNWise</i>	1,450	1,305	1,291	1,241	1,207
Predicado	15	15	15	20	15
# Min.El.	50	100	250	50	750

Por outro lado, de acordo com os diferentes resultados apresentados pelo método proposto, com o uso das diferentes Funções Kernel, verifica-se que as qualidades das segmentações não apresentaram dependência ao diâmetro dos agrupamentos, mas apenas ao número mínimo de elementos por agrupamento no espaço de atributos e/ou por regiões no domínio espacial, como pode ser observado nos gráficos ilustrados na Figura 5.

Em maioria, as Funções Kernel verificadas com os diferentes parâmetros estabelecidos no desenho deste experimento apresentaram o mesmo comportamento perante a variação do diâmetro dos agrupamentos. Os cinco melhores resultados obtidos pelo método proposto, segundo a medida *UNWise*, seguido de suas configurações e parâmetros, na segmentação das imagens IKONOS-II MS e LANDSAT-5 TM, são apresentados nas Tabelas 3 e 4, respectivamente.

Tabela 3: Melhores resultados obtidos pelo método proposto na segmentação da imagem IKONOS-II MS

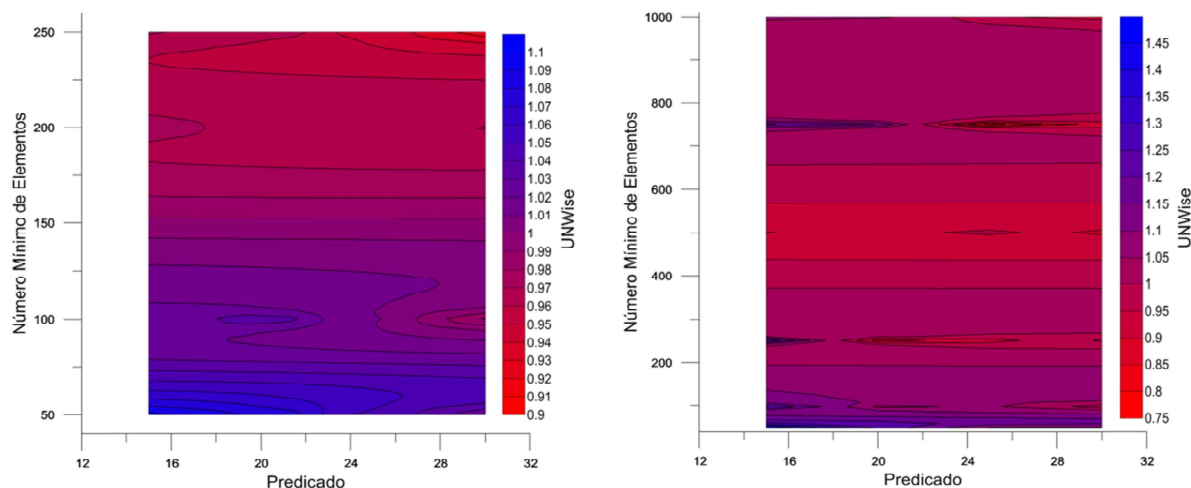
<i>UNWise</i>	1,204	1,200	1,199	1,198	1,198
Kernel	Poli.	Poli.	RBF	RBF	RBF
Parâm.	3	1	2,5	1,0	0,5
Diâmetro	5%	1%	25%	5%	5%
# Min.El.	50	50	50	50	50

Tabela 4: Melhores resultados obtidos pelo método proposto na segmentação da imagem LANDSAT-5 TM

<i>UNWise</i>	1,687	1,686	1,685	1,685	1,684
Kernel	Poli.	Poli.	RBF	Poli.	RBF
Parâm.	2	1	1,0	5	1,0
Diâmetro	10%	5%	5%	5%	25%
# Min.El.	50	50	50	50	50

Este comportamento distinto, com relação à delimitação dos alvos, apresentados pelos diferentes métodos é justificado pela forma como o processo de segmentação é conduzido. Enquanto o método Crescimento de Regiões delimita os objetos da imagem a partir de similaridades entre os pixels no domínio espacial, o método proposto inicia a identificação dos segmentos no espaço de atributos da imagem e posteriormente estende tal identificação para o domínio espacial, a partir de objetos espectralmente consistentes.






(a) IKONOS-II MS.


(b) LANDSAT-5 TM.

Fig. 4 – Avaliação dos resultados obtidos pelo método Crescimento de Regiões, segundo a medida *UNWise*, sobre as diferentes imagens de estudo e diante diferentes combinações de valores para os parâmetros “Predicado” e “Número Mínimo de Elementos”.



(a) IKONOS-II MS – Kernel Polinomial –  $d = 3$ .

(b) IKONOS-II MS – Kernel RBF –  $\sigma = 2,5$ .



(c) LANDSAT-5 TM – Kernel Polinomial –  $d = 2$ .

(d) LANDSAT-5 TM – Kernel RBF –  $\sigma = 1,0$ .

Fig. 5 – Avaliação dos resultados obtidos pelo método proposto, segundo a medida *UNWise*, sobre as diferentes imagens de estudo e diante diferentes combinações de valores para os parâmetros “Diâmetro” (em porcentagem) e “Número Mínimo de Elementos”, para alguns casos particulares de Funções Kernel e respectivos parâmetros.

## 5. CONCLUSÃO

Este trabalho consistiu na proposta de um novo método de segmentação de imagens e na aplicação desta nova proposta em dois estudos práticos, considerando imagens dos satélites IKONOS-II e LANDSAT-5. A finalidade destes estudos foi de validação e comparação com o um método de segmentação bem estabelecido na literatura, neste caso, o método Crescimento de Regiões. O segmentador proposto, baseado em AHD, *K*-Médias e distâncias induzidas por Funções Kernel, apresentou resultados satisfatórios.

De acordo com os valores da medida de avaliação adotada, denominada *UNWise*, o método proposto foi capaz de proporcionar melhores resultados de segmentação em comparação ao método de Crescimento de Regiões. Além da avaliação quantitativa fornecida pela medida *UNWise*, foi possível ainda verificar que o algoritmo proposto fornece resultados mais condizentes à delimitação dos alvos presentes nas imagens empregadas nos experimentos realizados (vide Figura 6).

Como mencionado durante as formulações, o método proposto tem como característica não limitar a segmentação dos alvos em uma quantidade pré-definida de agrupamentos no espaço de atributos, o que permite por sua vez a discriminação de alvos distintos até que seja alcançado um limiar de similaridade definido *a priori*. Tal característica implicou em resultados de segmentação cujos alvos são delimitados em maior detalhe em comparação ao método Crescimento de Regiões.

Por fim, é oportuno ainda citar que o uso do Kernel polinomial de grau 1 proporcionou resultados de segmentação cujos índices expressos pela medida *UNWise* são numericamente próximos aos valores obtidos com Kernel Polinomial de graus superiores ou mesmo com o Kernel RBF. No entanto, com atenção ao fato do Kernel Polinomial de grau 1 ser equivalente ao produto interno no espaço de atributos original e, que por sua vez, faz a distância induzida por tal Kernel corresponder a distância euclidiana, conclui-se que nos estudos de caso realizados o uso de funções Kernel não implicaram em melhores resultados de segmentação.

Como perspectivas futuras ao método

proposto, são inclusas avaliações e análises envolvendo outras funções Kernel e comparações com outros métodos de segmentação, em especial, considerando métodos com mesma natureza da proposta apresentada, isto é, de abordagem *top-down*.

## AGRADECIMENTOS

Os autores agradecem a FAPESP (Proc. 2014/14830-8) e a PROPe/UNESP (Proc. 2015/146) pelo suporte financeiro.

## REFERÊNCIAS BIBLIOGRÁFICAS

BORGES, V. R. P. Comparação entre as técnicas de agrupamento k-means e fuzzy c-means para segmentação de imagens coloridas. In: VIII Encontro Anual de Computação, Catalão. 2010. **Anais**. P. 1-8, 2010.

DHILLON, I. S.; GUAN, Y. & KULIS, B. Kernel K-means: Spectral Clustering and Normalized Cuts **Proceedings of the Tenth ACM SIGKDD International Conference on Knowledge Discovery and Data Mining**, ACM, p.551-556, 2004.

EVERITT, B. S.; LANDAU, S.; LEESE, M. **Cluster Analysis**. 4ª Ed. London, Arnold, 2001. 256p.

GONZALEZ, R. C.; WOODS, R. E. **Digital Image Processing**. 3ª Ed. Saddle River, Prentice-Hall, 2006. 976p.

JAIN, A. K. **Fundamentals of Digital Image Processing**. Englewood Cliffs, Prentice-Hall, 1989. 569p.

LINDEN, R. Técnicas de agrupamento. **Revista de Sistemas de Informação da FSMA**, n.4, p.18-36, 2009.

LIU, J.; YANG, Y H. Multiresolution color image segmentation. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, p.689-700, 1994.

LUCCA, E. V. D. **Avaliação e comparação de algoritmos de segmentação de imagens de radar de abertura sintética**. Dissertação (Mestrado), Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 1998. 207p.

MUSCI, M.; FEITOSA, R. Q.; COSTA, G. A. O.

- P. Uma abordagem baseada em objeto na análise de imagens com a utilização de segmentações independentes. **XVI Simpósio Brasileiro de Sensoriamento Remoto**, p. 8230-8237, 2013.
- MOIK, J. G. **Digital processing of remotely sensed images**. National Aeronautics and Space Administration, U.S. Govt. Print. Washington, 1980. 330p.
- NEGRI, R. G. **Máquina de Vetores de Suporte Adaptativa ao Contexto: formalização e aplicações em Sensoriamento Remoto**. Tese (Doutorado), Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2013. 140p.
- REIS, M. S.; PANTALEÃO, E. P.; SANT'ANNA, S. J. S.; DUTRA, L. V. Análise de índice ponderado para avaliação de segmentação. **Revista Brasileira de Cartografia**, n. 67, p. 1421–1437, 2016.
- SILVA, L. **Segmentação de Imagens de Profundidade por Detecção de Bordas**. Dissertação (Mestrado), UFPR, Curitiba, 2000. 113p.
- THEODORIDIS, S.; KOUTROUMBAS, K. **Pattern Recognition**. 4<sup>a</sup> Ed. San Diego, Academic Press, , 2008. 984p.
- WU, X.; KUMAR, V.; ROSS QUINLAN, J.; GHOSH, J.; YANG, Q.; MOTODA, H.; MCLACHLAN, G. J.; NG, A.; LIU, B.; YU, P.; ZHOU, Z.-H.; STEINBACH, M.; HAND, D. & STEINBERG, D. **Top 10 Algorithms in Data Mining**, Knowledge Information Systems, Springer-Verlag New York, Inc., 2007, 14, 1-37
- WU, L.; WANG, Y.; LONG, J.; LIU, Z. A non-seed-based region growing algorithm for high resolution remote sensing image segmentation. **Image and Graphics: 8th International Conference**, p.263-277, 2015.
- ZHANG, Y. J. A survey on evaluation methods for image segmentation. **Pattern Recognition**, v.29, p.1335–1346, 1996.
- ZUCKER, S. W. Region growing: Childhood and adolescence. **Computer Vision, Graphics and Image Processing**, v.5, p.382-399, 1976.