

Revista Brasileira de Cartografia (2015) N<sup>o</sup> 67/7: 1421-1437  
Sociedade Brasileira de Cartografia, Geodésia, Fotogrametria e Sensoriamento Remoto  
ISSN: 1808-0936

## ANÁLISE DE ÍNDICE PONDERADO PARA AVALIAÇÃO DE SEGMENTAÇÃO

*Analysis of Weighted Index for Segmentation Evaluation*

**Mariane Souza Reis<sup>1</sup>, Eliana Pantaleão<sup>2</sup>, Sidnei João Siqueira Sant'Anna<sup>1</sup>  
& Luciano Vieira Dutra<sup>1</sup>**

**<sup>1</sup> Instituto Nacional de Pesquisas Espaciais – INPE  
Divisão de Processamento de Imagens - DPI**

Av. dos Astronautas, 1.758 - Jardim da Granja - CEP: 12227-010 - São José dos Campos/SP, Brasil  
{reis, sidnei, dutra}@dpi.inpe.br

**<sup>2</sup> Universidade Federal de Uberlândia – UFU**

**Centro de Ciências Exatas e Tecnologia, Faculdade de Ciências da Computação**  
Av. Getúlio Vargas, 230 - Centro - CEP: 38700-900 - Patos de Minas/MG, Brasil  
epantaleao@ufu.br

*Recebido em 07 de Abril, 2014/ Aceito em 29 de Agosto, 2015*  
*Received on April 07, 2014/ Accepted on August 29, 2015*

### RESUMO

O uso de técnicas baseadas em regiões, ou orientadas a objetos, pode melhorar a exatidão da classificação da cobertura da terra utilizando imagens provenientes de sensoriamento remoto. Devido à grande variedade de segmentadores disponíveis e à necessidade de testes para seleção de seus parâmetros, torna-se essencial uma metodologia objetiva para avaliação e comparação de segmentações. Neste artigo, avalia-se o Índice Ponderado para Avaliação de Segmentação (*Weighted Index for Segmentation Evaluation - WISE*) e algumas variações deste, por meio de sua comparação com outros dois índices encontrados na literatura, aplicados para selecionar a segmentação ótima para imagens sintéticas. Esses índices também foram avaliados em função dos resultados da classificação utilizando o Classificador de Vizinho mais Próximo. Os índices foram testados em três cenários distintos, que consideram classes de cobertura da terra com diferentes níveis de separabilidade. O *WISE* e suas variações apresentaram bons resultados para a seleção de segmentações quando comparados com os demais, sem apresentar alguns dos problemas operacionais ou teóricos encontrados nos demais índices.

**Palavras chave:** Índice de Segmentação, Avaliação de Segmentações, Comparação de Segmentadores, Segmentação de Dados Óticos.

### ABSTRACT

The use of region based or object oriented techniques can enhance the accuracy of remote sensing based land cover classification. Due to the great amount of available segmenters and the need to select its parameters, a methodology for segmentation evaluation and comparison is of great relevance. The Weighted Index for Segmentation Evaluation (*WISE*) and some variations are analyzed in this work, by comparing them to other two indices from literature, for optimal segmentation of synthetic images. The indices were also evaluated by the classification results obtained

with Nearest Neighbor classifier. These indices were tested in three different scenarios, that is, considering sets of land cover classes with different levels of separability. When compared to other indices, *WISE* and its variations showed good results for segmentation selection, while some of the operational and theoretical problems found in other indices were not observed.

**Keywords:** Segmentation Index, Segmentation Evaluation, Segmenters Comparison, Optical Data Segmentation.

## 1. INTRODUÇÃO

A segmentação de imagens é um processo importante para análise de imagens, vídeos e aplicações de visão computacional (ZHANG *et al.*, 2008). Segundo Zhang (1996), segmentar uma imagem consiste em subdividir a referida imagem em suas partes constituintes e destas extrair partes de interesse (objetos). Esta é uma etapa crítica no processamento de imagens, principalmente no que se refere à classificação de imagens provenientes de sensoriamento remoto. Trabalhos como os de Aboud (2009), Lu *et al.* (2012) e Negri *et al.* (2012) mostraram melhorias na classificação de imagens óticas e daquelas provenientes de radares de abertura sintética com o uso de classificação baseada em regiões, em contraposição às baseadas em pixel. Além disso, para estudos multitemporais em que há exigência de correspondência entre feições presentes em duas ou mais imagens, o uso de técnicas baseadas em regiões pode diminuir os erros causados por alinhamento, sejam estes resultantes de pequenas distorções ou de problemas de registro entre as imagens (WHITE e OLIVER, 1990). Blaschke (2010) ressalta ainda que com a crescente demanda de dados com melhor resolução espacial, técnicas baseadas em análise de objetos têm adquirido um papel fundamental para estudos voltados ao uso e cobertura da terra. Ainda segundo o autor, a abordagem mais comumente utilizada para a construção de objetos é a segmentação de imagens. Outra vantagem de classificar imagens por técnicas baseadas em regiões é a facilidade em armazenar e manipular estes dados em sistemas de informação geográfica (ESPÍNDOLA *et al.*, 2006).

O resultado da classificação está intrinsecamente relacionado à qualidade da segmentação utilizada (COSTA *et al.*, 2008). No entanto, o processo de segmentar uma imagem é dependente de algumas escolhas do usuário, geralmente feitas de modo subjetivo: qual dos diversos segmentadores presentes na literatura

e com quais parâmetros utilizar. Mesmo considerando um único segmentador, a relação entre os parâmetros utilizados e a segmentação resultante não é óbvia (ACHANCCARAY *et al.*, 2014).

Em uma tarefa de processamento de imagens, é comum que o usuário teste diferentes segmentadores e/ou diferentes parametrizações e escolha a que melhor se ajuste a seus dados. No entanto, cada pessoa possui conceitos diferentes de o que é uma boa segmentação e este conceito pode ser diretamente dependente da aplicação (RÄSÄNEN *et al.*, 2013). De forma a otimizar o processo de segmentação de imagens e também diminuir a subjetividade deste, e consequentemente validar a comparação de algoritmos, métodos de avaliação de segmentação têm sido propostos. Vide, por exemplo, Zhang (1996) e Zhang *et al.* (2008).

No trabalho de Zhang *et al.* (2008), os métodos de avaliação de uma segmentação estão divididos entre subjetivos e objetivos. Nos métodos subjetivos, o analista (humano) avalia a segmentação visualmente, enquanto nos objetivos há outro critério de avaliação, explicado a seguir. Os métodos objetivos podem ser divididos entre "avaliação do nível de sistema", ou seja, como determinada segmentação impacta em um sistema ou aplicação (exatidão de uma classificação, por exemplo), ou ainda em métodos diretos, em que se avaliam os métodos de segmentação independentemente. Os autores ainda classificam os métodos diretos como analíticos e empíricos. Nos métodos analíticos, avalia-se o método de segmentação (em relação à estratégia de segmentação ou eficiência, por exemplo), enquanto nos empíricos o resultado da segmentação é avaliado. Segundo os autores, métodos subjetivos são custosos e de difícil reprodução, enquanto os métodos análise de nível do sistema e analítico podem não retornar uma segmentação que melhor represente os dados.

Os métodos empíricos podem ser divididos

em supervisionados e não supervisionados. Métodos supervisionados são aqueles em que uma determinada segmentação é comparada com uma referência, seja esta uma verdade de campo, uma segmentação desenhada (ZHANG *et al.*, 2008) ou ainda apenas alguns objetos, também desenhados (ACHANCCRAY *et al.*, 2014). Métodos não supervisionados são aqueles que avaliam a segmentação sem a necessidade de uma referência. Como em alguns casos é impossível determinar a referência de forma não subjetiva, torna-se essencial o desenvolvimento e uso de índices não supervisionados. O uso destes também possibilita a avaliação de uma grande quantidade de segmentações sem a necessidade de conhecimento prévio das imagens sobre as quais as segmentações foram geradas.

Segundo Zhang *et al.* (2008), acredita-se que a comparação direta entre a referência e uma segmentação permite uma avaliação em uma resolução mais fina que o uso de índices não supervisionados. No entanto, para a aplicação de dados de sensoriamento remoto raramente há uma referência disponível. A criação de uma ou mais referências para determinada área de estudo acrescentaria custos e subjetividade ao processo, dadas as escolhas humanas envolvidas em desenhar uma segmentação, ou objetos individuais, em uma imagem real.

Diversos índices não supervisionados foram desenvolvidos ao longo do tempo (BORSOTTI *et al.*, 1998; ESPÍNDOLA *et al.*, 2006; CHABRIER *et al.*, 2006; ZHANG *et al.*, 2012). Geralmente, para a aplicação desses índices, não se considera o propósito da segmentação.

Neste sentido, ainda se deve definir o que é uma boa segmentação. Para estudos que utilizam técnicas baseadas em análise de objetos, uma boa segmentação é aquela em que objetos com significado próprio, ou que correspondem a feições do mundo real, estão distinguidos (RÄSÄNEN *et al.*, 2013). De forma geral, o uso de índices supervisionados é mais indicado para este tipo de avaliação, uma vez que um objeto real não necessariamente apresenta-se como uma feição homogênea na imagem. Exemplos de medidas propícias para este tipo de avaliação podem ser encontradas em Delves *et al.* (1992), Zhan *et al.* (2005), Möller *et al.*

(2007) e Achancray *et al.* (2014).

Uma definição comumente encontrada é que uma boa segmentação é aquela que divide a imagem em regiões homogêneas, de forma a minimizar a heterogeneidade (variância) no interior dos segmentos e maximizar a heterogeneidade intersegmentos (ZHANG *et al.*, 2008; ESPÍNDOLA *et al.*, 2006). Com a utilização dessa definição, é necessário salientar que quando duas ou mais feições de classes muito parecidas são vizinhas, uma segmentação que separe essas feições pode ser considerada ruim, dependendo do método utilizado na análise. Isto porque a heterogeneidade intersegmentos não foi maximizada, enquanto a heterogeneidade no interior do segmento não sofreu alterações suficientes para justificar a escolha de outra segmentação em que essa separação ocorra.

Para fins de classificação por regiões, uma boa segmentação pode, então, ser aquela que melhor preserva a fronteira entre feições de duas classes distintas, sendo que cada segmento possui o maior número possível de amostras representativas daquela feição. A separação entre feições de classes distintas é essencial para uma boa classificação, uma vez que se estas estiverem unidas em uma mesma região, uma das feições será inevitavelmente classificada de forma incorreta, quando não as duas. O número de amostras pode ou não ser importante dependendo do método de classificação adotado, mas em geral um maior número de amostras aumenta a representatividade do conjunto. Um índice desenvolvido para avaliar segmentações considerando esta definição é o Índice Ponderado para Avaliação de Segmentação (Weighted Index for Segmentation Evaluation - *WISE*) proposto por Reis *et al.* (2014a).

O *WISE* é uma modificação do índice proposto por Espíndola *et al.* (2006). Ambos consideram medidas de heterogeneidade inter e intrasegmentos. A principal diferença entre eles é que a ponderação entre as componentes, no *WISE*, não ocorre de forma equitativa, e sim ponderada por medidas de separabilidade entre as classes que se pretende classificar. Assim, o *WISE* favorece imagens em que duas feições, de classes similares, estejam separadas.

Estudos preliminares utilizando o *WISE* demonstraram bons resultados para a avaliação de segmentações provenientes de dados óticos

(Reis *et al.*, 2014a). No entanto, outros testes se fazem necessários para melhor entender o desempenho deste índice, principalmente quando comparado a outros índices supervisionados e não supervisionados. Além disso, como demonstrado na Seção 2 deste trabalho, as modificações feitas sobre o índice proposto por Espíndola *et al.* (2006), que levaram à formulação do *WISE*, se deram por motivos distintos. Análises que ajudem no entendimento de como cada modificação influencia no resultado do índice também são importantes, para tornar futuras melhorias e/ou simplificações na formulação do *WISE* possíveis.

Dessa forma, o objetivo deste trabalho é avaliar o desempenho do *WISE*, bem como de suas versões intermediárias, para seleção da segmentação ótima para três cenários distintos. Cada cenário corresponde a uma imagem multicanal sintética, segmentada utilizando três segmentadores e diversas parametrizações. Essas segmentações foram então avaliadas utilizando o índice proposto por Espíndola *et al.* (2006), adaptado para dados multicanais, a média aritmética de quatro medidas propostas por Delves *et al.* (1992), o *WISE* e 3 versões intermediárias entre o índice proposto por Espíndola *et al.* (2006) e o *WISE*. Os resultados de cada índice foram avaliados de forma visual, pelos valores de acurácia de classificação utilizando o classificador de Vizinho mais Próximo (Nearest Neighbor-NN) e pela comparação entre estes e os resultados dos outros índices.

Esta seção apresentou uma breve introdução acerca da avaliação de segmentações e objetivo deste trabalho. As seções a seguir estão organizadas como segue: na Seção 2, os índices avaliados são formulados. Uma breve descrição dos segmentadores utilizados encontra-se na Seção 3. Na Seção 4, estão descritos os procedimentos metodológicos para a geração dos cenários e avaliação dos resultados. Na Seção 5, apresentam-se os resultados obtidos, sendo que as conclusões obtidas a partir destes resultados, bem como perspectivas para a utilização dos índices e para trabalhos futuros, estão apresentados na Seção 6.

Para o melhor entendimento das próximas seções, algumas definições foram adotadas. São estas:

**região:** conjunto de pixels contíguos com identificador comum, espacialmente conectados considerando uma vizinhança 4;

**imagem segmentada:** imagem separada em regiões;

**imagem base:** imagem da qual se deseja obter a imagem segmentada. Pode se tratar de uma imagem real ou de uma imagem sintética. No caso de uma imagem multicanal, considera-se que todas as bandas da imagem base foram utilizadas para gerar a imagem segmentada;

**imagem referência:** corresponde à imagem segmentada ideal;

**imagem phantom:** imagem de referência com classes atribuídas às regiões. Também chamada de imagem de classes;

**índices de segmentação:** índices utilizados para avaliar uma imagem segmentada.

## 2. ÍNDICES DE AVALIAÇÃO DE SEGMENTAÇÃO

Nesta seção estão apresentados os índices de segmentação avaliados. Utilizou-se como índice de avaliação de segmentação supervisionado a média aritmética de quatro medidas de ajuste apresentadas por Delves *et al.* (1992). Estas medidas são calculadas para cada região da imagem de referência. A média aritmética simples entre os valores de cada medida para cada região retorna um valor para cada medida para toda a imagem. As medidas consideradas são: *Fitxy*, utilizada para medir o ajuste posicional da região, baseado no centro gravitacional; *Fiti*, utilizada para medir o quanto as intensidades de duas regiões são similares; *Fitn*, formulada para comparar o tamanho de duas regiões; e *Gshape*, utilizada para indicar a sobreposição entre duas regiões. Estas medidas avaliam o quanto uma dada imagem segmentada é parecida com a imagem referência nos citados aspectos.

Para o cálculo das medidas para cada região da imagem de referência é necessário selecionar sua região representante na imagem segmentada, denominada *bestFit*. Sejam a imagem de referência e a imagem segmentada com  $xpix$  colunas e  $ypix$  linhas. Uma região da imagem de referência será indexada por  $i$  e da segmentada por  $f$ , sendo o número de regiões em cada imagem  $M_i$  e  $M_f$ . As notações  $\langle g_i \rangle$  e  $\langle g_f \rangle$  representam a média da medida  $g$ , nas regiões

$i$  e  $f$ , e  $N(i)$  e  $N(f)$ , o número de pixels em  $i$  e  $f$ . As notações  $x_i$  e  $y_i$  correspondem à localização de um pixel qualquer da região  $i$  (coluna e linha, respectivamente). As matrizes  $G_f$  e  $Fit$ , ambas de tamanho  $M_i \times M_f$ , são construídas a partir de:

$$Gf(i, f) = \frac{N(i \cap f)}{N(i \cup f)} \quad (1)$$

$$Fit(i, f) = \frac{xd + yd + \frac{pd + id}{2}}{Gf(i, f)} \quad (2)$$

$$xd = \frac{|\langle x_i \rangle - \langle x_f \rangle|}{xpix} \quad (3)$$

$$yd = \frac{|\langle y_i \rangle - \langle y_f \rangle|}{ypix} \quad (4)$$

$$pd = \frac{|N(i) - N(f)|}{N(i) + N(f)} \quad (5)$$

$$id = \frac{|\langle V(i) \rangle - \langle V(f) \rangle|}{\langle V(i) \rangle + \langle V(f) \rangle} \quad (6)$$

e  $\langle V(i) \rangle$  é a média dos níveis de cinza dos pixels da imagem base, contidos na região  $i$ . Salienta-se que para o caso de uma imagem base multicanal, para cálculo de  $id$  são consideradas todas as bandas da imagem base.

Para cada região  $i$  da imagem de referência, sua região representante ( $bestFit$ ) é a região  $f$  que resulta no menor valor de  $Fit(i, f)$ . Para cada região  $bestFit$ , calculam-se as medidas (Delves *et al.*, 1992):

$$Fitxy = 1 - \frac{xd + yd}{2} \quad (7)$$

$$Fiti = 1 - id \quad (8)$$

$$Fiti = 1 - pd \quad (9)$$

$$Gshape = \frac{N(i \cap f)}{N(i \cup f)} \quad (10)$$

O índice adotado neste trabalho ( $Fitm$ ) é a média aritmética dessas quatro medidas, conforme já utilizada em trabalhos como Lucca *et al.* (1998) e Saldanha *et al.* (2014), para fins de avaliação de imagens segmentadas. Essas medidas possuem valores entre 0 e 1, sendo 1 o valor do melhor ajuste.

$$Fitm = \frac{Fitxy + Fiti + Fitn + Gshape}{4} \quad (11)$$

A medida  $Fitm$  é um índice supervisionado. Ou seja, necessita-se de uma referência para seu cálculo, a qual geralmente não está disponível em aplicações com dados reais de sensoriamento remoto.

Como índice não supervisionado, foi utilizada uma adaptação da função objetivo proposta por Espíndola *et al.* (2006). Esta função foi criada com o propósito de facilitar a sintonia de parâmetros de um algoritmo de segmentação, pela comparação entre as imagens segmentadas resultantes de diferentes parametrizações. A função combina uma medida de homogeneidade intrassegmento ( $v$ ) e uma de homogeneidade intersegmentos, correspondente ao índice de Moran ( $I$ ), de forma a retornar uma medida que avalia o quanto uma imagem segmentada possui regiões homogêneas internamente, mas heterogêneas em relação às regiões vizinhas. Esta função é calculada utilizando os valores dos pixels que compõem cada região em cada banda da imagem base, de forma que seu maior valor é atribuído à melhor imagem segmentada. A função objetivo varia de 0 a 2 e, considerando a banda  $b$  de uma imagem multicanal, é descrita por:

$$G(v_b, I_b) = F(v_b) + F(I_b) \quad (12)$$

em que:

$$v_b = \frac{\sum_{f=1}^M a_f \cdot v_f}{\sum_{f=1}^M a_f} \quad (13)$$

$$I_b = \frac{\sum_{f=1}^{M_f} \sum_{j=1}^{M_f} w_{fj} (V_f - \bar{V})(V_j - \bar{V})}{\left( \sum_{f=1}^{M_f} (V_f - \bar{V})^2 \right) \left( \sum_{f \neq j} w_{fj} \right)} \quad (14)$$

$$F(x) = \frac{x_{\max} - x}{x_{\max} - x_{\min}} \quad (15)$$

e  $v_f$  é a variância dos valores dos pixels da imagem base na região  $f$ ,  $af$  é a área da região  $f$  (em unidades de área);  $M$  é o número total de regiões,  $V_f$  é a média dos números digitais dos pixels da região  $f$  e  $V$  é a média dos níveis de cinza da imagem base. A variável  $w_{fj}$  é a medida da adjacência das regiões  $f$  e  $j$  e vale 1 caso essas regiões sejam adjacentes, e 0 caso contrário.

Uma desvantagem desta função objetivo é que o valor atribuído a cada imagem segmentada varia de acordo com o conjunto sendo avaliado, já que a normalização ocorre após o cálculo das componentes  $I_b$  e  $v_b$ . Além disso, esta função objetivo foi idealizada para dados monocanal.

Para resolver estes dois problemas, foram propostas duas versões intermediárias entre esta função objetivo e o *WISE*, denominadas Índice não Ponderado para Avaliação de Segmentação (*Unweighted Index for Segmentation Evaluation - UnWISE*) e *UnWISE'*. Estes índices são dados por:

$$UnwISE = \min(v') + \max(I') \quad (16)$$

$$UnwISE' = \min(v') + \max(I'') \quad (17)$$

em que  $v'$ ,  $I'$  e  $I''$  tratam-se dos conjuntos formados pelos valores  $v'_b$ ,  $I'_b$  e  $I''_b$ , respectivamente, calculados para cada banda  $b$ . Esses valores são dados por:

$$v'_b = 1 - \frac{v_b}{\sigma_b^2} \quad (18)$$

$$I'_b = 1 - abs(I_b) \quad (19)$$

$$I''_b = 1 - I_b \quad (20)$$

em que  $\sigma_b^2$  corresponde à variância da banda sendo analisada e  $abs(\cdot)$  retorna o valor absoluto da variável.

A única diferença entre *UnWISE* e *UnWISE'* está no uso, ou não, do valor absoluto de  $I$  no cálculo de  $I'$  e  $I''$ . Dadas as propriedades do Índice de Moran (0 atribuído à independência espacial, entre 0 e 1 à correlação

direta e entre -1 e 0 à correlação inversa) o uso do valor absoluto de  $I$  pode apresentar um comportamento desejável de *UnWISE* para a seleção de imagens segmentadas.

Esses índices são calculados para cada imagem segmentada de forma independente. Isto significa que para cada par formado por uma imagem segmentada e uma imagem base há apenas um valor possível para cada índice. Portanto, estes índices não são afetados pela quantidade ou características das demais imagens segmentadas em análise, como era o caso da função objetivo proposta por Espíndola *et al.* (2006).

Na formulação do *UnWISE* e *UnWISE'*, busca-se o mínimo valor de  $v'$  porque acredita-se que se uma feição é distinguível em uma determinada banda, mas esta feição não está separada na imagem segmentada, o índice deve retornar um valor baixo. No entanto, uma vez que essa feição é distinguível em uma banda, trata-se de uma feição que deve ser delimitada, mesmo que ela não seja distinguível nas demais bandas. Assim, utiliza-se o valor máximo de  $I'$  ou  $I''$ .

A partir destes índices, é possível formular o *WISE*, conforme proposto por Reis *et al.* (2014a) e uma variação denominada *WISE'*. Considere uma imagem base com  $c$  classes de cobertura definidas pelo usuário e  $c_1$  e  $c_2$  como sendo duas classes distintas a serem separadas na imagem segmentada. Tanto o *WISE* quanto o *WISE'* são ponderados em função de uma medida de divergência entre as classes  $c_1$  e  $c_2$ , representada pela variável  $d$ :

$$WISE = \frac{1}{d} \min(v') + \max(I') \quad (21)$$

$$WISE' = \frac{1}{d} \min(v') + \max(I'') \quad (22)$$

Conforme proposto por Reis *et al.* (2014a), determinam-se  $c_1$  e  $c_2$  como o par de classes (dentro  $C_{c,2}$ ) que retorna a mínima distância de Jeffries-Matusita (JM), dada por (SCHOWENGERDT, 2006):

$$JM = \sqrt{2(1 - e^{-B_{kl}})} \quad (23)$$

em que  $B_{kl}$  é a distância de Bhattacharyya entre as classes  $k$  e  $l$ . Para amostras com distribuição gaussiana,  $B_{kl}$  é dada por (THEODORIDIS; KOUTROUMBAS, 2006):

$$B_{kl} = \frac{1}{8}(\mu_k - \mu_l)^T \left( \frac{\Sigma_k + \Sigma_l}{2} \right)^{-1} (\mu_k - \mu_l) + \frac{1}{2} \ln \left( \frac{\left| \frac{\Sigma_k + \Sigma_l}{2} \right|}{\sqrt{|\Sigma_k| + |\Sigma_l|}} \right) \quad (24)$$

em que  $\mu_a$  é o vetor de médias das amostras da classe  $a$

( $a \in \{k, l\}$ ),  $\Sigma_a$  é a matriz de covariâncias da classe  $a$ ,  $(\cdot)^T$  é o transposto e  $|\cdot|$  o determinante da matriz. O valor atribuído a  $d$  corresponde à distância JM do par de classes  $c_1$  e  $c_2$ . Consideram-se todas as bandas da imagem base para o cálculo de  $B_{kl}$ .

### 3. SEGMENTADORES

Foram utilizados três segmentadores neste trabalho: Crescimento de Regiões implementado no *software* TerraPixel versão 1.04, *Multiresolution Segmentation* presente no *eCognition* versão 8 e o segmentador contido no *software* Idrisi Selva. Estes segmentadores foram testados por possuírem diferentes bases teóricas.

O algoritmo de Crescimento de Regiões divide a imagem em regiões homogêneas, definidas por um limiar de Similaridade e considerando uma Área Mínima para cada região (BINS *et al.*, 1996). Maiores valores de área mínima tendem a gerar segmentos maiores, enquanto valores mais altos de similaridade permitem segmentos mais heterogêneos.

O algoritmo *Multiresolution Segmentation* busca minimizar localmente a heterogeneidade interna de cada segmento, considerando a homogeneidade espectral e a de formato. Mais detalhes do algoritmo podem ser encontrados em Definiens (2009) e em Baatz e Schäpe (2000).

Segundo Clark Labs (s.d.), o algoritmo de segmentação contido no Idrisi Selva é baseado


em detecção de bacias sobre uma imagem de superfície gerada a partir da variância de cada banda da imagem base, sendo essa variância calculada com base em uma janela definida pelo usuário. Em casos de uma imagem base multicanal, gera-se uma imagem de superfície para cada banda. Essas imagens de superfície são combinadas por média ponderada, com pesos também definidos pelo usuário. Clark Labs (s.d.) sugere o uso de uma janela de 3x3 pixels para resultados ótimos. A imagem de superfície calculada possui valores próximos a zero dentro de áreas homogêneas e valores mais altos em pixels de borda. Considerando estes valores como as altitudes em um modelo digital de elevação, delimitam-se bacias, com as bordas das regiões similares a divisores de águas em uma bacia hidrográfica. Na etapa final, as regiões são agrupadas enquanto respeitarem o critério de Similaridade, também definido pelo usuário.

### 4. METODOLOGIA

Para a realização deste trabalho, foram necessários seis passos: a simulação de imagens; a segmentação de imagens simuladas; o cálculo de índices de avaliação de segmentação; a classificação das imagens utilizando as respectivas imagens segmentadas; a avaliação das imagens classificadas e a análise das imagens segmentadas.

Três imagens distintas, contendo múltiplos canais, foram simuladas para representar três cenários diferentes. Estas imagens foram simuladas utilizando o método proposto em Negri *et al.* (2012). Os dados de entrada para o processo de simulação são um conjunto de vetor de médias e matriz de covariância, obtidos de amostras de classes de cobertura presentes em uma imagem ótica, e uma imagem de referência com classes identificadas (imagem phantom). Para a modelagem das classes atribuídas à imagem phantom, adotou-se a distribuição gaussiana multivariada, sem correlação espacial.

A imagem phantom utilizada neste trabalho é mostrada na Figura 1. Trata-se de uma imagem de 496 por 496 pixels, com 78 polígonos de tamanhos variados distribuídos em seis classes diferentes.



■ Classe 1    ■ Classe 3    ■ Classe 5  
■ Classe 2    ■ Classe 4    ■ Classe 6

Fig. 1 - Imagem phantom, utilizada para gerar as imagens sintéticas.

Para a simulação de cada uma das três imagens sintéticas, utilizou-se a mesma imagem phantom, mas um conjunto diferente de 6 classes, com diferentes níveis de separabilidade, medidos pela distância JM entre os pares de classes. O vetor de média e a matriz de covariância de cada conjunto de seis classes foram extraídos de uma imagem LANDSAT5/TM adquirida em 29 de junho de 2010, órbita/ponto 227/62, bandas 3, 4 e 5. As classes de cobertura da terra identificadas na imagem LANDSAT5/TM são: floresta primária (FP), floresta degradada (FD), vegetação secundária em desenvolvimento inicial (SV1), vegetação secundária em desenvolvimento intermediário (SV2), vegetação secundária em desenvolvimento avançado (SV3), áreas cultivadas (AC), pasto limpo (PL), pasto sujo (PS), solo exposto (SE) e áreas agrícolas em pousio (AP). Para a descrição mais detalhada da imagem LANDSAT5/TM e classes utilizadas, consultar Reis (2014b).

As seis classes utilizadas para gerar cada imagem sintética estão apresentadas na Tabela 1. Os valores das distâncias JM de cada par de classes está apresentado na Tabela 2, após normalização das bandas das imagens para média 127 e desvio padrão 42 (procedimento feito para otimizar o processo de segmentação,

explicado na sequência). Como pode ser observado, na imagem sintética do Cenário 1, as classes apresentam maiores valores de distância JM, sendo que se espera que as classes sejam facilmente separáveis nesta imagem. A imagem do Cenário 2 apresenta alguns valores baixos e outros altos de distância JM, sendo esperada alguma dificuldade na separação entre alguns dos pares de classes. A imagem sintética do Cenário 3 apresenta valores mais baixos de distância JM entre as classes, sendo que se espera uma maior dificuldade em separar os pares de classes desta imagem.

Tabela 1: Conjunto de classes utilizados para a simulação da imagem simulada de cada cenário

Phantom	Imagem sintética		
	Cenário 1	Cenário 2	Cenário 3
1	AC	AP	FD
2	FP	FD	FP
3	PL	FP	VS1
4	PS	PL	VS2
5	SE	PS	VS3
6	VS1 +VS2	VS3	PS

Tabela 2: Distância JM entre pares de classes das imagens sintéticas nos três cenários propostos

Pares de classes	Distância JM		
	Imagem sintética do Cenário 1	Imagem sintética do Cenário 2	Imagem sintética do Cenário 3
1-2	1,414	1,413	0,834
1-3	1,393	1,414	1,412
1-4	1,385	1,337	0,327
1-5	1,414	1,412	0,838
1-6	1,410	1,413	1,354
2-3	1,412	0,860	1,413
2-4	1,410	1,413	0,847
2-5	1,414	1,412	0,807
2-6	1,134	0,458	1,349
3-4	1,282	1,414	1,407
3-5	1,414	1,414	1,396
3-6	1,410	0,939	1,321
4-5	1,414	1,311	0,616
4-6	1,263	1,411	1,282
5-6	1,414	1,408	1,124

Cada imagem sintética foi segmentada utilizando os três segmentadores apresentados, com diferentes parametrizações. Para o algoritmo de Crescimento de Regiões, foram variados os parâmetros Similaridade e Área Mínima, ambos de 5 a 60, em passos de 5 unidades, resultando em 144 imagens segmentadas por cenário. Para o algoritmo Multiresolution Segmentation, variaram-se os parâmetros Forma e Compacidade, de 0,1 a



0,9, de 0,2 em 0,2, enquanto variou-se o parâmetro Escala de 5 a 60, em passos de 5 unidades. Este procedimento gerou 300 imagens segmentadas por cenário. Para o segmentador contido no Idrisi Selva, foram variados os pesos dos Fatores de Média e de Variância, de 0,1 a 0,9 em passos de 0,2 unidades, de forma que a soma dos dois resulte em 1,0; com parâmetro de Similaridade variando de 0 a 60 em passos de 5 unidades e tamanho fixo de janela igual a 3 (conforme recomendação de Clark Labs (s.d.)), resultando em 60 imagens segmentadas por cenário. Esses parâmetros foram selecionados de modo a representar as segmentações possíveis, restringindo o número de resultados em função dos custos computacionais e de análise.

Considerando-se as variações dos parâmetros em cada algoritmo de segmentação, foram geradas 504 imagens segmentadas por cenário. Para cada cenário, de forma individual, foram calculados os valores do *UnWISE*, *UnWISE'*, *WISE*, *WISE'*, da Função Objetivo proposta por Espíndola *et al.* (2006) e de Fitm de cada imagem segmentada. Como a Função Objetivo ( $G(vb, Ib)$ ) foi originalmente proposta para imagens contendo apenas uma banda, optou-se por calculá-la para cada banda de forma independente e utilizar a média das três medidas (uma para cada banda da imagem sintética) como valor de índice para comparação de imagens segmentadas, conforme utilizado por Johnson e Xie (2011). Esta medida foi denominada FO. Para o cálculo de  $G(vb, Ib)$  é necessário indicar os valores máximos e mínimos da variância intrassegmento (*vb*) e do índice de Moran (*Ib*), considerando as imagens segmentadas sendo avaliadas. Optou-se por considerar o conjunto formado pelas 504 imagens segmentadas de cada cenário, sem distinção em função do algoritmo de segmentação que as geraram. Salienta-se que caso se escolhesse os valores máximos e mínimos de *I* e *v* segregando os dados em função do algoritmo de segmentação, os valores de FO poderiam mudar e, com essa mudança, também a imagem segmentada indicada como ótima por este índice poderia ser outra.

Utilizando cada imagem segmentada individualmente, as respectivas imagens sintéticas foram classificadas por uma metodologia Monte Carlo. O algoritmo NN presente no pacote estatístico RWeka (HORNIK *et al.*, 2009; WITTEN e FRANK, 2005) foi utilizado para classificar cada região das imagens segmentadas, baseado nos valores médios dos pixels de cada região (em

cada banda). Este algoritmo é supervisionado, ou seja, necessita de amostras de treinamento. Cada imagem segmentada (com atributo de média calculada) foi classificada 30 vezes, variando-se o conjunto de amostras de treinamento. Essas amostras de treinamento correspondem às médias de polígonos de diferentes formas e tamanhos desenhados sobre a imagem phantom. Para cada repetição da classificação, foram utilizadas as médias de 20 polígonos de cada classe, sorteados sem repetição desse conjunto de polígonos desenhados. A quantidade total de polígonos pertencentes a cada classe está registrada na Tabela 3. A classificação final de cada imagem segmentada corresponde à moda entre as 30 classificações.

Classe	# de polígonos de treinamento
1	46
2	54
3	38
4	37
5	35
6	34

Tabela 3: Número de polígonos de treinamento

As 1512 imagens classificadas resultantes (504 imagens segmentadas x 3 cenários) foram avaliadas por meio dos valores de Exatidão Global. Todos os pixels da imagem phantom foram utilizados para o cálculo desse índice, que corresponde à razão entre o número de pixels corretamente classificados e o total de pixels na imagem.

Por fim, o desempenho dos índices *WISE* e intermediários foi avaliado em função dos valores de Exatidão Global, em função do número de regiões, pela análise visual das imagens segmentadas e das imagens classificadas, em função do desempenho quando comparados uns com os outros e em relação à FO e Fitm. Para a análise do comportamento de um índice em relação aos demais, optou-se por utilizar o coeficiente de correlação de postos de Spearman. Este coeficiente varia entre -1 e 1, e é utilizado para indicar se há uma tendência de duas variáveis aumentarem (valores próximos a 1) ou diminuírem (valores próximos a -1) em conjunto. Este coeficiente foi calculado utilizando o pacote stats do software R.

## 5. RESULTADOS E DISCUSSÃO

Os valores do coeficiente de correlação de Spearman entre os índices de segmentação calculados para as imagens segmentadas do Cenário 1 estão apresentados na Tabela 4. Os valores referentes aos Cenários 2 e 3 estão apresentados nas Tabelas 5 e 6, respectivamente.

Conforme esperado, em função da formulação, para os pares *WISE-UnWISE* e *UnWISE'-WISE'*, têm-se que o valor do coeficiente de correlação diminui à medida em que o valor de *d* fica mais distante de 1. No entanto, mesmo para  $d = 0,327$  (Cenário 3), a correlação entre os postos desses dois pares de índice é alta, indicando uma possível não necessidade de se ponderar os índices. A não ponderação é desejável por permitir a avaliação de imagens segmentadas sem a necessidade de identificar e coletar amostras das classes presentes na imagem base.

A Figura 2 ilustra o diagrama de dispersão para os valores computados para o par de índices *UnWISE-UnWISE'*, para o Cenário 1. Os diagramas de dispersão para os demais cenários apresentam comportamento parecido e não serão apresentados, assim como os diagramas para o par *WISE-WISE'*. No diagrama apresentado na Figura 2 é possível notar o efeito ocasionado pelo uso do valor absoluto de *I* no cálculo de *I'*, mencionado anteriormente.

Tabela 4: Coeficiente de correlação entre os índices de segmentação calculados para o Cenário 1 ( $d=1,134$ )

	<i>WISE</i>	<i>WISE'</i>	<i>UnWISE</i>	<i>UnWISE'</i>	<i>FO</i>
<i>WISE'</i>	0,409	1,000	-	-	-
<i>UnWISE</i>	<b>1,000</b>	0,410	1,000	-	-
<i>UnWISE'</i>	0,415	<b>1,000</b>	0,416	1,000	-
<i>FO</i>	0,642	<b>0,834</b>	0,649	<b>0,843</b>	1,000
<i>Fitm</i>	0,604	0,376	0,610	0,384	0,644

Também foram observados altos valores de correlação entre os pares de índices *FO-WISE'* e *entre FO-UnWISE'*. Este resultado é interessante, pois indica a possibilidade de utilizar o *UnWISE'* como alternativa à *FO*. A Figura 3 apresenta o diagrama de dispersão para os valores computados para o par de índices *FO-UnWISE'*, para o Cenário 1, para visualização.

Ao se considerar os valores de Exatidão

Tabela 5: Coeficiente de correlação entre os índices de segmentação calculados para o Cenário 2 ( $d = 0,458$ )

	<i>WISE</i>	<i>WISE'</i>	<i>UnWISE</i>	<i>UnWISE'</i>	<i>FO</i>
<i>WISE'</i>	0,635	1,000	-	-	-
<i>UnWISE</i>	<b>0,954</b>	0,636	1,000	-	-
<i>UnWISE'</i>	0,515	<b>0,972</b>	0,568	1,000	-
<i>FO</i>	0,538	<b>0,950</b>	0,538	<b>0,945</b>	1,000
<i>Fitm</i>	0,791	0,698	0,771	0,605	0,562

Tabela 6: Coeficiente de correlação entre os índices de segmentação calculados para o Cenário 3 ( $d = 0,327$ )

	<i>WISE</i>	<i>WISE'</i>	<i>UnWISE</i>	<i>UnWISE'</i>	<i>FO</i>
<i>WISE'</i>	0,567	1,000	-	-	-
<i>UnWISE</i>	<b>0,904</b>	0,564	1,000	-	-
<i>UnWISE'</i>	0,478	<b>0,971</b>	0,567	1,000	-
<i>FO</i>	0,600	<b>0,988</b>	0,554	<b>0,932</b>	1,000
<i>Fitm</i>	0,581	0,490	0,544	0,467	0,489




Fig. 2 - Diagrama de dispersão para os valores computados para o par de índices *UnWISE-UnWISE'*, para o Cenário 1.

Global das imagens classificadas, deve-se salientar que as imagens segmentadas que levam aos melhores resultados de classificação não são, necessariamente, as melhores imagens segmentadas (dependendo da definição, conforme exposto na Seção 1). No caso abordado neste trabalho, dadas as características do classificador




Fig. 3 - Diagrama de dispersão para os valores computados para o par de índices  $FO-UnWISE'$ , para o Cenário 1.

NN e o fato de se tratarem de imagens sintéticas, obtiveram-se altos valores Exatidão Global de imagens classificadas provenientes de imagens supersegmentadas. Um exemplo desta situação está ilustrado na Figura 4. Nessa figura, está apresentada uma área da imagem segmentada do Cenário 1, obtida utilizando Multiresolution Segmentation com a parametrização Escala=5, Forma=0,1 e Compacidade=0,9, sobreposta à imagem phantom, e a mesma área da imagem classificada resultante. As cores apresentadas na imagem phantom se assemelham àquelas das respectivas classes na imagem sintética.

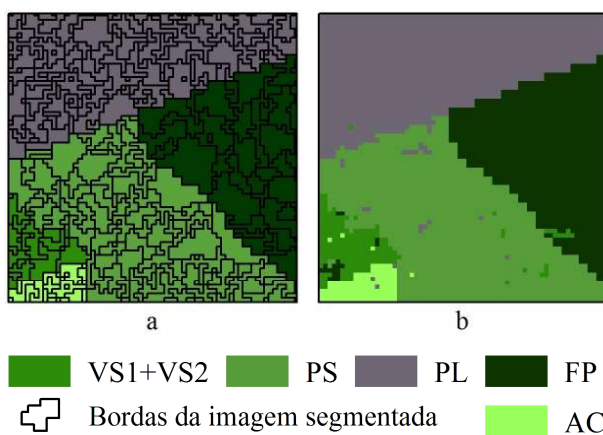


Fig. 4 - Exemplo de classificação com alto valor de acurácia utilizando uma imagem supersegmentada: a) bordas da imagem segmentada sobrepostas à imagem phantom; b) imagem classificada resultante.

A imagem segmentada apresentada na Figura 4 trata-se claramente de uma imagem supersegmentada. Considerando não só a área ilustrada, mas toda a imagem, tem-se que essa imagem segmentada possui 25136 regiões (322,26 vezes o número de regiões da imagem referência), sendo que a imagem classificada resultante possui Exatidão Global de 0,972, com erros encontrados em polígonos muito pequenos, por vezes de apenas 1 pixel (a imagem segmentada possui 6015 regiões com 1 pixel e 16964 regiões com 10 ou menos pixels). Imagens classificadas como essa são comuns, nos três cenários. A partir de imagens subsegmentadas não foram obtidas imagens classificadas com altos valores de Exatidão Global. Isso ocorre porque parte da região que engloba mais de uma classe necessariamente está classificada de forma incorreta.

Todos os índices tendem a retornar maiores valores para imagens segmentadas que possuem um maior número de regiões que a imagem referência. Com a exceção de *Fitm*, observaram-se valores altos para os índices de segmentação para imagens supersegmentadas com mais de 20000 regiões. A Figura 5 apresenta os diagramas de dispersão entre número de regiões e o índices *WISE*, *FO* e *Fitm*, do Cenário 1, para exemplificação. A Figura 6 apresenta os diagramas de dispersão para os mesmos índices, para o Cenário 3.

Além disso, observaram-se também valores parecidos entre os índices para imagens segmentadas muito diferentes, com exceção do *Fitm*. Na Figura 7 estão apresentadas duas áreas de duas imagens segmentadas do Cenário 3, sobrepostas à imagem phantom e com os valores dos índices de segmentação, bem como Exatidão Global (EG) e número de regiões (#regiões), indicados (calculados considerando toda a imagem).

Na Figura 8 são apresentadas as imagens segmentadas melhor avaliadas considerando cada índice de segmentação, para o Cenário 1. As mencionadas imagens segmentadas estão sobrepostas à imagem phantom. As imagens segmentadas que obtiveram os maiores valores para cada índice de segmentação dos Cenários 2 e 3 estão apresentadas nas Figuras 9 e 10, respectivamente. Estão registrados nessas figuras, também, os valores dos índices, o número de regiões (#regiões) e de Exatidão Global (EG).

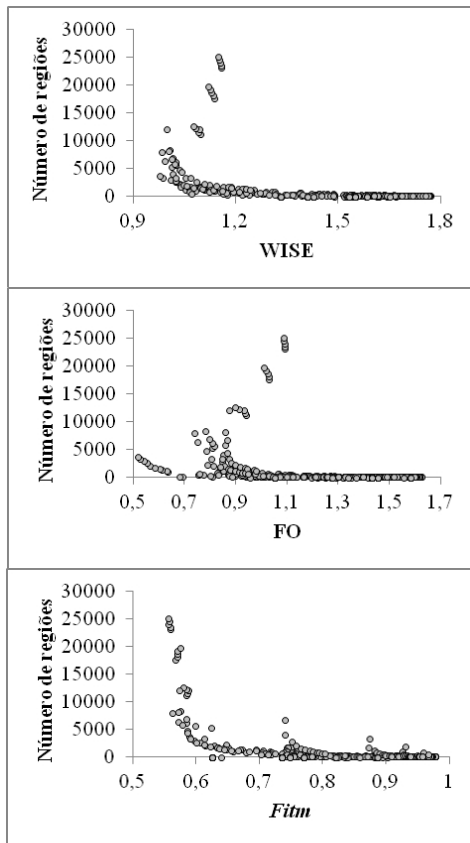


Fig. 5 - Diagramas de dispersão entre o Número de Regiões das imagens segmentadas e os valores computados para *WISE*, *FO* e *Fitm*, do Cenário 1.

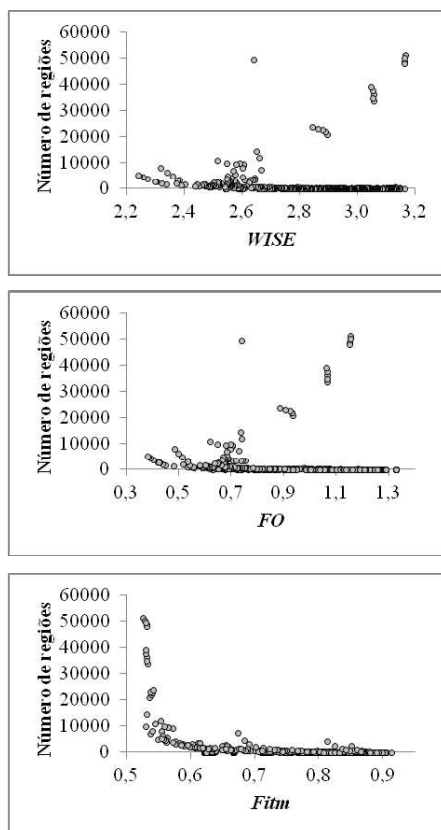


Fig. 6 - Diagramas de dispersão entre o Número de Regiões das imagens segmentadas e os valores computados para *WISE*, *FO* e *Fitm*, do Cenário 3.

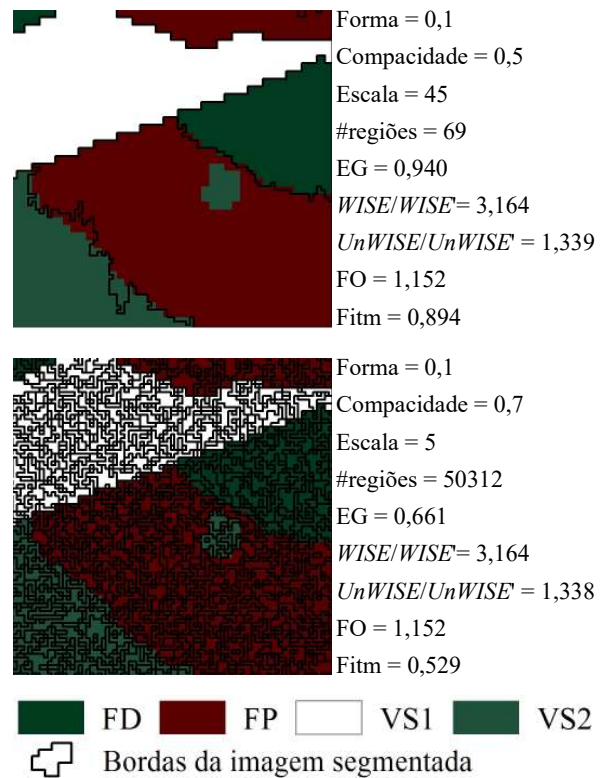



Fig. 7 - Exemplos de imagens segmentadas do Cenário 3.

Na Figura 8 são apresentadas as imagens segmentadas melhor avaliadas considerando cada índice de segmentação, para o Cenário 1. As mencionadas imagens segmentadas estão sobrepostas à imagem phantom. As imagens segmentadas que obtiveram os maiores valores para cada índice de segmentação dos Cenários 2 e 3 estão apresentadas nas Figuras 9 e 10, respectivamente. Estão registrados nessas figuras, também, os valores dos índices, o número de regiões (#regiões) e de Exatidão Global (EG).

*WISE e UnWISE - Multiresolution Segmentation*




*WISE' e UnWISE' - Crescimento de Regiões*




Área Mínima = 10  
 Similaridade = 50  
 #regiões = 42  
 EG = 0,729  
 WISE = 1,411  
 WISE' = 2,040  
 UnWISE = 1,504  
 UnWISE' = 2,132  
 FO = 1,433  
 Fitm = 0,735

*FO - Multiresolution Segmentation*



Forma = 0,1  
 Compacidade = 0,7  
 Escala = 50  
 #regiões = 72  
 EG = 0,998  
 WISE = 1,578  
 WISE' = 2,007  
 UnWISE = 1,681  
 UnWISE' = 2,110  
 FO = 1,623  
 Fitm = 0,958


*Fitm - Multiresolution Segmentation*



Forma = 0,1  
 Compacidade = 0,1  
 Escala = 30  
 #regiões = 75  
 EG = 0,998  
 WISE = 1,650  
 WISE' = 1,952  
 UnWISE = 1,754  
 UnWISE' = 2,055  
 FO = 1,569  
 Fitm = 0,978


AC FP PL PS SE VS1+VS2  
 Bordas da imagem segmentada

*WISE e UnWISE - Multiresolution Segmentation*




Forma = 0,1  
 Compacidade = 0,7  
 Escala = 25  
 #regiões = 105  
 EG = 0,935  
 WISE = 2,583  
 WISE' = 2,584  
 UnWISE = 1,725  
 UnWISE' = 1,726  
 FO = 1,070  
 Fitm = 0,893

*WISE', UnWISE' e FO - Multiresolution Segmentation*



Forma = 0,3  
 Compacidade = 0,1  
 Escala = 60  
 #regiões = 59  
 EG = 0,871  
 WISE = 2,376  
 WISE' = 2,893  
 UnWISE = 1,528  
 UnWISE' = 2,044  
 FO = 1,464  
 Fitm = 0,871

*Fitm - Multiresolution Segmentation*



Forma = 0,3  
 Compacidade = 0,1  
 Escala = 40  
 #regiões = 71  
 EG = 0,934  
 WISE = 2,447  
 WISE' = 2,830  
 UnWISE = 1,589  
 UnWISE' = 1,972  
 FO = 1,411  
 Fitm = 0,928

AP FD FP PL PS VS3  
 Bordas da imagem segmentada

Fig. 8 - Imagens segmentadas do Cenário 1 para as quais foram calculados os maiores valores de cada índice.

Fig. 9 - Imagens segmentadas do Cenário 2 para as quais foram calculados os maiores valores de cada índice.

Para o Cenário 1, todas as imagens segmentadas geradas pelo algoritmo de Crescimento de Regiões com Similaridade igual a 50 ou 55 e Área Mínima variando entre 10 e 60 apresentaram resultados praticamente iguais, bem como o mesmo valor para cada índice de segmentação calculado. Salienta-se que, ao se desconsiderar imagens segmentadas

iguais, o segundo maior valor de *UnWISE'* foi calculado para a mesma imagem segmentada que obteve o maior valor de *FO* (Multiresolution Segmentation, Forma=0,1, Compacidade=0,7 e Escala=50).

Neste cenário, *WISE* e *UnWISE* retornaram como ótima uma imagem supersegmentada. A imagem segmentada que obteve o maior

valor de *WISE'* e *UnWISE'* trata-se de uma subsegmentação. Os maiores valores de *FO* e de *Fitm* foram calculados para imagens segmentadas parecidas com a imagem referência, sendo que o *Fitm* apresentou o melhor resultado.

No Cenário 2, nenhum dos cinco índices retornou o maior valor para imagens segmentadas em que as classes *FD* e *VS3* estivessem efetivamente separadas, sendo esse par de classes supostamente difícil de separar, com distância  $JM=0,458$ . Os maiores valores de *WISE* e de *UnWISE* foram calculados para imagens segmentadas em que algumas das áreas de *AP* foram divididas desnecessariamente.

No Cenário 3, observa-se que o maior valor de *WISE* foi obtido de uma imagem supersegmentada com um número absurdo de regiões (51398). Conforme mencionado anteriormente, existem altos valores dos índices que não o *Fitm* para imagens com esta característica, principalmente neste cenário, em que algumas classes apresentam baixa separabilidade e há imagens segmentadas com um maior número de regiões. O maior valor de  $UnWISE'/WISE'/FO$  foi calculado para uma imagem subsegmentada. As imagens selecionadas pelos maiores valores de *UnWISE* e *Fitm* apresentam-se levemente supersegmentadas, com a maioria das bordas das feições preservadas, com algumas feições maiores divididas em regiões desnecessárias.

## 6. CONCLUSÕES E PERSPECTIVAS

Para o uso de técnicas de classificação e de análise baseadas em regiões, é essencial que existam ferramentas adequadas para a seleção da imagem segmentada ótima para o processo. Neste trabalho, analisou-se o desempenho do Índice Ponderado para Avaliação de Segmentação (*WISE*), bem como de suas versões intermediárias:

*UnWISE* - Índice não Ponderado para a Avaliação de Segmentação;


*WISE'* - Índice Ponderado para a Avaliação de Segmentação - modificado;

*UnWISE'* - Índice não Ponderado para a Avaliação de Segmentação - modificado;

para seleção da imagem segmentada ótima. O desempenho destes índices foi comparado ao de outros dois:


*FO* - a média aritmética dos valores, calculados

### *WISE* - Multiresolution Segmentation



Forma = 0,1  
Compacidade = 0,9  
Escala = 5  
#regiões = 51398  
EG = 0,659  
*WISE* = 3,165  
*WISE'* = 3,165  
*UnWISE* = 1,336  
*UnWISE'* = 1,336  
*FO* = 1,153  
*Fitm* = 0,527

### *UnWISE* - Multiresolution Segmentation




Forma = 0,3  
Compacidade = 0,5  
Escala = 30  
#regiões = 114  
EG = 0,955  
*WISE* = 3,147  
*WISE'* = 3,189  
*UnWISE* = 1,702  
*UnWISE'* = 1,743  
*FO* = 1,132  
*Fitm* = 0,852

### *WISE'*, *UnWISE'* e *FO* - Crescimento de Regiões



Área Mínima = 20  
Similaridade = 60  
#regiões = 26  
EG = 0,439  
*WISE* = 2,546  
*WISE'* = 3,559  
*UnWISE* = 1,229  
*UnWISE'* = 2,242  
*FO* = 1,327  
*Fitm* = 0,625

### *Fitm* - Multiresolution Segmentation



Forma = 0,1  
Compacidade = 0,5  
Escala = 35  
#regiões = 78  
EG = 0,970  
*WISE* = 2,980  
*WISE'* = 3,337  
*UnWISE* = 1,533  
*UnWISE'* = 1,889  
*FO* = 1,251  
*Fitm* = 0,913

FD FP VS1 VS2 VS3 PS  
Bordas da imagem segmentada

para cada banda das imagens sintéticas, da Função Objetivo proposta por Espíndola *et al.* (2006);

Fitm - a média aritmética de quatro medidas supervisionadas propostas por Delves *et al.* (1992).

Estes índices foram avaliados em três cenários distintos. Cada cenário se caracteriza pelo conjunto de uma imagem sintética e das imagens segmentadas provenientes desta, utilizando três diferentes algoritmos de segmentação. As imagens sintéticas de cada cenário apresentam diferentes características quanto à separabilidade entre as classes.

Foram utilizados diferentes algoritmos de segmentação apenas para gerar imagens segmentadas com características distintas, sendo que estas não foram agrupadas por algoritmo durante a avaliação. No entanto, foi possível perceber que o eventual agrupamento das imagens segmentadas por tipo de algoritmo utilizado acarreta em diferentes valores de FO para cada imagem segmentada. Eventualmente, também o ordenamento das imagens segmentadas em função dos valores de FO é alterado. Ou seja, em alguns casos, a imagem segmentada com maior valor de FO proveniente de um determinado algoritmo de segmentação, quando o FO é calculado utilizando também imagens provenientes de outros segmentadores, é diferente da imagem segmentada com maior valor de FO calculado apenas com as imagens segmentadas provenientes daquele segmentador. Esta é uma característica indesejável em um índice para avaliar uma imagem segmentada.

Para o conjunto de dados analisado, foram observados resultados altamente correlacionados entre o uso de *WISE* e *UnWISE* ou *WISE'* e *UnWISE'*. Esta alta correlação indica a não necessidade de ponderar os índices e consequentemente a não necessidade em identificar as classes presentes na imagem base para a segmentação, o que simplificaria e automatizaria o processo de avaliação das imagens segmentadas.

Para cada conjunto composto de uma imagem segmentada e uma imagem base, existe apenas um valor de *UnWISE* ou de *UnWISE'*. Para os três cenários avaliados, observou-se uma alta correlação entre o ordenamento dos valores de FO e de *UnWISE'*. Dessa forma, o *UnWISE'*

é indicado como substituto do FO para casos em que a variabilidade nos valores de FO em função do conjunto de imagens segmentadas analisado seja prejudicial à avaliação.

De forma geral, os índices FO, *UnWISE'* e *WISE'* apresentaram melhor desempenho na seleção de imagens segmentadas para os cenários com maior separabilidade entre as classes do que nos de baixa separabilidade. Tanto o *WISE* quanto o *UnWISE* retornaram maiores valores para imagens supersegmentadas para todos os cenários. Estes 5 índices apresentaram a tendência de retornar valores altos para imagens extremamente supersegmentadas. Há a necessidade de se verificar se este comportamento se relaciona às imagens sintéticas utilizadas ou se trata-se das componentes de avaliação de homogeneidade intra e intersegmentos, utilizadas para a formulação desses 5 índices.

Como era esperado, o Fitm obteve os melhores resultados para todos os cenários avaliados, uma vez que é o único índice que dispõe da referência para comparação. Além disso, quando se inclui a imagem referência no conjunto de imagens segmentadas de cada cenário, têm-se que apenas o Fitm retorna esta imagem segmentada como a melhor.

Ao se considerar os índices não supervisionados e os três cenários avaliados, o *UnWISE* apresentou os melhores resultados. Para sua utilização, bem como na dos outros índices não supervisionados apresentados neste trabalho, é recomendável que haja uma etapa prévia de seleção das imagens segmentadas, em que imagens com um número muito alto de segmentos sejam retiradas da análise.

São necessários estudos mais aprofundados para estender estes resultados para imagens de sensoriamento remoto reais. Também são necessários ajustes nos índices para evitar a ocorrência de valores próximos para imagens segmentadas muito diferentes e de valores altos para imagens extremamente supersegmentadas. A este respeito, acredita-se que o procedimento de simulação das imagens, sem correlação espacial, e subsequente normalização de média e variância, possa ter ocasionado a inserção de ruído nas imagens que ocasionaram valores muito altos para as medidas de homogeneidade intrassegmentos, utilizada no cálculo de todos os índices não supervisionados, o que explicaria

a ocorrência de altos valores dos índices nos cenários de menor separabilidade, no qual estão presentes as imagens segmentadas com maior número de regiões. Assim, trabalhos futuros englobam:

- 1) avaliar o desempenho do *WISE* e índices intermediários para imagens reais;
- 2) avaliar se há melhora no desempenho dos índices *WISE* e intermediários após aplicação de filtros de ruído nas imagens base;
- 3) determinar se a ponderação em função da mínima distância de Jeffries-Matusita entre pares de classes é desnecessária também para outros dados;
- 4) possível correção dos índices não supervisionados para que haja penalização de imagens segmentadas com um número muito grande de regiões;
- 5) comparação dos resultados dos índices não supervisionados apresentados com outros índices também não supervisionados, disponíveis na literatura;
- 6) avaliação dos resultados em função do algoritmo de segmentação.

## REFERÊNCIAS BIBLIOGRÁFICAS

- ABOUD, N. S. **Uso de imagens ALOS/PALSAR multipolarizadas para detecção de incremento de desflorestamento na Amazônia**. 2009. 264 p. INPE-16624-TDI/1598. Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2009.
- ACHANCCARAY, P.; AYMA, V.; JIMENEZ, L.; GARCIA, S.; HAPP, P.; FEITOSA, R.; PRAZA, A. A free software tool for automatic tuning of segmentation parameters. In: **5th GEOBIA, 2014, Thessalonik. South-Eastern European Journal of Earth Observation and Geomatics**. Thessaloniki: Aristotle University of Thessaloniki, v. 3, 2014. p. 707-712.
- BAATZ, M.; SCHÄPE A. Multiresolution Segmentation - an optimization approach for high quality multi-scale image segmentation. In: Strobl, J. et al. (eds.): *Angewandte Geographische Informationsverarbeitung XII. Anais...* Wichmann, Heidelberg, pp. 12-23, 2000.
- BINS, L.; FONSECA, L.; ERTHAL, G.; MITSUO, I. F. Satellite imagery segmentation: a region growing approach. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 8, 1996, Salvador. **Anais...** São José dos Campos, 1996. Disponível em: <<http://marte.sid.inpe.br/col/sid.inpe.br/deise/1999/02.05.09.30/doc/T205.pdf>>. Acesso em: 23 de fev. 2014.
- BLASCHKE, T. Object based image analysis for remote sensing. **ISPRS Journal of Photogrammetry and Remote Sensing**, n 65, p. 2-16, 2010.
- BORSOTTI, M.; CAMPADELLI, P.; SCHETTINI, R. Quantitative evaluation of color image segmentation results. **Pattern Recognition Letters**, v.19, p.741-747, 1998.
- CHABRIER, S.; EMILE, B.; ROSENBERGER, C.; LAURENT, H. Unsupervised performance evaluation of image segmentation. **EURASIP Journal on Applied Signal Processing**, v. 2006, p. 1 - 12, 2006.
- CLARK LABS. **IDRISI Selva Help System**. s.d. Disponível em:< <http://www.clarklabs.org/support/IDRISI-Taiga-Help-System.cfm>>. Acesso em 15 de maio de 2014.
- COSTA, G. A. O. P.; FEITOSA, R.; CAZES, T.; FEIJÓ, B. Genetic Adaptation of Segmentation Parameters. In: Blaschke, T.; LAND, S.; HAY, G. (Eds). **Object Based Image Analysis: Spatial Concepts for Knowledge Driven Remote Sensing Applications**. 1. ed. Berlin: Springer-Verlag Berlin Heidelberg, 2008.
- DEFINIENS. **eCognition Developer 8 Reference Book**. Munich, 2009. 276p.
- DELVES, L.M.; WILKINSON, R.; OLIVER, C.J.; WHITE, R.G. Comparing the performance of SAR segmentation algorithms. **International Journal of Remote Sensing**, v.13, n.2, p.2121-2149, 1992.
- ESPÍNDOLA, G. M.; CÂMARA, G.; REIS, I.; BINS, L.; MONTEIRO, A. Parameter selection for region-growing image segmentation algorithms using spatial autocorrelation. **International Journal of Remote Sensing**, v. 27, n. 14, p. 3035-3040, 2006.
- HORNIK, K.; BUCHTA, C.; ZEILEIS, A. Open-Source Machine Learning: R Meets Weka. **Computational Statistics**, v.24, n. 2, p. 225 - 232.



- JOHNSON, B.; XIE, Z. Unsupervised image segmentation evaluation and refinement using a multi-scale approach. **ISPRS Journal of Photogrammetry and Remote Sensing**, n.66, p.473 - 483, 2011.
- LU, D.; BATISTELLA, M.; LI, G.; MORAN, E.; HETRICK, S.; FREITAS, C.C.; DUTRA, L.V.; SANT'ANNA, S.J.S. Land use/cover classification in the brazilian amazon using satellite images. **Pesquisa agropecuária brasileira**, v. 47, n. 9, p. 1185–1208, 2012.
- LUCCA, E. V. D.; FREITAS, C. C.; FRERY, A. C. O.; SANT'ANNA, S.J.S. Comparison of SAR segmentation algorithms. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 9. (SBSR), 1998, Santos. **Anais...** São José dos Campos, p. 1097-1108, 1998.
- MÖLLER, M.; LYMBURNER, L.; VOLK, M. The comparison index: a tool for assessing the accuracy of image segmentation. **International Journal of Applied Earth Observation and Geoinformation**, v.9, p.311-321, 2007.
- NEGRI, R.G.; DUTRA, L.V.; SANT'ANNA, S.J.S. Stochastic approaches of minimum distance method for region based classification. **Progress in Pattern Recognition, Image Analysis, Computer Vision, and Applications Lecture Notes in Computer Science**, v. 7441, p. 797–804, 2012.
- RÄSÄNEN, A.; RUSANEN, A.; KUITUNEN, M.; LENSU, A. What makes segmentation good? A case study in boreal forest habitat mapping. **International Journal of Remote Sensing**, v. 34, n 23, p. 8603–8627, 2013.
- REIS, M. S. **Detecção de mudanças de uso e cobertura da terra utilizando dados óticos e de micro-ondas em uma região da Amazônia brasileira**. 2014. 331 p. Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2014b.
- REIS, M.S.; PANTALEÃO, E.; SANT'ANNA, S.J.S.; DUTRA, L.V. Proposal of a Weighted Index for Segmentation Evaluation. In: IEEE International Geoscience and Remote Sensing Symposium (IGARSS), 2014. **Proceedings...** Québec, 2014a.
- SALDANHA, M.F.S.; FREITAS, C.C. ; SANT'ANNA, S.J.S. Segmentação de imagens SAR usando abordagem probabilística baseada na distribuição Gama. **Revista Brasileira de Cartografia**, n. 66, v.1 p. 29-43, 2014.
- SCHOWENGERDT, R. **Remote Sensing: Models and methods for image processing**. 3. ed. USA: Academic Press, 2006. 560 p.
- THEODORIDIS, S.; KOUTROUMBAS, K. **Pattern Recognition**. 3. ed. San Diego: Academic Press, 2006. 984 p.
- WHITE, R.; OLIVER, C. Change detection in SAR imagery. **IEEE International Radar Conference**, p. 217–222, 1990.
- WITTEN, I.H.; FRANK, E. **Data Mining: Practical Machine Learning Tools and Techniques**. 2. ed. São Francisco: Morgan Kaufmann, 2005. 560p.
- ZHAN, Q.; MOLENAAR, M.; TEMPFLI, K.; SHI, W. Quality assessment for geo-spatial objects derived from remotely sensed data. **International Journal of Remote Sensing**, v.26, n.14, p.2953-2974, 2005.
- ZHANG, H.; FRITTS, J.E.; GOLDMAN, S.A. Image segmentation evaluation: A survey of unsupervised methods. **Computer Vision and Image Understanding**, v. 110, p. 260–280, 2008.
- ZHANG, X.; XIAO, P.; FENG, X. An unsupervised evaluation method for remotely sensed imagery segmentation. **IEEE Geoscience and Remote Sensing Letters**, v.9, n.2, p. 156 - 160, 2012.
- ZHANG, Y.J. A survey on evaluation methods for image segmentation. **Pattern Recognition**, v.29, n.8, p. 1335-1346, 1996.