

# VISUALIZANDO A PRECISÃO TEMÁTICA NO PROCESSO DE CLASSIFICAÇÃO DE PRODUTOS DO SENSORIAMENTO REMOTO: ABORDAGEM POR PIXEL E POR OBJETO

C. A. O.Vieira

Universidade Federal de Santa Catarina, Brasil

Comissão CT04

## RESUMO

Normalmente a precisão temática baseia-se em estatísticas não-espaciais, que sumarizam as características de uma matriz de erro. Essas estatísticas normalmente não consideram a distribuição espacial dos pixels erroneamente classificados. Consequentemente, a avaliação da precisão temática utilizando uma abordagem por pixel tem limitações óbvias quando aplicada à análise de imagens baseada em objetos. Assim, torna-se necessário o desenvolvimento de métodos para avaliar tanto a precisão temática, quanto a precisão geométrica (localização e forma) de objetos classificados. O objetivo deste artigo é apresentar alternativas para quantificar e visualizar a precisão temática da classificação de imagens, seguindo as abordagens por pixels e por objetos. Resultados mostram que pesquisas precisam ser realizadas antes da correta caracterização espacial dos erros oriundos do processo de classificação, de forma a serem devidamente comunicados em formatos e legendas padronizadas.

**Palavras chave:** Avaliação de Precisão, Precisão Temática, Classificações Baseadas em Pixels e em Objetos

## ABSTRACT

The accuracy of a thematic classification derived from remotely sensed data is generally based on non-spatial statistics that summarize the characteristics of a confusion or error matrix. None of these statistics explicitly considers the spatial distribution of misclassified pixels. This paper describes methods of assessment of thematic classifier performance, for both pixel-based and object-based approaches, that explicitly includes the spatial pattern of classification errors, and which presents the user with a visual indication of the reliability of the pixel or object label assignments. Results show that considerable amount of research and development needs to be accomplished before the spatial characterization of the thematic accuracy associated with remote sensing can be adequately reported in standardized formats and legends.

**Keywords:** Accuracy Assessment, Thematic Accuracy, Pixel-Based and Object-Based Classifications

## 1- INTRODUÇÃO

Validação é uma fase essencial em qualquer procedimento de mapeamento. Execução de operações para análise de dados espaciais sobre dados com precisão desconhecida, resultará em um produto com baixa confiabilidade e de uso limitado. Principalmente porque erros decorrentes de uma fonte podem se propagar no banco de dados através de produtos derivados (Lunetta et al., 1991).

Existem pelo menos dois componentes diferentes de precisão no contexto de sensoriamento remoto: *precisão posicional* e *precisão temática*. *Precisão Posicional* nos dados do sensoriamento remoto refere-se a precisão de uma imagem corrigida geometricamente, enquanto que a *precisão temática* refere-se à precisão da característica não-posicional de uma entidade de dados espaciais, os chamados atributos. Embora ambos os componentes sejam extremamente importantes para o processo de classificação,

a ênfase que será dada neste artigo é para a precisão temática.

Normalmente a precisão temática no contexto do sensoriamento remoto baseia-se geralmente em estatísticas não espaciais, que sumarizam as características de uma matriz de erro (ou confusão), a qual relaciona dados de saída de um classificador com dados de referência conhecidos (Congalton e Green, 2009). Essas estatísticas derivadas da matriz de erro incluem diversas índices estatísticos. Embora esses índices sejam bastante utilizados, nenhum deles considera, a distribuição espacial dos pixels erroneamente classificados (Lunetta et al., 1991). Erro neste contexto pode ser definido como uma discrepância entre a situação apresentada na imagem temática gerada e a realidade (Arbia et al., 1998). Para algumas aplicações, é importante visualizar a precisão temática de toda a imagem, mesmo para os pixels para os quais não existem dados de referência.

Por outro lado, a avaliação da precisão temática utilizando uma abordagem por pixel tem limitações óbvias quando aplicada à análise de imagens baseada em objetos geográficos GEOBIA (*Geographic Object-Based Image Analysis*) (Schöpfer e Lang, 2008). Embora esses métodos por pixels realmente forneçam informações sobre a qualidade ou precisão de uma classificação em locais específicos (x, y) na imagem (Zhan et al., 2005), quando aplicado a abordagem GEOBIA, apresentam incertezas sobre a extensão da classe de referência para além desse local. Em suma, utilizando a abordagem por pixel parece não responder as seguintes questões, apresentadas por Whiteside et al. (2014): “até que ponto o objeto classificado tipificam, tanto em termos temáticos e geométricos, o objeto do mundo real, que se destina a representar?” Portanto, torna-se necessário o desenvolvimento de métodos para avaliar tanto a precisão temática, quanto a precisão geométrica (localização e forma) de objetos classificados (Schöpfer et al., 2008).

O objetivo deste artigo é apresentar alternativas para avaliar a precisão temática da classificação de produtos do sensoriamento remoto, seguindo as abordagens baseadas em pixels e em objetos - como unidade de mapeamento. Complementarmente também incluir explicitamente o padrão espacial de erros oriundos do processo de classificação na fase de validação, e, assim, apresentar ao usuário uma indicação temática da confiabilidade das atribuições para toda imagem.

## 2- MATERIAL E ÁREA DE ESTUDO

Utilizou-se nesses experimentos uma imagem com três bandas multispectrais do sensor SPOT HRV 1 (*High Resolution Visible*) de 14 Junho de 1994 para uma região plana de terras agrícolas localizada nas imediações da cidade de *Littleport* (Fig. 1).



Fig. 1 – Área de estudo em Littleport

Para a geração da imagem de referência, foi utilizado um conjunto de formulários oficiais preenchidos individualmente por fazendeiros da região da área de estudo para o período de maio a julho de 1994. Foram selecionadas as três principais culturas agrícolas da região: batata, beterraba, trigo.

As operações de processamento de imagem foram realizadas utilizando o Sistema ERDAS Imagine 2010 e do Sistema IDRISI Taiga. Alguns programas foram desenvolvidos utilizando a linguagem C padrão, para realizar procedimentos específicos de validação. A correção geométrica da imagem foi realizada utilizando como base o sistema projetivo Britânico *Ordnance Survey* (GB) para a escala 1:25.000, como também usando 17 pontos de controle e reamostragem do vizinho mais

próximo. O erro médio quadrático obtido foi de 0,462 pixels. Não houve a necessidade de realizar uma correção radiométrica na imagem.

## 3- MÉTODOS

Inicialmente foram realizadas classificações supervisionadas, utilizando o classificador da máxima verossimilhança (MAXVER), seguindo as abordagens por pixel e por objeto, usando um conjunto de amostras independentes para seu treinamento e teste, e aplicando uma estratégia de amostragem aleatória estratificada, como descrita por Congalton e Green (2009).

### 3.1- Precisão Temática Baseada em Pixel

Métodos de avaliação da precisão temática, utilizando-se como unidade de classificação os *pixels* isolados, normalmente baseiam-se em estatísticas não espaciais, derivados da *Matriz de Erro*. Segundo Arsanjani e Vaz (2015) a matriz de erro ajuda a visualizar o grau de correspondência entre o conjunto de temas gerados pelo classificador e o conjunto de dados de referência. Essas estatísticas incluem: exatidão global, exatidão por classe individual (usuário e produtor) e de uma variedade de índices, como Kappa, e o teste Z estatístico, entre outras estatísticas.

Assim, para avaliar o desempenho do classificador, segundo Congalton e Green (2009) podem ser formuladas as seguintes hipóteses estatísticas: a hipótese nula  $H_0$ : Kappa = 0, e a hipótese alternativa  $H_1$ : Kappa  $<>$  0;  $H_0$  é rejeitada se o valor de Z calculado for maior do que o seu valor tabelado, assumindo graus de liberdade infinitos.

Embora estes índices estejam sendo bastante utilizados, nenhum deles considera a distribuição espacial dos pixels classificados erroneamente na imagem temática, implícita ou explicitamente.

#### 3.1.1- Caracterizando a distribuição espacial dos erros

Uma forma possível para caracterizar a distribuição espacial dos erros oriundos de uma classificação temática é através da geração de uma *imagem de distâncias* (ver Fig. 2a) que apresenta a distância entre os pixels individuais para os centroides das classes multivariadas a que foram atribuídos (Vieira e Mather, 2001). Tanto a distância Euclidiana como a distância *Mahalanobis* podem ser utilizadas. As distâncias individuais são escalonadas para um intervalo entre [0 e 255], e exibido como uma imagem em tons de cinza. Pixels mais escuros estão espectralmente "mais próximos" do centroide da classe (no sentido da distância estatística), e são, portanto, mais susceptíveis de serem classificados corretamente. Por outro lado, os pixels com maiores distância estão espectralmente mais distantes do centroide da classe à qual foram atribuídos, e são, assim, mais prováveis de serem classificados incorretamente.

Uma forma alternativa de observar a distribuição espacial dos erros presentes em uma imagem classificada é comparando diretamente a imagem temática com o respectivo mapa de referência. Um dos produtos desta comparação deve ser uma *imagem de erro binária* (Fig. 2b), na qual cada pixel

toma o valor 0 (corretamente rotulado) ou 1 (incorretamente rotulado).

Outro produto desta comparação é a *validação cruzada*, que compara imagens contendo variáveis categóricas. Esse procedimento gera uma imagem de classificação cruzada entre as classes informacionais presentes na imagem de referência em relação à imagem classificada. Normalmente, cores são atribuídas para caracterizar cada uma dos possíveis cruzamentos entre classes (Fig. 3a).




Fig. 2 - Imagem de Distâncias (a) Imagem de Erro Binária (b)

### 3.1.2- Visualizando a confiabilidade temática

Qualquer medida de distância, por exemplo, a *distância de Mahalanobis* (MD), entre o pixel e a distribuição de cada classe pode ser usada para calcular uma medida de confiabilidade (P) do rótulo de um pixel. A MD pode ser transformada em probabilidade utilizando-se a seguinte equação (Vieira e Mather, 2001):

$$P = MD^{-1} / MD^{-1} \quad (1)$$

onde MD é a *distância de Mahalanobis* entre cada pixel e cada classe k. As probabilidades foram agrupadas em 5 níveis diferentes. Cores individualizadas poderiam ser atribuídas para cada classe. E os níveis dentro da mesma classe poderiam também ser atribuídos tons distintos daquela cor, de modo a que cada classe é representada por cinco tons da cor básica (ver Fig. 3b). Este tipo de representação permite a apreciação visual do grau de confiabilidade com que cada cultura foi classificada.




Fig. 3 - Imagem de Validação Cruzada (a) Mapa de Confiabilidade Temática (b)

### 3.2- Precisão Temática Baseada em Objeto

Classificação de imagens baseadas em objetos normalmente produz resultados que têm propriedades temáticas e geométricas, uma vez que objetos classificados não só pertencem a classes informacionais específicas, mas também têm propriedades espaciais, tais como: a localização e forma. Portanto, qualquer avaliação da precisão temática de imagens utilizando a abordagem por objeto, deve necessariamente levar em conta as propriedades temáticas e geométricas (localização e forma) dos objetos classificados (Whiteside et al., 2014). Métodos tradicionais de avaliação da precisão temática, tais como matrizes de confusão (Congalton e Green, 2009), não fornecem esse tipo de informação geométrica, e tem havido poucos trabalhos de pesquisa para determinar as medidas de precisão espaciais adequadas para análise de imagens

baseada em objetos (Schöpfer et al., 2008; Zhan et al., 2005).

Ao determinar a precisão da classificação de objetos é importante considerar tanto: (a) a precisão da classificação dos objetos (também conhecido como categórica ou temática) e (b) a precisão espacial (localização e a forma) dos objetos.

Whiteside et al. (2014) refere-se a precisão espacial como sendo o quão bem um objeto classificado (C), corresponde espacialmente (localização e forma) ao mesmo objeto no mundo real (R, representado por dados de referência) que ele representa. A *precisão de localização* refere-se à posição no espaço de um objeto classificado (C) em relação a um objeto de referência (R) correspondente. *Precisão de forma* refere-se ao grau de semelhança entre os dois objetos (C e R) com base num certo número de critérios baseados na forma (incluindo a área, perímetro, etc.). Existe uma série de medidas baseadas em áreas que podem ser aplicadas para avaliar tanto a precisão temática, quanto a precisão geométrica (ou qualidade) de uma classificação baseada em objetos (Weidner, 2008; Zhan et al., 2005).

#### 3.2.1- Medidas de precisão de localização

Medidas de precisão baseados em localização avaliam a semelhança na localização entre um objeto classificado ou extraído (C) e seu objeto correspondente de referência (R), sendo que essa semelhança pode ser representada pela *distância* entre os objetos (C) e (R) e ainda ser considerada a medida de precisão do objeto. Assim, a distância a partir do centro do objeto classificado ( $X_{C_i}, Y_{C_i}$  - centroide C) até o centro do objeto de referência ( $X_{R_i}, Y_{R_i}$  - centroide R) é inversamente proporcional à precisão de localização (Whiteside et al., 2014). Ou seja, quanto menor for a distância entre os centroides (C e R), maior será a precisão da localização.

Congalton e Green (2009) apresentam o erro médio quadrático (RMSE) como uma medida de precisão horizontal de localização:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n ((X_{C_i} - X_{R_i})^2 + (Y_{C_i} - Y_{R_i})^2)}{n}} \quad (2)$$

onde n é o número de objetos amostrados.

#### 3.2.2- Medidas de precisão de forma

Existe uma série de métricas baseadas em áreas que podem ser aplicadas para determinar semelhança entre objetos classificados (C) e objetos de referência (R). Winter (2000) e Weidner (2008) apresentaram uma medida de *grau de similaridade* que utiliza as relações espaciais entre dois conjuntos de objetos C e R:

$$S_{II} = q = |C \cap R| / |C \cup R| \quad (3)$$

Em termos de precisão de forma do objeto, a área de sobreposição,  $|C \cap R|$ , é a área que está identificada corretamente,  $|C - R|$  é a área do erro de comissão, e  $|C - R|$  é a área do erro de omissão. Segundo Whiteside et al. (2014) em termos de sobreposição proporcional na área entre os dois objetos, a relação disjuntos tem um valor de 0, relação igual tem um valor de 1, e as relações de sobreposição, contém e contido por, situarem-se entre o intervalo 0 e 1. Na literatura, o

limiar de similaridade mais utilizado para definir semelhanças entre um objeto classificado (C) e o objeto de referência (R) é proporcional a uma sobreposição mínima de 0,5 ou 50% (Winter, 2000; Zhan et al., 2005). Utilizou-se, no escopo dessa pesquisa, o mesmo limiar de similaridade.

Para uma avaliação de precisão baseada em objeto multi-classe, a abordagem é mais complexa devido ao aumento do número de classes e de objetos em análise. Por exemplo, haverá interseção dos objetos ( $C_i \cap R_i$ ) para cada ( $i$ -ésima) classe  $k$ . Zhan et al. (2005) apresenta uma medida de similaridade para essa situação:

$$OQ_a = |C_i \cap R_i| / |C_i \cup R_i| \text{ para } i = 1..k. \quad (4)$$

### 3.2.3- Procedimentos

A partir da imagem temática classificada (C) e uma imagem de referência (R) correspondente, as classes ( $C_i$ ) e ( $R_i$ ) foram separadas em camadas individuais, utilizando uma operação reclassificação de atributos (*reclass*). Após, foi utilizado uma ferramenta para colocar identificadores (*group*) em agrupamentos contíguos de células semelhantes em uma imagem. Células pertencentes ao mesmo grupo contíguo foram atribuídas um único identificador, numeradas consecutivamente na ordem encontrada. E a partir de um processo de reclassificação (*reclass*), foi possível selecionar e separar polígonos  $j$  de cada classe  $i$  homólogos nas imagens ( $C_{ij}$ ) e ( $R_{ij}$ ). Neste caso, foram individualizados 7 polígonos ( $C_{11}, C_{12}, C_{13}, C_{21}, C_{22}, C_{31}, C_{32}$ ) e seus homólogos ( $R_{11}, R_{12}, R_{13}, R_{21}, R_{22}, R_{31}, R_{32}$ ).

Para cada polígono foram calculados os valores do centroide C ( $X_{C_i}, Y_{C_i}$ ), R ( $X_{R_i}, Y_{R_i}$ ) (*center*), como também o coeficiente de dispersão relativa (CV), e as suas respectivas áreas  $C_{ÁREA}$  e  $R_{ÁREA}$ .

E através de operações de sobreposição (*overlay*) multiplicativa e de sobreposição soma de camadas (seguido de uma reclassificação - *reclass*), foram gerados os valores (em  $m^2$ ) de interseção espacial entre os polígonos  $C_i \cap R_i$ , como também da união dos polígonos  $C_i \cup R_i$ , respectivamente. Utilizando a Equação (3) foi calculado para cada par de polígonos as medidas individuais de grau de similaridade ( $S_{ij} = q$ ). E de forma global foram também calculados os valores de erro médio quadrático (RMSE), e da medida global de similaridade  $OQ_a$ , utilizando as Equações (2) e (4), respectivamente.

Finalmente, utilizando ferramentas de análises, um conjugado de operações de reclassificação e sobreposição, foi possível espacializar as áreas totais com erros de comissão ( $(C \cap \neg R)$ ) e áreas totais com erros de omissão ( $(\neg C \cap R)$ ).

## 4- RESULTADOS E DISCUSSÃO

### 4.1. Matriz de Erro – por Pixel e por Objeto

A Tab. 1 apresenta as matrizes de erro para uma classificação por pixel e por objeto, utilizando o classificador MAXVER. Observa-se que no geral todos os índices apresentaram valores satisfatórios. Na classificação por pixel a exatidão global observada foi de 87,9%, índice Kappa e sua variância igual a 0,816 e 0,000036, respectivamente - com 95% de graus de confiança. O valor do teste Z Estatístico obtido foi de 135,239.

TABELA 1 – MATRIZES DE ERRO:

POR PIXEL										POR OBJETOS									
Classif	1	2	3	TOTAL	Imagem	OVERALL (%)	SD	Classif	1	2	3	TOTAL	Imagem	OVERALL (%)	SD				
1	100	0	0	100	100	100	0,000000	1	1	0	0	1	100	100	0,000000				
2	0	100	0	100	100	100	0,000000	2	1	4	0	5	57,1	100	0,000000				
3	0	0	100	100	100	100	0,000000	3	0	0	11	11	100	100	0,000000				
TOTAL	100	100	100	300	300	87,9	0,000036	TOTAL	2	4	11	17	83,3	100	0,012340				
Imagem	100	0	0	100	100	100	0,000000	Imagem	1	4	0	5	57,1	100	0,000000				
OVERALL (%)	100	100	100	300	300	87,9	0,000036	OVERALL (%)	100	100	100	300	300	83,3	0,012340				

Para a classificação por objeto, a exatidão global obtida foi de 83,3%, índice Kappa de 0,742 e sua variância igual 0,012340. O valor do teste Z Estatístico obtido foi de 6,679, enquanto o valor tabelado de Z foi de 1,96. Assim, dada a hipótese nula  $H_0$ : Kappa = 0, e a hipótese alternativa  $H_1$ : Kappa  $\neq$  0,  $H_0$  foi rejeitada. Como os valores do teste Z Estatístico foram maiores, em ambos os casos, do que os seus valores tabelado, os resultados são considerados significativos, e neste caso as classificações são significativamente melhores do que uma classificação aleatória. Infelizmente esses índices estatísticos não consideram a distribuição espacial dos pixels erroneamente classificados na imagem temática, implícita ou explicitamente.

### 4.2. Validação Temática Baseada em Pixel

Ao examinar a distribuição espacial dos pixels na *imagem distância* da Fig. 2a, e a *imagem binária* da Fig. 2b, observa-se que, por exemplo, os pixels que são classificados incorretamente, estão espacialmente correlacionados. Estes efeitos de correlação ocorrem, provavelmente, devido à presença de pixels de mistura nos limites entre talhões de classes diferentes, ou devido as variações no espectro de refletância causadas, mais provavelmente por variações no tipo de solo dentro de um talhão, ou devido aos efeitos das práticas de manejo. Um refinamento possível para a imagem temática seria aplicar um filtro da moda, sob o pressuposto de que os pixels de uma classe normalmente estão rodeados por pixels da mesma classe e não estão espacialmente correlacionados (Vieira e Mather, 2001).

A Fig. 3a apresenta uma alternativa para a avaliação do padrão de erros temáticos de uma imagem através de uma *validação cruzada*. Esse procedimento avalia relações entre as classes informacionais presentes na imagem de referência em relação à imagem classificada. Na Fig. 3a, por exemplo, os pixels com cor vermelho, significa que na imagem de referência pertenciam a classe 1 (Batata) e foram realmente classificados como classe 1 (Batata). Já os pixels com cor em amarelo claro, indicam os pixels que na imagem de referência pertenciam a classe 2 (Beterraba) e foram classificados como classe 1 (Batata), e assim sucessivamente. A tonalidade verde escuro (1|2), indica que dois talhões que eram de batata, foram totalmente classificados como beterraba.

Na Fig. 3b foi apresentado um tipo de representação alternativa, *mapa de confiabilidade temática*, que permite a apreciação visual do grau de precisão de cada pixel da imagem classificada. Esse tipo de representação ajuda o usuário a identificar partes do mapa temático com reduzida confiabilidade. Por exemplo, na Fig. 3b pode-se observar que a maioria absoluta dos pixels da classe trigo, foram classificados com precisões acima de 60%, diferente da classe batata, onde a grande maioria dos pixels foram classificados com precisões inferiores a 60%, possivelmente devido as

similaridades na resposta espectral, para essas bandas, dessa classe com a classe beterraba.

#### 4.3. Validação Temática Baseada em Objeto

Na Tab. 2 são apresentados os valores (em  $m^2$ ) de interseção espacial entre os polígonos  $C_i$  e  $R_i$ , como também da união dos polígonos  $C_i \cup R_i$ , respectivamente. Com a utilização da Equação 3 foram calculados para cada par de polígonos as medidas individuais de grau de similaridade ( $q = S_{ij}$ ). Também são apresentados na Tab. 2 os valores de erro médio quadrático (RMSE), e da medida global de similaridade  $OQ_a$ , utilizando as Equações (2) e (4), respectivamente.

TABELA 2 – ANÁLISE BASEADA EM OBJETOS

C	$X_{C_i}$ (m)	$Y_{C_i}$ (m)	CV (%)	$C_{i_{max}}$ ( $m^2$ )	R	$X_{R_i}$ (m)	$Y_{R_i}$ (m)	CV (%)	$R_{i_{max}}$ ( $m^2$ )	C ∩ R ( $m^2$ )	C ∪ R ( $m^2$ )	$q = S_{ij}$
$C_{11}$	559665,98	289992,56	11,24	82400	$R_{11}$	559658,18	289991,08	5,75	69600	65800	85200	0,79
$C_{12}$	560506,8	289223,97	14,98	150000	$R_{12}$	560524,02	289225,26	12,77	138800	122000	156800	0,84
$C_{13}$	559643,97	288894,55	18,95	231200	$R_{13}$	559641,58	288891,34	18,05	220400	219200	232400	0,94
$C_{14}$	559751,17	289256,9	24,29	130000	$R_{14}$	559731,31	289296,97	23,05	313200	289600	353600	0,82
$C_{15}$	560607,28	288700,4	34,44	636000	$R_{15}$	560630,46	288690,05	33,82	576000	565600	646400	0,88
$C_{16}$	560313,74	288885,6	41,96	985200	$R_{16}$	560324,95	28879,48	40	906000	897200	994000	0,90
$C_{17}$	560937,5	289000,39	16,52	204000	$R_{17}$	560942,27	289002,14	15,26	171600	170800	204800	0,83
									$\Sigma$	2341200	2673200	
									RMSE	21,66 m	OQ <sub>a</sub>	0,88

Inicialmente observa-se que o RMSE obtido indica uma precisão posicional das regiões (ou objetos) com um erro posicional de 21,66m, apresentando assim uma medida de precisão horizontal de localização próximo a 01 (um) pixel.

Observa-se ainda que a medida global de similaridade  $OQ_a$ , apresenta um valor de 0,88 que é maior do que 0,5 (50%) que foi estabelecido como o limite mínimo para mostrar semelhança entre objetos (C e R) sobrepostos. Nota-se ainda que nas comparações de objetos, individualmente, foram obtidos valores de grau de similaridade ( $S_{ij} = q$ ) maiores do que 0,5, indicando que houve uma grande semelhança entre os objetos (C e R) comparados.

Com exceção do objeto classificado  $C_{11}$  e do seu objeto homólogo de referência  $R_{11}$ , os experimentos apresentaram uma consistência de proporcionalidade nos valores de coeficiente de dispersão relativa (CV), o qual poderia ser utilizado também como uma medida de precisão de forma dos objetos.

Finalmente, na Fig. 4 foram espacializadas áreas com erros de comissão ( $|C - R|$ ) e áreas com erros de omissão ( $|R - C|$ ). Observa-se que tanto as áreas de comissão como as de omissão concentraram-se nos limites entre os objetos (talhões das culturas agrícolas).




Fig. 4 – Áreas totais para os sete pares de objetos C e R com erros de: comissão (a) e omissão (b)

## 5- CONCLUSÕES

Este artigo apresentou técnicas espaciais para avaliar a precisão temática das classificações, seguindo uma abordagem por pixel e por objeto. Estas técnicas levam em conta o padrão espacial de erros de omissão e comissão, e apresentam ao usuário uma indicação da confiabilidade das atribuições do rótulo dos pixels como também dos objetos. Uma quantidade considerável de

pesquisas e desenvolvimentos metodológicos precisam ser realizadas antes da correta caracterização espacial dos erros oriundos do processo de classificação associados aos produtos do sensoriamento remoto, como também possam ser devidamente comunicados em formato e legendas padronizadas. Por outro lado, uma análise da incidência espacial do erro de classificação indica um padrão característico espacialmente correlacionado. Esses erros são normalmente agrupados, com uma alta proporção de pixels ou objetos erroneamente rotulados ocorrendo nas proximidades dos limites entre feições espaciais. Uma sugestão para trabalhos futuros seria o desenvolvimento de estudos aprofundados de correlação espacial, através do uso, por exemplo, de Índice de Moran ou *Join Count Statistics* - a fim de determinar se esses efeitos de correlação são aleatórios ou agrupados na sua distribuição espacial. Poderia também ser utilizada uma máscara e adição dessas feições, que não fizeram parte do processo de classificação, com o objetivo de minimizar esse problema de correlação espacial. Olhando para a distribuição espacial dos erros remanescentes poderia ajudar a refinar o processo de classificação.

## AGRADECIMENTOS

Agradeço as empresas *Logica PLC* e *Spot Image* pela permissão de uso de suas imagens.

## REFERÊNCIAS BIBLIOGRÁFICAS

- Arbia, G.; Griffith, D. e R. Haining, 1998. Error propagation modelling in raster GIS: overlay operations. *International Journal of Geographical Information Science*, Vol. 12, pp. 145-167.
- Arsanjani, J. J. e E.Vaz, 2015. An assessment of a collaborative mapping approach for exploring land use patterns for several European metropolises. *International Journal of Applied Earth Observation and Geoinformation*, Vol. 35, pp. 329-337.
- Congalton, R. G. e K. Green, 2009. *Assessing the Accuracy of Remotely Sensed Data: Principles and Practices*, 2<sup>nd</sup> Ed. CRC Press, Boca Raton, FL.
- Lunetta, R. S., Congalton, R. G., Fenstermaker, L. K.; Jessen, J. H. e K. C. McGwire, 1991. Remote sensing and geographic information system data integration: error sources and research issues. *Photogrammetric Engineering and Remote Sensing*, Vol. 57, N° 6, pp. 677-687.
- Schöpfer, E., Lang, S. e F. Albrecht, 2008. Object-fate analysis: spatial relationships for the assessment of object transition and correspondence. In: *Object-Based Image Analysis: Spatial Concepts for Knowledge-Driven Remote Sensing Applications*. (Eds.) Blaschke, T., Lang, S., Hay, G.J., Springer, Berlin, pp. 785-801.
- Vieira, C. A. O. e P. M. Mather, 2001. On the Assessment of Spatial Reliability of Thematic Images. *Innovation in GIS: Spatial Information and the Environment*, (Ed) London: Taylor and Francis, Vol. 8, pp. 120-135.
- Weidner, U., 2008. Contribution to the assessment of segmentation quality for remote sensing applications. In: *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Vol. XXXVII-B7, pp. 479-484.
- Whiteside, T. G., Maier, S. W. e G. S. Boggs, 2014. Area-based and location-based validation of classified image objects. *International Journal of Applied Earth Observation and Geoinformation*, Vol. 28, pp. 117-130.
- Winter, S., 2000. Location similarity of regions. *ISPRS Journal of Photogrammetry and Remote Sensing*, Vol. 55, pp.189-200.
- Zhan, Q., Molenaar, M., Tempfli, K. e W. Shi, 2005. Quality assessment for geo-spatial objects derived from remotely sensed data. *International Journal of Remote Sensing*, Vol. 26, pp. 2953-2974.