

# AVALIAÇÃO DAS INCERTEZAS NAS CLASSIFICAÇÕES DE MÁXIMA VEROSSIMILHANÇA E CONTEXTUAL DE MODAS CONDICIONAIS ITERATIVAS

CAMILO DALELES RENNÓ  
SIDNEI JOÃO SIQUEIRA SANT'ANNA  
CORINA DA COSTA FREITAS  
INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS (INPE)  
12227-010  
AV. DOS ASTRONAUTAS, 1758 – SÃO JOSÉ DOS CAMPOS-SP  
E-MAIL: [camilo,sidnei,corina,]@dpi.inpe.br

## RESUMO

Neste trabalho é apresentado uma metodologia para a elaboração de mapas de incertezas espacialmente distribuídas, associados a classificações digitais de imagens. A elaboração de mapas de incertezas é de extrema importância por indicar espacialmente as áreas em que o classificador pode estar errando. Com isso, as decisões tomadas sobre esta classificação podem ser ponderadas por estas incertezas. A metodologia é desenvolvida para dois tipos de classificadores: um classificador pontual por máxima verossimilhança (MaxVer) e um pontual/contextual por modas condicionais iterativas (ICM). A metodologia é exemplificada gerando-se classificações de uma imagem do sensor JERS-1 e, simultaneamente, os respectivos mapas de incertezas. Os mapas de incertezas refletem as dúvidas, durante o processo de classificação, da atribuição de um *pixel* a uma determinada classe, diferindo do erro do classificador, o qual está relacionado à comparação do mapa com uma dada referência. Uma medida global do erro do classificador também é fornecida, através da estimativa do coeficiente de concordância *Kappa*, obtido através de matrizes de confusão. Os resultados indicam que as incertezas relativas ao classificador ICM são menores que as do MaxVer. É observado que com o aumento do número de iterações do ICM as maiores incertezas ocorrem nas áreas de contato (bordas) entre classes. Para as três classes de interesse definidas neste trabalho (floresta primária, regeneração e atividades recentes), as menores incertezas estão associadas à classe floresta primária.

## ABSTRACT

This article presents a methodology for building uncertainty maps, associated to digital image classifications. These maps are extremely important to indicate areas, spatially distributed, where classification errors may occur. Then, decisions about the classifications may be weighted by these uncertainties. The methodology is developed for two types of classifiers: a punctual maximum likelihood classifier (MaxVer) and a punctual/contextual iterated conditional modes classifier (ICM). The methodology is exemplified by classifying a JERS-1 image, with the aforementioned classifiers, and obtaining the correspondent uncertainty maps. These uncertainty maps reflect the doubts occurred during the classification process of attributing a *pixel* to a class, differing from the error of a classifier, which is related to the comparison of a map with a given reference. A global measure of the classifier's error is also given, through the use of the estimated *Kappa* coefficient of agreement, obtained from the confusion matrices. The results indicate that the uncertainties related to the ICM classifier are smaller than those related to the MaxVer classifier. It was observed that the largest uncertainties occurred on the classes boundaries, when the ICM iteration number was increased. For the three classes defined in this paper (primary forest, regeneration, and recent activities), the smaller uncertainties are associated to the primary forest class.

## 1 INTRODUÇÃO

Em sensoriamento remoto, uma das técnicas de processamento de imagens mais importantes e utilizadas é a classificação digital. No processo de classificação, parte-se de uma imagem de entrada e gera-se uma imagem rotulada, onde cada *pixel* recebe um rótulo que identifica a classe a qual ele foi atribuído, segundo uma regra de decisão. Os métodos de classificação podem ser divididos em dois grupos: supervisionados ou não supervisionados. No primeiro, supondo-se o número de classes presente na imagem conhecido, define-se um conjunto de amostras como pertencentes a cada uma das classes (amostras de treinamento), extrai-se algum tipo de informação destas amostras para cada classe (etapa de aprendizado ou treinamento), a partir da qual constroem-se critérios que permitirão agrupar os *pixels* ou regiões com características similares (classificação propriamente dita). No segundo, é desconhecido o número de classes existente na imagem, e assim procura-se verificar a existência de grupos naturais de *pixels* ou regiões, de modo que elementos de um mesmo conjunto (classe) tenham características semelhantes, ao mesmo tempo que elementos de conjuntos diferentes possuam as características mais distintas possíveis. Ao leitor interessado em mais detalhes sobre classificação digital, recomenda-se Schowengerdt (1983), Jain (1989), Mascarenhas e Velasco (1989), e Richards (1993).

O produto gerado pela classificação, geralmente denominado mapa temático, por ser uma fonte de informação, é utilizado na tomada de decisão. Dessa forma, a avaliação das incertezas deste produto é muito importante pois permite ao tomador de decisão analisar o grau de confiabilidade desta informação. Existem diferentes fontes de incerteza no processo de classificação, tais como, as suposições implícitas no classificador (incluindo a modelagem adotada para os dados) e, para classificadores supervisionados, a definição do número de classes de interesse, a amostragem para caracterização destas classes (que definirá a representatividade de cada classe), etc.

A incerteza está relacionada às dúvidas, durante o processo de classificação, no momento da atribuição do *pixel* a uma determinada classe, enquanto que o erro está diretamente ligado à comparação do mapa com uma referência (que pode ser a verdade de campo, as amostras de teste ou um outro mapa).

Comumente, a avaliação de um mapa é feita usando-se a matriz de confusão elaborada a partir de amostras (amostras de teste, considerando-se uma referência) cujas classes são conhecidas. A matriz de confusão permite avaliar os erros de omissão e comissão e, em geral, apenas um índice é calculado para representar os erros (ou confusões) de classificação para todo o mapa e, por esta razão, são denominados índices globais. Entre os índices globais mais utilizados, destacam-se a exatidão total e os coeficientes de concordância *Kappa* e *Tau*. Detalhes sobre índices de concordância podem ser encontrados em Brites et al. (1996), Næsset (1996) e Nishii e Tanaka (1999).

As incertezas oriundas da classificação são quase sempre desconhecidas no processo de avaliação de um mapa. Idealmente, a avaliação do mapa seria melhor se estas incertezas fossem espacialmente distribuídas por todo o mapa, e não apenas dadas por um valor único representativo do mapa. Um experimento Monte Carlo, a princípio, poderia ser utilizado para se obter estimativas de incertezas espacialmente distribuídas. Este experimento consistiria da replicação do processo de classificação de uma imagem, por exemplo, para um classificador supervisionado, variando-se as amostras de treinamento. No entanto, o experimento Monte Carlo é, em geral, muito oneroso computacionalmente e a determinação de todas as variáveis envolvidas neste experimento não é uma tarefa muito simples.

Este trabalho propõe uma metodologia para a estimação das incertezas espacialmente distribuídas provenientes da classificação digital de imagens, utilizando-se classificadores supervisionados que possuem regra de decisão probabilística. Para ilustrar a aplicação desta metodologia, utilizou-se um classificador pontual por máxima verossimilhança (MaxVer) e um pontual/contextual por modas condicionais iterativas (ICM - *Iterated Conditional Modes*). Os mapas de incertezas foram gerados simultaneamente à obtenção das classificações, a partir de uma imagem do sensor JERS-1.

## 2 CLASSIFICAÇÃO E MAPA DE INCERTEZAS

O classificador estatístico mais conhecido e comumente utilizado em sensoriamento remoto é o de Máxima Verossimilhança (MaxVer), que é pontual, supervisionado e possui baixo custo computacional. O processo de classificação por máxima verossimilhança consiste em atribuir o *pixel* à classe que maximize a probabilidade *a posteriori*. Esta probabilidade representa a probabilidade de ocorrência de uma classe  $\omega$  (com  $\omega \in \Omega$ , onde  $\Omega$  é o conjunto das classes definidas na classificação) dado que o valor  $\mathbf{x}_s$  (vetor de atributos) foi observado na coordenada  $s$  da imagem. Com base na teoria Bayesiana, a probabilidade *a posteriori* pode ser calculada por

$$P(\omega / \mathbf{x}_s) = \frac{P(\mathbf{x}_s / \omega) \cdot P(\omega)}{P(\mathbf{x}_s)},$$

onde  $P(\mathbf{x}_s / \omega)$  representa a probabilidade de ocorrência do valor  $\mathbf{x}_s$  conhecida a classe  $\omega$  e pode ser modelada por uma função densidade de probabilidade  $f_\omega$ ,  $P(\omega)$  é a probabilidade de ocorrência da classe  $\omega$ , e  $P(\mathbf{x}_s)$  é a probabilidade de ocorrência do valor  $\mathbf{x}_s$ .

Como  $P(\mathbf{x}_s)$  é constante para todas as classes,  $P(\omega / \mathbf{x}_s)$  é proporcional a seguinte função:

$$L(\omega) = P(\mathbf{x}_s / \omega) \cdot P(\omega),$$

ou seja,  $P(\omega / \mathbf{x}_s) = cL(\omega)$ , onde  $c$  é uma constante, e maximizar  $P(\omega / \mathbf{x}_s)$  é equivalente a maximizar  $L(\omega)$ .

Note que esta classificação leva também em consideração que cada classe pode ocorrer com uma probabilidade *a priori* diferente. Mas, surpreendentemente, este conhecimento prévio é quase sempre negligenciado no processo de classificação, supondo-se que todas as classes têm igual chance de ocorrência (Eastman, 1998). Assim, considerando-se que  $P(\omega)$  é a mesma para todas as classes,  $P(\omega / \mathbf{x}_s)$  torna-se proporcional a  $P(\mathbf{x}_s / \omega)$ , e maximizar  $L(\omega)$  equivale a maximizar  $f_\omega(\mathbf{x}_s)$ .

Dessa forma, a classificação MaxVer é realizada com base apenas no valor observado de cada *pixel*  $\mathbf{x}_s$  e no modelo  $f_\omega$  escolhido para cada classe. Este critério não considera a informação contextual, uma vez que supõe a independência entre os valores dos *pixels*. Algumas propostas para a incorporação da informação contextual podem ser encontradas na literatura, como por exemplo Besag (1989). No entanto, grande parte destas propostas são baseadas em algoritmos computacionalmente muito dispendiosos e difíceis de serem utilizados. Em Frery (1993), encontra-se uma versão de um algoritmo de classificação contextual que apresenta boas características de desempenho e de facilidade de uso. Este classificador, denominado ICM, foi revisado e melhorado por Vieira (1996). O ICM baseia-se na substituição da classe associada a cada *pixel* da imagem por aquela que maximiza a distribuição *a posteriori* da classe, conhecido o valor do

*pixel* (componente MaxVer) e as classes presentes numa certa vizinhança (componente contextual). A influência das classes dos *pixels* vizinhos é quantificada por um parâmetro real ( $\beta$ ), que é estimado iterativamente supondo o modelo baseado em campos Markovianos. Neste caso, desconsiderando os elementos constantes para todas as classes, tem-se que a função a ser maximizada é dada por

$$L(\omega) = f_{\omega}(\mathbf{x}_s) \exp(\beta \# \{t \in \partial_s : \omega_t = \omega\}),$$

onde # representa o número de elementos de um conjunto,  $t$  denota a coordenada de um *pixel* e  $\partial_s$  é o conjunto de coordenadas em torno do *pixel* a ser classificado. Segundo Frery (1993), esta função é proporcional a  $P(\omega / \mathbf{x}_s)$  e, assim como para o classificador MaxVer, maximizar  $L(\omega)$  é equivalente a maximizar  $P(\omega / \mathbf{x}_s)$ .

Como o processo de classificação baseia-se na escolha da classe que maximiza  $L(\omega)$ , pode haver uma possibilidade do classificador estar errando nesta escolha, uma vez que há uma probabilidade, mesmo que pequena, daquele *pixel* pertencer às outras classes. Denotando  $\omega_{sel}$  como a classe selecionada entre as  $n$  classes definidas na classificação, ou seja,  $\omega_{sel}$  possui o maior valor de  $L(\omega)$ , pode-se verificar que a razão entre  $L(\omega_{sel})$  e a soma dos  $L(\omega)$  de todas as classes consideradas representa a certeza com que o classificador selecionou aquela classe. Para os classificadores MaxVer e ICM, como a probabilidade *a posteriori* é proporcional a  $L(\omega)$ , pode-se provar que

$$\frac{L(\omega_{sel})}{\sum_{\omega \in \Omega} L(\omega)} = \frac{kP(\omega_{sel} / \mathbf{x})}{\sum_{\omega \in \Omega} kP(\omega / \mathbf{x})} = \frac{P(\omega_{sel} / \mathbf{x}_s)}{\sum_{\omega \in \Omega} P(\omega / \mathbf{x}_s)},$$

onde  $k$  representa uma constante de proporcionalidade. Considerando que todas as  $n$  classes são suficientes para representar toda a variação dos valores  $\mathbf{x}_s$ , tem-se que a soma das probabilidades *a posteriori* para todas as classes é igual a um e portanto

$$\frac{L(\omega_{sel})}{\sum_{\omega \in \Omega} L(\omega)} = P(\omega_{sel} / \mathbf{x}_s).$$

Assim, a incerteza na classificação pode ser dada por:

$$Incerteza = 1 - P(\omega_{sel} / \mathbf{x}_s) = 1 - \frac{L(\omega_{sel})}{\sum_{\omega \in \Omega} L(\omega)}.$$

É importante observar que esta incerteza está mais relacionada ao algoritmo de classificação, às classes de estudo e às amostras de treinamento escolhidas do que a verdade propriamente dita. Ou seja, um valor baixo de incerteza indica que há evidências de que a classificação tenha sido bem conduzida e não que aquela classificação obrigatoriamente corresponda à verdade. Por outro lado, altos valores de incerteza indicam que há grandes probabilidades de confusão entre classes e que o resultado da classificação pode estar errado, ou, em outras palavras, que há uma grande chance do *pixel* pertencer a qualquer uma das outras classes que não a selecionada na classificação.

### 3 METODOLOGIA

A área de estudo localiza-se no município de Santarém, Estado do Pará, a cerca de 80 km do núcleo urbano e engloba parte da Floresta Nacional de Tapajós. Situa-se entre os paralelos 3° 04' 42" e 3° 18' 24" de latitude sul e os meridianos 54° 52' 27" e 54° 59' 15" de longitude oeste. A Figura 1a apresenta uma imagem do sensor TM/Landsat da área de estudo datada de 29 de maio de 1993, na composição colorida das bandas 5, 4 e 3 (nos canais vermelho, verde e azul, respectivamente) e resolução espacial de 30 m. Esta imagem foi utilizada apenas como referência durante a definição das classes de estudo e a aquisição das amostras de treinamento.

A imagem utilizada neste trabalho para a avaliação das incertezas nas classificações MaxVer e ICM é proveniente do sensor JERS-1 de 26 de junho de 1993, na banda L, polarização HH, número de *looks* nominal igual a 3 e espaçamento entre *pixel* de 12,5x12,5 m, mostrada na Figura 1b.

A Figura 2 apresenta, de maneira resumida, o fluxograma de execução deste trabalho. Inicialmente, a imagem do JERS-1 foi registrada (usando-se a amostragem pelo vizinho mais próximo) à imagem do TM/Landsat previamente georreferenciada, alterando desta forma, as propriedades estatísticas dos dados originais. Foram definidas 3 classes de uso do solo: floresta primária, regeneração (incluindo pastagem) e atividades recentes (compreendendo basicamente solo exposto e algumas culturas agrícolas). Sobre a imagem do JERS-1, com base na imagem do TM/Landsat, selecionou-se algumas amostras (amostras de treinamento) de cada classe em estudo. Estas amostras, apresentadas na Figura 1b, continham 12098, 1823 e 2294 *pixels* para as classes de floresta primária, regeneração e atividades recentes, respectivamente.

Partindo-se das amostras de treinamento, selecionou-se as distribuições que melhor se ajustaram a cada classe, usando-se o sistema desenvolvido no INPE (Frery et al., 1997). Estimados os parâmetros de cada distribuição, procedeu-se à classificação MaxVer da imagem do JERS-1, obtendo-se também o mapa de incertezas associado a esta classificação.

A classificação ICM da imagem do JERS-1 foi realizada em cinco iterações. Para cada iteração, o mapa resultante da classificação e o mapa de incertezas foram obtidos. Para efeito de simplificação da análise dos resultados, apenas a primeira e a última iterações foram consideradas.

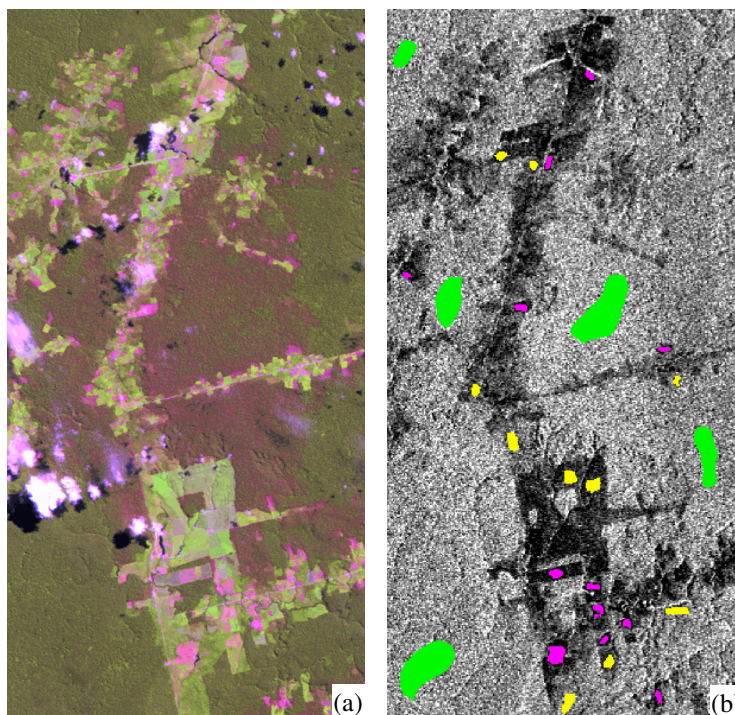


Figura 1. Imagens dos sensores: (a) TM/Landsat na composição colorida das bandas 5, 4 e 3 (nos canais vermelho, verde e azul, respectivamente) e (b) JERS-1, mostrando as amostras de treinamento de cada classe de uso do solo: floresta primária (verde), regeneração (amarelo) e atividades recentes (magenta).

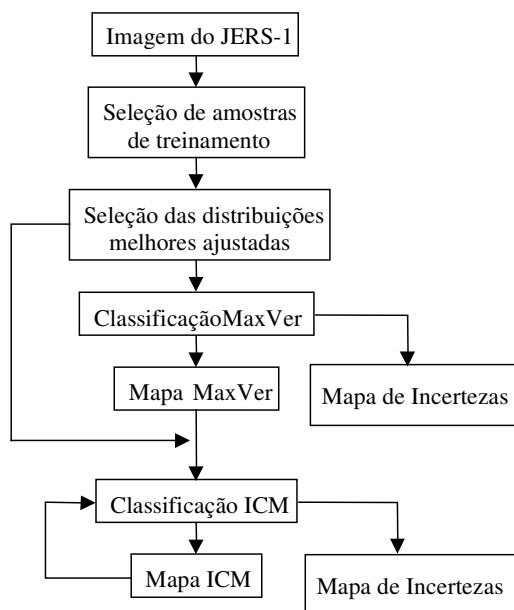


Figura 2. Fluxograma de execução do trabalho.

Foi também coletado um segundo conjunto de amostras de cada classe (amostras de teste) para obtenção da matriz de confusão e cálculo do coeficiente de concordância  $Kappa$  estimado. Estas amostras possuíam, respectivamente, 5186, 1009 e 1880 *pixels* para as classes floresta primária, atividades recentes e regeneração.

#### 4 RESULTADOS E DISCUSSÃO

A Tabela 1 apresenta a distribuição (função densidade de probabilidade) selecionada para cada classe de interesse, bem como a estimativa dos parâmetros que caracterizam estas distribuições, as quais são mostradas na

Figura 3. No que para a classe regeneração existem grandes áreas sob a curva da distribuição que possuem interseção com as das outras duas classes, indicando uma provável confusão entre a classe regeneração e as demais.

Tabela 1. Distribuições que melhor se ajustaram às classes de interesse e as respectivas estimativas dos parâmetros.

Classe	Distribuição	Parâmetros*
Floresta	Lognormal	$\mu = 4,67$ e $\sigma = 0,15$
Atividades Recentes	GA0	$\alpha = -15,22$ ; $\gamma = 47543,18$ e $n = 13,20$
Regeneração	Lognormal	$\mu = 4,39$ e $\sigma = 0,18$

\* As parametrizações destas distribuições podem ser encontradas em Vieira (1996).

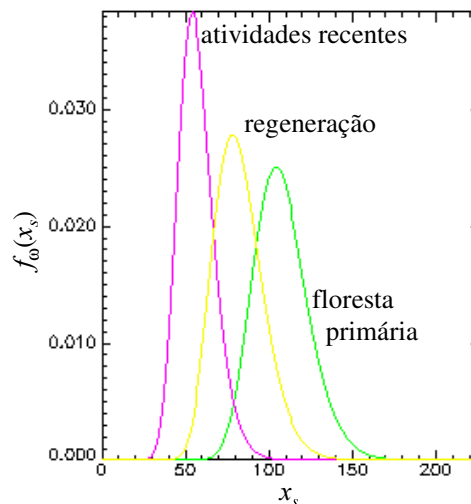


Figura 3. Distribuições que melhor se ajustaram às classes de interesse.

As Figuras 4a e d mostram respectivamente o resultado da classificação MaxVer e o mapa de incerteza desta classificação. É possível observar que as áreas com maiores incertezas estão associadas às áreas antropizadas (classes regeneração e atividades recentes). As incertezas médias dos *pixels* classificados como floresta primária, atividades recentes e regeneração foram 0,21, 0,25 e 0,36, respectivamente. Através da matriz de confusão (Tabela 2), pode-se notar que várias áreas de regeneração foram erroneamente classificadas como floresta primária, sendo o recíproco também verdadeiro, mostrando uma maior confusão na classificação dessas duas classes. A classificação apresentou o valor estimado de *Kappa* igual a 0,49 que representa um grau regular de acerto, segundo Landis e Koch (1977). É importante ressaltar que para o cálculo das incertezas médias são considerados todos os *pixels* classificados em cada classe (todo o mapa), enquanto que para a estimação de *Kappa* são considerados apenas os *pixels* de amostras, as quais não incluem *pixels* de regiões de fronteiras (limites entre classes). Desta forma, estas medidas não são obtidas sobre as mesmas áreas e portanto deve-se ter o cuidado ao relacioná-las.

Tabela 2. Matriz de confusão, em *pixels*, da classificação MaxVer da imagem do JERS-1 e o respectivo *Kappa* estimado. Os números mostrados entre parênteses referem-se a percentagem relativa à verdade terrestre.

		Verdade Terrestre		
		Floresta	Ativ. Rec.	Regeneração
Classificação	Floresta	4205 (81,1)	9 (0,9)	604 (32,1)
	Ativ. Rec.	17 (0,3)	702 (69,6)	295 (15,7)
	Regeneração	964 (18,6)	298 (29,5)	981 (52,2)

*Kappa* = 0,49




Figura 4. Imagens classificadas: (a) pelo MaxVer, (b) da 1ª iteração do ICM e (c) da 5ª iteração do ICM, onde as classes floresta primária, atividades recentes e regeneração são mostradas respectivamente nas cores verde, magenta e amarelo; e os respectivos mapas de incertezas associados: (d) ao MaxVer, (e) à 1ª iteração do ICM e (f) à 5ª iteração do ICM, onde as cores estão associadas a graduação das incertezas.

O resultado da 1ª iteração da classificação ICM é mostrado na Figura 4b, juntamente com o mapa de incertezas associado (Figura 4e). Nesta 1ª iteração cerca de 10% dos *pixels* foram reclassificados, com relação ao resultado da classificação MaxVer. Observe que já na 1ª iteração, com a incorporação da informação contextual, a incerteza diminui em praticamente toda a área, principalmente nas áreas de floresta primária. As incertezas médias foram 0,05, 0,10 e 0,13 para as áreas de floresta primária, atividades recentes e regeneração, respectivamente. A matriz de confusão (Tabela 3) mostra um aumento do acerto na classificação ( $Kappa = 0,60$ ); no entanto, grandes confusões entre as classes podem ainda ser observadas.

Na 5ª iteração da classificação ICM (Figura 4c), quando praticamente nenhum *pixel* foi reclassificado (pouco mais de 0,1% dos *pixels* foram reclassificados comparando-se com a 4ª iteração do ICM), a incerteza maior restringe-se basicamente às bordas (ou áreas de contato) das manchas de cada classe, sendo as incertezas médias dos *pixels* classificados como floresta primária, atividades recentes e regeneração 0,01, 0,04, e 0,04, respectivamente (Figura 4f). Apesar desta aparente baixa incerteza, as confusões entre classes continuam a existir, como pode ser visto na matriz de confusão mostrada na Tabela 4. Nesta classificação, há apenas um pequeno aumento do acerto ( $Kappa = 0,67$ ). Observe que especificamente para a classe atividades recentes praticamente não houve melhora da classificação MaxVer para as classificações ICM. Os maiores ganhos são observados pela diminuição da confusão entre as classes floresta primária e regeneração.

Tabela 3. Matriz de confusão, em *pixels*, da classificação da 1ª iteração do ICM da imagem do JERS-1 e o respectivo *Kappa* estimado. Os números mostrados entre parênteses referem-se a percentagem relativa à verdade terrestre.

		Verdade Terrestre		
		Floresta	Ativ. Rec.	Regeneração
Classificação	Floresta	4620 (89,1)	2 (0,2)	547 (29,1)
	Ativ. Rec.	0 (0,0)	723 (71,7)	271 (14,4)
	Regeneração	566 (10,9)	284 (28,1)	1062 (56,5)

*Kappa* = 0,60

Tabela 4. Matriz de confusão, em *pixels*, da classificação da 5ª iteração do ICM da imagem do JERS-1 e o respectivo *Kappa* estimado. Os números mostrados entre parênteses referem-se a percentagem relativa à verdade terrestre.

		Verdade Terrestre		
		Floresta	Ativ. Rec.	Regeneração
Classificação	Floresta	4816 (92,9)	4 (0,4)	461 (24,5)
	Ativ. Rec.	0 (0,0)	723 (71,6)	264 (14,0)
	Regeneração	370 (7,1)	282 (28,0)	1155 (61,5)

*Kappa* = 0,67

As incertezas médias calculadas para a classe atividades recentes são menores para o classificador ICM que para o MaxVer, sem, no entanto, indicar uma diminuição, na mesma proporção, dos erros de classificação mostrados nas matrizes de confusão. Note que, para esta classe, as confusões são praticamente as mesmas para as três classificações. Portanto, a diminuição das incertezas não necessariamente implica no aumento da exatidão de classificação de uma determinada classe.

## 5 CONCLUSÕES

A elaboração de mapas de incertezas associados à classificação é de extrema importância por indicar espacialmente as áreas em que o classificador pode estar errando. Com isso, as decisões tomadas sobre esta classificação podem ser ponderadas por estas incertezas.

Este trabalho propôs uma metodologia para a elaboração de mapas de incertezas que refletem a probabilidade de se estar atribuindo erroneamente um *pixel* a uma classe, conhecendo-se previamente o valor do *pixel* e, no caso do classificador ICM, também os valores dos *pixels* vizinhos e das classes a eles associadas.

De modo geral, a classificação ICM apresenta melhores resultados quando comparados à classificação MaxVer, com base na estimativa do coeficiente de concordância *Kappa*. As incertezas do classificador ICM são menores do que as do MaxVer, e elas diminuem a cada iteração. Aparentemente, a diminuição das incertezas do ICM a cada iteração não correspondente necessariamente a um aumento no valor do *Kappa* estimado na mesma proporção. O valor das incertezas decresce mais rapidamente que o aumento do valor do *Kappa* estimado, mostrando que a cada iteração a incerteza do classificador ICM diminui, mas isto não necessariamente significa que o mapa reflete melhor a verdade terrestre. Ou seja, os mapas refletem basicamente as incertezas estatísticas da atribuição de um *pixel* a uma classe, podendo não refletir a verdade terrestre. Numa classificação contextual, como o ICM, as maiores incertezas são encontradas principalmente nas áreas de contato entre duas classes.

É importante ressaltar que os mapas de incertezas deveriam também incluir os erros de classificação, incorporando informações da matriz de confusão, ou seja, deveriam refletir a incerteza devido ao método de classificação utilizado e também os erros de classificação.

## AGRADECIMENTOS

Os autores gostariam de agradecer o apoio recebido do CNPq (Proc. 300927/92-4) e do PPG-7 (0808/95 e 0816/95), Convênio FINEP (6.6.96.0473.00 e 6.6.96.0474.00). Os autores agradecem também ao Instituto Nacional de Pesquisas Espaciais pela oportunidade da realização deste trabalho.

## REFERÊNCIAS BIBLIOGRÁFICAS

- Besag, J. Towards bayesian image analysis. **Journal of Applied Statistics**, 16(3):395-407, 1989.
- Brites, R.S.; Soares, V.P.; Ribeiro, C.A.A.S. Comparação de desempenho entre três índices de exatidão aplicados a classificação de imagens orbitais. In: Simpósio Brasileiro de Sensoriamento Remoto, 8, Salvador, BA, 14-19 abril 1996. **CDROM**.
- Eastman, J.R. **IDRISI for Windows**: introdução e exercícios tutoriais. Porto Alegre, UFRGS Centro de Recursos Idrisi, 1998.
- Frery, A.C. **Algumas ferramentas estatísticas na síntese, análise e processamento de imagens de radar de abertura sintética**. São José dos Campos, INPE, 1993. (Tese de doutorado)
- Frery, A.C.; Yanasse, C.C.F.; Vieira, P.R.; Sant'Anna, S.J.S.; Rennó, C.D. A user-friendly system for synthetic aperture radar image classification based on grayscale distributional properties and context. In: **Simpósio Brasileiro de Computação Gráfica e Processamento de Imagens**, 10., 1997. Los Alamitos, CA, USA, IEEE Computer Society, p. 211-218, 1997.
- Jain, A.K. **Fundamentals of digital image processing**. USA, Prentice-Hall International Editions, 1989.
- Landis, J.; Koch, G.G. The measurements of observer agreement for categorical data. **Biometrics**, 33(3):159-174, 1977.
- Mascarenhas, N.D.A.; Velasco, F.R.D. **Processamento digital de imagens**. São Paulo, IME, 1989, Quarta Escola de Computação. 2<sup>a</sup> ed.
- Næsset, E. Conditional tau coefficient for assessment of producer's accuracy of classified remotely sensed data. **ISPRS Journal of Photogrammetry and Remote Sensing**, 51:91-98, 1996.
- Nishii, R.; Tanaka, S. Accuracy and inaccuracy assessments in land cover classification. **IEEE Transactions on Geoscience and Remote Sensing**, 37(1):491-498, 1999.
- Richards, J.A. **Remote sensing digital image analysis: an introduction**. Berlin, Springer-Verlag, 1993. 2<sup>a</sup> ed.
- Schowengerdt, R.A. **Techniques for image processing and classification in remote sensing**. London, Academic, 1983.
- Vieira, P.R. **Desenvolvimento de classificadores de máxima verossimilhança pontuais e ICM para imagens de radar de abertura sintética**. São José dos Campos, INPE, 1996. (Dissertação de mestrado)